

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

Rodrigo Coral

**MÉTODO PARA ESTIMAR A CAPACIDADE DE REFRIGERAÇÃO
DE COMPRESSORES HERMÉTICOS INTEGRÁVEL À 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
2014

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

Coral, Rodrigo

Método para estimar a capacidade de refrigeração de
compressor herméticos integrável à linha de produção /
Rodrigo Coral ; orientador, Carlos Alberto Flesch ;
coorientador, Cesar Alberto Penz. - Florianópolis, SC, 2014.
238 p.

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

Inclui referências

1. Engenharia Mecânica. 2. ensaios de desempenho de
compressores herméticos. 3. capacidade de refrigeração. 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.

Rodrigo Coral

**MÉTODO PARA ESTIMAR A CAPACIDADE DE REFRIGERAÇÃO
DE COMPRESSORES HERMÉTICOS INTEGRÁVEL À 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, 12 de setembro de 2014.

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. Paulo Smith Schneider, Dr. Eng. (Relator)
Universidade Federal do Rio Grande do Sul

Prof. Armando Albertazzi Gonçalves Jr., Dr. Eng.
Universidade Federal de Santa Catarina

Prof. César José Deschamps, Ph. D.
Universidade Federal de Santa Catarina

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

Prof. Mauro Roisenberg, Dr. Eng.
Universidade Federal de Santa Catarina

AGRADECIMENTOS

À minha esposa, agradeço pelo carinho e dedicação que sempre teve comigo, e também pelo incentivo dado durante todo o desenvolvimento deste trabalho. Uma pessoa sem igual e que constantemente me inspira a ser um ser humano melhor.

À minha família, agradeço pelo incentivo e apoio que sempre tiveram comigo, e em especial agradeço aos meus pais, Zelindo e Graça, pessoas que sempre souberam o valor da educação.

Ao professor Carlos Alberto Flesch, agradeço toda a confiança depositada em mais de uma década de convivência, desde a orientação na graduação até esse momento. Agradeço também pelas oportunidades de crescimento pessoal e profissional.

Ao Cesar Alberto Penz, agradeço não só pelo esmero na coorientação deste trabalho, mas por todo incentivo em mais de uma década de amizade.

Aos membros da banca, agradeço pela avaliação do trabalho e contribuições para a consolidação do documento.

À Embraco, agradeço pela confiança e oportunidades geradas na parceria, especialmente aos colaboradores: Ronsani, Cláudio, Deandro e Fernando.

Aos parceiros e amigos: Pacheco, Miguel, André, Rodolfo, Scussel, Paulo, Reginalda e Ary, sempre dispostos a colaborar com o trabalho ou tomar umas cervejas para descontrair nos momentos mais difíceis.

Ao Labmetro e LIAE, professores e colaboradores que garantem o suporte para o desenvolvimento de trabalhos.

À UFSC, EMC e PosMEC, pela infraestrutura invejável para execução dos trabalhos.

Ao IFSC pela liberação para o desenvolvimento dos trabalhos.

À Secretaria de Educação do Estado de Santa Catarina, pela bolsa concedida através do programa FUMDES.

RESUMO

Capacidade de refrigeração é um parâmetro altamente representativo da qualidade do compressor hermético e da sua adequação a um sistema de refrigeração. Atualmente, a medição desse parâmetro é realizada através de ensaio laboratorial com duração média de 4,5 horas e incerteza de medição de aproximadamente $\pm 3\%$. Devido ao tempo e custos envolvidos no ensaio, quando um lote de compressores é produzido, esse parâmetro é avaliado através de uma amostra muito pequena. Para contornar esse problema, a proposta apresentada nesta tese se afasta do conceito tradicional de medição da capacidade de refrigeração. A ideia central do método proposto é a utilização da correlação existente entre a capacidade de refrigeração e a capacidade do compressor em elevar a pressão de ar num volume fixo. Através de compressores ensaiados tanto na linha de produção (medição da taxa de elevação da pressão) quanto em laboratório (medição da capacidade de refrigeração) foi possível avaliar a viabilidade de uso de tal correlação. Um conjunto de ensaios foi utilizado para treinamento de modelos neurais artificiais, os quais foram empregados para realizar inferências sobre o valor da capacidade de refrigeração através da capacidade de elevação da pressão. Através do estudo de caso, que faz parte deste documento, os compressores de um conjunto de teste apresentaram diferenças típicas de 1% entre os resultados obtidos no laboratório e na linha de produção. No entanto, mesmo o modelo neural apresentando bons resultados de inferência, um dos entraves mais significativos para o uso de redes neurais em atividades metrológicas é a inexistência de métodos de avaliação de incerteza condizentes com os preceitos metrológicos. Para contornar esse problema, uma nova técnica foi desenvolvida. Tal técnica utiliza uma combinação da reamostragem *bootstrap*, frequentemente utilizada para fornecer intervalos de confiança em redes neurais, e o método de Monte Carlo, frequentemente utilizado na avaliação da incerteza de medição. Assim, é possível obter uma incerteza da inferência que considere, além dos erros provenientes do processo de treinamento, as incertezas das medições durante o treinamento e uso das redes neurais. A integração desses métodos representa uma evolução no estado da arte no que concerne estimar a dúvida na saída de um modelo neural artificial. No estudo de caso, os compressores de teste apresentaram o valor típico de $\pm 4,5\%$ para a incerteza da inferência do modelo neural. O tempo médio para obtenção de um resultado na linha de produção ficou próximo a 7 segundos, o que significa que essa ocorrerá em tempo inferior a um milésimo do atualmente necessário para medição da capacidade de refrigeração em uma bancada no laboratório.

Palavras chave: ensaios de desempenho de compressores herméticos; capacidade de refrigeração; redes neurais artificiais; avaliação de incertezas em inferências.

ABSTRACT

The refrigerating capacity is an important parameter for the quality of hermetic compressors and to make a proper assignment of them to a certain refrigeration system. Typical tests for measuring de refrigerating capacity are run in laboratory facilities and which last 4.5 hours, at average, and present measurement uncertainty of about $\pm 3\%$. As a consequence related to typical tests duration and their associated costs, the evaluation of production lots are made by testing small samples. The purpose of this thesis is to present a method to overcome the small sample issue through the measurement of the refrigerating capacity using a strategy that avoids the typical tests approach. The main idea is the use of the existing correlation between the refrigerating capacity and the capacity of the compressor to increase the air pressure in a fixed volume vessel. The appropriateness on using this correlation was evaluated through test data obtained from production line tests (air pressure increase rate measurements) and from laboratory tests (refrigerating capacity measurements). The data was used for training neural networks models that were designed to infer the refrigerating capacity using air pressure increase rate. The evaluation presented in this thesis shown that the differences between production line inferences and laboratory results were about 1%. However, even with the good results obtained using neural networks, a lack of a proper way for evaluating the uncertainties related to the use of neural networks on metrological activities should be fulfilled. To overcome this problem a new technique was developed. It uses the bootstrap resampling method – usually applied for the determination of neural networks confidence intervals – and the Monte Carlo method – usually applied for measurement uncertainty evaluation. Therefore, it is possible to achieve an inference uncertainty that considers the errors from the neural networks training process as well as the measurement uncertainties related the inputs during the training and the using of the neural networks. The integration of these methods represents an evolution on the state of art related to the estimation of the doubt of an artificial neural network model. The results presented in this thesis shown typical uncertainties for the inferences of about $\pm 4.5\%$. The average duration for the tests in the production line was about 7 seconds – less than a thousandth of the time required for the refrigerating capacity measurement in laboratory.

Keywords: performance testing of hermetic compressors; refrigerating capacity; artificial neural networks; assessment of uncertainties in inferences.

LISTA DE FIGURAS

FIGURA 1: CALORÍMETRO DE FLUIDO SECUNDÁRIO.	49
FIGURA 2: MEDIÇÃO FLUXO DE MASSA NA LINHA DE SUCCÃO DO COMPRESSOR (ISO, 1989)	50
FIGURA 3: DIAGRAMA ESQUEMÁTICO DA BANCADA DISPONÍVEL NO LABMETRO.....	52
FIGURA 4: RESULTADOS DA REDUÇÃO DO TEMPO NA BANCA DE ENSAIO DE DESEMPENHO	52
FIGURA 5: GRAFO DO MODELO MATEMÁTICO DE UM NEURÔNIO.....	60
FIGURA 6: REDE <i>FEEDFORWARD</i> COM UMA ÚNICA CAMADA	62
FIGURA 7: REDE <i>FEEDFORWARD</i> COM UMA CAMADA OCULTA	63
FIGURA 8: FLUXO DE SINAIS DURANTE O TREINAMENTO.....	64
FIGURA 9: COMITÊ DE RNA BASEADA NA MÉDIA ARITMÉTICA SIMPLES.....	72
FIGURA 10: REDE AUMENTADA (PAPADOPOULOS, 2001)	75
FIGURA 11: COMPORTAMENTO DA CAPACIDADE DE REFRIGERAÇÃO NAS BANCADAS DE DESEMPENHO DE COMPRESSORES (PENZ, 2011).....	79
FIGURA 12: MÉTODO APLICADO NA LINHA DE PRODUÇÃO.....	80
FIGURA 13: CURVAS DE PRESSÃO E POTÊNCIA DO COMPRESSOR ENSAIADO NA LINHA DE PRODUÇÃO.....	81
FIGURA 14: GRÁFICO DA CAPACIDADE DE REFRIGERAÇÃO VS CAPACIDADE DE ELEVAÇÃO DA PRESSÃO	85
FIGURA 15: FUNCIONAMENTO DA RNA PARA DETERMINAÇÃO DA CAPACIDADE DE REFRIGERAÇÃO DO COMPRESSOR	87
FIGURA 16: REDE NEURAL ARTIFICIAL GENÉRICA APRESENTADA POR GUSMAN (2011)....	93
FIGURA 17: APLICAÇÃO DO MÉTODO DE MONTE CARLO PARA PROPAGAR AS PDF ATRAVÉS DE UMA REDE NEURAL	99
FIGURA 18: APLICAÇÃO DO MMC PARA PROPAGAÇÃO DAS PDF EM MODELOS NEURAIIS ARTIFICIAIS	102

FIGURA 19: PROCESSO DE TREINAMENTO UTILIZANDO N SMMC ^T	104
FIGURA 20: COMITÊ DE RNA TREINADOS A PARTIR DE SIMULAÇÕES DE MMC.....	105
FIGURA 21: PROPOSTA PARA CONTORNAR O PROBLEMA DO TEMPO DE PROCESSAMENTO NA APLICAÇÃO DO MMC.....	106
FIGURA 22: FASE DE TREINAMENTO DO MODELO NEURAL NO MÉTODO PARA A EXPRESSÃO DA INCERTEZA DA INFERÊNCIA	109
FIGURA 23: EVOLUÇÃO DA DIFERENÇA A MEDIDA QUE MAIS RNA SÃO INSERIDAS NO COMITÊ	120
FIGURA 24: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO.....	122
FIGURA 25: EVOLUÇÃO DA DIFERENÇA E DESVIO PADRÃO PARA O LOTE	125
FIGURA 26: GRÁFICOS DOS RESULTADOS APRESENTADOS PELO COMITÊ COM 10^3 RNA E DA TEMPERATURA DO COMPRESSOR NO MOMENTO DO ENSAIO.....	127
FIGURA 27: GRÁFICOS DOS RESULTADOS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE	128
FIGURA 28: HISTOGRAMA COM A RESPOSTA DO MODELO NEURAL APLICANDO O MMC PARA AS IM DAS GRANDEZAS DE ENTRADA NO COMPRESSOR DE TESTE 5	133
FIGURA 29: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO.....	134
FIGURA 30: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE	137
FIGURA 31: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO E DAS RESPECTIVAS I-IF	138
FIGURA 32: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO.....	141
FIGURA 33: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE	142

FIGURA 34: EVOLUÇÃO DA CAPACIDADE DE ELEVAÇÃO DA PRESSÃO EM FUNÇÃO DA TEMPERATURA DO COMPRESSOR	144
FIGURA 35: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO.....	146
FIGURA 36: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE	147
FIGURA 37: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO E AS RESPECTIVAS I-IF.....	148
FIGURA 38: EVOLUÇÃO DO RESULTADO DA INFERÊNCIA À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 1000 SMMC ^U	151
FIGURA 39: EVOLUÇÃO DO VALOR ENCONTRADO PARA A I-IF À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 1000 SMMC ^U	152
FIGURA 40: EVOLUÇÃO DO RESULTADO DA INFERÊNCIA À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 900 SMMC ^U	153
FIGURA 41: EVOLUÇÃO DO VALOR ENCONTRADO PARA A I-IF À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 900 SMMC ^U	153
FIGURA 42: COMPARATIVO ENTRE DIFERENTES CONFIGURAÇÕES DE RNA E SMMC ^U	154
FIGURA 43: RESPOSTA PARA OS COMPRESSORES DEFEITUOSOS	156
FIGURA 44: HISTOGRAMA COM A RESPOSTA APRESENTADA PARA O COMPRESSOR DEFEITUOSO D5.....	157
FIGURA 45: RESPOSTA PARA OS COMPRESSORES DEFEITUOSOS A PARTIR DO NOVO TREINAMENTO	158
FIGURA 46: HISTOGRAMA COM A RESPOSTA APRESENTADA PARA O COMPRESSOR DEFEITUOSO D5 APÓS NOVO TREINAMENTO	159
FIGURA 47: CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR	180
FIGURA 48: ESTÁGIOS DE COMPRESSÃO PROPORCIONADO PELO PISTÃO DE UM COMPRESSOR ALTERNATIVO DE REFRIGERAÇÃO (SILVEIRA, 2010)	182

FIGURA 49: COMPRESSOR HERMÉTICO DE REFRIGERAÇÃO (SCUSSEL, 2006)	184
FIGURA 50: CALORÍMETRO INUNDADO.	185
FIGURA 51: CALORÍMETRO A SECO.	187
FIGURA 52: MEDIÇÃO FLUXO DE MASSA NA LINHA DE DESCARGA DO COMPRESSOR	188
FIGURA 53: MEDIÇÃO DE FLUXO DE MASSA NA FASE LÍQUIDA DO REFRIGERANTE	189
FIGURA 54: CONDENSADOR RESFRIADO A ÁGUA	190
FIGURA 55: RESFRIAMENTO PARCIAL DO VAPOR DE REFRIGERANTE	191
FIGURA 56: CALORÍMETRO NA LINHA DE DESCARGA.....	193
FIGURA 57: RESPOSTA APRESENTADA PARA O MÉTODO <i>BOOTSTRAP</i>	207
FIGURA 58: RESPOSTA APRESENTADA PELO MÉTODO <i>BOOTSTRAP</i> EM CONJUNTO COM O MMC PARA PROPAGAR AS DISTRIBUIÇÕES DURANTE O USO DO COMITÊ	209
FIGURA 59: RESPOSTA DO MODELO NEURAL PARA O MMC APLICADO NO TREINAMENTO E USO	212
FIGURA 60: RESPOSTA DO MODELO NEURAL PARA O MMC APLICADO NO TREINAMENTO E USO	214
FIGURA 61: REPOSTA DO MODELO NEURAL PARA O MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA	216
FIGURA 62: RESPOSTA APRESENTADA PARA O MÉTODO <i>BOOTSTRAP</i>	220
FIGURA 63: REPOSTA DO MODELO NEURAL PARA O MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA	222
FIGURA 64: RESPOSTA DE UM SISTEMA DE PRIMEIRA ORDEM A ENTRADA EM RAMPA ...	225
FIGURA 65: HISTOGRAMA COM AS RESPOSTAS DO MODELO NEURAL APLICANDO O MMC PARA AS IM DAS GRANDEZAS DE ENTRADA NOS COMPRESSORES DE TESTE DE 1 ATÉ 6	229
FIGURA 66: HISTOGRAMA COM AS RESPOSTAS DO MODELO NEURAL APLICANDO O MMC PARA AS IM DAS GRANDEZAS DE ENTRADA NOS COMPRESSORES DE TESTE DE 7 ATÉ 12	230

FIGURA 67: RESULTADO DA CAPACIDADE DE REFRIGERAÇÃO SOBRE COMPRESSORES

DEFEITUOSOS..... 231

FIGURA 68: RESULTADO DA CAPACIDADE DE REFRIGERAÇÃO DOS COMPRESSORES

DEFEITUOSOS APÓS NOVO TREINAMENTO 233

FIGURA 69: SISTEMÁTICA DE MELHORIA CONTÍNUA 237

LISTA DE TABELAS

TABELA 1: LIMITES MÁXIMOS DE VARIAÇÃO PARA BANCADAS DE DESEMPENHO	54
TABELA 2: FONTES DE ERROS QUE PODEM SER SIGNIFICATIVAS EM UM PROJETO DE RNA .92	
TABELA 3: ERROS CONSIDERADOS PELO AVALIAÇÃO DA IM DOS DADOS DE ENTRADA DA RNA	95
TABELA 4: ERROS CONSIDERADOS PELO MÉTODO <i>BOOTSTRAP</i>	97
TABELA 5: ERROS CONSIDERADOS PELA PROPAGAÇÃO DAS DISTRIBUIÇÕES NO TREINAMENTO E USO DO MODELO NEURAL	108
TABELA 6: ERROS CONSIDERADOS PELO MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA	110
TABELA 7: CAPACIDADE DE REFRIGERAÇÃO PARA O CONJUNTO DE TESTE	114
TABELA 8: ARQUITETURA DAS RNA	115
TABELA 9: RESPOSTA DO MODELO NEURAL E A DIFERENÇA PERCENTUAL EM RELAÇÃO AOS RESULTADOS DE LABORATÓRIO	119
TABELA 10: RESULTADO DO PROCESSO DE INFERÊNCIA OBTIDO A PARTIR DO MODELO NEURAL TREINADO PELO MÉTODO <i>BOOTSTRAP</i>	121
TABELA 11: COMPARATIVO ENTRE OS RESULTADOS DO TEL E OBTIDOS ATRAVÉS DOS COMITÊS	125
TABELA 12: COMPARATIVO ENTRE O RESULTADOS DO TEL E DO MODELO NEURAL PARA COMPRESSORES ENSAIADOS COM TEMPERATURAS ACIMA DE 35°C.....	127
TABELA 13: FONTES DE ERROS CONSIDERADAS NA APLICAÇÃO COM MÉTODO <i>BOOTSTRAP</i>	129
TABELA 14: RESPOSTA DO COMITÊ PROPAGANDO AS DISTRIBUIÇÕES NO TREINAMENTO	131
TABELA 15: FONTES DE ERROS CONSIDERADAS NA APLICAÇÃO DO MMC NO TREINAMENTO DO MODELO NEURAL	132
TABELA 16: RESULTADO DA INFERÊNCIA DA CAPACIDADE DE REFRIGERAÇÃO.....	134

TABELA 17: COMPARATIVO ENTRE O RESULTADO DO TEL E OBTIDO ATRAVÉS DA INFERÊNCIA	137
TABELA 18: FONTES DE ERROS CONSIDERADAS NA APLICAÇÃO DO MMC NO TREINAMENTO E NO USO DO MODELO NEURAL	139
TABELA 19: FONTES DE ERROS CONSIDERADAS ATRAVÉS PROPOSTA APRESENTADA PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA DO MODELO NEURAL	140
TABELA 20: RESPOSTA DO MODELO NEURAL TREINADO A PARTIR DO MÉTODO PROPOSTO PARA ESTIMAR A INCERTEZA DA INFERÊNCIA	141
TABELA 21: COMPARATIVO ENTRE O RESULTADO DO TEL E OBTIDO ATRAVÉS DA INFERÊNCIA	142
TABELA 22: RESULTADO DA INFERÊNCIA PARA A CAPACIDADE DE REFRIGERAÇÃO	145
TABELA 23: COMPARATIVO ENTRE O RESULTADO DO TEL E O OBTIDO ATRAVÉS DA INFERÊNCIA	147
TABELA 24: TEMPOS EM SEGUNDOS PARA O PROCESSAMENTO DAS INFORMAÇÕES.....	150
TABELA 25: RESULTADOS PARA DIFERENTES CONFIGURAÇÕES DE RNA E SMMC ^U	154
TABELA 26: RESPOSTA PARA OS COMPRESSORES DEFEITUOSOS	156
TABELA 27: RESPOSTA PARA COMPRESSORES DEFEITUOSOS APÓS NOVO TREINAMENTO	158
TABELA 28: COMPARATIVO ENTRE RESULTADOS DOS COMPRESSORES DE TESTE PARA COMITÊS TREINADOS COM COMPRESSORES SEM E COM DEFEITO.....	160
TABELA 29: DADOS DO CONJUNTO DE TREINAMENTO	205
TABELA 30: RESPOSTAS PARA O MÉTODO <i>BOOTSTRAP</i>	206
TABELA 31: RESPOSTAS PARA O MÉTODO <i>BOOTSTRAP</i> COM PROPAGAÇÃO DAS DISTRIBUIÇÕES DAS ENTRADAS PARA A SAÍDA DO MODELO NEURAL	208
TABELA 32: RESPOSTA DO MODELO NEURAL APLICANDO O MMC NO TREINAMENTO E USO 10 ⁵ RNA E 10 ⁵ SMMC ^U	211
TABELA 33: RESPOSTA DO MODELO NEURAL APLICANDO MMC NO TREINAMENTO E USO - 1000 RNA E 1000 SMMC ^U	213

TABELA 34: RESPOSTA DO MODELO NEURAL PARA O MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA	215
TABELA 35: DADOS DO CONJUNTO DE TREINAMENTO	218
TABELA 36: RESPOSTAS PARA O MÉTODO <i>BOOTSTRAP</i>	219
TABELA 37: RESPOSTAS OBTIDAS PELO MÉTODO PROPOSTO	221
TABELA 38: INCERTEZAS PARA OS DADOS DO CONJUNTO DE TREINAMENTO	227

LISTA DE ABREVIATURAS

COP	Coeficiente de Performance do Compressor
GUM	Guia para a Expressão da Incerteza de Medição
IA	Inteligência Artificial
IC	Intervalos de Confiança
IEC	<i>International Electrotechnical Commission</i>
IM	Incerteza de Medição
I-If	Incerteza da Inferência
ISO	<i>International Organization for Standardization</i>
Labmetro	Laboratório de Metrologia e Automatização da UFSC
MMC	Método de Monte Carlo
PDF	Funções Densidade de Probabilidade
RNA	Redes Neurais Artificiais
SMMC	Simulação pelo Método de Monte Carlo
SMMC ^U	Simulação pelo Método de Monte Carlo no Uso das RNA
SMMC ^T	Simulação pelo Método de Monte Carlo no Treinamento das RNA
TEL	Teste em Laboratório

SUMÁRIO

1	INTRODUÇÃO	39
1.1	CONTEXTUALIZAÇÃO.....	39
1.2	OBJETIVOS	43
1.2.1	OBJETIVO GERAL	43
1.2.2	OBJETIVOS ESPECÍFICOS.....	43
1.3	INOVAÇÕES CONCRETIZADAS	44
1.4	ESTRUTURA DO DOCUMENTO	44
2	ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS	45
2.1	MÉTODOS DE ENSAIO DE DESEMPENHO SEGUNDO A NORMA ISO 917	45
2.1.1	MÉTODO A: CALORÍMETRO DE FLUIDO SECUNDÁRIO ..	48
2.1.2	MÉTODO D1: MEDIÇÃO DO FLUXO DE MASSA DE VAPOR DE REFRIGERANTE	50
2.2	BANCADA DE ENSAIO DE DESEMPENHO DE COMPRESSORES	51
2.3	MEDIÇÃO DA CAPACIDADE DE REFRIGERAÇÃO PARA CONTROLE DA QUALIDADE	53
3	REDES NEURAIS ARTIFICIAIS NO ÂMBITO DESTE TRABALHO	57
3.1	REDES <i>FEEDFORWARD</i>	58
3.1.1	MODELO GERAL DE NEURÔNIO	59
3.1.2	ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS	60
3.1.2.1	REDES <i>FEEDFORWARD</i> COM CAMADA ÚNICA.....	61

3.1.2.2	REDES <i>FEEDFORWARD</i> COM MÚLTIPLAS CAMADAS.....	62
3.2	APRENDIZADO DE REDES NEURAIIS	63
3.2.1	APRENDIZADO <i>BACK-PROPAGATION</i>	64
3.2.2	APRENDIZADO LEVENBERG–MARQUARDT	68
3.3	MÁQUINAS DE COMITÊ	71
3.4	MÉTODOS PARA ESTIMAÇÃO DE INTERVALOS DE CONFIANÇA EM REDES NEURAIIS ARTIFICIAIS	72
4	PROPOSTA DE ENSAIO PARA ESTIMAR A CAPACIDADE DE REFRIGERAÇÃO NA LINHA DE PRODUÇÃO	77
4.1	CONSIDERAÇÕES INICIAIS.....	77
4.2	PROPOSTA DE ENSAIO NA LINHA DE PRODUÇÃO	79
4.3	CORRELAÇÃO ENTRE OS ENSAIOS DE LINHA E DE LABORATÓRIO	84
4.4	PROPOSTA DE MODELAGEM NEURAL ARTIFICIAL.....	86
5	PROPOSTA DE MÉTODO METROLOGICAMENTE EMBASADO PARA EXPRESSÃO DA INCERTEZA NA INFERÊNCIA DE MODELOS NEURAIIS ARTIFICIAIS	89
5.1	APLICAÇÃO DO GUM NO USO DE REDES NEURAIIS ARTIFICIAIS TREINADAS.....	93
5.2	APLICAÇÃO DO MÉTODO <i>BOOTSTRAP</i> NO TREINAMENTO DE REDES NEURAIIS ARTIFICIAIS	95
5.3	APLICAÇÃO DO MÉTODO DE MONTE CARLO NO TREINAMENTO E USO DE REDES NEURAIIS ARTIFICIAIS	98
5.4	PROPOSTA DE MÉTODO PARA A EXPRESSÃO DA INCERTEZA DA INFERÊNCIA APRESENTADA POR MODELOS NEURAIIS	108

6	ESTUDO DE CASO	113
6.1	CONSIDERAÇÕES INICIAIS.....	113
6.2	MODELO NEURAL ARTIFICIAL TREINADO A PARTIR DO MÉTODO <i>BOOTSTRAP</i>	118
6.3	MODELO NEURAL ARTIFICIAL TREINADO A PARTIR DO MÉTODO DE MONTE CARLO PARA PROPAGAR AS DISTRIBUIÇÕES.....	129
6.4	MODELO NEURAL TREINADO A PARTIR DA PROPOSTA PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA	139
6.5	MODELO NEURAL ARTIFICIAL CONSIDERANDO AS VARIAÇÕES DE TEMPERATURAS DURANTE O ENSAIO NA LINHA DE PRODUÇÃO	143
6.6	ANÁLISE DOS TEMPOS DE PROCESSAMENTO DO MODELO NEURAL	148
6.7	INFERÊNCIA DA CAPACIDADE DE REFRIGERAÇÃO EM COMPRESSORES DEFEITUOSOS	155
7	CONSIDERAÇÕES FINAIS.....	163
7.1	CONCLUSÕES	163
7.1.1	QUANTO À REVISÃO BIBLIOGRÁFICA	163
7.1.2	QUANTO À OBTENÇÃO DA CAPACIDADE DE REFRIGERAÇÃO DE FORMA INTEGRÁVEL À LINHA DE PRODUÇÃO.....	163
7.1.3	QUANTO À AVALIAÇÃO DA INCERTEZA NA APLICAÇÃO DE MODELOS NEURAI.....	164
7.1.4	QUANTO AO ESTUDO DE CASO	164
7.2	SUGESTÕES DE TRABALHOS FUTUROS.....	166

REFERÊNCIAS.....	167
APÊNDICE A – CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR E COMPRESSORES HERMÉTICOS DE REFRIGERAÇÃO	179
APÊNDICE B – MÉTODOS DE ENSAIO DE DESEMPENHO DE COMPRESSORES APRESENTADOS PELA NORMA ISO 917	185
APÊNDICE C - RESULTADO DA REGRESSÃO DA CAPACIDADE DE REFRIGERAÇÃO VERSUS OS RESULTADOS DOS ENSAIOS DE LINHA DE PRODUÇÃO	195
APÊNDICE D – MÉTODOS DE AVALIAÇÃO DA INCERTEZA DE MEDIÇÃO.....	197
APÊNDICE E – EXEMPLO SIMULADO PARA COMPROVAR A VIABILIDADE DA PROPOSTA PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA.....	203
APÊNDICE F – ANÁLISE DAS INCERTEZAS DE MEDIÇÃO ENVOLVIDAS NA EXPRESSÃO DA INCERTEZA DA INFERÊNCIA.....	223
APÊNDICE G – RESULTADOS DA APLICAÇÃO DO MMC NO USO DO MODELO NEURAL ARTIFICIAL	229
APÊNDICE H - RESULTADOS DA MEDIÇÃO DA CAPACIDADE DE REFRIGERAÇÃO DOS COMPRESSORES DEFEITUOSOS	231

APÊNDICE I - RESULTADO DA CAPACIDADE DE REFRIGERAÇÃO DOS COMPRESSORES DEFEITUOSOS APÓS NOVO TREINAMENTO	233
APÊNDICE J – SISTEMÁTICA PARA A MANUTENÇÃO DA CONFIABILIDADE DAS INFERÊNCIAS E MELHORIA CONTÍNUA DO MODELO NEURAL	235

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

O mercado de compressores herméticos para refrigeração impõe a necessidade de desenvolvimento de novas tecnologias que resultem em produtos cada vez mais eficientes. Pode-se destacar que um dos fatores decisivos na compra de refrigeradores pelos consumidores é a eficiência energética. (MME, 2011; CARDOSO, 2008; SILVA, 2005). Prova disso é o fato de que os compressores atuais, produzidos pela empresa líder mundial nesse segmento, consomem hoje metade da energia em relação aos compressores com capacidades de refrigeração equivalentes de duas décadas atrás (EMBRACO, 2013).

Nesse contexto, o ensaio de desempenho do compressor, que neste trabalho refere-se ao ensaio destinado à determinação da capacidade de refrigeração do compressor, potência elétrica consumida e o coeficiente de performance do compressor (COP), torna-se fator importante para desenvolvimento e aprimoramento desses produtos, bem como para garantir a qualidade dos produtos oferecidos ao mercado. No entanto, o elevado volume de produção e o longo tempo despendido para a verificação das características de desempenho de um compressor inviabilizam tais testes junto às linhas de produção (MIDANY, 2013).

Dentre os parâmetros de desempenho do compressor está a capacidade de refrigeração, que é uma das principais variáveis no estabelecimento de um projeto de sistemas de refrigeração. Assim, esse é um dos parâmetros mais cobrados pelos clientes das empresas fabricantes de compressores.

A norma ISO 917 (1989) estabelece que a capacidade de refrigeração de um compressor hermético seja medida através do ensaio de desempenho, o qual deve ocorrer em condição de regime permanente em circuitos de refrigeração especiais. Tal condição é caracterizada por variáveis confinadas em limites estabelecidos durante uma hora (ISO 917, 1989). No entanto, o tempo total de ensaio é muito maior. Em média, ele é superior a quatro horas. Isso se deve ao tempo de transitório e à dificuldade de se encontrar o momento em que o compressor atinge o regime permanente (GUSTAFSON, 1992; POLETTI, 2006). Vale destacar que nem todos os ensaios para a determinação da capacidade de refrigeração necessitam ser realizados segundo os critérios estabelecidos pela norma. Mesmo assim, todos ainda apresentam elevado tempo, que em geral é maior que uma hora (PENZ, 2011). Quando se acrescenta os tempos de retirada do produto da linha de produção e de espera na fila

para o ensaio, esse valor aumenta substancialmente, podendo atingir duas semanas para que um compressor seja ensaiado. Aliados ao grande tempo despendido para o ensaio existem também os altos custos envolvidos na medição e o enorme volume de produção. Uma única bancada de ensaio pode custar centenas de milhares de dólares e o número de compressores fabricados em uma única planta industrial pode chegar a dezenas de milhares por dia.

Frente a esse cenário, uma grande oportunidade de inovação é estabelecida, pois o elevado volume de produção, aliado ao longo tempo de ensaio, impede muitas vezes que correções no processo de fabricação sejam implementadas antes que um número muito grande de peças não-conformes seja produzido. Situação pior é quando o fabricante encaminha o produto ao cliente sem que a amostra de avaliação do lote tenha sido testada, o que pode incorrer em prejuízos financeiros e de imagem corporativa, incluindo eventuais multas contratuais.

Atualmente, os testes nas linhas de produção de compressores herméticos são realizados para detectar problemas grosseiros de ruído, consumo e vazamento. No entanto, ficam muito aquém de um ensaio de desempenho realizado em laboratório.

Pesquisas desenvolvidas em parceria entre o Laboratório de Metrologia e Automatização (Labmetro) da Universidade Federal de Santa Catarina e a Whirlpool S.A. – Unidade Embraco de Compressores focam na redução do tempo de ensaio de desempenho de compressores herméticos, consequentemente na redução do tempo para determinar a capacidade de refrigeração. Destacam-se alguns trabalhos realizados em tal parceria:

1. Henklein (2006) propôs o prognóstico¹ do resultado dos ensaios a partir do transitório utilizando diferentes ferramentas de inteligência artificial (IA), como redes neurais artificiais e lógica *fuzzy*;
2. Scussel (2006) propôs a redução do tempo de ensaio pela redução do regime transitório através de técnicas

¹ Assim como Penz (2011), o presente trabalho diferencia o termo prognóstico de inferência através das seguintes definições: Prognóstico – suposição, baseada em dados da realidade, sobre o que deve acontecer no futuro (HOUAISS, 2002); 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 (HOUAISS, 2002). Deste modo, neste trabalho tem-se o primeiro como a previsão dos resultados futuros dos parâmetros dos ensaios de desempenho e o segundo como a determinação da capacidade de refrigeração através dos ensaios de linha.

- para aquecimento forçado do compressor sem alteração de características de desempenho;
3. Steinbach (2008) explorou o uso das redes neurais artificiais para determinar o instante de entrada em regime permanente e conseqüente diminuição do tempo de ensaio, também explorou o uso dessas no prognóstico dos resultados para os parâmetros de desempenho do compressor;
 4. Casella (2008) também focou na determinação do instante do regime permanente para o ensaio da capacidade de refrigeração, só que utilizando redes *fuzzy*-bayesianas;
 5. Lima (2010a) implantou uma primeira versão de ferramentas de inteligência artificial, incluindo um conjunto de redes neurais artificiais para o prognóstico dos parâmetros de desempenho, em uma bancada de ensaios de compressores;
 6. Silveira (2010) implementou estratégia para aquecimento forçado através a injeção de corrente contínua no motor durante o ensaio a fim de diminuir o tempo de transitório;
 7. Flesch (2010; 2011) desenvolveu técnicas avançadas de controle para aumentar a confiabilidade e reduzir o tempo de ensaio de desempenho de compressores herméticos;
 8. Penz (2011) propôs procedimentos para a garantia da confiabilidade na aplicação de ferramentas de IA nos ensaios de desempenho de compressores herméticos.

Esses trabalhos mostram a viabilidade do uso de ferramentas de inteligência artificial no desenvolvimento de sistemas para realização de ensaios em compressores herméticos. No entanto, muito há de ser pesquisado nessa área de conhecimento. Pode-se inclusive afirmar que ainda não existe consenso entre os diferentes estudiosos da área da inteligência artificial para a definição do próprio termo em si (RUSSELL, 2013). Porém, o estudo dessa disciplina vem despontando e seus benefícios têm sido investigados nos mais diferentes campos da ciência (COLORADO, 2011; HECKMANN, 1999), indo desde a área da robótica até diferentes aplicações no campo da medicina (COLORADO, 2011; AGUIRRE, 2007; BELLAZZI, 2007).

Modelos matemáticos² de sistemas físicos são ferramentas essenciais para um imenso número de áreas do conhecimento. Todavia, a complexidade muitas vezes torna inviável a aplicação desses e isso é um dos motivos para a grande expansão da inteligência artificial nas áreas da engenharia (AGUIRRE, 2007). Uma das técnicas que mais se destacam dentro da inteligência artificial é a que faz uso das redes neurais artificiais. Isso se deve ao fato de sua utilização simples para a solução de problemas complexos e apresentar saídas adequadas para entradas que não estavam presentes durante a fase de treinamento (HAYKIN, 1999). Técnicas de modelagem utilizando redes neurais vêm sendo utilizadas cada vez mais em aplicações nas áreas diversas da engenharia (COLORADO, 2011; ERTUNC, 2005). Atualmente, redes neurais artificiais estão sendo largamente utilizadas na análise de dados, bem como na predição de resultados a partir de dados iniciais de séries temporais. Porém, como em outros modelos de previsão, a utilização dessa ferramenta envolve cuidados e a seleção de uma série de parâmetros (GHEYAS, 2009; HASHEM, 1999).

Pode-se dizer que, mesmo as ferramentas de inteligência artificial sendo utilizadas em diferentes aplicações, até o presente momento não foi encontrada na literatura alguma pesquisa que tente implementar ensaios para determinar a capacidade de refrigeração de compressores herméticos, em 100% das peças e avaliando o compressor pronto no final da linha de produção. Porém, assim como Henklein (2006), Steinbach (2008), Lima (2010a), Casella (2008) e Penz (2011), alguns trabalhos utilizam ferramentas de inteligência artificial na avaliação de compressores e sistemas de refrigeração. Yang (2005) e Dencker (2003) utilizam redes neurais artificiais para detectar problemas de fabricação em linha de produção de compressores, e Ertunc (2005) faz uso das redes neurais para modelar sistemas de refrigeração com condensadores evaporativos.

No que concerne à inferência da capacidade de refrigeração na linha de produção, Midany (2013) propõe controlar problemas de fabricação a partir de uma rede neural capaz verificar problemas de capacidade de refrigeração. Porém, a rede proposta realiza o prognóstico a partir de quatro parâmetros específicos do sistema de válvula do com-

² Neste trabalho foram adotados os seguintes termos: modelo matemático clássico ou simplesmente modelo matemático, para definir um modelo analítico que descreve um fenômeno físico através de equações matemáticas; e modelo neural artificial ou simplesmente modelo neural, para definir o modelo matemático não analítico gerado após o processo de aprendizagem das redes neurais artificiais. Um modelo neural pode ser composto por uma ou mais RNA.

pressor. Deste modo, outros parâmetros que afetam diretamente a capacidade de refrigeração não são considerados.

Os trabalhos aqui apresentados servem de motivadores para o desenvolvimento de uma solução que utilize RNA para alcançar o objetivo traçado nesta tese de doutorado.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Desenvolver um método que permita estimar a capacidade de refrigeração de compressores herméticos em tempo extremamente reduzido, de modo que possa ser utilizado no controle da qualidade junto à linha de produção.

1.2.2 OBJETIVOS ESPECÍFICOS

- analisar o estado da arte dos atuais métodos de ensaios para a determinação da capacidade de refrigeração de compressores herméticos;
- analisar o estado da arte na determinação de intervalos de confiança na aplicação de redes neurais artificiais;
- propor um método de ensaio junto à linha de produção que não necessite usar fluido refrigerante nem óleo de funcionamento no compressor;
- correlacionar os resultados de ensaios de capacidade de refrigeração realizados em laboratório, com resultados de ensaios junto à linha de produção;
- estabelecer um modelo baseado em redes neurais artificiais, a partir de dados prévios obtidos em laboratório e na linha de produção, que possa ser utilizado para realizar inferência da capacidade de refrigeração do compressor;
- desenvolver um método, metrologicamente embasado, para expressar a incerteza da inferência do modelo neural artificial;
- promover estudo de caso para avaliar os conceitos propostos nesta tese de doutorado.

1.3 INOVAÇÕES CONCRETIZADAS

O presente trabalho propiciou avanços no estado da arte, principalmente no que concerne às seguintes contribuições inéditas:

- medição do valor da capacidade de refrigeração de compressores herméticos através de inferências realizadas na linha de produção, em tempos extremamente reduzidos e sem a necessidade de utilização de sistemas de refrigeração;
- método para estimar a incerteza da inferência, metrologicamente mais adequado do que os atualmente disponíveis na literatura, para aplicações de redes neurais artificiais em processos metrológicos.

1.4 ESTRUTURA DO DOCUMENTO

O capítulo 2 aborda o estado da arte em ensaios de desempenho de compressores e um relato dos trabalhos realizados até o momento na parceria Labmetro e Embraco para diminuição do tempo de ensaio de compressores. No capítulo 3 é apresentado um resumo sobre redes neurais artificiais incluindo a estrutura básica de um neurônio artificial, as estruturas das redes do tipo *feedforward* e os algoritmos de aprendizagem *back-propagation* e *Levenberg-Marquardt*. Técnica para minimização dos erros aleatórios oriundos do processo de treinamento e métodos de estimação de intervalos de confiança em redes neurais também fazem parte desse capítulo. No capítulo 4 são expostas as soluções propostas para o ensaio na linha de produção e para a modelagem neural artificial que, quando integradas, realizarão a inferência do valor da capacidade de refrigeração de compressores. No capítulo 5 é proposto um método para expressar a incerteza da inferência de modelos neurais artificiais. No capítulo 6 é apresentado um estudo de caso. No capítulo 7 são apresentadas as conclusões e sugestões de trabalhos futuros. O documento conta ainda com as referências bibliográficas e apêndices.

2 ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS

Este capítulo apresenta o estado da arte em ensaios de compressores herméticos para refrigeração, os quais estabelecem os atuais métodos para a determinação da capacidade de refrigeração. Desse modo, será possível compreender as atuais dificuldades envolvidas na realização dos ensaios. Mostra que os métodos estabelecidos por normas para determinação da capacidade de refrigeração de um compressor passam pela implementação de ciclos de refrigeração controlados em bancadas de ensaios. No apêndice A é apresentado um breve relato do princípio de funcionamento do ciclo de refrigeração por compressão de vapor, bem como do compressor hermético. Assim, espera-se que o leitor que não esteja familiarizado com os conceitos abordados neste capítulo, tenha meios para fazê-lo.

Os ensaios de desempenho de compressores herméticos têm por objetivos determinar os valores da capacidade de refrigeração, da potência elétrica consumida pelo compressor e, conseqüentemente, do coeficiente de performance. Para a determinação de tais parâmetros não existe um experimento único e universalmente aceito (ANSI/ASHRAE, 2005; ISO, 1989). Porém, existem normas que buscam padronizar os diferentes métodos, de modo que os resultados possam ser comparados e aceitos com maior confiança pelos fabricantes de sistemas de refrigeração (PENZ, 2011).

Dentre as normas pode-se destacar ANSI/ASHRAE 23 (ANSI/ASHRAE, 2005), DIN EN 13771 (DIN, 2008) e ISO 917 (ISO, 1989). Todas as normas são similares (PENZ, 2011), diferenciando-se apenas nas tolerâncias dos transdutores e limites de operação estabelecidos para os ensaios (POLETTI, 2006). Assim, este trabalho abordará resumidamente os ensaios de desempenho contidos na norma ISO 917 - *Testing of Refrigerant Compressors* (ISO, 1989), por ser destacadamente a norma mais consolidada e internacionalmente aceita no meio industrial.

2.1 MÉTODOS DE ENSAIO DE DESEMPENHO SEGUNDO A NORMA ISO 917

A norma ISO 917 (ISO, 1989) apresenta diferentes métodos de ensaio para a determinação dos parâmetros de desempenho dos compressores. Eles podem ser basicamente divididos em métodos de medi-

ção através de calorímetros³ e métodos de medição de fluxo de massa. Alguns métodos necessariamente devem trabalhar segundo um ciclo completo de refrigeração por compressão de vapor. Porém, para outros métodos não são necessários circuitos completos de refrigeração para a determinação dos parâmetros (ISO, 1989; ANSI/ASRAE, 2005). Isso ocorre, pois, em síntese, busca-se os resultados de desempenho do compressor e não do circuito de refrigeração, o que torna o circuito, apenas um meio.

A adoção de um método ou outro dependerá, dentre muitas variáveis, da faixa de capacidade do compressor. Para compressores com capacidade de refrigeração maiores, o fluxo de mássico no sistema do fluido refrigerante é maior e, conseqüentemente, métodos de medição por fluxo de massa se mostram melhores por ser um processo mais rápido e de melhor controle. Porém, para compressores de capacidade menor, os métodos de medição através de calorímetros se mostram mais adequados. No entanto, estes últimos demandam um controle mais robusto das variáveis do ciclo de refrigeração (FLESCH, 2010).

Os ensaios de desempenho têm como objetivo a determinação dos seguintes parâmetros (ISO, 1989):

- capacidade de refrigeração do compressor (Φ_0), definida como o produto da vazão de massa do refrigerante deslocado através do compressor pela diferença de entalpia específica do refrigerante na sucção do compressor e a entalpia específica do líquido saturado na temperatura correspondente à pressão de descarga do compressor – equação (1). Em outras palavras, capacidade de refrigeração é uma medida da capacidade do compressor de gerar vazão mássica de fluido refrigerante frente a um diferencial de pressão imposto entre as tomadas de sucção e descarga do compressor (STOECKER, 2002). Neste trabalho será adotado o SI⁴, assim, a unidade de medida da capacidade será sempre expressa em watt;

³ Calorímetro – definição clássica para calorímetro é um ambiente, ou volume, dedicado à quantificação das trocas térmicas entre elementos fixos e/ou que passam pelo seu interior (HANSEN, 2003).

⁴ SI – Sistema Internacional de Unidades: documento internacional com o propósito de difundir o conhecimento metrológico a respeito das unidades de medidas (INMETRO, 2007).

$$\dot{\Phi}_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}) \quad (1)$$

Onde:

$\dot{\Phi}_0$	capacidade de refrigeração do compressor	[W];
q_{mf}	fluxo de massa de refrigerante	[kg/s];
V_{ga}	volume específico do fluido refrigerante (gás) entrando no compressor, durante o ensaio	[m ³ /kg];
V_{gl}	volume específico do refrigerante entrando no compressor estabelecido anteriormente ao ensaio	[m ³ /kg];
h_{g1}	entalpia específica do refrigerante entrando no compressor nas condições básicas específicas de ensaio	[kJ/kg];
h_{f1}	entalpia específica do refrigerante líquido na pressão correspondente à descarga do compressor	[kJ/kg];

- potência consumida (P), definida como a potência no eixo para um compressor aberto ou a potência elétrica nos terminais do motor do compressor hermético, mais a potência absorvida pelos acessórios necessários para a operação do compressor, por exemplo: bomba de óleo, circuitos eletrônicos e outros. A unidade de medida é watt;
- coeficiente de performance (COP) do compressor, definido como a razão da capacidade de refrigeração do compressor pela potência consumida pelo mesmo – equação (2). É adimensional.

$$COP = \frac{\dot{\Phi}_0}{P} \quad (2)$$

Onde:

COP coeficiente de performance;

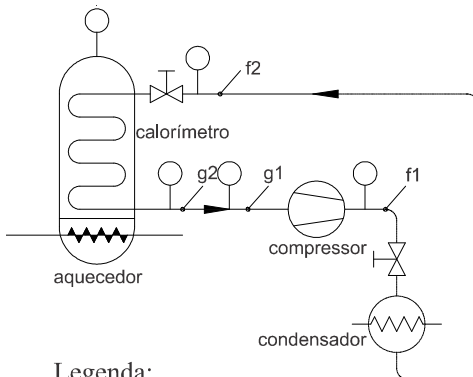
\dot{Q}_0	capacidade de refrigeração do compressor	[W];
P	potência consumida	[W].

Para se alcançar os parâmetros citados anteriormente, a norma ISO 917 (1998) estabelece nove métodos de ensaio. Na sequência serão abordados dois deles, que foram aqueles utilizados na determinação da capacidade de refrigeração dos compressores para o estudo de caso apresentado nesta tese. Também, por apresentarem um método baseado em calorímetro e outro na medição de fluxo de massa. Os demais métodos são apresentados no apêndice B desse documento. Os métodos apresentam o atual estado da arte em ensaios de desempenho de compressores herméticos, e conseqüentemente em ensaios para medição da capacidade de refrigeração.

2.1.1 MÉTODO A: CALORÍMETRO DE FLUIDO SECUNDÁRIO

O método do calorímetro de fluido secundário consiste em um ciclo de compressão de vapor de fluido refrigerante (fluido primário), onde o evaporador encontra-se suspenso na parte mais alta de um vaso de pressão hermético e termicamente isolado. Uma resistência na base do vaso aquece um fluido volátil (fluido secundário), o qual deve permanecer na condição de saturação, mantendo dessa forma a temperatura homogênea dentro do vaso de pressão. Como apresentado na figura 1 (a) e (b), os fluidos encontram-se em circuitos separados e nunca entram em contato entre si, havendo somente troca de calor através da serpentina do evaporador do circuito de refrigeração.

Tendo o dispositivo de expansão próximo à entrada do calorímetro, idealmente a mudança de fase do fluido primário ocorrerá somente com o acréscimo de energia fornecida pela resistência, que é transportada até o evaporador sob a forma de calor por meio do fluido secundário. Assim, monitorando e controlando as diferentes variáveis do processo, é possível realizar o balanço energético do sistema e obter a vazão mássica do refrigerante através da equação (3), e conseqüentemente obter a capacidade de refrigeração do compressor através da equação (1) (pág. 47). Medindo a potência elétrica consumida pelo compressor também é possível determinar o COP do mesmo.



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

(a) - diagrama do circuito



(b) - calorímetro de fluido secundário

FIGURA 1: CALORÍMETRO DE FLUIDO SECUNDÁRIO.

Fluxo de massa do refrigerante é dado por:

$$q_{mf} = \frac{\Phi_i + F_i(T_a - T_g)}{h_{g2} - h_{f2}} \quad (3)$$

Onde:

q_{mf} fluxo de massa do fluido refrigerante [kg/s];

Φ_i calor cedido pela fonte externa [kJ];

F_l	fator de perda	[kJ/K];
T_a	temperatura ambiente	[K];
T_g	temperatura interna ao calorímetro	[K];
h_{g2}	entalpia do vapor saturado saindo do calorímetro	[kJ/kg];
h_{f2}	entalpia do líquido entrando no calorímetro	[kJ/kg].

2.1.2 MÉTODO D1: MEDIÇÃO DO FLUXO DE MASSA DE VAPOR DE REFRIGERANTE

Nesse método, o fluxo de massa, necessário para o cálculo da capacidade de refrigeração do compressor através da equação (1) (página 47), é obtido por meio da medição direta fluxo de massa de vapor do refrigerante realizada na linha de sucção do compressor (figura 2). Desse modo, não é necessário o balanço de energia como realizado no método anterior.

Para esse tipo de ensaio é necessário um meio de impor a pressão de trabalho adequada no terminal de descarga do compressor, e um meio de reduzi-la à pressão de trabalho adequada no terminal de sucção. Por esse motivo não é necessário que o refrigerante mude de fase, podendo o mesmo se manter sempre no estado de vapor. Porém, a medição deve ser isenta de óleo proveniente do compressor. Para a determinação do COP, basta medir a potência elétrica consumida pelo compressor.

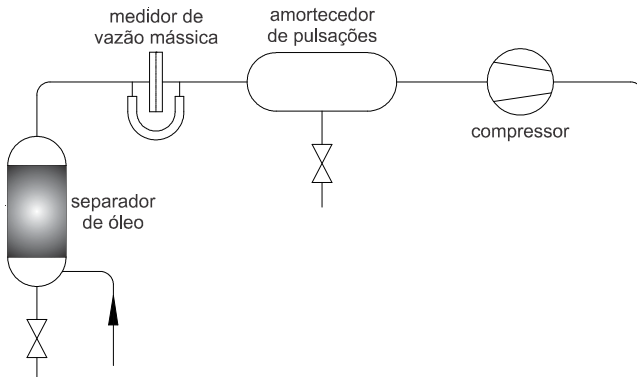


FIGURA 2: MEDIÇÃO FLUXO DE MASSA NA LINHA DE SUÇÃO DO COMPRESSOR (ISO, 1989)

2.2 BANCADA DE ENSAIO DE DESEMPENHO DE COMPRESSORES

Uma bancada de ensaio de desempenho de compressores é a implementação física de meios para a determinação da capacidade de refrigeração, potência consumida e COP. A norma ISO 917 apresenta diretrizes gerais para a montagem de uma bancada e, em todos os métodos apresentados, existe a necessidade da utilização de fluido refrigerante e óleo de funcionamento para qual o compressor foi projetado.

A figura 3 apresenta o diagrama esquemático da bancada disponível no Labmetro, na qual foram desenvolvidas diferentes pesquisas no intuito de melhorar a confiabilidade metrológica (GAVILON, 2008; BARBOSA, 2006; POLETO, 2006), o controle e a automação das variáveis do processo de medição (FLESCHE, 2010; PETROVIC, 2007) e diminuição do tempo de ensaio com garantia metrológica (PENZ, 2011; SILVEIRA, 2010; LIMA, 2010a,b; CASELLA, 2008; STEINBACH, 2008; SCUSSEL, 2006; HENKLEIN, 2006). Ela mostra que um sistema de medição baseado nos métodos propostos pela norma ISO 917 (ISO, 1989), requer diversos dispositivos periféricos destinados a manter a estabilidade das variáveis necessárias para determinar os parâmetros de desempenho do compressor, incluindo dois sistemas de climatização, um para o ambiente do compressor sob ensaio e outro para o ambiente do calorímetro.

Através dos trabalhos realizados na parceria UFSC/Labmetro e Whirlpool/Embraco, significativa redução de tempo foi alcançada. Com a inserção de modernos sistemas de medição⁵, desenvolvimento de avançados sistemas de controle e técnicas de aceleração do transitório, uma nova arquitetura foi desenvolvida. Através dela, o tempo médio de ensaio de um compressor passou de 286 minutos para 138 minutos, que corresponde a uma redução de aproximadamente 52%. Com a inserção de ferramentas de inteligência artificial para a detecção do instante de entrada em regime permanente e prognóstico dos parâmetros de desempenho, é possível conhecer o resultado final, com significativa confiança, em um tempo médio de 54 minutos, como pode ser visualizado pela figura 4 (PENZ, 2011).

⁵ Sistema de medição: conjunto de um ou mais instrumentos de medição e frequentemente outros dispositivos, associados e adaptados para fornecer informação destinada a obter valores medidos (INMETRO, 2009).

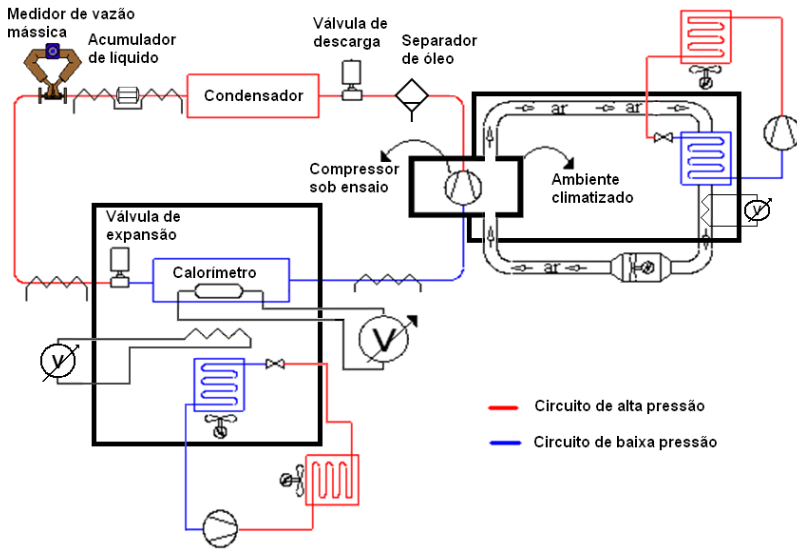


FIGURA 3: DIAGRAMA ESQUEMÁTICO DA BANCADA DISPONÍVEL NO LABMETRO




FIGURA 4: RESULTADOS DA REDUÇÃO DO TEMPO NA BANCA DE ENSAIO DE DESEMPENHO

Conhecer como são implementados fisicamente os métodos descritos pela norma é de grande valia para esta tese. Por se tratarem do estado da arte em ensaios de capacidade de refrigeração do compressor, esses foram considerados na busca de uma proposta de ensaio a ser realizado junto à linha de produção. A utilização dos métodos descritos pela norma também são cruciais para validar a proposta de solução. Através dos resultados obtidos pelas bancadas é possível confrontar as respostas obtidas junto à linha de produção.

2.3 MEDIÇÃO DA CAPACIDADE DE REFRIGERAÇÃO PARA CONTROLE DA QUALIDADE

Devido ao elevado volume de produção e longo tempo de ensaio, a capacidade de refrigeração para qualquer lote de compressores é determinada por uma amostra extremamente pequena, situação que vale para todos os fabricantes em nível mundial. No entanto, os procedimentos de execução dos ensaios estabelecidos por norma são gerais para todas as situações de operação. Desse modo, os métodos propostos podem simular diferentes condições de um ciclo de refrigeração. Assim, é possível o estabelecimento de diferentes temperaturas de condensação e evaporação. Para tal, devem ser estabelecidos valores apropriados para condições de operação do compressor, como: pressão absoluta de sucção e descarga; temperatura de sucção; e rotação. As demais variáveis podem ser fixas, independentes das condições de ensaio. Porém, todas elas devem variar dentro de limites máximos estabelecidos, como pode ser observado na tabela 1 (ISO, 1989). Nessa tabela aparecem limites de variabilidade máxima para capacidade de refrigeração, potência elétrica e temperatura da carcaça do compressor, que não são definidos pela norma e sim por especialistas em compressores e ensaios de desempenho (PENZ, 2011).

Mesmo as bancadas de desempenho podendo imprimir inúmeras condições de operação, é necessário que os compressores provenientes da linha de produção⁶ sejam ensaiados dentro de uma condição específica. Essa, que é chamada de condição típica de operação, serve para que produtos de diferentes fabricantes possam ser comparados entre si pelos clientes. Atualmente não existem normas para definir as condições típicas de operação para um compressor. No entanto, o mercado de compressores herméticos para refrigeração usualmente define essa condição como $-23,3^{\circ}\text{C}$ e $+54,4^{\circ}\text{C}$ ⁷, para temperaturas de evaporação e condensação, respectivamente.

⁶ Ensaios de desempenho de compressores podem ser realizados, tanto para verificação de dados de compressores comerciais, como para verificação de dados de compressores em fase de pesquisa e desenvolvimento. Neste trabalho serão abordados somente ensaios destinados à verificação de compressores comerciais.

⁷ Nos métodos em que não é necessária a mudança de fase do refrigerante, as condições típicas de ensaio ($T_E = -23,3^{\circ}\text{C}$ e $T_C = +54,4^{\circ}\text{C}$) se dão pelo estabelecimento de pressões absolutas de sucção e descarga ($P_S = 1,148$ bar e $P_D = 14,698$ bar – refrigerante R134a), que correspondem as mesmas pressões impostas ao compressor em um ciclo de refrigeração por compressão de vapor para as temperaturas T_E e T_C .

TABELA 1: LIMITES MÁXIMOS DE VARIAÇÃO PARA BANCADAS DE DESEMPENHO

Grandeza	Limites de operação
Pressões	$\pm 1\%$ do valor especificado
Temperaturas	$\pm 3^{\circ}\text{C}$ do valor especificado
Tensão de alimentação	$\pm 3\%$ do valor nominal
Frequência	$\pm 1\%$ 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	$\pm 1\%$ do valor médio da última hora de ensaio
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

Como exemplo, atualmente a unidade da Embraco em Joinville conta com 24 bancadas de ensaio de desempenho, com diferentes configurações, trabalhando vinte e quatro horas por dia, atendendo a demanda de oito linhas de produção em ensaios para a venda, levantamento de dados para catálogo e inúmeros ensaios de projetos relacionados com pesquisa e de desenvolvimento.

Ao final do capítulo 2 pode ser observado que os atuais métodos para avaliação de desempenho necessitam bancadas complexas e de elevado custo. Pode ser observado também, que esses métodos requerem um elevado tempo de ensaio e a realização de vácuo no sistema de refrigeração.

Em relação a esses tradicionais métodos pode-se concluir que:

- atualmente eles são incapazes de atender, em tempo hábil, a verificação da produção em larga escala de compressores;
- dificilmente podem ser integrados à linha de produção e muito menos em 100% das peças produzidas;
- os avanços que possibilitaram a redução do tempo de ensaio ficaram restritos a ambientes laboratoriais.

3 REDES NEURAIS ARTIFICIAIS NO ÂMBITO DESTE TRABALHO

O estudo das redes neurais artificiais (RNA) teve seu início com a publicação do inovador artigo de Warren McCulloch e Walter Pitts (McCULLOCH, 1943). Inspirados por trabalhos que indicavam a natureza booleana da atividade neuronal do cérebro humano, apresentaram pela primeira vez o modelo matemático para um neurônio. Esse artigo estabeleceu de modo científico, a ligação entre inteligência e atividade nervosa (KÓVACS, 2006).

Desde o começo, trabalhos com redes neurais artificiais (RNA) têm como principal motivador o modo como o cérebro humano processa as informações, pois por ser um sistema de processamento de informação complexo, não linear e altamente paralelo, possui a capacidade de processar informações de forma diferente de um computador digital convencional. Se comparado com portas lógicas em um circuito eletrônico, o tempo de processamento de um evento em um neurônio biológico é muito superior, enquanto no primeiro caso esse tempo está na ordem de nanossegundos, para o segundo ele fica na ordem dos milissegundos. Porém, o cérebro compensa o processamento mais lento com uma grande quantidade de neurônios e conexões maciçamente distribuídas entre si. Assim, para uma atividade computacional complexa, como o reconhecimento perceptivo como o reconhecimento de um rosto familiar, por exemplo, o cérebro humano pode levar uma pequena fração de segundo. Por outro lado, um computador com capacidade de processamento convencional, que não fazem uso de técnicas de IA, pode levar dias para processar tarefas de complexidade inferior (GUPTA, 2003; HAYKIN, 1999).

A diferença fundamental entre projetos de engenharia que utilizam RNA e aqueles com processamento convencional, é que este último faz uso de modelos matemáticos dos fenômenos físicos, já para o primeiro, isso não ocorre por meio desse tipo de modelagem. Em geral, projetos de RNA fazem uso diretamente de dados do mundo real, permitindo que a rede aprenda com o conjunto de dados e forneça um modelo implícito do caso sobre análise. Dessa forma, para problemas complexos, onde a modelagem matemática dos fenômenos físicos se torna inviável, o uso

de redes neurais artificiais se apresenta como uma solução viável (HAYKIN, 1999)⁸.

Dentre os benefícios da utilização de RNA, como as *feedforward* por exemplo, destacam-se (BRASZA, 2010; NYGREN, 2004; GUPTA, 2003; HAYKIN, 1999; SVOZIL, 1997):

- não-linearidade – uma RNA constituída por neurônios não-lineares é uma rede não-linear, o que é uma propriedade essencial para a modelagem de fenômenos físicos, que, em sua maioria, possuem aspectos de não-linearidade;
- mapeamento de entrada/saída – uma RNA possui seu aprendizado através da modificação dos pesos sinápticos pela aplicação de um conjunto de treinamento, obtidos de amostras com entradas e saídas conhecidas;
- adaptabilidade – uma RNA pode facilmente ser retreinada para lidar com pequenas modificações nas condições iniciais;
- analogia neurobiológica – uma RNA funciona de modo análogo ao cérebro humano, possuindo assim uma estrutura maciça e paralelamente distribuída, com rápido poder de processamento das informações;
- generalização – uma RNA possui a capacidade de apresentar saídas adequadas, para entradas que não estavam presentes no conjunto de treinamento.

O estudo da aplicação de RNA é aqui realizado por se apresentar como uma técnica de modelagem eficaz para descrever modelos complexos com resultados bastante adequados (SINGARAM, 2011; GHOBADIAN, 2009; ERTUNC, 2005; ARCAKLIOĞLU, 2004; RUSSELL, 2013; SWIDER, 2001; HAYKIN, 1999).

3.1 REDES *FEEDFORWARD*

A teoria do estudo de RNA apresenta diferentes tipos de redes passíveis de implementação em conjunto com diferentes algoritmos de

⁸ O livro *Neural Networks – A Comprehensive Foundation* (HAYKIN, 1999) é referência mundial na explanação das RNA. Incorpora extensa bibliografia do assunto. Por esse motivo é utilizada neste capítulo como referência básica e, seguida de outras, reforçam a explanação do tema abordado.

aprendizagem. Neste trabalho, será explorada a morfologia das RNA do tipo alimentadas para frente (*feedforward*) com aprendizado de retropropagação de erro, por ser o conjunto mais utilizado em projetos diversos, por retornarem respostas adequadas para diferentes tipos de problemas (SUMATHI, 2009; GOVINDARAJAN, 2007) e por terem apresentado resultados consistentes no prognóstico dos parâmetros de desempenho de compressores para os trabalhos apresentados anteriormente (PENZ, 2011; LIMA, 2010a; STEINBACH, 2008; HENKLEIN, 2006).

3.1.1 MODELO GERAL DE NEURÔNIO

A unidade fundamental de processamento e armazenamento de informação de uma RNA é o neurônio. O processamento das informações se dá por meio das operações matemáticas aplicadas aos sinais de entrada, que geram um único sinal de saída, e o armazenamento de informações se dá pela modificação dos pesos sinápticos durante a fase de treinamento da RNA (SUMATHI, 2009; HAYKIN, 1999).

Na figura 5 é possível identificar os elementos básicos de um neurônio:

- pesos sinápticos (w) – porta de entrada do neurônio, onde o sinal de uma sinapse é inicialmente modificado conforme o peso que essa conexão representa na RNA;
- somador (Σ) – soma os diferentes sinais das entradas já ponderados pelos pesos sinápticos;
- função de ativação ou de transferência ($\varphi(\cdot)$) – função que limita o intervalo permissível de amplitude do sinal de saída do neurônio.

Assim a saída y_k do neurônio é dada pela equação (4):

$$y_k = \varphi(v_k) \quad (4)$$

Onde:

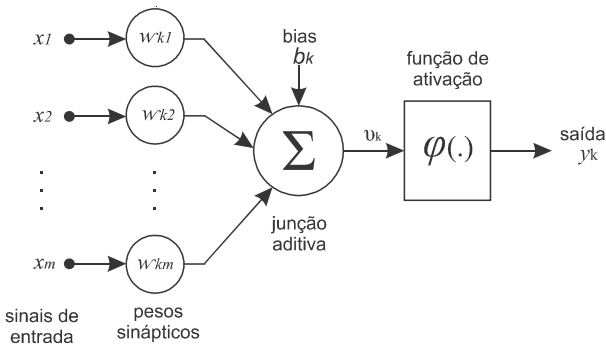
- $\varphi(\cdot)$ função de transferência;
- v_k campo local induzido no neurônio k .

e v_k é dado por:

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (5)$$

Onde:

- w_{kj} peso da sinapse do sinal proveniente do neurônio j sobre o neurônio k ;
- x_j sinal na entrada proveniente do neurônio j ;
- b_k bias do neurônio k .



legenda:

- x_j - sinal de entrada
- w_{kj} - peso sináptico
- Σ - somador
- v_k - campo local induzido
- $\varphi(.)$ - função de ativação
- y_k - sinal de saída

FIGURA 5: GRAFO DO MODELO MATEMÁTICO DE UM NEURÔNIO

3.1.2 ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS

A definição da arquitetura para uma RNA está intimamente ligada com a aplicação a que a rede se propõe. A princípio qualquer configuração organizada de neurônios pode dar origem a uma RNA. Porém, a literatura estabelece duas principais categorias para a arquitetura das redes, que são: redes *feedforward* e redes recorrentes ou cíclicas (RUS-

SELL, 2013; HAYKIN, 1999). Uma rede com alimentação para frente representa uma função das entradas do conjunto de treinamento e não possui nenhum conhecimento além do adquirido no momento do treinamento. Situação diferente ocorre para as redes recorrentes, que utilizam respostas de sua saída para realimentar suas entradas, assim oferece a capacidade de memória de curto prazo, mas que pode gerar, além do estado estável, oscilações ou comportamento caótico (RUSSELL, 2013).

A aplicação a que se destina a RNA também define outras características da arquitetura das redes como: número de camadas, número de neurônios por camadas e grau de conectividade entre os neurônios (um a um, conectividade plena, esparsa ou randômica). Assim, o modo como a estrutura está organizada definirá as características de generalização, armazenamento do conhecimento e o esforço computacional da RNA (PENZ, 2011).

Redes *feedforward* ou de alimentação para frente são assim chamadas, pois o sinal processado projeta-se sempre no sentido da saída e nunca o contrário. Esse tipo de arquitetura está basicamente dividida em duas: redes de camada única e de múltiplas camadas.

3.1.2.1 REDES *FEEDFORWARD* COM CAMADA ÚNICA

RNA com camada única é a forma mais simples de redes do tipo *feedforward*. Como mostrado na figura 6 são apresentados quatro falsos neurônios na entrada, os quais não são considerados por não realizar qualquer processo computacional. A única função deles é o estabelecimento das sinapses entre o sinal de entrada e os neurônios da camada de saída, que é onde está armazenado o conhecimento da RNA.

Redes de camada única fazem uso de algoritmos de aprendizagem relativamente simples, o que permite grande velocidade durante a fase de aprendizagem. No entanto, esse tipo de arquitetura fica basicamente restrita ao uso em classificadores de padrões linearmente separáveis (HAYKIN, 1999).




FIGURA 6: REDE *FEEDFORWARD* COM UMA ÚNICA CAMADA

3.1.2.2 REDES *FEEDFORWARD* COM MÚLTIPLAS CAMADAS

A segunda classe de redes *feedforward* se distingue da primeira por apresentar uma ou mais camadas de neurônios entre a entrada e a saída. Essas camadas são denominadas camadas ocultas e sua função é intervir entre a entrada e a saída de modo útil. Essas camadas permitem que a RNA extraia estatísticas de ordem elevada, resolvendo deste modo o problema com padrões não linearmente separáveis (HAYKIN, 1999).

A figura 7 apresenta o grafo de uma rede com uma camada extra com oito neurônios ocultos. Assim, como na arquitetura apresentada no item 3.1.2.1, os neurônios da camada de entrada não realizam nenhuma operação matemática, funcionando somente como elementos de sinapses entre os sinais de entrada e a primeira camada oculta. Porém, a camada oculta apresenta neurônios, os quais possuem a mesma topologia dos neurônios da saída. Esses, assim como os da camada de saída, processam e armazenam informações.




FIGURA 7: REDE *FEEDFORWARD* COM UMA CAMADA OCULTA

Os neurônios ocultos desempenham um papel crucial na operação de uma RNA com múltiplas camadas. Eles agem como detectores de características conforme o processo de aprendizagem avança, e gradualmente salientam as funções que caracterizam o conjunto de treinamento (HAYKIN, 1999).

3.2 APRENDIZADO DE REDES NEURAIIS

Uma propriedade primordial das RNA é a capacidade de aprender a partir de dados do ambiente sob estudo e melhorar sua resposta à medida que o treinamento evolui. Esse processo se dá por meio da modificação e ajuste dos pesos sinápticos e bias. Existem diversos algoritmos de aprendizagem, neste trabalho serão explanados dois largamente utilizados (YU, 2011).

3.2.1 APRENDIZADO *BACK-PROPAGATION*

O algoritmo de aprendizado mais popular para o treinamento das RNA, do tipo *feedforward* com múltiplas camadas, é o *back-propagation*. Ele consiste basicamente em uma técnica derivativa e possui as seguintes propriedades (GOVINDARAJAN, 2007; HAYKIN, 1999):

- simples de calcular localmente;
- realiza descida estocástica do gradiente de erro no espaço dos pesos.

Em uma rede *feedforward* com aprendizado *back-propagation*, dois sinais circulam pela RNA durante a fase de treinamento (ARBIBI, 2003; HAYKIN, 1999):

- sinal funcional ou de entrada – sinal que flui da entrada para a saída através da rede, e é apresentado como resposta na saída da RNA;
- sinal de erro – erro que se origina na saída da rede e é propagado para trás, camada por camada, na direção da entrada.

O algoritmo *back-propagation* interage com os pesos de todos os neurônios através do erro obtido entre as respostas da rede e aquelas conhecidas do conjunto de treinamento. É possível notar pela figura 8 que o sinal de erro retrocede modificando os pesos até as sinapses estabelecidas pelos neurônios da camada de entrada da rede neural artificial.

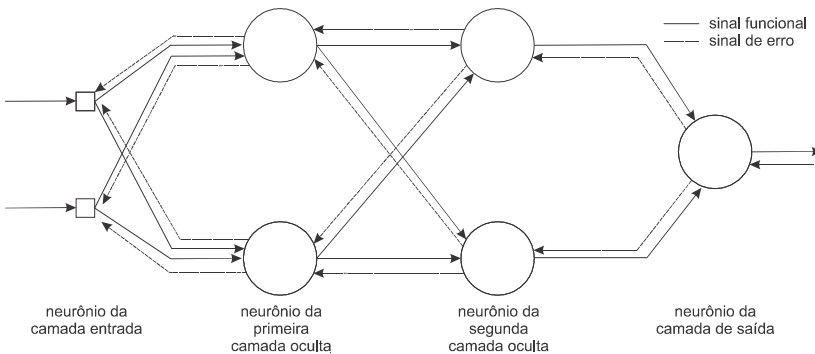


FIGURA 8: FLUXO DE SINAIS DURANTE O TREINAMENTO

Nesse aprendizado, o ajuste dos pesos se dá pelo gradiente de decida da função de erro através da regra delta, equação (6)⁹ (YU, 2011; HAYKIN, 1999):

(6)

$$\Delta w_{ji} = -\eta \cdot \frac{\partial \varepsilon}{\partial w_{ji}}$$

Onde:

- Δw_{ji} correção do peso da sinapse do neurônio j , que é a entrada para o sinal proveniente do neurônio i ;
- η parâmetro da taxa de aprendizagem definido pelo especialista no momento do treinamento;
- $\frac{\partial \varepsilon}{\partial w_{ji}}$ gradiente de decida da função de erro total.

Entretanto, como o gradiente local aponta para as modificações necessárias nos pesos sinápticos, pode-se definir o gradiente de decida da função de erro total através da equação (7) (HAYKIN, 1999).

$$\frac{\partial \varepsilon}{\partial w_{ji}} = -\delta_j y_i \quad (7)$$

Onde:

- δ_j gradiente local de decida no neurônio j ;
- y_i sinal da sinapse de entrada no neurônio j proveniente do neurônio i .

No algoritmo *back-propagation*, o processo de aprendizagem consiste de épocas¹⁰, onde são apresentadas nas entradas da RNA os dados do

⁹ Nessa equação o neurônio i encontra-se imediatamente antes do neurônio j em relação à entrada da rede.

¹⁰ O termo época em RNA significa que todos os exemplos presentes no conjunto de treinamento foram apresentados à rede e os erros foram calculados e retropropagados para as entradas. Assim, uma época denota uma iteração no processo de aprendizagem, o qual é mantido em uma base de época em época até que os pesos e bias se estabilizem e o erro médio quadrado sobre o conjunto de treinamento convirja para um valor mínimo (HAYKIN, 1999).

conjunto de treinamento e quando calculado o erro na saída, esse é então retropropagado. Deste modo, a cada época de treinamento da RNA o erro é minimizado e o processo de aprendizado ocorre. O treinamento fica em *loop* contínuo até que o processo seja interrompido.

O ajuste dos pesos ocorre aplicando-se a equação (8) a cada época. Para isso é necessário conhecer o gradiente local de decida δ_j (HAYKIN, 1999).

$$[\Delta w_{ji}(n)] = [\eta] \cdot [\delta_j(n)] \cdot [y_i(n)] \quad (8)$$

Onde:

- Δw_{ji} correção do peso da sinapse do neurônio j , que é a entrada para o sinal proveniente do neurônio i ;
- η parâmetro da taxa de aprendizagem definido pelo especialista no momento do treinamento;
- δ_j gradiente local de decida no neurônio j ;
- y_i sinal da sinapse de entrada no neurônio j proveniente do neurônio i ;
- n e-ésima época de aprendizado.

Porém, o algoritmo trata os neurônios das camadas ocultas de modo diferentemente daqueles na camada de saída, isso dado ao fato de que para os neurônios de saída, a resposta desejada é única e conhecida para cada dado de treinamento. Assim, o gradiente δ_j para os neurônios dessa camada pode ser obtido pelas equações (9) e (10) (HAYKIN, 1999).

$$\delta_j(n) = e_j(n) \varphi'_j(v_j(n)) \quad (9)$$

Onde:

- e_j sinal de erro na saída do neurônio j ;
- φ'_j derivada da função de transferência do neurônio j ;
- v_j campo local induzido do neurônio j .
- n e-ésima época de aprendizado.

Com e_j dado por:

$$e_j(n) = d_j - y_j(n) \quad (10)$$

Onde:

- d_j resposta desejada para o neurônio j da camada de saída da RNA;
- y_j resposta da rede para o neurônio j da camada de saída da RNA;
- n e-nesima época de aprendizado.

Essa situação não ocorre para os neurônios das camadas ocultas, pois não há o conhecimento das respostas desejadas. Desse modo, o gradiente δ_j é obtido em termos dos sinais de erros de todos os neurônios k , aos quais a saída do neurônio oculto j está diretamente conectada. Para as camadas ocultas, o gradiente é obtido através da equação (11)¹¹ (HAYKIN, 1999).

$$\delta_j(n) = \left(\sum_k \delta_k(n) w_{kj}(n) \right) \varphi'_j(v_j(n)) \quad (11)$$

Onde:

- δ_k gradiente de decida do neurônio k , o qual o neurônio j está conectado através de sua saída;
- w_{kj} peso sináptico do neurônio k na sinapse com o neurônio j ;
- φ'_j derivada da função de transferência do neurônio j ;
- v_j campo local induzido do neurônio j ;
- n e-nesima época de aprendizado.

Se compararmos as equações (9) e (11), é possível notar que a parcela do erro para a saída dos neurônios da camada oculta provem das ligações sinápticas que cada um desses possui em sua saída. É importan-

¹¹ Nessa equação o neurônio j encontra-se imediatamente antes do neurônio k em relação à entrada da rede.

te ressaltar que para a utilização do algoritmo *back-propagation* a função de transferência deve ter derivada conhecida.

3.2.2 APRENDIZADO LEVENBERG–MARQUARDT

O algoritmo Levenberg-Marquardt fornece uma solução com convergência rápida e estável para a minimização do erro em problemas de RNA pequenos e médios.

Mesmo o algoritmo *back-propagation* sendo o mais popular no uso em RNA, esse possui convergência lenta. Essa convergência pode significativamente melhorada se utilizarmos o algoritmo Gauss-Newton, que utiliza derivadas de segunda ordem da função de erro, avaliando assim a curvatura da superfície de erro para uma convergência mais rápida. No entanto, diferentemente do algoritmo *back-propagation*, este pode não convergir para todos os casos, sendo que a convergência só é possível se a aproximação quadrática da função de erro for razoável (YU, 2011).

Nesse sentido, o algoritmo Levenberg-Marquardt combina o método do gradiente descendente, utilizado no *back-propagation*, e da avaliação da curvatura da superfície de erro, utilizado no Gauss-Newton. Deste modo, ele herda a estabilidade de um e a rapidez do outro, convergindo mesmo em situações onde a curvatura for mais complexa que a quadrática e podendo ser muito mais rápido do que o método do gradiente descendente. Assim, este algoritmo executa um processo combinado, onde em torno da área com uma curvatura complexa, quem atua é o método do gradiente descendente, até que a curvatura local seja aproximadamente quadrática, quando é então utilizado o método de Gauss-Newton (YU, 2011, HAGAN, 1994).

O ajuste dos pesos nesse algoritmo se dá através da regra dada pela equação (12) (YU, 2011).

$$[\Delta w_{ji}(n)] = (H_{ji}(n) + \mu I)^{-1} \cdot \left[\frac{\partial \varepsilon}{\partial w_{ji}}(n) \right] \quad (12)$$

Onde:

Δw_{ji} correção do peso da sinapse do neurônio j , que é a entrada para o sinal proveniente do neurônio i ;

H_{ji}	matriz Hessiana ¹² ;
I	matriz identidade;
$\frac{\partial \varepsilon}{\partial w_{ji}}$	gradiente de decida da função de erro total;
μ	coeficiente de combinação;
n	e-nésima época de aprendizado.

No algoritmo Levenberg-Marquardt a matriz identidade garante que a Hessiana seja inversível, pois μ é sempre positivo e diferente de zero. Sendo que este último é ajustado constantemente à medida que o aprendizado evolui. Assim, no início do treinamento, onde a curvatura da superfície de erro é mais complexa, μ possui um valor elevado, o que diminui a influência da matriz Hessiana, predominando então o método do gradiente de decida. Com a evolução do treinamento e a minimização do erro, o valor de μ cai e o método de Gauss-Newton passa a predominar, justamente onde a superfície local do erro é menos complexa (YU 2011, HAGAN, 1994).

Devido à dificuldade de se estabelecer a matriz Hessiana e suas derivadas de segunda ordem da função do erro, o algoritmo simplifica esse processo fazendo uso da matriz Jacobiana¹³, a qual é de mais fácil obtenção por ser constituída apenas por derivadas de primeira ordem. Deste modo, a matriz Hessiana pode ser simplificada pela equação (13) e o gradiente pode ser dado pela equação (14) (YU, 2011, HAGAN, 1994).

$$H \approx J^{-1} \cdot J \quad (13)$$

Onde:

H	matriz Hessiana;
J	matriz Jacobiana.

¹² Matriz Hessiana de uma função de n variáveis é a matriz quadrada $n \times n$ das derivadas parciais de segunda ordem, e descreve a curvatura local da função.

¹³ Matriz Jacobiana é a matriz formada pelas derivadas parciais de primeira ordem de uma função.

$$\left[\frac{\partial \varepsilon}{\partial w} \right] = J \cdot e \quad (14)$$

Onde:

$\frac{\partial \varepsilon}{\partial w}$ gradiente de decida da função de erro;
 J matriz Jacobiana;
 e vetor de erro.

Introduzindo as equações (13) e (14) na equação (12) o ajuste dos pesos pode ser dado pela equação (15).

$$[\Delta w_{ji}(n)] = (J_{ji}^{-1}(n) \cdot J_{ij}(n) + \mu I)^{-1} \cdot J_{ji}(n) \cdot e(n) \quad (15)$$

Onde:

Δw_{ji} correção do peso da sinapse do neurônio j , que é a entrada para o sinal proveniente do neurônio i ;
 J_{ji} matriz Jacobiana;
 I matriz identidade;
 e vetor de erro;
 μ coeficiente de combinação;
 n e-nésima época de aprendizado.

Inserindo a equação (9) em (7) tem-se:

$$\frac{\partial \varepsilon}{\partial w_{ji}}(n) = -e_j(n) \varphi'_j(v_j(n)) y_i(n) \quad (16)$$

Comparando-se as equações (14) e (16) é possível extrair os valores das derivadas parciais da matriz Jacobiana a cada época através da equação (17).

$$\frac{\partial e}{\partial w_{ji}}(n) = \varphi'_j(v_j(n)) y_i(n) \quad (17)$$

A retropropagação do erro nesse método se dá do mesmo modo que ocorre no algoritmo *back-propagation*, como apresentado no item anterior.

3.3 MÁQUINAS DE COMITÊ

Mesmo que as RNA apresentem vantagens na modelagem de problemas complexos, seu uso requer cuidados. Uma aplicação simplista, sem que a devida cautela na minimização do erro de aprendizagem e na consideração dos erros nos dados, pode apresentar soluções distantes das almeçadas (PENZ, 2011; HAYKIN, 1999). Assim, alguns pontos também devem ser atentados quando uma RNA é utilizada diretamente em tomadas de decisões (PENZ, 2011; PAPADOPOULOS, 2001):

- não há segurança de que o algoritmo de aprendizagem chegou a um mínimo global para a função de erro;
- mesmo alcançando o mínimo global para a função de erro, a solução pode não ser ótima;
- a não informação de incertezas no momento de treinamento contribui para que esse seja não otimizado;
- a natureza aleatória do processo de aprendizagem pode apresentar valores diferentes para um mesmo conjunto de treinamento.

Para minimizar o efeito da aleatoriedade proveniente do treinamento, uma solução é trabalhar com um selecionado de redes neurais, também chamados de comitê de RNA. Dessa forma, as respostas de diferentes redes neurais são combinadas para que se chegue a uma resposta única (AHMAD, 2002; HAYKIN, 1999).

Existem diferentes métodos para combinação das saídas das RNA, o mais utilizado é o método da média simples (AHMAD, 2002), que consiste do treinamento de diferentes redes, com condições semelhantes de aprendizado, onde a resposta final é saída do comitê, que nada mais é do que a média aritmética simples de todas as respostas individuais das k redes.




FIGURA 9: COMITÊ DE RNA BASEADA NA MÉDIA ARITMÉTICA SIMPLES

A ideia básica do comitê, apresentada na figura 9, é a minimização do efeito aleatório introduzido nas RNA devido ao processo de aprendizagem. Aqui, é possível fazer uma analogia direta com a metrologia, onde para determinar o valor de grandezas com presença de efeitos aleatórios no sistema de medição, a média de mais de uma medição representa melhor o resultado do que uma única medição individualmente (BIPM, 2008a).

Penz (2011) apresenta um estudo bastante extenso e com diversas referências (EDWARDS, 2002; HU, 2002; GRANITTO, 2005; ZIO, 2006; FORTUNA, 2007; YU, 2009; WU, 2010; TRICHAKIS; 2011), as quais fazem uso de comitês de redes em diferentes aplicações. Apresenta também um estudo detalhado sobre uso de máquinas de comitê para o prognóstico dos parâmetros de desempenho de compressores herméticos. Estabelece que para um número acima de trinta RNA em um comitê, o ganho para a minimização dos efeitos aleatórios começa a ficar irrelevante, o que representa então custo adicional de treinamento para um mínimo ganho na redução de erro.

3.4 MÉTODOS PARA ESTIMAÇÃO DE INTERVALOS DE CONFIANÇA EM REDES NEURAIIS ARTIFICIAIS

Mesmo que uma RNA tenha convergido de modo correto e esteja apresentando valores com erros mínimos, na prática fica impossível se conhecer o erro final apresentado pelo modelo neural. O reconhecimento desse fato levou ao desenvolvimento de métodos para estimação de intervalos de confiança (IC). Até a presente data, muitos métodos foram desenvolvidos para estimar esses intervalos. No entanto, eles não satis-

fazem as necessidades metrológicas e não são aceitos segundo os preceitos de avaliação da incerteza de medição.

Os métodos foram concebidos com o intuito de prover confiabilidade aos modelos neurais e geralmente dependem do tipo de arquitetura da RNA (NETO, 2012). Os trabalhos de Chryssolouris (1996), seguido de Hwang (1997) e deVeaux (1998) são até os dias atuais referências seguidamente citadas pelos mais diferentes autores. Estes estabeleceram abordagens para a estimativa do IC, assumindo que os erros apresentados são normalmente distribuídos e independentes. Os autores utilizam técnicas de estimação de IC aplicadas em regressões não lineares e associaram a informação de que os modelos foram obtidos a partir de dados contaminados por ruídos aleatórios. Através da equação (18) Chryssolouris (1996) estabelece um método de como obter o IC para o resultado de uma rede neural.

$$IC = \pm t_{n-p|\frac{\alpha}{2}} [s_1^2 + (s_1^2 + s_2^2)f_0^T(F^T F)^{-1}f_0]^{1/2} \quad (18)$$

Onde:

- $t_{n-p|\frac{\alpha}{2}}$ fator *t-student* com $n - p$ graus de liberdade e nível de confiança $\frac{\alpha}{2}$;
- n número de padrões utilizados no treinamento;
- p número de parâmetros da RNA (pesos e bias);
- s_1^2 estimador não tendencioso do erro referente ao modelo causado pelas variáveis não observáveis ou não controláveis;
- s_2^2 estimador dos erros aleatórios de medição presentes nas entradas da rede;
- f_0 vetor de derivadas da função aprendida pela rede em relação a cada parâmetro da rede para cada nova entrada;
- F matriz jacobiana $n \times p$ da função aprendida pela rede.

Em contraste ao método de determinação de IC apresentado por Chryssolouris (1996), outros propõem estimar a variabilidade dos dados de treinamento a partir do próprio treinamento do modelo neural. Outra diferença marcante é que esses métodos não consideram constante a variabilidade dos dados, o que permite valores diferentes de IC ao longo da função de saída da RNA (ZAPRANIS, 2005). Papadopoulos (2001) compara três desses principais métodos no intuito de mostrar qual o mais adequado a uma aplicação industrial específica. Os métodos testados obtêm um IC através de um estimador de variância associado a cada valor de saída durante uso do modelo neural. Espera-se que este estimador possa então representar a variabilidade dos dados utilizados durante a fase de treinamento. Os seguintes métodos são apresentados:

- treinamento via máxima verossimilhança, que estabelece a criação de uma rede aumentada conforme apresentado na figura 10, a qual tem o objetivo de se obter um estimador de variância que represente a variabilidade dos dados utilizados durante a aprendizagem da RNA. O treinamento das duas redes é realizado conjuntamente através de uma função que engloba todos os parâmetros;
- treinamento bayesiano aproximado, que também faz uso de uma rede aumentada como apresentado na figura 10, porém realiza o treinamento das duas redes separadamente;
- método *bootstrap*, que parte da criação de um comitê de RNA, onde um selecionado de k redes, com a mesma configuração, é obtido através da reamostragem com reposição dos dados do conjunto de treinamento. Assim, a cada nova aprendizagem, um conjunto de n elementos é escolhido aleatoriamente de uma base de dados de treinamento de N elementos. Nesse caso, o resultado do modelo é dado pela média aritmética simples das saídas das redes que formam o comitê, e a variância é o estimador da variabilidade, o qual é usado para a obtenção do IC.




FIGURA 10: REDE AUMENTADA (PAPADOPOULOS, 2001)

Os métodos apresentados mostram o interesse dos autores em estabelecer meios que possam fornecer confiabilidade aos modelos neurais treinados a partir de dados contaminados. Porém, todos os métodos se preocupam exclusivamente com os erros aleatórios. No entanto, em muitas situações práticas de medição, os erros sistemáticos podem ter maior influência do que os erros aleatórios.

Na verdade, tanto o erro aleatório quanto o erro sistemático estão presentes em uma medição, e a dúvida em relação ao resultado sempre irá existir. Cabe aqui relatar que a IM é uma medida de dúvida e não corresponde à variabilidade dos dados. Assim, em casos onde a dúvida referente ao erro sistemático for maior que a do erro aleatório, os métodos apresentados não irão fornecer um IC adequado.

Outra situação metrológica não abordada pelos métodos apresentados para a determinação dos IC, é que os mesmos não se preocupam com as IM dos instrumentos durante o uso das RNA. Eles consideram que os dados obtidos durante o uso permanecerão com a mesma variabilidade daqueles coletados durante a fase de treinamento. Tal consideração foge aos preceitos da avaliação da IM, pois os instrumentos de medição utilizados durante a fase de treinamento podem não ser os mesmos que aqueles utilizados durante o uso das RNA.

O capítulo 3 apresentou: como as RNA são estruturadas e como se dá o aprendizado das mesmas; um meio para a minimização dos erros aleatórios provenientes do treinamento; métodos conceituados para estimar intervalos de confiança.

Em relação às RNA no âmbito deste trabalho pode se concluir que:

- os métodos encontrados na literatura para estimar intervalos de confiança de resultados de redes neurais artificiais não satisfazem os preceitos metrológicos vigentes;
- até o presente não foi encontrado na literatura um método que seja capaz de considerar as incertezas das medições do conjunto de treinamento.

4 PROPOSTA DE ENSAIO PARA ESTIMAR A CAPACIDADE DE REFRIGERAÇÃO NA LINHA DE PRODUÇÃO

A solução apresentada nesta tese está dividida em duas partes, que quando integradas permitirão realizar inferência do valor da capacidade de refrigeração do compressor na linha de produção. A primeira consiste em um rápido ensaio, onde o compressor hermético, originalmente projetado para fazer circular fluido refrigerante em um sistema fechado, comprime ar para dentro de um pequeno vaso de pressão. A segunda consiste em estabelecer um modelo neural artificial capaz de correlacionar os resultados obtidos na linha com aqueles obtidos em laboratório.

A hipótese estabelecida nessa proposta é que a capacidade do compressor deslocar massa de ar para o interior de um recipiente fechado pode ser correlacionada com a capacidade de refrigeração do mesmo. Hipótese esta que, até o presente, não foi encontrada na literatura especializada na área de refrigeração ou de compressores herméticos para refrigeração.

4.1 CONSIDERAÇÕES INICIAIS

Para o desenvolvimento de uma proposta de ensaio aplicável a 100% da produção de compressores herméticos, um ponto importante a ser atentado é o tempo de ciclo de produção da linha de manufatura. Esse tempo é extremamente reduzido e fica em torno de poucos segundos, dado que os fabricantes trabalham com grandes volumes de produção (ABDELWAHED, 2012). Na planta de Joinville, a Whirlpool/Embraco estabelece o tempo de ciclo para uma linha em aproximadamente sete segundos. Assim, a proposta de ensaio deve respeitar esse tempo, o que inevitavelmente exige um método baseado no prognóstico ou na inferência do valor da capacidade de refrigeração. Isso é necessário, pois a estabilidade das grandezas inerentes aos compressores herméticos nos sistemas de refrigeração é alcançada em tempos que podem variar de duas a cinco horas na aplicação (PORKHIAL, 2002), e de uma a quatro horas em circuitos especiais de medição (PENZ, 2011).

No entanto, mesmo com a considerável redução de tempo obtida com o uso de ferramentas de inteligência artificial nos trabalhos de Henklein (2006), Steinbach (2008), Casella (2008), Lima (2010a) e Penz (2011), uma nova abordagem é necessária. Isso ocorre porque as soluções apresentadas concentraram-se na redução da duração de ensaios realizados nas tradicionais bancadas de avaliação de desempenho de

compressores. Uma ação nessa direção certamente resultaria em tempo muito superior ao almejado para este trabalho.

A tentativa de se estabelecer o prognóstico da capacidade de refrigeração do compressor nos primeiros segundos de ensaio com o uso de bancadas convencionais, esbarra na aleatoriedade e instabilidade inicial da grandeza de interesse. Por observações prévias pode-se concluir que antes dos primeiros 10 minutos nada faz sentido nesses ensaios (PENZ, 2011; CASELLA, 2008; HENKLEIN, 2006). Pela figura 11, é possível notar que nos primeiros minutos, o comportamento das medições da capacidade de refrigeração, para quatro compressores ensaiados em bancadas de laboratório, não seguem um padrão definido (PENZ, 2011; HENKLEIN, 2006).

Nesse sentido, torna-se inviável a utilização dos métodos propostos pelas normas ISO 917 (ISO, 1989) ou ANSI/ASHRAE 23 (ANSI/ASHRAE, 2005) para os ensaios a serem realizados na linha de produção.

Também corrobora para o desenvolvimento de uma abordagem, diferente das apresentadas pelas normas, o fato de que para todos os métodos é obrigatório o uso de fluido refrigerante para qual o compressor foi projetado. Existe também, para qualquer que seja o método normatizado, a necessidade da inclusão do óleo de funcionamento no compressor. Esses dois fatores também são impedimento para a aplicação desses métodos normatizados, dado o alto custo envolvido na reciclagem do fluido refrigerante e o fato de que nem todos os compressores produzidos podem ter contato com o óleo de funcionamento durante a produção devido a cláusulas contratuais. Nesse sentido, o desenvolvimento da solução considerou a não utilização de fluido refrigerante e a não utilização de óleo para o funcionamento do compressor.




FIGURA 11: COMPORTAMENTO DA CAPACIDADE DE REFRIGERAÇÃO NAS BANCADAS DE DESEMPENHO DE COMPRESSORES (PENZ, 2011)

4.2 PROPOSTA DE ENSAIO NA LINHA DE PRODUÇÃO

Devido à inviabilidade de se realizar prognósticos a partir dos métodos normatizados, para se alcançar o objetivo traçado nesta tese, uma nova proposição foi feita. Para tal, buscou-se um ensaio que pudesse ser realizado junto à linha de produção e que fosse possível correlacionar grandezas passíveis de serem medidas na linha com a capacidade de refrigeração do compressor.

Atualmente, as linhas de produção da Whirlpool/Embraco contam com painéis automatizados para a realização de testes de verificação de funcionamento dos compressores. Esses testes ficam muito aquém de um ensaio de desempenho de compressores e não fazem qualquer correlação com a capacidade de refrigeração do compressor, sendo utilizados apenas para acompanhar a estabilidade da produção ao longo do tempo

através de parâmetros específicos como: capacidade de elevação da pressão sobre um volume pequeno em um determinado tempo; potência elétrica consumida pelo compressor; ruído gerado durante o funcionamento e a parada.

A figura 12 apresenta a concepção do painel de teste da linha de produção. Para o ensaio é acoplado no terminal de descarga do compressor uma linha de ar comprimido com volume conhecido e estável. Nesse caso, essa linha de ar comprimido funciona como o vaso de pressão quando selada e a entrada externa de ar possui duas funções básicas:

- manter a pressão constante em 2 bar durante as medições da potência elétrica consumida pelo compressor e o ruído de funcionamento, as quais são realizadas simultaneamente durante 1,5 s;
- elevar a pressão na linha de descarga para 7 bar e logo após selá-la, para que o compressor possa então elevar a pressão por si só e o painel medir essa capacidade durante o intervalo de 0,8 s.

A pré-pressurização em 7 bar da linha conectada ao terminal de descarga é um meio de conseguir que o compressor trabalhe sobre pressões mais elevadas, sem que a peça ensaiada tenha que chegar por si só a essa pressão, o que certamente demandaria tempos muito superiores aos sete segundos de ensaio, que é atualmente o tempo de ciclo dessa linha de produção.

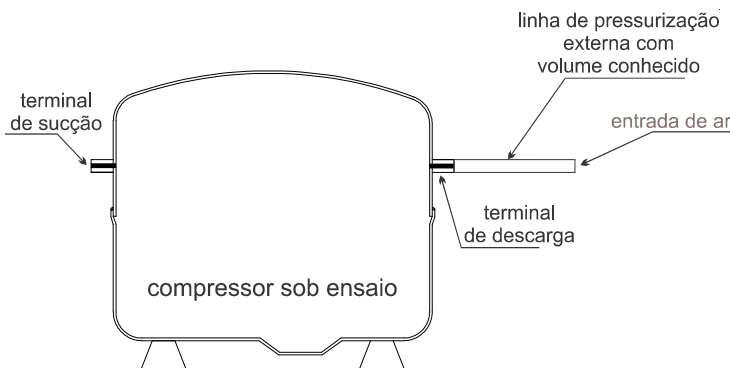


FIGURA 12: MÉTODO APLICADO NA LINHA DE PRODUÇÃO

O gráfico apresentado na figura 13 mostra as curvas de pressão e potência consumida pelo compressor durante a realização de um ensaio em uma das linhas de produção da Whirlpool/Embraco. Por ele é possível vislumbrar os instantes de medição da potência consumida pelo compressor, frente a uma pressão constante de 2 bar no terminal de descarga, e a curva de subida da pressão, quando a linha está selada e funcionando como vaso de pressão.

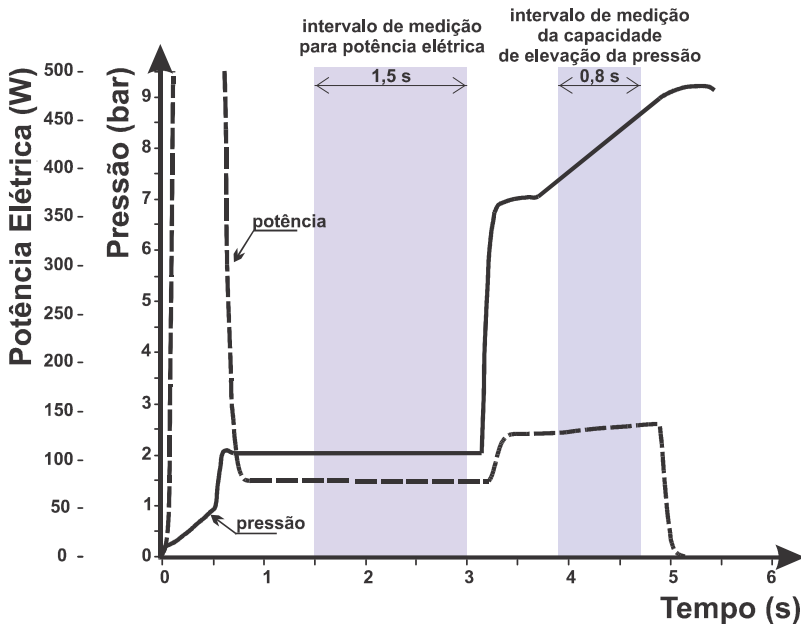


FIGURA 13: CURVAS DE PRESSÃO E POTÊNCIA DO COMPRESSOR ENSAIADO NA LINHA DE PRODUÇÃO

Tem-se como tese que esse ensaio pode ser utilizado para realizar inferências sobre o valor da capacidade de refrigeração, pois, tomando a equação (1) (página 47), percebe-se que o compressor é responsável pelo valor da vazão mássica no cálculo da capacidade de refrigeração do mesmo. Assumindo que as temperaturas na sucção e descarga, bem como as pressões na sucção e descarga, são constantes para qualquer compressor sob ensaio em laboratório, pode-se afirmar que quanto maior for a capacidade do compressor gerar fluxo de massa, maior será a capacidade de refrigeração do mesmo. Por outro lado, nesse ensaio na

linha, se forem conhecidos volume, pressões e temperaturas no início e fim do mesmo, é possível determinar o deslocamento de massa de ar durante o tempo de duração do ensaio. Assim, tem-se a hipótese de que essa vazão mássica terá correlação com a capacidade de refrigeração do compressor e, conseqüentemente, os parâmetros obtidos no ensaio na linha também terão.

Cabe ressaltar, que o painel na linha não mede diretamente a vazão de massa de ar deslocada para dentro do vaso, ele mede a capacidade de elevação da pressão em mbar/s. No entanto, isolando a massa na equação de estado do gás (19) e assumindo que o volume é constante durante o ensaio na linha, a vazão de massa de ar (obtida pela derivada da massa em relação ao tempo), dada em kg/s, pode ser expressa em função da taxa de elevação da pressão, dada em bar/s, equação (20). Essa equação também mostra que a vazão de massa é diretamente proporcional a taxa de elevação da pressão.

Assim, partindo da premissa que as condições se mantêm para todos os ensaios realizados na linha, e que o tempo de medição também permanece constante para todas as medições, é possível concluir que a capacidade de elevação da pressão será maior a medida que uma maior quantidade de massa for deslocada para o interior do vaso. Nesse sentido, a própria capacidade de elevação da pressão terá correlação com a capacidade de refrigeração do compressor. Deste modo, será possível desenvolver modelos capazes de apresentar inferências da capacidade de refrigeração através das informações extraídas nesse ensaio da linha.

As curvas também se mostram bem comportadas para esse intervalo de tempo extremamente curto na qual o compressor é submetido ao ensaio. Essa situação fortalece a ideia de que esses dados podem ser utilizados para a inferência da capacidade de refrigeração do compressor em tempo extremamente reduzido.

$$m = \frac{P \cdot V \cdot M}{R \cdot T} \quad (19)$$

Onde:

m	massa do gás;	[kg];
P	pressão;	[bar];
V	volume;	[m ³];

M	massa molar do gás;	[kg/mol];
R	constante universal dos gases;	[J.K ⁻¹ .mol ⁻¹];
T	temperatura;	[K];

$$\frac{dm}{dt} = \frac{V \cdot M}{R \cdot T} \cdot \frac{dP}{dt} - \frac{P \cdot V \cdot M}{R \cdot T^2} \cdot \frac{dT}{dt} \quad (20)$$

Onde:

$\frac{dm}{dt}$	vazão de massa;	[kg/s];
$\frac{dP}{dt}$	taxa de elevação da pressão;	[bar/s];
$\frac{dT}{dt}$	taxa de variação da temperatura;	[K/s];
P	pressão;	[bar];
V	volume;	[m ³];
M	massa molar do gás;	[kg/mol];
R	constante universal dos gases;	[J.K ⁻¹ .mol ⁻¹];
T	temperatura;	[K];

A utilização do painel de testes facilita a aplicação junto à linha de produção para a realização do estudo de caso, pois é um recurso já existente, e pode ser adequado futuramente para a implantação definitiva da proposta apresentada nesta tese.

Devido ao tempo extremamente reduzido proposto, não existe a necessidade de utilização da carga de óleo para o funcionamento do compressor e os mesmos deverão ser ensaiados nas condições que se encontram na linha durante sua montagem final. Da mesma forma, não é necessário o uso de qualquer fluido refrigerante, dado que apenas ar é comprimido durante o processo.

4.3 CORRELAÇÃO ENTRE OS ENSAIOS DE LINHA E DE LABORATÓRIO

Como a proposta parte do pressuposto de que a capacidade de elevação da pressão possui correlação com a capacidade de refrigeração do compressor, é necessário inicialmente verificar como isso ocorre. Para constatar se existe ou não correlação entre essas duas grandezas, compressores ensaiados na linha e em laboratório podem ter seus resultados confrontados. Desse modo, para cada peça ensaiada é possível conhecer essas duas características e, assim, obter-se uma confirmação estatística.

Neste trabalho, para a análise estatística, foram utilizados 61 compressores¹⁴ de 14 lotes com diferentes modelos, o que corresponde a um total próximo a 270 horas de ensaio em bancadas de avaliação de desempenho e 6,5 minutos de ensaios no painel da linha de produção.

Uma forma de verificar a existência da correlação entre duas variáveis é através do coeficiente de correlação de Pearson¹⁵ (MONTGOMERY, 2003). No entanto, esse método estatístico é bastante conclusivo em relação à afirmação de que duas variáveis são linearmente correlacionadas, mas correlações não lineares podem apresentar baixo coeficiente, o que pode levar a conclusão de dados não correlacionados, quando na verdade são (DEVORE, 2006).

Fato importante é que quanto melhor for a correlação entre as variáveis, mais fácil será estabelecer um modelo (HIGGINS, 2005; COSTA, 2011). Nesse sentido, para que a correlação entre duas variáveis seja considerada forte, o coeficiente em relação à população deve ser maior que 0,8 (DEVORE, 2006).

A partir dos dados coletados foi construído um gráfico da capacidade de refrigeração versus capacidade de elevação (figura 14). Esse gráfico mostra, em uma análise superficial, indicativo da existência de correlação entre a grandeza obtida na linha e aquela obtida em laboratório. Porém, para a confirmação da existência de correlação entre as amostras apresentadas no gráfico foram utilizadas ferramentas de análise de correlação contidas no *software* de análise estatística Minitab, o qual apresenta também inferência sobre o coeficiente de correlação de Pearson para a população de compressores (MINITAB, 2010).

¹⁴ Esta tese ateu-se aos compressores projetados para trabalhar com fluido refrigerante R134a.

¹⁵ O coeficiente de Pearson pode apresentar valores entre -1 e 1, sendo que os valores extremos indicam correlação linear máxima entre duas variáveis de modo que $Y = aX + b$ (com $a \neq 0$), e o valor zero indica completa ausência de correlação linear (DEVORE, 2006).

Desse modo, o *software* retornou o resultado de 0,84 para o coeficiente de correlação da amostra e indicou que também existe correlação significativa para a população de compressores. O intervalo, com 95% de confiança, para o coeficiente de correlação da população ficou entre 0,74 e 0,94. Isso mostra a forte correlação entre os dois ensaios, o que, em tese, permite o desenvolvimento de modelos capazes de realizar inferências do valor da capacidade de refrigeração através do ensaio proposto.




FIGURA 14: GRÁFICO DA CAPACIDADE DE REFRIGERAÇÃO VS CAPACIDADE DE ELEVAÇÃO DA PRESSÃO

Apesar do resultado obtido para a correlação entre a capacidade de refrigeração e de elevação se mostrar significativo, a utilização de mais de uma variável para conceber o modelo neural pode ser vantajosa. Como o painel utilizado na linha realiza medições de outras grandezas, verificar quais delas possuem significativa relação com a capacidade de refrigeração é importante. Além da capacidade de elevação da pressão, são medidos: potência elétrica consumida, temperatura da carcaça do compressor, ruído de funcionamento e de parada.

As cinco grandezas medidas no ensaio de capacidade de elevação foram avaliadas conjuntamente em relação à capacidade de refrigeração. Para isso foram utilizadas as ferramentas de análise de regressão linear múltipla do *software* Minitab. Os resultados completos retornados pelo *software* de análise estatística podem ser visualizados no apêndice C.

Através da análise, pode-se concluir que para a capacidade de refrigeração, mostraram-se significativas a capacidade de elevação, consumo e temperatura. Esses resultados mostram que essas grandezas devem ser levadas em consideração na construção do modelo proposto.

Outro fator importante observado durante o processo de análise foi a influência da temperatura do compressor na linha de produção sobre o resultado da capacidade de elevação da pressão. Ensaios adicionais realizados nos compressores, nos quais foram impostas variações de temperatura, evidenciou essa forte influência.

A consideração desse efeito no modelo neural é imprescindível, pois os compressores chegam ao final da linha de produção com temperaturas típicas na faixa de $(21 \text{ a } 46)^\circ\text{C}$, como constatado *in-loco*. Essa variação deve-se ao fato de que o compressor sai da estufa de secagem de pintura com temperatura próxima dos 50°C e resfria para aproximadamente 46°C até chegar no final da linha de montagem, onde é realizado o ensaio. Porém, muitas vezes devido a paradas na linha de montagem final, compressores são retirados para que a montagem seja concluída posteriormente. Essa espera causa o resfriamento do compressor até temperaturas próximas a 21°C , pois a linha de montagem final é climatizada nessa temperatura.

Ao final, as análises realizadas neste item mostram que existe correlação entre os resultados dos ensaios de laboratório e de linha. Essa constatação permite supor que, é possível utilizar o ensaio de linha para estabelecer um modelo de correlação e estimar na linha de produção a capacidade de refrigeração dos compressores.

4.4 PROPOSTA DE MODELAGEM NEURAL ARTIFICIAL

A partir da confirmação da existência de correlação e de posse das informações dos ensaios de laboratório e de linha de produção, pode-se, então, treinar redes neurais e estabelecer modelos para realizar inferências do valor da capacidade de refrigeração do compressor. O uso dessa ferramenta de inteligência artificial se apresenta como uma opção bastante vantajosa, pois a realização de ensaios junto à linha de produção está sujeita a diferentes grandezas de influência, o que torna difícil o estabelecimento de um modelo matemático correlacionando às medições realizadas na linha com a capacidade de refrigeração. Nesse sentido, o uso de RNA se mostra adequado quando se dispõe de dados experimentais suficientes para extrair conhecimento dos mesmos (PENZ, 2011; LIMA, 2010a; HENKLEIN, 2006; RUSSELL, 2013; HAYKIN, 1999). Corroborar também o fato dessa modelagem ser bastante adequada e

menos custosa que a modelagem matemática clássica de sistemas de refrigeração (ERTUNC, 2005; ARCAKLIOĞLU, 2004; SWIDER, 2001).

Nesta proposta, para a modelagem através das redes neurais, são imprescindíveis exemplos práticos no processo de aprendizagem (HAYKIN, 1999). Desse modo, além dos valores das grandezas medidas na linha, necessita-se também dos valores obtidos em laboratório. Assim, para cada compressor que compõe o conjunto de treinamento, os resultados medidos na linha para a capacidade de elevação da pressão (mbar/s), o consumo de potência elétrica (W) e a temperatura ($^{\circ}\text{C}$) são tidos como entradas da RNA e, a respectiva medição, no laboratório, para a capacidade de refrigeração (W), como a saída da rede.

Após definidas as entradas e saídas, coletados os dados na linha e em laboratório, será possível então realizar o treinamento das redes neurais. Com as RNA treinadas e o modelo neural estabelecido, inferências sobre o valor da capacidade de refrigeração de cada compressor poderá ser obtida. Desse modo, o resultado da inferência na linha será dado exclusivamente através das medições dos ensaios realizados no painel de teste (figura 15), dispensando assim o uso de dos circuitos de refrigeração.

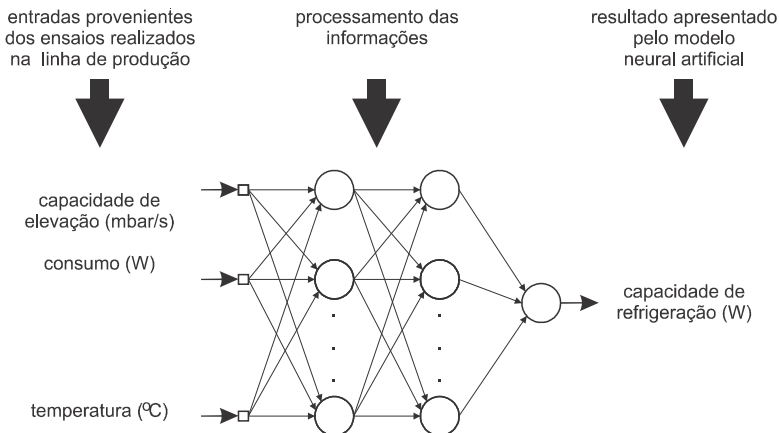


FIGURA 15: FUNCIONAMENTO DA RNA PARA DETERMINAÇÃO DA CAPACIDADE DE REFRIGERAÇÃO DO COMPRESSOR

O capítulo 4 apresentou uma proposta para estimar o valor da capacidade de refrigeração do compressor junto à linha de produção. Essa proposta consiste num ensaio em que o compressor hermético desloca massa de ar para dentro de um pequeno vaso de pressão e um modelo neural artificial que permite realizar inferências através da correlação da capacidade de elevação da pressão com a capacidade de refrigeração.

Em relação a essa proposta para estimar a capacidade de refrigeração integrável à linha de produção pode-se concluir que:

- há necessidade de um ensaio que se afaste dos conceitos atuais para a medição da capacidade de refrigeração;
- a capacidade do compressor deslocar massa de ar para dentro de um vaso de pressão pode ser correlacionada com a capacidade de refrigeração desse compressor;
- a temperatura do compressor no momento do ensaio na linha influencia significativamente a capacidade de elevação de pressão;
- a modelagem neural artificial se mostra como uma opção adequada para a obtenção desse modelo de correlação entre o ensaio na linha e o ensaio em laboratório;
- o comportamento da curva de elevação da pressão, obtida em um curto espaço de tempo, é adequado para a realização da inferência da capacidade de refrigeração em tempos extremamente reduzidos.

5 PROPOSTA DE MÉTODO METROLOGICAMENTE EMBASADO PARA EXPRESSÃO DA INCERTEZA NA INFERÊNCIA DE MODELOS NEURAIIS ARTIFICIAIS

Como mencionado no capítulo 3, RNA se apresentam como alternativa a inúmeros problemas onde a aplicação de técnicas tradicionais de modelagem não é viável (SINGARAM, 2011; GHOBADIAN, 2009; ERTUNC, 2005; ARCAKLIOĞLU, 2004; RUSSELL, 2013). No entanto, os trabalhos acadêmicos e industriais nessa área não abordam os aspectos metroológicos de modo suficiente para a garantia da confiabilidade dos resultados das redes, como pode ser constatado em Papadopoulos (2001), deVeaux (1998), Hwang (1997) e Chryssolouris (1996), que são propostas seguidamente citadas na literatura (PENZ, 2011; ZAPRANIS, 2005). O resultado, do ponto de vista metroológico, é abordado de modo simplista através do desvio padrão e erros dos resultados obtidos para os dados do conjunto de treinamento (KHAWAJA, 2005; BARRHEN, 2002). Essa visão é tratada como a “incerteza” da RNA, o que contrapõe os conceitos metroológicos e que, necessariamente, devem ser levados em consideração quando uma rede é utilizada como parte integrante de um processo de medição (PENZ, 2011). Para auxiliar o leitor que não está familiarizado com os métodos internacionalmente aceitos para avaliação e expressão da incerteza de medição, este trabalho apresenta um resumo de tais métodos no apêndice D deste documento.

O treinamento de um modelo neural livre de erros de medição só é possível se for conhecido o modelo matemático do fenômeno a ser modelado, pois assim não haveria necessidade de dados oriundos de medições para formação do conjunto de treinamento. Tentar estabelecer um modelo neural para descrever um fenômeno físico tendo-se o modelo matemático seria um paradoxo, já que o motivo para o uso de RNA é justificável quando modelos matemáticos são inexistentes ou difíceis de serem obtidos. Na prática, o conjunto de treinamento é obtido a partir de medições e a modelagem matemática é desconhecida por parte do especialista. Quando isso ocorre, o conjunto de dados de treinamento é obtido do mundo real através de medições, e como existem erros nessas medições, certamente haverá uma diferença entre o modelo matemático e o modelo neural devido a esses erros.

Assim, quando redes neurais são utilizadas em um processo de medição para determinar o valor de uma grandeza física, seu resultado pode ser metrologicamente contestado. Isso porque, quando se relata um resultado de medição é obrigatório que seja apresentada uma indicação quantitativa da qualidade desse resultado e, metrologicamente, essa

informação da qualidade é dada pela IM e sua probabilidade de abrangência. Sem essa indicação não é possível a comparação de resultados entre si ou com valores de referência fornecidos por especificações (BIPM, 2008a).

A incerteza da medição decorre da ação combinada de múltiplas fontes de erros (ALBERTAZZI, 2008; BIPM, 2008a). De modo amplo, a incerteza descreve a dúvida sobre os erros aleatórios e os erros sistemáticos não compensados em uma medição. No entanto, neste trabalho, não será utilizado o termo incerteza da medição para o valor da capacidade de refrigeração obtido na linha de produção. Como o modelo neural fornece uma inferência sobre o valor da capacidade de refrigeração, aqui será utilizado o termo incerteza da inferência (I-If), que descreverá, nesta tese de doutorado, a dúvida sobre o resultado apresentado na saída do modelo neural artificial.

Partindo-se do fato de que os erros de medição não compensados durante a formação do conjunto de treinamento afetam diretamente a aprendizagem de uma RNA e, conseqüentemente, o seu desempenho final, para expressar a I-If deve-se necessariamente considerá-los na avaliação dessa incerteza. No entanto, esses erros não são os únicos que devem ser investigados.

Muitas são as fontes de erros que podem contribuir para a I-If. Neste documento essas fontes serão divididas em dois grupos: erros decorrentes do processo de medição dos dados; erros decorrentes do processo de aprendizagem.

Em relação ao grupo dos dados de medição, tanto os erros aleatórios como sistemáticos estão presentes no resultado de uma medição e, conseqüentemente, ocasionam erros no processo de inferência. Porém, para os erros sistemáticos é possível que uma correção seja aplicada. Assim, o efeito desse erro pode ser minimizado e em algumas situações pode até mesmo ser considerado insignificante no processo de avaliação da IM (ALBERTAZZI, 2008). No entanto, quando não compensados, esses devem ser considerados como parte integrante da IM (BIPM, 2008a). Vale lembrar que as fontes de erros de medições estão presentes durante o treinamento e o uso do modelo neural.

Do ponto de vista deste trabalho, em relação ao processo de treinamento, três são as fontes de erros significativas que podem afetar o resultado da inferência na saída do modelo neural (PAPADOPOULOS, 2001; HAYKIN, 1999):

- processo de otimização – para o processo de minimização do erro do conjunto de treinamento, os valores iniciais dos pesos e bias são escolhidos aleatoriamente. Assim, para

um mesmo conjunto de treinamento, respostas distintas serão encontradas a cada processo de aprendizagem. Espera-se que essas respostas fiquem muito próximas umas das outras, ocasionando então um erro aleatório em torno do mínimo erro encontrado no treinamento;

- incompletude dos dados de treinamento – para o conjunto de treinamento nem todos os exemplos de entrada-saída possíveis estão disponíveis. Tal fato pode levar a uma interpolação errada por parte das redes neurais. Essa é uma característica sistemática, já que ocorrerá da mesma forma para redes treinadas com o mesmo conjunto de dados;
- arquitetura do modelo neural – a topologia de uma RNA pode ser configurada de diferentes maneiras, podendo conter mais ou menos camadas, assim como mais ou menos neurônios em cada camada, dependendo exclusivamente da escolha do especialista que conduz o experimento. Na literatura não existem regras definidas para essa escolha e, certamente, uma ou outra topologia poderá refletir melhor ou pior o fenômeno que se deseja modelar. No entanto, quando uma topologia é escolhida, pode-se dizer que um erro sistemático será gerado devido a essa escolha.

No contexto desta tese, a tabela 2 apresenta as fontes de erros que podem ser significativas em um projeto metrológico que envolve RNA, bem como o tipo de erro que cada fonte pode proporcionar¹⁶.

Em relação ao erro devido à arquitetura do modelo neural, esse pode ser tratado de modo análogo à inexatidão do modelo matemático que descreve uma medição, que também pode ser incompleto e apresentar um erro sistemático na medição de uma grandeza. Para este último erro não cabe na avaliação da IM como estipulado pelo GUM (BIPM, 2008a). Tal documento assume que o modelo tem o grau adequado à exatidão requerida na medição. Porém, o modelo da medição deve, sempre que factível, ser verificado através de padrões de referências e gráficos de controle que possam indicar se a medição está sob controle estatístico. Essas ações devem fazer parte do esforço de obtenção de

¹⁶ As medições utilizadas em um projeto envolvendo RNA devem estar livres de erros grosseiros, assim como no processo de avaliação da IM. Por esse motivo não fazem parte da avaliação da incerteza da inferência.

avaliações confiáveis da incerteza e o modelo da medição deve sempre ser revisto quando os dados observados indiquem que o modelo está incompleto. O GUM alerta ainda para o fato de que um experimento bem projetado é uma parte importante da arte da medição. Nesse sentido, não é possível incluir o erro devido à arquitetura do modelo neural na avaliação e expressão da I-If, cabendo somente o controle da estabilidade do modelo através de comparações com padrões, ou quando não houver padrões disponíveis, intercomparações com outros métodos (BIPM, 2008a).

TABELA 2: FONTES DE ERROS QUE PODEM SER SIGNIFICATIVAS EM UM PROJETO 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 dos dados de treinamento	não	sim
arquitetura do modelo neural	não	sim

A seguir, os itens 5.1 e 5.2 apresentam a análise de viabilidade de diferentes ferramentas encontradas na literatura para expressão da incerteza de resultados apresentados por redes neurais. O item 5.3 apresenta as limitações do método de Monte Carlo como ferramenta para avaliação de incerteza em modelos neurais, mesmo quando empregado nas fases de treinamento e uso das redes. Ficarão evidenciadas, nos itens 5.1, 5.2 e 5.3, as limitações de cada uma das ferramentas no contexto da obtenção de uma incerteza metrologicamente confiável. No item 6.4 será apresentada uma proposta de método para expressar a incerteza da inferência de modelos neurais artificiais condizente com os preceitos metrológicos de avaliação da incerteza de medição.

5.1 APLICAÇÃO DO GUM NO USO DE REDES NEURAIS ARTIFICIAIS TREINADAS

Uma rede neural, como as utilizadas neste trabalho, depois de treinada, é uma função matemática com parâmetros definidos, o que significa que mais nenhum conhecimento é adquirido durante seu uso. Assim, seus pesos, bias, e funções de transferência não sofrem mais modificações (HAYKIN, 1999).

O fato é que após o treinamento da rede, conhecendo-se os pesos, bias e funções de transferência de cada neurônio, pode-se expressar a saída em função de suas entradas. Assim, do ponto de vista metroológico da avaliação da IM, uma RNA pode ser tratada de modo análogo a um modelo matemático da medição. Desse modo, o método clássico, como descrito no GUM (BIPM, 2008a) e apresentado neste documento no item A), pode ser utilizado para propagar as incertezas das entradas para a saída de uma RNA.

Em seu trabalho, Gusman (2011) apresenta um exemplo do uso desse método para uma RNA genérica com 2 neurônios na camada de entrada, 2 neurônios na camada intermediária e 1 único neurônio na camada de saída, como mostrado na figura 16.




FIGURA 16: REDE NEURAL ARTIFICIAL GENÉRICA APRESENTADA POR GUSMAN (2011)

A função de saída para essa RNA é dada pela equação (21).

$$y = f(x_1, x_2) = \varphi\{b_3 + w_3 \cdot \varphi[b_1 + w_{11} \cdot x_1 + w_{21} \cdot x_2] + w_4 \cdot \varphi[b_2 + w_{12} \cdot x_1 + w_{22} \cdot x_2]\} \quad (21)$$

Onde:

- y saída da RNA;
- x_i entradas da RNA;
- φ função de transferência de cada neurônio;
- w_{ij} pesos associados a cada entrada dos neurônios da camada intermediária;
- w_k pesos associados a cada entrada do neurônio da camada de saída;
- b_i bias de cada neurônio.

Gusman (2011) mostra que, se no modelo matemático dado por (21), x_i representasse os valores das medições das grandezas de entrada e y representasse o valor da grandeza de saída, então para que se obter a IM de y , basta aplicar a lei de propagação das incertezas na função $f(x_1, x_2)$, como mostrado por (22), (23) e (24).

$$u(y) = \sqrt{\frac{\partial(x_1, x_2)}{\partial x_1}^2 \cdot u_{x_1}^2 + \frac{\partial(x_1, x_2)}{\partial x_2}^2 \cdot u_{x_2}^2} \quad (22)$$

Onde:

$$\frac{\partial(x_1, x_2)}{\partial x_1} = \varphi'(x_1) \cdot [w_3 \cdot \varphi'(x_1) \cdot w_{11} + w_4 \cdot \varphi'(x_1) \cdot w_{12}] \quad (23)$$

$$\frac{\partial(x_1, x_2)}{\partial x_2} = \varphi'(x_2) \cdot [w_3 \cdot \varphi'(x_2) \cdot w_{21} + w_4 \cdot \varphi'(x_2) \cdot w_{22}] \quad (24)$$

É possível verificar que, para a aplicação da lei de propagação das incertezas em RNA, é necessário que se empreguem funções de transferência deriváveis (φ'). Assim, conhecendo as incertezas padrão das entradas (u_{x_i}) e os pesos dos neurônios, pode-se conhecer a incerteza padrão da grandeza de saída. No entanto, para configurações com mui-

tas camadas intermediárias e muitos neurônios, a obtenção das derivadas parciais pode ser demasiadamente custosa (GUSMAN, 2011).

Este item mostrou que é possível obter um resultado quantitativo da dúvida proveniente das medições dos dados apresentados nas entradas de uma RNA após as redes treinadas. Porém, mesmo utilizando o método clássico para propagar as incertezas, a I-If na saída da RNA não é confiável em termos metrológicos. A simples aplicação desse método não é capaz de considerar os erros gerados por outras fontes como os erros das medições do conjunto de treinamento e os erros provenientes do processo de aprendizagem, como exemplificado na tabela 3.

TABELA 3: ERROS CONSIDERADOS PELO AVALIAÇÃO DA IM DOS DADOS DE ENTRADA DA RNA

	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 dos dados de treinamento	não se aplica	não considera

Como esse método não é suficientemente capaz de expressar de modo completo a I-If outros meios devem ser considerados do ponto de vista metrológico.

5.2 APLICAÇÃO DO MÉTODO *BOOTSTRAP* NO TREINAMENTO DE REDES NEURAS ARTIFICIAIS

O item 5.1 mostrou que o método para propagar as incertezas pode ser utilizado para fornecer um valor de incerteza na saída do modelo neural. No entanto, como exemplificado na tabela 3, a simples aplicação desse método considera somente uma pequena parte das fontes de erros que podem estar presentes em processos metrológicos envolvendo RNA.

Por outro lado, existem métodos tradicionais para estimar intervalos de confiança em redes neurais, como mostrado no item 3.4 (página

72). Entre eles será destacado nesta tese o método *bootstrap*, por ser uma técnica bastante popular na estimação de intervalos de confiança em redes neurais (BRABANTER, 2011), por utilizar um comitê de RNA, o que minimiza os erros devido ao processo de treinamento aumentando a robustez do modelo neural (AHMAD, 2002) e por ir ao encontro da solução proposta neste trabalho¹⁷.

O método *bootstrap* estabelece valores para os IC¹⁸ através de um comitê de RNA, onde os exemplos de treinamento são escolhidos aleatoriamente de um mesmo banco de dados. Para esse método, a reamostragem possibilita que cada rede, que compõe o comitê, apresente um resultado diferente. Isso ocorre, pois os exemplos utilizados no treinamento, para cada uma das k RNA, possuem n dados, os quais são obtidos a partir de um conjunto de N elementos. Como a reamostragem é feita aleatoriamente com reposição, certamente dentro de um conjunto de n elementos existirão alguns dados repetidos e outros que não aparecerão, formando assim k conjuntos de treinamentos diferentes. Espera-se então que essa escolha aleatória imprima no comitê a variabilidade dos dados contida na base de conhecimento de tamanho N . Vale lembrar que no processo de treinamento das RNA é comum que o conjunto inicial de pesos atribuídos a cada neurônio seja escolhido aleatoriamente e, assim, não há garantia de que o processo de otimização dos pesos atinja a mesma solução em cada treinamento. Esses fatos implicam que redes treinadas com os mesmos dados apresentem resultados distintos. A variabilidade desses resultados é então utilizada para estabelecer o IC e é capaz de considerar os erros aleatórios dos dados do conjunto de treinamento, os erros devido ao processo de otimização e aqueles devido a incompletude dos dados do conjunto de treinamento (ALLENDE, 2004; PAPADOPOULOS, 2001), como exemplificado pela tabela 4.

Como o método *bootstrap* não faz qualquer tratativa em relação aos dados que serão inseridos no modelo neural após a rede treinada, em termos metrológicos, ele não é capaz de considerar os erros dos dados durante o uso do modelo neural. Logo, em termos gerais, a reamostragem obtida pelo método *bootstrap* possibilita considerar somente os

¹⁷ Dentre os métodos apresentados para estimar IC em RNA, será dado destaque ao método *bootstrap*, que é utilizado neste trabalho, em conjunto com outra técnica, para elaborar um novo método capaz de expressar a I-If de modo mais confiável do ponto de vista metrológico.

¹⁸ Para os métodos tradicionais, encontrados na literatura, para expressar a dúvida a cerca do resultado de uma RNA, será utilizado o termo intervalo de confiança (IC) e não o termo incerteza da inferência (I-If), por essa ser a nomenclatura usualmente utilizada nos trabalhos que fazem uso desses métodos.

erros devido ao processo de aprendizagem e a variabilidade dos dados do conjunto de treinamento.

TABELA 4: ERROS CONSIDERADOS PELO MÉTODO *BOOTSTRAP*

	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 dos dados de treinamento	não se aplica	considera

Outro fato relevante sobre essa técnica utilizada para estimar IC, é que erros sistemáticos não compensados durante as medições não são considerados. Assim, quando esses erros forem significativos, o método *bootstrap* não será capaz de apresentar IC condizentes do ponto de vista metroológico. No entanto, a dúvida sobre cada uma das medições utilizadas na aprendizagem ainda existe e, metrologicamente, os erros sistemáticos não compensados encontram-se dentro dela. Vale lembrar, que os demais métodos apresentados no item 3.4, que são aqueles frequentemente citados na literatura especializada (PENZ, 2011), também não consideram esses erros sistemáticos não compensados em uma medição. Tais métodos focam exclusivamente na variabilidade dos dados do conjunto de treinamento para considerar os erros de medições.

No exemplo apresentado no apêndice E, é exposta uma situação onde os dados de medição utilizados no treinamento e no uso do modelo neural possuem erros sistemáticos não compensados e que são significativos. Para esse exemplo, o método *bootstrap* não apresentou IC capazes de considerar tais erros, fornecendo um resultado final incompatível com o que seria esperado do ponto de vista metroológico.

De modo semelhante, o apêndice E mostra que mesmo utilizando o método *bootstrap* e considerando as incertezas dos dados de medição presentes nas entradas do modelo neural, também não é possível considerar todas as fontes de erros que podem ser significativas na busca da I-If.

Metrologicamente, o meio para considerar os erros não compensados é através da IM. Porém, até o presente momento, não foi encontrada na literatura uma solução que estime I-If, em RNA, e empregue o conceito de avaliação da IM para considerar todas as fontes de erro que podem ser significativas. Tal constatação levou o autor a desenvolver meios para expressar o valor da incerteza da inferência e que seja metrologicamente mais confiável do que aqueles obtidos pelos métodos disponíveis na literatura.

5.3 APLICAÇÃO DO MÉTODO DE MONTE CARLO NO TREINAMENTO E USO DE REDES NEURAS ARTIFICIAIS

Assim como o método de propagação das incertezas, apresentado no item 5.1, também é possível aplicar o MMC, como apresentado no item B), para propagar as distribuições das entradas para a saída de uma RNA e, então, considerar as incertezas dos dados de medições durante o uso das redes neurais.

Trabalhos desenvolvidos por Colorado (2011) e Zou (2002), mesmo não citando o GUM (BIPM, 2008a) ou seu suplemento JCGM 101 (BIPM, 2008b), utilizam o MMC para propagar as distribuições das entradas para a saída durante o uso das RNA. Colorado (2011), por exemplo, mesmo não adotando o rigor metrológico imposto pelo GUM, busca estimar a dúvida na saída de uma RNA propagando as distribuições das IM nas entradas dessa rede. Para tal, ele aplica simulações pelo método de Monte Carlo durante o uso do modelo neural. Metrologicamente isso é possível, pois, como mostrado no item B), cada medição na entrada de uma RNA pode ser descrita através de uma $g_x(\xi)$ (onde, g_x representa as PDF relativas à IM com ξ variando de menos infinito até mais infinito). Desse modo, n valores podem ser simulados para as medições nas entradas e propagados através da RNA. Ao final serão obtidos n valores na saída, que, quando combinados, descrevem a propagação de todas as PDF que representam as IM presentes nas entradas da RNA.

A figura 17 mostra como esse processo ocorre. A cada iteração do MMC são gerados valores aleatórios nas entradas da RNA respeitando as PDF de cada IM e uma saída distinta é obtida. Ao final, essas saídas são agrupadas formando modelo discreto de PDF que, descreve em si, a dúvida devido às incertezas das medições dos dados de entrada. Por se tratar de um método numérico, diferentemente do método clássico, que é exclusivamente analítico, o MMC dispensa a obtenção das derivadas parciais em relação às medições nas entradas do modelo (BIPM, 2008b),

o que pode ser considerado uma vantagem quando se está utilizando RNA com elevados números de neurônios e de camadas intermediárias.

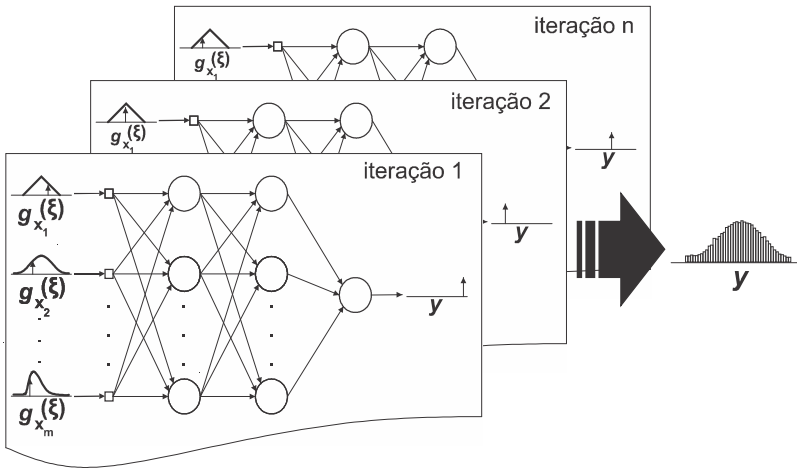


FIGURA 17: APLICAÇÃO DO MÉTODO DE MONTE CARLO PARA PROPAGAR AS PDF ATRAVÉS DE UMA REDE NEURAL

A propagação das distribuições, como apresentado na figura 17, considera somente os erros dos dados de medição nas entradas das RNA após o treinamento. Deste modo, assim como no método clássico, apresentado no item 5.1, não é possível considerar outras fontes de erros que podem influenciar no resultado da inferência, exatamente como apresentado na tabela 3.

Ocorre que, como colocado por Colorado (2011), o MMC considerou somente os dados de medições durante o uso da RNA já treinada. Porém, dados de medições também podem estar presentes no conjunto de treinamento. Deste modo, é necessário ampliar a aplicação desse método para que seja possível propagar as distribuições dos dados desse conjunto.

Para tal, foi tomado como orientação o documento JCGM 101 (BIPM, 2008b) para a propagação das distribuições pelo MMC e, como no método *bootstrap*, buscou-se considerar as fontes de erros de medição através de um comitê de redes neurais treinadas a partir de uma mesma base de dados.

Partiu-se do conceito metrológico de que o resultado final de uma medição é dado em termos probabilísticos (BIPM, 2008b). Assim, cada

medição presente no conjunto de treinamento pode ser descrita como: $g_x(\xi)$ ou $g_y(\xi)$, com $-\infty < \xi < +\infty$ (onde g_x e g_y são as PDF relativas a IM dos dados de entrada e saída, respectivamente, e ξ é a variável que descreve todos os valores possíveis). Esse fato pode então ser utilizado para constituir diferentes conjuntos de treinamento a partir da mesma base de conhecimento, sem que para isso seja feita uma reamostragem com reposição.

A lógica por traz da propagação das distribuições através do MMC é que, metrologicamente, cada valor gerado aleatoriamente é tão legítimo quanto aquele indicado pelo instrumento de medição (BIPM, 2008b). Seguindo essa mesma lógica, durante o treinamento de uma RNA, os dados de medições que compõem o conjunto de treinamento também podem ser escolhidos aleatoriamente a partir das PDF que representam suas respectivas IM. Desse modo, cada RNA treinada pode ser considerada tão legítima quanto uma que utilizou somente as indicações dos instrumentos de medição.

No entanto, considerar apenas as incertezas das medições presentes no conjunto de treinamento não é suficiente para obtenção de um valor metrologicamente condizente para a I-If. Para tal, é necessário que sejam consideradas também as incertezas presentes nas medições realizadas durante o uso do modelo neural.

O documento JCGM 101 (BIPM, 2008b) define que para cada dado de medição deve ser gerado um valor aleatório, que respeite a PDF da IM, a cada simulação pelo Método de Monte Carlo (SMMC)¹⁹. Assim, para obtenção de uma I-If que propague as distribuições, aplicando-se diretamente o MMC como apresentado no documento JCGM 101 (BIPM, 2008b), uma nova RNA deve ser treinada a cada SMMC. Isso ocorre porque o conjunto de treinamento possui dados oriundos de medições, logo, valores aleatórios também devem ser gerados para esses dados a cada nova SMMC.

Como em cada aprendizagem das redes os dados do conjunto de treinamento são alterados através da SMMC, as RNA terão variação entre si, o que ao final permite considerar a incerteza de cada dado de medição presente no conjunto de treinamento.

Após o treinamento de cada RNA, também deve ser realizada uma SMMC para cada dado de medição que é apresentado para a rede. As-

¹⁹ O termo Simulação pelo Método de Monte Carlo (SMMC) será utilizado neste documento para descrever uma iteração do processo de geração de dados aleatórios necessários para a propagação da IM.

sim, ao final, para k SMMC, k RNA serão treinadas e k conjuntos de dados de entrada serão gerados, obtendo-se k respostas distintas, como mostrado na figura 18. Deste modo, a resposta do modelo pode ser dada pela média aritmética simples das k respostas e, através da variabilidade dos dados, será possível expressar a I-If que vai considerar as incertezas de todos os dados oriundos de medições.

O apêndice E apresenta um experimento simulado, mantendo as mesmas condições do experimento realizado para o método *bootstrap*, onde foi possível comprovar que a proposta de uso do MMC, para propagar as distribuições no treinamento e uso do modelo neural, apresentou valores para a I-If metrologicamente mais condizentes.

Mesmo esse apêndice mostrando que a proposta é capaz de apresentar valores de I-If metrologicamente mais adequados que os métodos apresentados nos itens 5.1 e 5.2, uma quantidade elevada de SMMC pode ser exigida para que o erro amostral seja baixo na saída. O documento JCGM 101 (BIPM, 2008b) indica a execução de 10^5 a 10^6 SMMC para garantir 2 algarismos significativos no valor da IM. Nesse caso, seriam exigidos também 10^5 a 10^6 processos de aprendizagem de RNA, o que demandaria uma quantidade considerável de tempo computacional.

No apêndice E, foi aplicado o MMC para a propagação das distribuições no treinamento e no uso de uma rede capaz de indicar o valor da potência elétrica através de valores de tensão e corrente. O tempo para se gerar uma resposta na saída do modelo com 10^5 resultados distintos ficou próximo a 6 horas de processamento²⁰.

Mesmo sem mencionar as RNA em um processo de medição, o documento JCGM 101 (BIPM, 2008b) já alerta para o fato de que um milhão de SMMC pode levar a elevados tempos de processamento, principalmente para os casos onde o modelo matemático é complexo.

Nesse sentido, a utilização desta proposta não é economicamente viável para a aplicação no contexto deste trabalho. Porém, algumas alterações podem ser feitas para reduzir o tempo de processamento.

Um fato relevante em projetos que envolvem RNA é que as medições podem ser divididas em dois grupos: aquelas que compõem o conjunto de treinamento; aquelas que são apresentadas nas entradas da RNA após o treinamento, isto é, no uso do modelo neural artificial.

²⁰ Para tal foi utilizado um computador com as seguintes configurações: processador Intel Core i5, 8 Gbytes de memória RAM, sistema operacional Microsoft Windows 7 de 64 bits e o Matlab R2009a para o processamento das RNA.

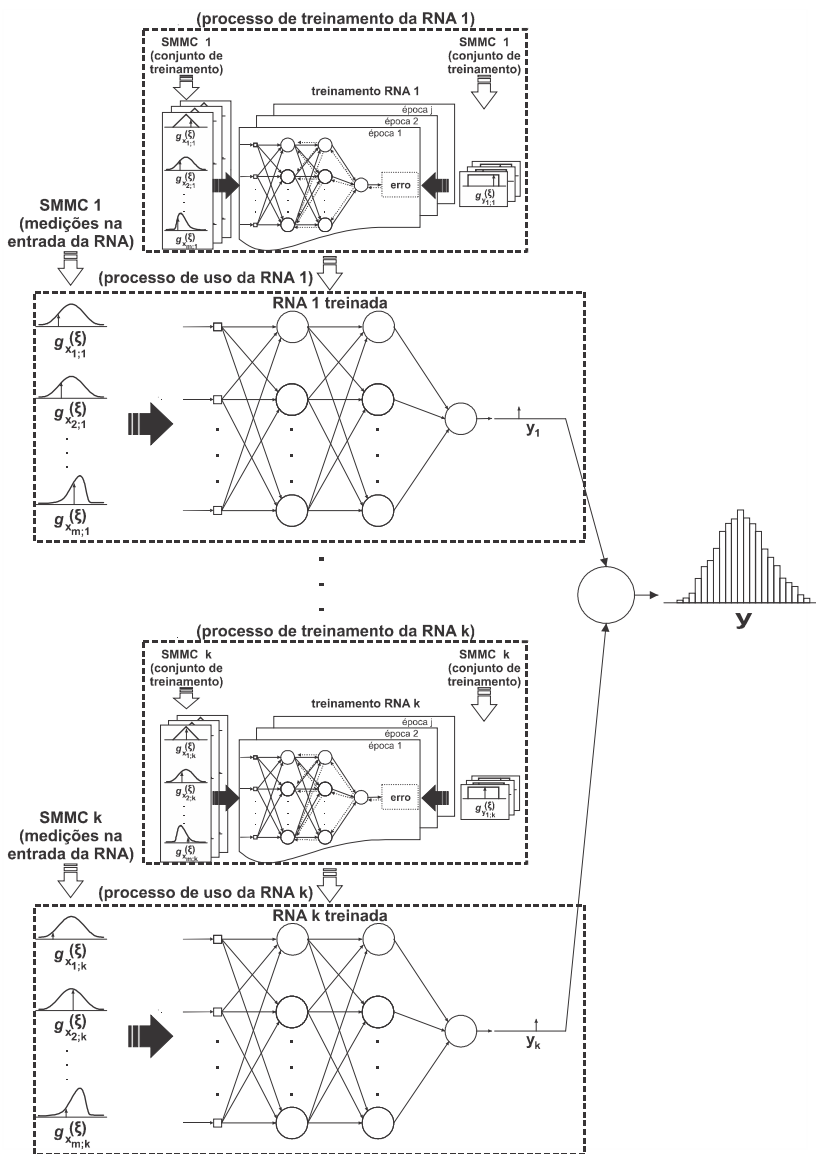


FIGURA 18: APLICAÇÃO DO MMC PARA PROPAGAÇÃO DAS PDF EM MODELOS NEURAIIS ARTIFICIAIS

As medições nesses dois grupos são empregadas em momentos distintos nas RNA. Para o conjunto de treinamento, as medições são realizadas anteriormente ao processo de aprendizagem, utilizadas para o treinamento e não variam depois que a rede é treinada. Já para o grupo das medições que são apresentadas à RNA após o treinamento, essas podem ocorrer a qualquer momento e cada vez que a rede é utilizada, um novo grupo de medidas é apresentado a ela.

Sabendo que as medições realizadas para compor o conjunto de treinamento não variam durante o uso do modelo neural, não existe a necessidade de se realizar SMMC para esse conjunto toda vez que o modelo neural for utilizado. Um único comitê, treinado uma única vez com a aplicação de SMMC^{T-21}, já basta para que sejam propagadas as distribuições dos dados do conjunto de treinamento. Essa abordagem é suficiente para eliminar o tempo despendido no treinamento das RNA durante o uso do modelo neural.

No entanto, mesmo que o treinamento seja realizado antecipadamente, se para cada RNA for feita uma única SMMC^U, quantidades iguais de redes e SMMC^U serão necessárias. Assim, para se obter uma resposta na saída do comitê com 10^5 valores, por exemplo, seriam necessárias 10^5 RNA treinadas através de SMMC^T e 10^5 SMMC^U. Cabe alertar, que o tempo para o processamento de 10^5 SMMC^U sobre uma quantidade tão grande de RNA pode ser substancialmente elevado. Durante o desenvolvimento dos trabalhos para a construção do apêndice E, esse tempo foi levantado para o exemplo ali apresentado. Para esse exemplo, aproximadamente 20 minutos foi o tempo necessário para processar uma SMMC^U em cada uma das 10^5 RNA previamente treinadas e assim obter 10^5 resultados para a potência elétrica.

A forma como foi utilizado o MMC para propagar as distribuições durante o treinamento e uso do modelo neural segue a lógica apresentada no documento JCGM 101 (BIPM, 2008b). Nela o número de SMMC deve ser igual para todas as grandezas medidas. Isso é definido assim, porque o referido documento trata todas as grandezas como entradas de um modelo matemático e todas as medições devem ser inseridas simultaneamente nele para se obter o resultado na saída.

²¹ A partir deste ponto do documento será feita uma diferenciação para o termo SMMC. Assim, SMMC será utilizado de modo genérico, SMMC^T será utilizado para referir-se às simulações realizadas no conjunto de treinamento durante o processo de aprendizagem das RNA e SMMC^U será utilizado para referir-se às simulações realizadas nos dados apresentados nas entradas das RNA com elas já treinadas durante o uso do modelo neural.

Porém, como para redes neurais as medições são empregadas em dois momentos distintos (treinamento e uso do modelo neural), essa situação, que não é prevista no documento JCGM 101 (BIPM, 2008b), pode ser utilizada na redução do tempo de processamento para a expressão da I-If através da técnica que será apresentada a partir deste ponto.

Propõe-se inicialmente que seja montado um comitê realizando n SMMC^T, como ilustrado na figura 19. Após o treinamento das redes espera-se que quando um único conjunto de entrada seja aplicado ao modelo neural, cada RNA forneça uma resposta distinta. Deste modo, quando essas respostas forem agrupadas, um modelo discreto de PDF será formado, como exemplificado pela figura 20. Essa PDF representará a incerteza do modelo neural quanto às contribuições das IM dos dados do conjunto de treinamento.

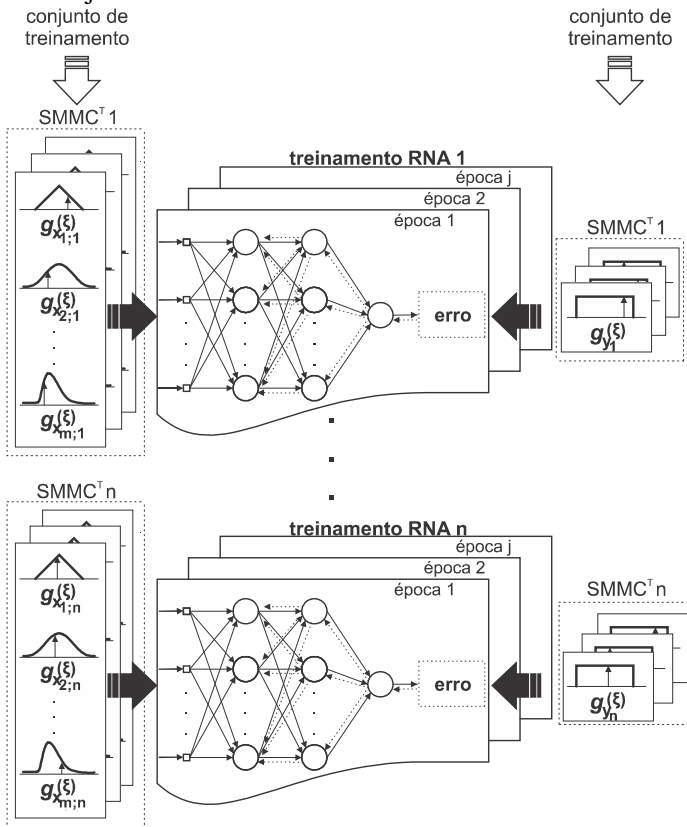


FIGURA 19: PROCESSO DE TREINAMENTO UTILIZANDO n SMMC^T




FIGURA 20: COMITÊ DE RNA TREINADOS A PARTIR DE SIMULAÇÕES DE MMC

A partir desse ponto, para contornar o problema de processamento, ao invés de gerar uma única $SMMC^U$ para cada RNA, é proposto que sejam realizadas k $SMMC^U$ e aplicadas diretamente ao comitê, que por sua vez é composto por n RNA.

A figura 21 exemplifica esse conceito. Por ela percebe-se que um comitê formado por n RNA, treinadas a partir de n $SMMC^T$, é utilizado k vezes, que é o número de simulações pelo MMC realizadas durante o uso do modelo neural artificial. Assim, para cada $SMMC^U$ o modelo apresenta n respostas distintas e quando combinadas formam um modelo discreto da PDF, com k vezes n respostas distintas, que representará a I-If na saída no modelo neural.

Desse modo, é possível aplicar o MMC para propagar as distribuições e obter uma saída com 10^6 resultados realizando 1000 $SMMC^U$ em um modelo neural constituído por 1000 RNA. Esse arranjo possibilita uma redução substancial do tempo de processamento, ao passo que mantém um número elevado de resultados na saída do modelo, o que em essência mantém um erro amostral baixo (BIPM, 2008b).

No apêndice E, para se obter uma resposta com 10^6 resultados distintos para a potência elétrica, foi utilizado um comitê composto por 1000 RNA e foram realizadas 1000 $SMMC^U$ para os valores de tensão e corrente apresentados nas entradas do modelo neural. Para esse experimento específico, o tempo de processamento ficou em aproximadamente 11 segundos, que é consideravelmente menor que as 6 horas que são

necessárias para obter 10^5 respostas distintas treinando uma RNA a cada SMMC ou os 20 minutos que são necessários para processar uma única SMMC^U para cada uma das 10^5 RNA treinadas previamente.

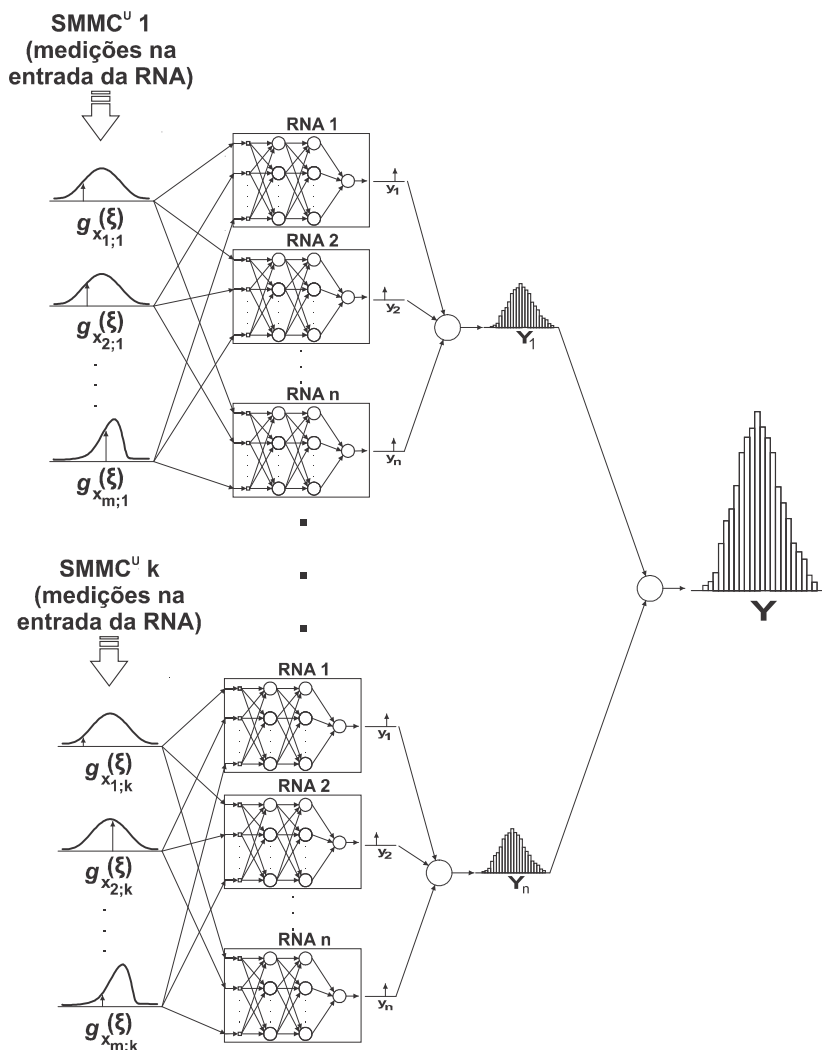


FIGURA 21: PROPOSTA PARA CONTORNAR O PROBLEMA DO TEMPO DE PROCESSAMENTO NA APLICAÇÃO DO MMC

No experimento com 1000 RNA e 1000 SMMC^U, as respostas obtidas tiveram variações mínimas em relação a aquelas apresentadas para a propagação das distribuições realizando-se 10^5 SMMC^T e 10^5 SMMC^U. No entanto, do ponto de vista metrológico, mesmo esta proposta se mostrando muito mais adequada do que os métodos apresentados nos itens 5.1 e 5.2, ainda assim não foi capaz de considerar todos os erros envolvidos em um processo de medição que faz uso de redes neurais. Isso pode ser percebido pelas respostas apresentadas no experimento do apêndice E, onde a I-If, apresentada pela propagação das distribuições dos dados de medição no treinamento e no uso do modelo neural, foi capaz de apresentar resultados aceitáveis para 90% dos casos. Mesmo sendo muito superior ao método *bootstrap*, que não apresentou resultados condizentes para nenhum caso, onde os erros sistemáticos eram significativos, ainda assim, em termos metrológicos seria desejável que o valor verdadeiro ficasse dentro dos limites da I-If em pelo menos 95% dos casos.

A tabela 5 apresenta quais erros são considerados quando o MMC é utilizado para propagar as distribuições no treinamento e uso do modelo neural. Essa proposta é capaz de considerar todos os erros provenientes das medições²², sejam eles do conjunto de treinamento ou no uso do modelo neural e é capaz de considerar os erros do processo de otimização. Esse último erro, que é de origem aleatória, é considerado pela formação do comitê de redes neurais, pois a cada novo treinamento essas variações são incorporadas a cada uma das RNA (PAPADOPOULOS, 2001). Porém, o uso do MMC para propagar as distribuições no treinamento e uso do modelo neural não é capaz de considerar a incompletude dos dados. Esse erro, que é de origem sistemática, é contemplado no método *bootstrap* pela reamostragem com reposição (PAPADOPOULOS, 2001), situação que não foi originalmente abordada na utilização do MMC para propagar as distribuições, pois, como colocado, não existe a amostragem com reposição dos dados de treinamento, mas sim uma simulação respeitando as PDF de cada incerteza dos dados de medição. Assim, todos os dados que compõem o conjunto de treinamento são utilizados no processo para formação do modelo neural artificial.

²² Nesse trabalho é admitido que todos os erros não compensados em uma medição são considerados na avaliação da IM.

TABELA 5: ERROS CONSIDERADOS PELA PROPAGAÇÃO DAS DISTRIBUIÇÕES NO TREINAMENTO E USO DO MODELO NEURAL

	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 dos dados de treinamento	não se aplica	não considera

Para contornar o problema da incompletude dos dados que formam o conjunto de treinamento, o método *bootstrap* pode ser integrado à proposta de propagar as distribuições no treinamento e uso do modelo neural, como demonstrado a seguir no item 5.4.

5.4 PROPOSTA DE MÉTODO PARA A EXPRESSÃO DA INCERTEZA DA INFERÊNCIA APRESENTADA POR MODELOS NEURAI

O item 5.3 mostrou que a aplicação do MMC para propagar as distribuições durante o treinamento e uso é factível. Tal método, que não foi encontrado similar na literatura, permite que as incertezas de todas as medições envolvidas sejam consideradas. Porém, além dos erros de medição, erros inerentes ao processo de aprendizagem das RNA também estão envolvidos e podem ser significativos na composição final do erro apresentado para a inferência do modelo neural.

Dentre as fontes de erros do processo de aprendizagem, o método apresentado no item 5.3 não é capaz de considerar a incompletude dos dados do conjunto de treinamento. Já o método *bootstrap* possibilita que essa incompletude seja considerada através da amostragem com reposição. Para contornar esse problema é proposto que seja aplicada a reamostragem *bootstrap* em conjunto com o MMC para propagar as distribuições no treinamento e uso do modelo neural.

A figura 22 ilustra como o método proposto nesta tese se desenvolve na fase de aprendizagem do comitê de RNA. Inicialmente, para

cada processo de aprendizagem é realizado uma $SMMC^T$ para os dados do conjunto de treinamento, sempre respeitando as PDF referentes às IM. Após, é realizada a amostragem aleatória com reposição, como definido no método *bootstrap*. Assim, a $SMMC^T$ realiza a propagação das distribuições do conjunto de treinamento, o que permite considerar os erros relativos às medições dos dados desse conjunto; a amostragem com reposição, assim como no método *bootstrap*, permite considerar o erro devido à incompletude dos dados do conjunto de treinamento; e a formação do comitê permite considerar os erros devido ao processo de otimização. Depois do comitê treinado, durante o seu uso devem ser realizadas as $SMMC^U$ para os dados de medições nas entradas, possibilitando considerar todas as fontes de erros significativas, como exemplificado na tabela 6.

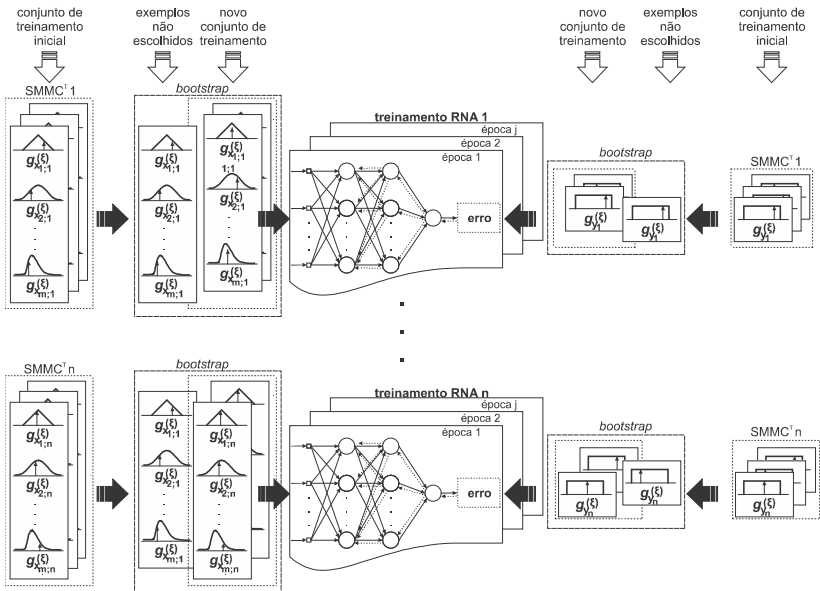


FIGURA 22: FASE DE TREINAMENTO DO MODELO NEURAL NO MÉTODO PARA A EXPRESSÃO DA INCERTEZA DA INFERÊNCIA

Como no item 5.3, para contornar o problema do tempo de processamento, é proposto que sejam treinadas n RNA e, para cada uma delas, sejam realizadas k $SMMC^U$ para propagar as distribuições durante o uso do modelo neural, possibilitando assim n vezes k resultados de inferên-

cia, onde a variabilidade encontrada será utilizada para expressar a Incerteza da Inferência (I-If).

TABELA 6: ERROS CONSIDERADOS PELO MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA

	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 dos dados de treinamento	não se aplica	considera

É importante destacar que nesta proposta, para cada dado obtido através de um processo de medição é necessário o conhecimento da IM e sua respectiva PDF.

Este capítulo apresentou uma proposta para expressar a I-If em modelos neurais artificiais que é capaz de considerar a incerteza dos dados oriundos de medições e das incertezas provenientes do processo de treinamento.

Em relação à expressão da I-If, pode-se concluir que:

- quando dados de medição são utilizados para formar um modelo neural, é imprescindível que as incertezas de medição sejam consideradas;
- é possível aplicar o método clássico e o método de propagação das distribuições para considerar as incertezas durante o uso do modelo neural, mas ainda assim isso não é suficiente para fornecer resultados metrologicamente adequados na saída do modelo neural;
- os métodos tradicionais para estimar intervalos de confiança, como a reamostragem *bootstrap*, não são capazes de

- considerar os erros sistemáticos não compensados das medições que formam o conjunto de treinamento;
- mesmo para situações nas quais os dados são contaminados exclusivamente com erros aleatórios, o método *bootstrap* pode apresentar intervalos de confiança inadequados do ponto de vista metrológico;
 - o método de Monte Carlo, como apresentado no suplemento do GUM (BIPM, 2008b), pode ser aplicado para propagar as distribuições referentes a todas as incertezas de medições, tanto no treinamento quanto no uso do modelo neural, porém, não é capaz de considerar os erros de treinamento, como a incompletude dos dados;
 - a reamostragem *bootstrap* pode ser integrada ao método de Monte Carlo a fim de estabelecer um novo método de avaliação de incerteza capaz de considerar todas as fontes de erro que podem ser significativas em um processo de medição que faz uso de RNA.

6 ESTUDO DE CASO

Este capítulo apresenta um estudo de caso com o intuito de comprovar que é possível realizar inferências do valor da capacidade de refrigeração de compressores herméticos através de um ensaio de capacidade de elevação da pressão. Como realizadas, as análises permitem a comparação entre os diferentes métodos apresentados no capítulo 5.

Este estudo de caso mostra ainda que a temperatura dos compressores ensaiados na linha de produção afeta significativamente o resultado do modelo neural, exigindo compensação. Meio para realizar tal compensação é apresentado.

Análises adicionais em relação ao tempo de processamento das informações no modelo neural artificial e da inferência em compressores com capacidade de refrigeração abaixo do esperado também fazem parte deste estudo de caso.

6.1 CONSIDERAÇÕES INICIAIS

Este estudo de caso foi realizado em uma das linhas de produção da empresa Whirlpool/Embraco e somente para os compressores projetados para trabalhar com fluido refrigerante R134a.

Os ensaios em laboratório foram realizados dentro das condições típicas de operação, definidas como $-23,3^{\circ}\text{C}$ e $+54,4^{\circ}\text{C}$ para as temperaturas de evaporação e condensação, respectivamente. Para essas medições da capacidade de refrigeração do compressor, 11 diferentes bancadas de ensaio foram utilizadas, sendo que cada compressor foi ensaiado uma única vez e utilizou somente uma dessas bancadas. O tempo médio dos ensaios realizados em laboratório foi de aproximadamente 4,5 horas por compressor.

Para os ensaios de capacidade de elevação da pressão foi utilizado o painel de teste presente na linha de produção escolhida para o estudo de caso, cujo conceito foi apresentado no item 4.2 deste trabalho. Deste modo, o painel foi utilizado tanto nas medições que compõe o conjunto de treinamento quanto naquelas utilizadas avaliação da proposta.

Testes de verificação da viabilidade da proposta foram realizados a partir de uma amostra de 12 peças, as quais foram retiradas do conjunto de 61 compressores utilizado na análise realizada no item 4.3. Além dos compressores de teste, também foram realizadas análises em um lote inteiro de peças produzidas, confrontando assim as medições para uma

amostra de teste em laboratório (TEL)²³ com os valores de inferências obtidos na linha.

Neste estudo de caso, para os compressores do conjunto de teste, espera-se que a inferência realizada junto à linha de produção apresente valores de capacidade de refrigeração próximos aos mostrados na tabela 7, os quais foram obtidos através de medições realizadas em laboratório. É importante destacar que essas medições realizadas em laboratório possuem IM da ordem de $\pm 3\%$ em relação ao valor indicado.

TABELA 7: CAPACIDADE DE REFRIGERAÇÃO PARA O CONJUNTO DE TESTE

Compressor	Capacidade de Refrigeração (W)
1	194,9
2	195,7
3	197,7
4	196,6
5	239,2
6	241,2
7	232,2
8	233,5
9	231,5
10	232,9
11	274,2
12	275,6

Através da mesma base de conhecimento, composta por 49 compressores para o conjunto de treinamento, foram realizadas análises nas seguintes situações:

- comitê treinado utilizando o método *bootstrap*;

²³ Devido à impossibilidade de se medir capacidade de refrigeração para todos os compressores pertencentes ao lote, os resultados para o teste em laboratório (TEL) foram obtidos de uma amostra de 5 compressores. O termo TEL será utilizado ao longo deste estudo de caso para representar essa amostra composta por 5 compressores.

- comitê treinado utilizando o MMC para propagar as distribuições no treinamento e no uso do modelo neural;
- comitê treinado a partir da proposta apresentada no item 5.4 para expressar a I-If.

Também faz parte deste estudo de caso: particularidades na aplicação da proposta com a variação da temperatura de ensaio dos compressores na linha de produção; análise do tempo de processamento das informações; tratativa de dados de compressores defeituosos.

Para todas as análises, as RNA foram treinadas com a mesma topologia apresentada na tabela 8. Todos os treinamentos foram do tipo supervisionado; utilizaram o algoritmo de otimização Levenberg-Marquardt para atualização dos pesos e bias das redes; a função de erro avaliada no treinamento foi a soma quadrática dos erros. O *toolbox* de redes neurais do *software* de programação matricial Matlab foi utilizado durante todas as etapas do processo (MATHWORKS, 2007). A padronização da topologia da rede, bem como dos parâmetros de treinamento, permitiram a comparação entre as diferentes situações apresentadas nesse estudo de caso.

TABELA 8: ARQUITETURA DAS RNA

<i>Camada</i>	<i>Número de neurônios</i>	<i>Função de transferência</i>
Entrada	4	-
1ª escondida	10	Tangente hiperbólica
2ª escondida	10	Tangente hiperbólica
3ª escondida	10	Tangente hiperbólica
Saída	1	Tangente hiperbólica

A escolha do algoritmo Levenberg-Marquardt para o processo de otimização dos pesos e bias se deu por ele mostrar velocidade de treinamento muito superior ao algoritmo *back-propagation*. Como quantidades significativas de RNA foram treinadas para a se chegar a um modelo neural artificial adequado aos objetivos propostos nesta tese, a maior velocidade possibilitou versatilidade no desenvolvimento dos trabalhos. Porém, cabe aqui ressaltar, que análises experimentais foram realizadas e indicaram que o uso de um ou outro algoritmo não possui influência significativa no resultado final. Dentro dessas análises experimentais, que extrapolaram em muito os dados apresentados neste capítulo, diferentes configurações de redes neurais também foram utilizadas,

sendo que a apresentada na tabela 8 foi a que alcançou os melhores resultados em relação aos compressores de teste.

A utilização da função de transferência sigmoide, do tipo tangente hiperbólica, se deu por essa figurar entre as mais utilizadas em aplicações de RNA (GOMES, 2008), por permitir um balanceamento adequado entre o comportamento linear e não linear, por ser diferenciável em toda sua extensão e também por ser uma função anti-simétrica, característica que permite maior velocidade no processo de otimização através do algoritmo Levenberg-Marquardt (COPPIN, 2012; HAYKIN, 1999). Mesmo assim, outras funções de transferência foram testadas em conjunto e isoladamente. Ao final, a função tangente hiperbólica foi a que apresentou os melhores resultados quando utilizada em todos os neurônios.

Para aprimorar o processo de treinamento, os compressores de teste, junto com os compressores não selecionados pela reamostragem *bootstrap*, formaram o conjunto de validação cruzada²⁴, o que possibilitou uma aprendizagem supervisionada para todas as RNA, minimizando assim a probabilidade de *overfitting* (PAPADOPOULOS, 2001).

É importante destacar que, mesmo os dados das medições sendo essenciais na modelagem neural, a teoria de representação do conhecimento define dois tipos de informação pertinentes para o treinamento de uma RNA (HAYKIN, 1999):

- observações – obtidas por meios de medições;
- informação prévia – fatos sobre o que é conhecido.

A incorporação desse segundo tipo de informação pode melhorar significativamente o processo de aprendizagem e a generalização das RNA, principalmente quando se dispõe de poucos exemplos no conjunto de treinamento. Porém, não existem regras definidas de como realizar tal tarefa (HAYKIN, 1999).

Neste trabalho, o longo tempo despendido para se realizar um único ensaio em laboratório, aliado à grande dificuldade de realização de testes junto à linha de produção, resultou em uma quantidade limitada

²⁴ O processo de validação cruzada, ou validação *on-line*, consiste num artifício, utilizado durante o processo de treinamento das redes, que visa minimizar a tendência de memorização (*overfitting*) dos padrões de treinamento, o que acarretaria perda da capacidade de generalização em regiões onde o conjunto de treinamento é bem definido. Desse modo, durante o treinamento, o erro médio quadrático para o conjunto de treinamento é comparado com o obtido para o conjunto de validação cruzada. Se o último apresenta tendência de aumento, enquanto o primeiro diminui, significa que o treinamento tende à memorização e, então, o processo de ajuste dos parâmetros da rede deve ser finalizado. Assume-se, então, como rede final, aquela imediatamente anterior a essa tendência (PENZ, 2011).

de compressores utilizados como exemplos no conjunto de treinamento. Assim, informação prévia da classe de projeto²⁵ do compressor foi integrada às informações da capacidade de elevação e da temperatura para formarem uma quarta entrada na RNA. Essa nova entrada consiste no resultado do logaritmo do produto dessas três informações, como definido pela equação (25).

$$\text{entrada} = \log(\text{classe} \cdot \text{capacidade_elevação} \cdot \text{temperatura}) \quad (25)$$

Projetos envolvendo RNA geralmente produzem respostas satisfatórias através de um estudo experimental exaustivo, sendo o projetista parte essencial ciclo de aprendizagem (HAYKIN, 1999). Nesse sentido, uma extensa experimentação foi realizada para encontrar o melhor modo de incorporar essa informação prévia e contornar a quantidade limitada de exemplos no conjunto de treinamento. Ao final, a introdução do dado da classe do compressor permitiu que o modelo neural apresentasse respostas melhores e a junção desse valor com a capacidade de elevação possibilitou que esta última informação não perdesse significância devido à introdução dessa informação prévia da classe do compressor. A introdução do valor da temperatura busca compensar o efeito da mesma sobre o valor da capacidade de elevação da pressão. O uso do logaritmo se dá, pois, a classe do compressor é diretamente proporcional à capacidade de elevação da pressão, o que torna esse produto uma função não linear. Assim, buscou-se deixar a função mais linear para minimizar o custo de aprendizagem da rede neural artificial. Outras formas de linearização dessa função podem ser utilizadas, como a raiz cúbica do produto desses três fatores, por exemplo. Neste trabalho optou-se por uma que se mostrou adequada para a aplicação, mas essas outras formas devem ser investigadas futuramente.

O fato é que existem diferentes de modos para incorporar informações prévias em um projeto utilizando RNA (HAYKIN, 1999). Este documento adotou um que se mostrou experimentalmente adequado. Porém, vale lembrar, que o aumento do número de exemplos pode minimizar o efeito da informação prévia como colocado neste trabalho, podendo inclusive ficar insignificante caso um número grande de com-

²⁵ Quando projetado, um modelo de compressor é classificado por sua provável capacidade de refrigeração em btu. No entanto, o valor nominal definido para o modelo é declarado somente após ensaios realizados nas bancadas de desempenho, podendo então haver pequenas diferenças entre o valor declarado para a classe do compressor e seu valor nominal.

pressores com capacidades de refrigeração bem distintas venham a ser incluídos no conjunto de treinamento.

Definidas as condicionantes para a realização do estudo de caso, pode-se então iniciar a explanação das análises.

6.2 MODELO NEURAL ARTIFICIAL TREINADO A PARTIR DO MÉTODO *BOOTSTRAP*

Optou-se pelo método *bootstrap* para a formação do modelo neural artificial nesta etapa, por ele ser um método tradicionalmente utilizado para a estimação de intervalos de confiança em aplicações de RNA e por apresentar particularidades com a proposta para expressar a I-If, o que permite uma comparação adequada entre os resultados encontrados.

Por se tratar de um método centrado no estabelecimento de um comitê de redes neurais artificiais, também é possível analisar o comportamento da diferença²⁶ à medida que mais uma rede é inserida no mesmo. Para essa análise foram treinadas 1000 RNA, onde foi possível variar o número de redes no comitê. Após o treinamento, foi realizada uma comparação entre os resultados obtidos na linha de produção com aqueles obtidos em laboratório (tabela 7 – página 114), e assim pode ser apresentada a diferença encontrada para o modelo neural.

Essa análise permitiu a construção da tabela 9, a qual mostra que individualmente uma RNA pode fornecer resultados com diferenças da ordem de até 7% em relação ao valor obtido através das bancadas de desempenho. No entanto, quando os resultados individuais são combinados em um comitê, na qual a resposta é a média aritmética simples das saídas, existe a tendência de queda dessa diferença. É possível verificar que para 1000 RNA obteve-se diferença máxima de 4,3% entre os valores encontrados na linha e em laboratório.

A figura 23 apresenta de modo gráfico a evolução da diferença percentual média para o conjunto dos 12 compressores de teste à medida que mais uma RNA é inserida no comitê. Nele é possível observar que a diferença, entre os valores obtidos em laboratório e linha, diminui com o aumento de redes, parecendo chegar à estabilidade em comitês com aproximadamente 60 RNA.

²⁶ A expressão diferença ou diferença%, neste capítulo, refere-se à diferença obtida entre os valores medidos em laboratório, os quais servem como referência para avaliar a proposta, e os valores inferidos na linha de produção, obtidos utilizando-se a bancada de capacidade de elevação da pressão e o modelo neural. Esse termo será utilizado ao longo do texto e nas tabelas é utilizada a abreviação – difer. %.

Estudos anteriores apresentados por Penz (2011) indicam que a partir de 30 RNA em um comitê, muito esforço pode ser despendido para o treinamento de mais redes, ao passo que pouco se obtém na diminuição do erro. A análise feita aqui corrobora com essa indicação, pois, com a inserção das primeiras 30 RNA no comitê, a diferença média caiu de 2,59% para 1,42%, ao passo que a inserção de mais 30 redes, para a formação de um novo comitê com 60 RNA, a diferença média que era de 1,42% foi reduzida para 1,33%. Essa análise permite supor que uma solução baseada no uso de um comitê, o qual tenha quantidade suficiente de RNA, pode apresentar resultados melhores do que uma solução centrada em uma única RNA.

TABELA 9: RESPOSTA DO MODELO NEURAL E A DIFERENÇA PERCENTUAL EM RELAÇÃO AOS RESULTADOS DE LABORATÓRIO

compressor	01 RNA (W)	difer %	comitê 03 RNA (W)	difer. %	comitê 30 RNA (W)	difer. %	comitê 100 RNA (W)	difer %	comitê 1000 RNA (W)	difer %
1	207,8	6,6	200,9	3,1	198,2	1,7	197,6	1,4	197,7	1,4
2	205,0	4,8	202,8	3,6	200,3	2,3	200,7	2,5	200,6	2,5
3	198,0	0,2	199,2	0,8	197,5	-0,1	197,5	-0,1	197,5	-0,1
4	196,9	0,2	196,9	0,2	198,7	1,1	198,6	1,0	198,7	1,1
5	237,8	-0,6	236,8	-1,0	235,9	-1,3	237,2	-0,8	237,9	-0,6
6	228,3	-5,4	231,3	-4,1	230,5	-4,5	231,1	-4,2	231,0	-4,3
7	230,1	-0,9	232,9	0,3	232,6	0,2	233,3	0,5	233,4	0,5
8	250,6	7,3	241,1	3,3	241,4	3,4	241,8	3,6	241,3	3,3
9	229,1	-1,0	232,1	0,3	231,8	0,1	232,4	0,4	232,4	0,4
10	234,0	0,5	234,1	0,5	233,5	0,3	233,8	0,4	234,2	0,5
11	274,9	0,3	273,4	-0,3	271,7	-0,9	272,3	-0,7	272,7	-0,5
12	284,6	3,3	287,3	4,3	278,7	1,1	276,8	0,4	277,0	0,5




FIGURA 23: EVOLUÇÃO DA DIFERENÇA A MEDIDA QUE MAIS RNA SÃO INSERIDAS NO COMITÊ

Outra análise indicada para verificar se um modelo está respondendo adequadamente é a da correlação linear. Assim, a correlação entre os valores obtidos pela média das RNA e os valores esperado deve ser linear e o coeficiente de Pearson deve ser próximo de 1, indicando assim um alto grau de correlação linear (GAYESKI, 2010; WATANABE, 2009; GHOBADIAN, 2009; ARCAKLIOĞLU, 2004; SWIDER, 2001; KIM, 1995). A análise estatística aponta um coeficiente de 0,958 para uma única rede e de 0,981, 0,987, 0,988 e 0,988, para os comitês com 3, 30, 100 e 1000 RNA, respectivamente. Isso é um bom indicativo de que as inferências realizadas pelas redes estão apresentando resultados adequados.

É importante lembrar, que os resultados obtidos em laboratório são medições e como tal apresentam dúvidas em relação ao valor verdadeiro da grandeza²⁷, as quais são expressas através da IM. Os ensaios realizados em laboratório para determinar o valor da capacidade de refrigeração apresentam incertezas da ordem de $\pm 3\%$ em relação ao valor medido. Assim, a simples análise da diferença não fornece a completa dimensão dos resultados apresentados para este estudo de caso. Nesse sentido, um comparativo dos valores obtidos em laboratório, incluindo suas respectivas IM, com os valores obtidos junto à linha de produção, seguido dos respectivos IC, torna-se necessário.

²⁷ O valor verdadeiro de uma grandeza é considerado único e, na prática, impossível de ser conhecido (BIPM, 2008c).

A tabela 10 apresenta os resultados das capacidades de refrigeração fornecidos pelo processo de inferência, obtidas através de um modelo com 1000 RNA treinadas pelo método *bootstrap*, junto com seus respectivos IC. Já a figura 24 apresenta o comparativo entre os resultados obtidos em laboratório e linha, incluindo as IM e os IC²⁸, respectivamente. Nessa figura, é possível verificar que, com exceção dos compressores 6 e 8, todas as outras inferências apresentaram indicações dentro da faixa de IM atribuída para os resultados de laboratório. No entanto, se considerarmos o IC atribuídos para estes dois compressores, não é possível indicar esses resultados como errados ou afirmar que o modelo neural esteja apresentando valores não condizentes. Na verdade, a análise dos resultados obtidos até este ponto, indica que o processo de inferência está fornecendo valores adequados para a capacidade de refrigeração.

TABELA 10: RESULTADO DO PROCESSO DE INFERÊNCIA OBTIDO A PARTIR DO MODELO NEURAL TREINADO PELO MÉTODO *BOOTSTRAP*

compressor	inferência (W)	IC (W)	IC %	difer. %
1	197,7	± 4,4	± 2,2	+ 1,4
2	200,6	± 4,9	± 2,4	+ 2,5
3	197,5	± 2,9	± 1,5	- 0,1
4	198,7	± 4,8	± 2,4	+ 1,1
5	237,9	± 7,8	± 3,3	- 0,6
6	231,0	± 6,8	± 2,9	- 4,3
7	233,4	± 4,9	± 2,1	+ 0,5
8	241,3	± 5,9	± 2,4	+ 3,3
9	232,4	± 4,8	± 2,1	+ 0,4
10	234,2	± 6,2	± 2,6	+ 0,5
11	272,7	± 8,5	± 3,1	- 0,5
12	277,0	± 13	± 4,7	+ 0,5

²⁸ Tanto a IM quanto o IC são estimados para um nível de confiança de 95%. Para a definição do IC foi utilizado o comitê com 10³ RNA.




FIGURA 24: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO

Neste ponto do documento é importante ressaltar, que mesmo os IC apresentando uma região de dúvida em relação aos resultados obtidos nas saídas das RNA, eles não representam a IM na saída do modelo neural. Esse processo de estimação de IC ateu-se somente às variações adquiridas pelo processo de aprendizagem e àquelas contidas no conjunto de treinamento. Em grande parte, estas variações são devidas aos erros aleatórios provenientes dos diferentes processos de medição envolvidos na coleta dos dados, incluindo o processo de medição da capacidade de refrigeração em laboratório e da capacidade de elevação da pressão junto à linha de produção. Por esse motivo, pode ser dito que mesmo de modo incompleto, o método *bootstrap* reflete uma parcela da dúvida proveniente do processo de medição dos dados de treinamento. No entanto, a IM não fica resumida a consideração da variabilidade dos valores medidos e é correto afirmar que a avaliação por outros meios²⁹ é tão relevante quanto à consideração da variabilidade dos dados, principalmente quando essa é obtida de um número consideravelmente pequeno de medições (BIPM, 2008a).

²⁹ O Guia para a Expressão da Incerteza de Medição (GUM) define dois modos para se avaliar as incertezas padrão: o primeiro através da análise estatística de uma série de observações; segundo através de outros meios, os quais podem incluir: dados de medições prévias, experiência ou o conhecimento geral do comportamento e propriedades dos instrumentos, especificações dos fabricantes, incertezas de referências extraídas de manuais, entre outros (BIPM, 2008a).

Terminada a análise feita com os 12 compressores de teste, uma análise adicional foi realizada durante a produção de um lote inteiro de compressores. Os resultados da inferência do valor da capacidade de refrigeração, obtidos através dos ensaios na linha para esse lote composto por 2383 compressores, foram comparados com a amostra de TEL.

Devido à impossibilidade de se realizar ensaios em laboratório para todos os compressores produzidos no lote, os resultados foram comparados em relação à média, à diferença percentual³⁰ e o desvio padrão, tanto para os resultados de TEL quanto para os resultados de inferência obtidos na linha de produção.

Como está sendo utilizada uma amostra para TEL, é necessário estimar o intervalo de confiança para a média da população de compressores do lote. Através da equação (26) é possível estimar o intervalo de confiança para a capacidade de refrigeração média desse lote. Essa equação é utilizada quando não se tem conhecimento do desvio padrão populacional e parte do princípio de que a população é normalmente distribuída. Por tanto, é necessário estimar o desvio padrão, que é obtido pela equação (27) através da mesma amostra utilizada para a obtenção da média.

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

Onde:

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

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

³⁰ Neste documento, a diferença percentual é dada em relação aos resultados obtidos em laboratório, e por vezes são apresentadas em módulo para facilitar o entendimento.

Onde:

s	desvio padrão estimado para a amostra;
n	tamanho da amostra;
x_i	valor da amostra i ;
\bar{x}	média da amostra de tamanho n .

Como a incerteza da medição da capacidade de refrigeração para cada compressor ensaiado na amostra de TEL é da ordem de $\pm 3\%$ e como são utilizadas poucas amostras para a obtenção da média, essa IM deve ser considerada na obtenção do IC para a média populacional. Para tal, foi utilizado o MMC com 10^5 SMMC.

A tabela 11 apresenta os valores médios, diferenças e desvios padrões, o IC para a média populacional ficou em $\pm 3,6\%$ em relação à média do TEL. Essa tabela coloca lado a lado os resultados obtidos através de diferentes quantidades de RNA na composição do comitê, com aqueles obtidos para a amostra do TEL. Os IC³¹ são apresentados com um nível de confiança de 95%.

Do mesmo modo que na análise feita para os 12 compressores de teste, a utilização de um número maior que 30 RNA se mostrou adequada para a composição do comitê. A figura 25 apresenta como se deu a evolução da diferença percentual para a inferência média dos 2383 compressores assim que mais uma RNA é inserida no comitê. Nela também é possível visualizar a evolução do desvio padrão dos resultados medidos na linha. Essa figura reafirma a vantagem da utilização de um comitê ao invés da utilização de uma simples RNA neste trabalho, pois à medida que mais redes são inseridas no comitê menor é a diferença encontrada.

³¹ O processamento, através do modelo neural, dos resultados médios encontrados no ensaio na linha de produção resultou no intervalo de confiança para a média das inferências.

TABELA 11: COMPARATIVO ENTRE OS RESULTADOS DO TEL E OBTIDOS ATRAVÉS DOS COMITÊS

Comparativo dos resultados da capacidade de refrigeração para o lote			
média dos resultados de TEL (W)	resultado 01 RNA (W)	resultado 30 RNA (W)	resultado 1000 RNA (W)
235,7	228,5	231,4	231,9
	difer. %	difer. %	difer. %
	-3,0	-1,8	-1,6
IC %		IC %	IC %
±3,6		±3,5	±3,6
desvio padrão %	desvio padrão %	desvio padrão %	desvio padrão %
0,9	3,2	1,3	1,3




FIGURA 25: EVOLUÇÃO DA DIFERENÇA E DESVIO PADRÃO PARA O LOTE

Pela análise da diferença pode-se concluir que um número maior que 60 RNA já seria suficiente para se obter um modelo adequado quando o método *bootstrap* é utilizado. No entanto, a figura 25 também apresenta o comportamento do desvio padrão entre os resultados obtidos para cada um dos compressores que compõem o lote. Por esse gráfico é possível perceber que um número maior de RNA pode ser necessário para se chegar à estabilidade, tanto na diferença quanto na variabilidade entre as inferências. Por tal motivo, a partir deste ponto do documento, as análises, tanto para o método *bootstrap* quanto para outros, se darão com comitês compostos por 1000 RNA, salvo quando o número de RNA for especificado.

A simples análise dos resultados médios, apresentados até este ponto, mostrou que é possível realizar inferências sobre o valor da capacidade de refrigeração na linha de produção e de modo satisfatório. Porém, quando os resultados individuais, obtidos para cada compressor do lote, são confrontados com as respectivas temperaturas medidas no momento do ensaio realizado na linha de produção, é possível observar que o modelo neural não responde como o esperado para todas as peças. Pela figura 26, nota-se que compressores ensaiados com temperaturas mais baixas sofrem forte influência dessa grandeza. Isso se deve ao fato de que os dados coletados para o treinamento tinham pouca variação de temperatura entre si, sendo que a temperatura média é de 38°C. Assim, compressores ensaiados com temperaturas mais baixas que 35°C não foram utilizados como exemplos no conjunto de treinamento.

O fato é que uma rede neural artificial, como as utilizadas nesta tese, tem capacidade de modelar fenômenos físicos ajustando os pesos e bias de acordo com exemplos apresentados durante a fase de treinamento. Assim, o modelo neural gerado no final pode apresentar bom desempenho interpolando os valores dentro dos limites estabelecidos pelos dados do conjunto de treinamento. Porém, quando os valores apresentados nas entradas do modelo neural extrapolam esses limites, os resultados podem não ser condizentes (HAYKIN, 1999). Nesse sentido, compressores ensaiados com temperaturas abaixo dos 35°C encontram-se nessa região de extrapolação e, como mostrado, não estão apresentando resultados de inferência adequados.




FIGURA 26: GRÁFICOS DOS RESULTADOS APRESENTADOS PELO COMITÊ COM 10^3 RNA E DA TEMPERATURA DO COMPRESSOR NO MOMENTO DO ENSAIO

Normalmente, os compressores chegam ao final da linha de produção com temperaturas que ficam perto dos 40°C . No entanto, devido a paradas na linha de produção essa temperatura pode cair significativamente. Para o lote, 10% dos compressores foram ensaiados na linha com temperaturas abaixo dos 35°C . Eliminando essas peças da análise, chega-se a um resultado mais próximo da média apresentada pelo TEL, como pode ser visto na tabela 12.

Estatisticamente, uma amostra com 90 % de uma população com 2383 compressores, apresentará resultados com um erro amostral muito baixo em relação à média da população. Assim, a retirada de 10% desses compressores não é significativa e apresentará um resultado mais próximo em relação à média da população de compressores desse lote.

TABELA 12: COMPARATIVO ENTRE O RESULTADOS DO TEL E DO MODELO NEURAL PARA COMPRESSORES ENSAIADOS COM TEMPERATURAS ACIMA DE 35°C

Comparativo para resultados obtidos com temperaturas acima de 35°C					
média dos resultados do lote de TEL (W)	235,7	média dos resultados do comitê com 10^3 RNA (W)	232,7	difer. %	-1,3
IC %	$\pm 3,6$	IC %	$\pm 1,5$		
desvio padrão %	0,9	desvio padrão %	0,5		

A figura 27 apresenta dois gráficos; o superior com as respostas para todos os compressores do lote, e o inferior com as respostas somente para os compressores ensaiados com temperaturas superiores a 35°C. Em ambos os gráficos existem 3 linhas de referência, sendo a linha central o resultado médio do TEL e as outras duas os valores de 3 vezes o desvio padrão em relação a essa média, tanto para mais quanto para menos. Através desses gráficos, é possível visualizar que, para o segundo caso, as respostas ficam mais próximas daquilo que seria esperado.




FIGURA 27: GRÁFICOS DOS RESULTADOS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE

Nessa parte do estudo de caso, mesmo a análise não podendo ser realizada em 100% dos compressores produzidos, ainda assim um ganho significativo é alcançado quando comparado com o método atual, onde o resultado da capacidade de refrigeração para a média de um lote é obtido de uma pequena amostra e pode levar dias para ser apresentado.

A aplicação do método exposto neste item vale para o reconhecimento de que é possível realizar inferências do valor de capacidade de refrigeração utilizando a capacidade de elevação da pressão. Porém, do modo como foi apresentado, uma lacuna metrológica é deixada, pois o método *bootstrap* considera, para a formação do IC, somente as fontes

de erros apresentadas pela tabela 13. Nesse sentido, a análise a seguir aplica o MMC para propagar as distribuições referentes às incertezas dos dados oriundos das medições realizadas em laboratório e linha durante o treinamento e uso do modelo neural.

TABELA 13: FONTES DE ERROS CONSIDERADAS NA APLICAÇÃO COM MÉTODO *BOOTSTRAP*

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
capacidade elevação (mbar/s)	considera	não considera
potência elétrica (W)	considera	não considera
temperatura do compressor ($^{\circ}\text{C}$)	considera	não considera
capacidade de refrigeração (W)	considera	não considera
uso da RNA		
capacidade elevação (mbar/s)	não considera	não considera
potência elétrica (W)	não considera	não considera
temperatura do compressor ($^{\circ}\text{C}$)	não considera	não considera
aprendizagem		
processo de otimização	considera	não se aplica
incompletude dos dados de treinamento	não se aplica	considera

6.3 MODELO NEURAL ARTIFICIAL TREINADO A PARTIR DO MÉTODO DE MONTE CARLO PARA PROPAGAR AS DISTRIBUIÇÕES

Neste item, os mesmos 49 compressores utilizados no item anterior formaram o conjunto de treinamento. Porém, aqui não foi utilizado o método *bootstrap* para considerar a variabilidade dos dados e formar o IC na saída do comitê. Esta análise utilizou o MMC, como apresentado no item 5.3, para propagar as distribuições durante o treinamento e uso do modelo neural artificial. Essa aplicação permite verificar o comportamento da incerteza em torno da inferência quando um comitê é forma-

do somente com a propagação das distribuições e sem o uso da reamostragem *bootstrap*.

Para essa análise é necessário que todas as incertezas das medições sejam conhecidas, tanto para as medições do conjunto de treinamento quanto aquelas presentes durante o uso do modelo neural artificial. Neste estudo de caso, as IM são apresentadas no apêndice F. Essas incertezas foram utilizadas ao longo deste capítulo para estimar a I-If.

Diferente do método *bootstrap*, que exige a reamostragem com repetição, aqui, os 49 compressores foram utilizados juntos no processo de aprendizagem. Assim, a geração aleatória de dados, a partir das PDF que representam as IM, possibilita que o comitê apresente uma região de dúvida em torno de uma saída distinta, a qual compreende inclusive a variabilidade dos dados de treinamento.

Um traço marcante na aplicação do MMC para propagar as distribuições é que ele pode considerar também a incerteza de outros componentes, como a dúvida a respeito de erros sistemáticos não compensados no processo de medição, por exemplo. Assim, para os casos onde a IM represente mais do que a variabilidade dos dados, é esperado que o modelo neural treinado apresente uma região de dúvida maior que aquela dada pelo método de *bootstrap*, dado que nenhum novo compressor foi adicionado ao conjunto de treinamento.

Em uma análise inicial, o MMC foi utilizado para propagar as distribuições somente no treinamento das RNA. Essa análise permite verificar a parcela de incerteza que é exclusiva do modelo neural artificial, sem que as distribuições das IM sejam propagadas durante o seu uso. A tabela 14 apresenta os resultados obtidos para as inferências com suas respectivas incertezas. Os intervalos para as incertezas são apresentados com 95% de nível de confiança e a diferença percentual é dada em relação aos resultados obtidos em laboratório (tabela 7 - página 114).

Os resultados mostram que as incertezas apresentadas pela propagação das distribuições durante o treinamento são maiores que os IC originados pelo método *bootstrap*. Isso indica que uma parcela maior de dúvida foi inserida durante a construção do modelo neural. Vale esclarecer, que o fato da incerteza ser maior quando utilizado o MMC não indica um método pior, apenas que ele contempla maior quantidade de componentes de incerteza durante o treinamento do modelo neural. A tabela 15 apresenta quais fontes de erros estão sendo consideradas. Percebe-se por ela que a propagação das distribuições pode considerar os erros sistemáticos não compensados nas medições do conjunto de treinamento, situação que não é possível pelo método *bootstrap* (tabela 13 - página 129).

Percebe-se também, que independente do método que se utilize (propagação das distribuições ou *bootstrap*) os modelos neurais estão convergindo para resultados muito semelhantes. Mesmo que ambos os comitês tenham sido treinados com técnicas diferentes, já seria esperado que convergissem para pontos muito próximos. Isso porque a arquitetura da rede e os parâmetros de aprendizagem não foram alterados, bem como nenhum novo dado foi inserido no conjunto de treinamento.

TABELA 14: RESPOSTA DO COMITÊ PROPAGANDO AS DISTRIBUIÇÕES NO TREINAMENTO

compressor	comitê 1000 RNA (W)	I-If %	difer. %
1	196,0	±2,8	+0,6
2	201,7	±3,6	+3,1
3	196,6	±2,5	-0,6
4	199,1	±3,7	+1,3
5	238,7	±3,5	-0,2
6	232,6	±2,9	-3,6
7	233,8	±2,5	+0,7
8	236,8	±2,6	+1,4
9	233,5	±2,4	+0,9
10	233,9	±3,9	+0,4
11	272,6	±4,0	-0,4
12	277,8	±5,0	+0,9

A análise realizada até este ponto indica que, metrologicamente, a propagação das distribuições no treinamento pode apresentar vantagens sobre o método *bootstrap*, pois utiliza dados da incerteza das medições do conjunto de treinamento. Ainda assim, é necessário que as distribuições sejam propagadas das entradas para a saída durante o uso do modelo neural. Com isso é possível a obtenção de um valor para a I-If que considere todas as IM envolvidas no processo de inferência da capacidade de refrigeração dos compressores herméticos.

TABELA 15: FONTES DE ERROS CONSIDERADAS NA APLICAÇÃO DO MMC NO TREINAMENTO DO MODELO NEURAL

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
capacidade elevação (mbar/s)	considera	considera
potência elétrica (W)	considera	considera
temperatura do compressor (°C)	considera	considera
capacidade de refrigeração (W)	considera	considera
uso da RNA		
capacidade elevação (mbar/s)	não considera	não considera
potência elétrica (W)	não considera	não considera
temperatura do compressor (°C)	não considera	não considera
aprendizagem		
processo de otimização	considera	não se aplica
incompletude dos dados de treinamento	não se aplica	não considera

Para propagar as distribuições durante o uso do modelo neural é necessário o conhecimento das IM envolvidas durante o uso desse modelo. Neste trabalho, os instrumentos utilizados são os mesmos para a obtenção dos dados do conjunto de treinamento e para o processo de inferência da capacidade de refrigeração³². Porém, vale lembrar que, independentemente de serem utilizados os mesmos instrumentos, durante o uso das RNA novas medições são realizadas na linha, o que certamente requer que as respectivas PDF de suas IM sejam propagadas pelo comitê.

Assim, de posse das incertezas dos dados medidos durante o uso do modelo neural artificial, pode-se então propagar as distribuições

³² Para a formação do conjunto de treinamento, houve a necessidade de se medir a capacidade de refrigeração através de bancadas de avaliação de desempenho, as quais possuem IM de $\pm 3\%$ do valor obtido, com PDF normal. No entanto, a IM desses dados são aplicadas somente durante o treinamento das RNA e não são necessárias durante o uso das mesmas. Durante o uso são necessárias somente as IM dos dados apresentados nas entradas do comitê.

através do comitê. Para cada um dos compressores de teste foram realizadas 1000 SMMC^U respeitando as PDF das IM das grandezas de entrada das RNA. Como foi utilizado o comitê com 1000 RNA, ao final obteve-se uma resposta com 10⁶ resultados distintos.

A figura 28 apresenta a resposta do modelo neural para o compressor número 5 do conjunto de teste, onde foram propagadas as distribuições no treinamento e uso. As demais respostas podem ser visualizadas no apêndice G. Através dessas observações, é possível concluir que a I-If tende para uma distribuição normal.

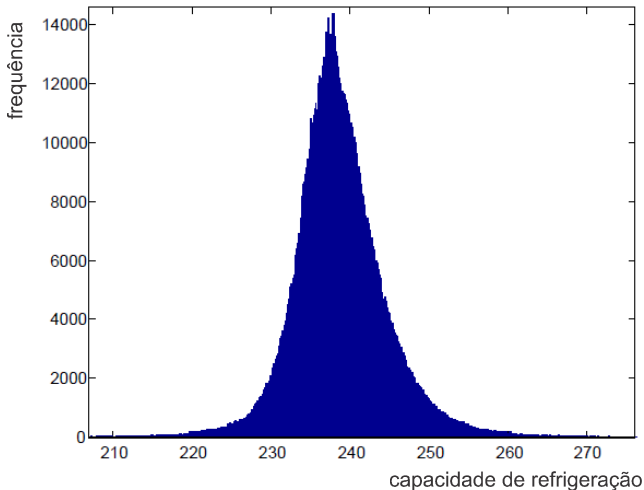


FIGURA 28: HISTOGRAMA COM A RESPOSTA DO MODELO NEURAL APLICANDO O MMC PARA AS IM DAS GRANDEZAS DE ENTRADA NO COMPRESSOR DE TESTE 5

A tabela 16 mostra o resultado da capacidade de refrigeração e as I-If obtidos após as SMMC^U para os 12 compressores de teste. Os valores médios indicados apresentam pequenas diferenças em relação àqueles obtidos sem o uso da SMMC^U (tabela 14 – página 131). Essa diferença ocorre devido à geração aleatória dos dados e, como esperado, essa diferença é mínima, sendo de, no máximo, 0,2% entre esses valores. Isso mostra que a propagação das PDF sobre modelo neural está ocorrendo como deveria, mantendo o valor médio da capacidade de refrigeração praticamente inalterado.

Tomado conhecimento desse fato, é possível comparar os valores da inferência e suas respectivas incertezas com aqueles obtidos através

das bancadas de avaliação de desempenho. A figura 29 apresenta esse comparativo.

TABELA 16: RESULTADO DA INFERÊNCIA DA CAPACIDADE DE REFRIGERAÇÃO

compressor	inferência (W)	I-If (W)	I-If %
1	197	± 11	± 5,6
2	203	± 13	± 6,4
3	196,9	± 7,4	± 3,8
4	200	± 14	± 7,0
5	239	± 12	± 5,0
6	233	± 12	± 5,2
7	234	± 11	± 4,7
8	237	± 11	± 4,6
9	234	± 11	± 4,7
10	233	± 16	± 6,9
11	273	± 19	± 7,0
12	277	± 22	± 7,9

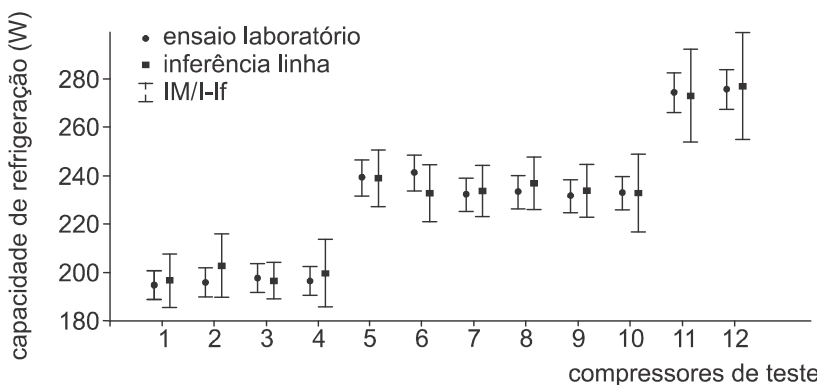


FIGURA 29: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO

A figura 29 mostra que todos os valores para as inferências obtidas na linha de produção apresentaram resultados condizentes com aqueles obtidos em laboratório. Mostra ainda que as IM e as I-If se sobrepõem, porém, para os compressores de maior capacidade, mesmo que a diferença de indicação tenha sido pequena, a I-If ficou bastante afetada. Isso ocorreu devido aos poucos compressores disponíveis no conjunto de treinamento para essa faixa de capacidade, apenas 8 compressores dos 49 utilizados. Essa é uma situação que pode ser melhorada ampliando o número de compressores no conjunto de treinamento.

Esta análise demonstrou ainda que o MMC para propagar as distribuições apresenta resultados médios muito próximos ao método *bootstrap*, o que em essência indica que ele é tão adequado para realizar a inferência quanto esse. No entanto, em relação à estimar os valores de I-If, o MMC apresentou intervalos maiores que aqueles obtidos pelo método *bootstrap* e isso se deve ao fato de que o método considera a IM ao invés de considerar somente a variabilidade dos dados de treinamento, o que metrologicamente é considerado mais adequado.

Porém, nesse ponto do documento cabe fazer um esclarecimento quanto às I-If apresentadas pela propagação das distribuições. Quando analisados os resultados através da figura 29, pode-se chegar a uma conclusão errônea de que os valores das incertezas estão superestimados, o que também levaria a conclusão de que os valores de IM dos dados medidos na linha estariam superestimados, isso porque as diferenças encontradas são muito pequenas se comparadas às I-If apresentadas. Dois foram os fatores para que isso ocorresse: o primeiro devido ao nível de IM encontrado em laboratório; o segundo deve-se às medições realizadas junto à linha de produção.

Em relação às medições realizadas em laboratório para a capacidade de refrigeração, a IM é de $\pm 3\%$ da indicação. Como a distribuição referente a essa incerteza foi propagada durante o treinamento das RNA, seria esperado que esse nível fosse refletido durante a estimação dos valores de I-If obtidos pelo modelo neural.

Em relação ao segundo fator, pode-se dizer que as medições realizadas em um ambiente industrial deixam os instrumentos suscetíveis a deriva ao longo do tempo. Isso corrobora para obtenção de valores de incertezas elevados nas medições realizadas na linha de produção, pois é esperado que esses desvios estejam dentro dos níveis de IM apresentados. Ocorre, no entanto, que os instrumentos utilizados para formar o conjunto de treinamento foram os mesmos utilizados para a realização das medições durante o uso das RNA. Nesse sentido, os erros sistemáticos que, por ventura, estiveram presentes na formação do conjunto de

treinamento foram propagados durante a formação do modelo neural. Assim, quando esses instrumentos foram utilizados no processo de inferência, os mesmos erros sistemáticos estavam presentes nas medições junto à linha de produção e, possivelmente, foram compensados, o que provavelmente levou a apresentação de diferenças relativamente baixas, mesmo com da I-If elevada.

Como a proposta permite que instrumentos diferentes sejam utilizados na formação e uso do modelo, os valores de I-If não podem ser considerados superestimados e, provavelmente, as inferências devam apresentar diferenças maiores se instrumentos diferentes vierem a ser utilizados no futuro. No entanto, mesmo que essas diferenças venham a ser maiores, ainda assim os valores encontrados para a I-If serão adequados e suficientes para apresentar um resultado com um elevado grau de confiança para um ensaio na linha de produção.

Complementado essa etapa e, assim como no item 6.2, aqui também foi realizada análise sobre o lote de compressores. Foram mantidas as mesmas considerações do item 6.2, e os resultados médios foram comparados com os resultados obtidos para a amostra de TEL.

Como mostrado anteriormente nesse item, o valor médio na saída do comitê fica praticamente inalterado quando é aplicado o MMC para a propagação das PDF durante o uso do modelo neural. Por esse motivo, para a análise sobre o lote, os resultados são apresentados propagando-se as PDF³³ através do comitê formado por 10^3 RNA.

O resultado para o lote pode ser visualizado através da tabela 17. Comparando os resultados médios, com aquele apresentado na tabela 11 (página 125), também para um comitê com 1000 RNA, pode-se observar que esses resultados ficam bastante próximos, o que leva novamente à conclusão de que o método proposto equivale ao método *bootstrap* para esta aplicação.

Individualmente as inferências obtidas para cada compressor pertencente ao lote também apresentaram resultados semelhantes aos obtidos pelo método *bootstrap*. Pelo gráfico³⁴ da figura 30 é possível observar o mesmo problema encontrado anteriormente em relação à temperatura. Isso já era esperado, dado que nenhum novo compressor foi inserido no conjunto de treinamento.

³³ Foram realizadas 10^3 SMMC^U, o que corresponde na saída do comitê uma quantidade de 10^6 resultados distintos.

³⁴ No gráfico a linha central representa a média do TEL e as linhas paralelas representam a dispersão para essa média através de 3 desvios padrões para mais e para menos.

TABELA 17: COMPARATIVO ENTRE O RESULTADO DO TEL E OBTIDO ATRAVÉS DA INFERÊNCIA

Comparativo dos resultados da capacidade de refrigeração para o lote					
média dos resultados do lote de TEL (W)	235,7	média dos resultados do comitê com 10 ³ RNA (W)	233,2	difer. %	-1,0
IC %	±3,6	I-If % ³⁵	±6,0		
desvio padrão %	0,9	desvio padrão %	2,2		




FIGURA 30: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE

Assim como ocorreu no item 6.2, os compressores ensaiados em temperaturas mais baixas encontram-se em uma região onde há extrapolação de dados, o que leva a uma generalização inadequada por parte das RNA. Isso pode ser mais bem entendido quando se analisa a distribuição dos valores obtidos na saída do modelo neural. Para tal, a figura 31 apresenta o gráfico com as inferências incluindo suas respectivas incertezas para um nível de confiança de 95%. Nessa figura são apresentados os resultados, em forma de histograma, para dois compressores: um ensaiado na temperatura de 41°C, e outro na temperatura de 22°C. As respostas indicam que compressores com temperaturas mais elevadas levaram a uma dispersão menor dos dados, ao passo que compressores com temperaturas menores levaram a uma grande dispersão, fato que determinou inclusive o aumento do valor da I-If. Outro fato importante, é que os resultados obtidos para estes últimos compressores não apre-

³⁵ O processamento, através do modelo neural, dos resultados médios encontrados no ensaio na linha de produção resultou no intervalo de confiança para a média das inferências.

sentaram sua dispersão tendendo uma PDF normal, o que reforça a tese de que o problema está no baixo poder de generalização do modelo neural devido à extrapolação dos dados de entrada, e não na baixa capacidade de refrigeração dos compressores em si. Pois, caso o comitê estivesse generalizando de modo adequado, pelo teorema central do limite, essa distribuição deveria tender para uma PDF normal.

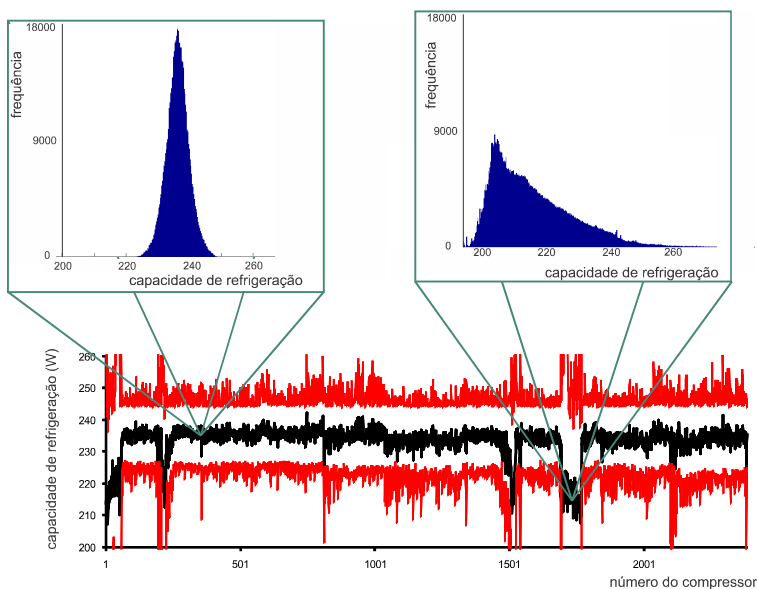


FIGURA 31: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO E DAS RESPECTIVAS I-If

Ao final, esta análise mostrou que, para se expressar a incerteza do valor da inferência apresentada para a capacidade de refrigeração, é essencial propagar as distribuições referentes a todas as fontes IM no treinamento e no uso do modelo neural. No entanto, como exposto na tabela 18, a incompletude dos dados não pode ser considerada aplicando-se somente o MMC na propagação das distribuições.

Tal incompletude pode ser significativa quando poucos dados formam o conjunto de treinamento.

A análise a seguir aplica a proposta desenvolvida nesta tese de doutorado e apresentada no item 5.4. É esperado que através dela, todas as fontes de erro sejam consideradas na expressão da incerteza da inferência da capacidade de refrigeração.

TABELA 18: FONTES DE ERROS CONSIDERADAS NA APLICAÇÃO DO MMC NO TREINAMENTO E NO USO DO MODELO NEURAL

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
capacidade elevação (mbar/s)	considera	considera
potência elétrica (W)	considera	considera
temperatura do compressor ($^{\circ}$ C)	considera	considera
capacidade de refrigeração (W)	considera	considera
uso da RNA		
capacidade elevação (mbar/s)	considera	considera
potência elétrica (W)	considera	considera
temperatura do compressor ($^{\circ}$ C)	considera	considera
aprendizagem		
processo de otimização	considera	não se aplica
incompletude dos dados de treinamento	não se aplica	não considera

6.4 MODELO NEURAL TREINADO A PARTIR DA PROPOSTA PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA

Pode-se dizer que, quando se dispõe de um conjunto de treinamento bem selecionado, a utilização do MMC para propagar as distribuições, no treinamento e no uso do modelo neural, se mostra metrologicamente mais adequada que o método *bootstrap* no que concerne expressar a I-If. Isso ocorre porque a propagação das distribuições é capaz de considerar IM do conjunto de treinamento e também durante o uso do modelo neural. No entanto, quando se dispõe de poucos dados para a aprendizagem das RNA, ou quando esses dados não são bem selecionados, o conjunto de treinamento pode ser incompleto.

O erro gerado por essa incompletude é considerado pelo método *bootstrap* através da reamostragem, porém, o uso MMC para propagar

as distribuições, apresentado no item 5.3 e aplicado no item 6.3 deste estudo de caso, não realiza essa reamostragem. Para contornar esse problema foi proposto no item 5.4 um método capaz de considerar, além das incertezas dos dados de medições, também a incompletude do conjunto de treinamento através da reamostragem *bootstrap*. Assim, espera-se que todas as fontes de erros, que podem ser significativas em processos metrológicos que fazem uso de RNA, sejam consideradas na avaliação da I-If, como exemplificado pela tabela 19 para este estudo de caso.

TABELA 19: FONTES DE ERROS CONSIDERADAS ATRAVÉS PROPOSTA APRESENTADA PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA DO MODELO NEURAL

	erro aleatório	erro sistemático não compensado
dados de medições		
treinamento da RNA		
capacidade elevação (mbar/s)	considera	considera
potência elétrica (W)	considera	considera
temperatura do compressor ($^{\circ}$ C)	considera	considera
capacidade de refrigeração (W)	considera	considera
uso da RNA		
capacidade elevação (mbar/s)	considera	considera
potência elétrica (W)	considera	considera
temperatura do compressor ($^{\circ}$ C)	considera	considera
aprendizagem		
processo de otimização	considera	não se aplica
incompletude dos dados de treinamento	não se aplica	considera

Este item manteve as mesmas condições apresentadas anteriormente nos itens 6.2 e 6.3. Assim, foram utilizados os mesmos 49 compressores tidos como base de conhecimento no processo de treinamento. Foi treinado um comitê com 1000 RNA a partir do método proposto, foram realizadas 1000 SMMC^U e os valores obtidos para I-If foram apresentados para um nível de confiança de 95%. Os resultados encontrados para os 12 compressores de teste são apresentados pela tabela 20

e a figura 32 compara, de modo gráfico, os resultados obtidos em laboratório com as inferências obtidas na linha de produção.

TABELA 20: RESPOSTA DO MODELO NEURAL TREINADO A PARTIR DO MÉTODO PROPOSTO PARA ESTIMAR A INCERTEZA DA INFERÊNCIA

compressor	comitê 1000 RNA (W)	I-If (W)	I-If %	difer. %
1	197	±11	±5,7	+0,8
2	202	±12	±6,2	+3,2
3	197,1	±8,0	±4,1	-0,3
4	201	±14	±7,2	+2,1
5	239	±14	±5,7	-0,1
6	234	±14	±5,8	-3,3
7	233	±12	±5,2	+0,9
8	237	±13	±5,4	+1,5
9	234	±12	±5,2	+1,1
10	233	±17	±7,6	+0,2
11	273	±21	±7,7	-0,5
12	278	±26	±9,4	+0,9




FIGURA 32: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO

As indicações encontradas para a capacidade de refrigeração foram similares as obtidas anteriormente para os métodos *bootstrap* e MMC, diferenciando essencialmente nos valores encontrados para a I-If. Para o método proposto, os valores para a incerteza foram maiores que nos métodos anteriores, o que já era esperado, dado que ele é uma combinação de ambos os métodos (*bootstrap* e MMC para propagação das distribuições) e considera assim uma quantidade maior de fontes de erros que podem afetar o resultado do modelo neural.

Os dados do lote de compressores também foram reprocessados utilizando o modelo neural treinado neste item. Os valores de inferência podem ser observados através da tabela 21 e da figura 33³⁶.

TABELA 21: COMPARATIVO ENTRE O RESULTADO DO TEL E OBTIDO ATRAVÉS DA INFERÊNCIA

Comparativo dos resultados da capacidade de refrigeração para o lote					
média dos resultados do lote de TEL (W)	235,7	média dos resultados do comitê com 10 ³ RNA (W)	233,6	difer. %	-0,9
IC %	±3,6	I-If %	±6,5		
desvio padrão %	0,9	desvio padrão %	2,2		




FIGURA 33: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE

Comparando-se os resultados obtidos neste item, com aqueles apresentados nos itens 6.2 e 6.3, os valores para a inferência foram muito semelhantes, diferenciando-se de modo mais significativos nos valores encontrados para a I-If. Até este ponto do estudo de caso, foram obtidos

³⁶ No gráfico a linha central representa a média do TEL e as linhas paralelas representam a dispersão para essa média através de 3 desvios padrões para mais e para menos.

resultados semelhantes inclusive para o problema dos compressores ensaiados com temperaturas abaixo dos 35°C.

Por fim, esta análise mostrou os resultados da aplicação da proposta apresentada no item 5.4 no contexto deste estudo de caso. A partir dela pode-se concluir que o modelo neural obtido foi capaz de apresentar resultados médios muito próximos daqueles apresentados pelo método *bootstrap*, o que possibilita dizer que, em relação à indicação da inferência, a proposta é tão válida quanto esse tradicional método. Em relação aos valores obtidos para a I-If, a proposta apresentou valores maiores que os IC obtidos pelo método *bootstrap*. Porém, esses valores de incerteza para a inferência podem ser tidos como metrologicamente mais confiáveis, pois, consideram a IM de todas as medições envolvidas no processo de inferência, o que os métodos encontrados na literatura para estimar IC em RNA não fazem. No entanto, como apresentado, o modelo não pode ser utilizado para estimar o valor da capacidade de refrigeração em 100% das peças produzidas. Nesse sentido dois caminhos são válidos: um excluir compressores com temperaturas abaixo de 35°C, dado que poucas são as peças ensaiadas nessas temperaturas, o que ainda assim já seria considerado um ganho expressivo quando comparado ao atual meio de controle da qualidade; outro seria compensar os efeitos oriundos da variação da temperatura dos ensaio na linha e buscar, então, alcançar ensaios em 100% das peças produzidas. Este último caminho é apresentado no item a seguir.

6.5 MODELO NEURAL ARTIFICIAL CONSIDERANDO AS VARIAÇÕES DE TEMPERATURAS DURANTE O ENSAIO NA LINHA DE PRODUÇÃO

Neste item, além dos 49 compressores inicialmente utilizados nos treinamentos das análises anteriores, foram inseridos ensaios de 23 compressores de 4 modelos com capacidades de refrigeração diferentes. Esses compressores foram ensaiados na linha de produção com variações de temperatura. Assim, inicialmente para cada compressor foram medidas a capacidade de elevação da pressão e o consumo, isso a temperaturas entre 40°C e 44°C, que são temperaturas típicas quando não há paradas na linha de produção. Após, com o resfriamento natural do compressor, essas mesmas medidas foram tomadas a cada decaimento de aproximadamente 5°C. O gráfico da figura 34 mostra o comportamento típico da capacidade de elevação da pressão em função da temperatura.




FIGURA 34: EVOLUÇÃO DA CAPACIDADE DE ELEVAÇÃO DA PRESSÃO EM FUNÇÃO DA TEMPERATURA DO COMPRESSOR

Independentemente da capacidade de refrigeração do compressor, o comportamento da capacidade de elevação ocorre de modo semelhante para as variações de temperatura. Assim, espera-se com a introdução desses novos dados, que o modelo neural aprenda sobre esse comportamento e, conseqüentemente, generalize melhor. Desse modo, será possível apresentar um resultado mais adequado para as inferências realizadas nos compressores com temperaturas mais baixas.

É importante ressaltar que esses ensaios ocorreram na linha de produção e que o decaimento da temperatura se deu naturalmente. Esses experimentos possibilitaram obter resultados típicos encontrados no dia a dia da planta produtiva, situação que não seria possível se o resfriamento ocorresse do modo forçado. Devido ao elevado tempo envolvido no decaimento da temperatura e a dinâmica fabril, não foi possível realizar experimentos com temperaturas abaixo dos 25°C, mesmo essas sendo temperaturas possíveis na prática.

Do mesmo modo que na análise anteriormente realizada no item 6.4, foram treinadas 1000 RNA utilizando SMMC^T e a reamostragem *bootstrap*. Durante o uso do modelo neural, foram realizadas 1000 SMMC^U, o que representa uma resposta com 10⁶ valores distintos, na qual foi possível expressar a I-If.

As respostas obtidas para os 12 compressores de teste podem ser visualizadas pela tabela 22, a diferença apresentada foi dada em relação aos valores obtidos em laboratório. A figura 35 coloca lado a lado os

resultados de laboratório e de linha para facilitar a visualização das respostas.

Comparando os resultados obtidos através desse modelo neural, treinado com um número maior de compressores, com aqueles obtidos pelo modelo da análise anterior (tabela 20 – pág. 141), chega-se a conclusão que, para ambos os casos, os resultados médios permaneceram praticamente inalterados. Porém, a inclusão de novos dados no conjunto de treinamento permitiu que o comitê apresentasse faixas menores de I-If. Essa redução se deu, principalmente, para os compressores com capacidades de refrigeração mais elevadas, os quais inicialmente possuíam poucos compressores no conjunto de treinamento. A inclusão desses novos dados permitiu que o modelo pudesse realizar uma combinação melhor das PDF que representam a IM dos dados de treinamento, situação que resulta numa variância menor na PDF formada na saída do comitê.

TABELA 22: RESULTADO DA INFERÊNCIA PARA A CAPACIDADE DE REFRIGERAÇÃO

compressor	inferência (W)	I-If (W)	I-If %	difer. %
1	197	± 11	± 5,6	+1,1
2	202	± 13	± 6,4	+3,2
3	198,0	± 8,1	± 4,1	+0,2
4	197,9	± 7,8	± 3,9	+0,7
5	234,7	± 9,6	± 4,1	-1,9
6	234,0	± 8,2	± 3,5	-3,0
7	234,1	± 8,1	± 3,5	+0,8
8	235,2	± 9,7	± 4,1	+0,7
9	234,1	± 7,8	± 3,3	+1,1
10	234	± 11	± 4,7	+0,6
11	275	± 15	± 5,5	+0,3
12	278	± 14	± 5,0	+0,9




FIGURA 35: COMPARATIVO ENTRE OS RESULTADOS DE LABORATÓRIO E LINHA DE PRODUÇÃO

A utilização dessa técnica de inclusão de dados ensaiados com variação de temperatura se mostrou bastante eficaz para a solução do problema encontrado anteriormente no lote de compressores. Quando reprocessadas as informações desse lote, os compressores apresentaram resultados condizentes e dentro da faixa esperada.

Na tabela 23 é possível verificar que os resultados para a média e desvio padrão ficaram mais próximos do resultado do TEL do que a análise anterior (tabela 21 – página 142), o que indica melhoria nas inferências apresentadas pelo modelo neural. A figura 36³⁷ apresenta os resultados para todos compressores que compõem o lote. Nele é possível verificar que esses ficaram muito próximos da média obtida para o TEL, sendo que praticamente todos ficaram dentro da faixa de mais ou menos 3 desvios padrões em relação a essa média. Isso mostra que a proposta de melhorar o aprendizado através de ensaios específicos com variações da temperatura é válida.

³⁷ No gráfico a linha central representa a média do TEL e as linhas paralelas representam a dispersão para essa média através de 3 desvios padrões para mais e para menos.

TABELA 23: COMPARATIVO ENTRE O RESULTADO DO TEL E O OBTIDO ATRAVÉS DA INFERÊNCIA

Comparativo dos resultados da capacidade de refrigeração para o lote				
média dos resultados do lote de TEL (W)	235,7	média dos resultados do comitê com 10 ³ RNA (W)	234,6	difer. % -0,5
IC %	±3,6	I-If %	±4,0	
desvio padrão %	0,9	desvio padrão %	0,5	




FIGURA 36: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO PARA O LOTE

Mesmo com os bons resultados apresentados por esse modelo, a impossibilidade de realizar ensaios com temperaturas menores que 25°C prejudicou a resposta para alguns compressores, os quais foram ensaiados abaixo desse valor. A figura 37, assim como a figura 31 (página 138), apresenta os resultados das inferências da capacidade de refrigeração e suas respectivas incertezas. Apresenta também os resultados, em forma de histograma, para os mesmos dois compressores da análise anterior: um ensaiado na temperatura de 41°C, e outro na temperatura de 22°C. A comparação entre as figuras mostra que mesmo para as peças ensaiadas a uma temperatura menor que 25°C, o I-If ficou significativamente reduzido, e apresentou uma PDF mais próxima de uma distribuição normal, fato que indica uma melhor generalização por parte do modelo neural.




FIGURA 37: GRÁFICO DOS RESULTADOS DAS INFERÊNCIAS DAS CAPACIDADES DE REFRIGERAÇÃO E AS RESPECTIVAS I-IF

Fica comprovado que utilizando os meios apresentados nesta tese é possível realizar inferências do valor da capacidade de refrigeração de compressores herméticos junto à linha de produção e em 100% das peças produzidas. Porém, duas análises ainda são importantes: a dos tempos de processamento do modelo neural artificial; a da inferência do valor da capacidade de refrigeração de compressores defeituosos.

6.6 ANÁLISE DOS TEMPOS DE PROCESSAMENTO DO MODELO NEURAL

Um ponto importante objetivado neste trabalho, é que a proposta respeite o tempo de ciclo de uma linha de produção de compressores herméticos. Esse tempo é 7 segundos para uma linha da empresa onde o estudo de caso foi realizado, assim esse foi estabelecido como alvo para concepção de uma solução viável.

Para a bancada encontrada na linha, o tempo de ensaio é de aproximadamente 6,5 segundos. Em uma análise superficial se chegaria à conclusão que o tempo de processamento do modelo neural artificial

está limitado aos 0,5 segundo restante. Porém, mesmo que as medições no *hardware* ocorram exatamente em 7 segundos, o tempo de processamento não depende desse intervalo. O fato é que o processamento ocorre de modo subsequente ao ensaio físico, por esse motivo, este também fica limitado pelo tempo de ciclo da linha de produção. A ocorrência disso possibilita que, em um intervalo de 14 segundos, dois processos de inferência sejam realizados simultaneamente. Isso só é possível porque, enquanto o modelo neural está processando as informações de um dado compressor, a bancada já está liberada para realizar as medições em outra peça. Assim, mesmo que o tempo para obtenção de um valor de inferência em um único compressor consuma 14 segundos, na média esse tempo não ultrapassa os 7 segundos.

Definido o tempo de ciclo da linha como o intervalo limite para o processamento das informações no modelo neural artificial, é então necessária uma configuração adequada para realizar a inferência dentro do tempo estipulado. É importante ressaltar que o tempo de processamento depende muito do *hardware* e do *software* computacional utilizado nessa tarefa. Para as análises aqui realizadas foi utilizado um computador com processador Intel Core i5, 8 Gbytes de memória RAM, sistema operacional Microsoft Windows 7 de 64 bits e o Matlab R2009a para o processamento das RNA. Durante os experimentos notou-se que os tempos ficaram limitados à capacidade do processador. Assim, a substituição desse, por um capaz de realizar cálculos mais rapidamente, certamente melhoraria os tempos aqui encontrados, ao passo que o aumento da memória RAM não influiria significativamente nesse tempo.

Com essa configuração, para os resultados encontrados nas análises anteriores, utilizando 1000 simulações propagadas através de um comitê com 1000 RNA, o tempo de processamento para cada compressor ficou em aproximadamente 15 segundos. Esse intervalo é muito superior ao previamente estabelecido e pode ser diminuído com a substituição do *hardware* computacional, porém, essa análise não foi realizada neste trabalho. Aqui, optou-se por encontrar o equilíbrio entre o número de simulações e de RNA, de modo que se obtenha um resultado metrologicamente adequado dentro das condições estipuladas.

Para encontrar uma configuração adequada é inicialmente necessário entender o comportamento do tempo de resposta de um comitê em função do número RNA e de SMMC^U. Vale lembrar que o treinamento das redes não afeta o tempo de processamento, pois esse processo é realizado anteriormente ao uso do modelo neural artificial. Para cada inferência, o tempo de processamento pode ser aproximado pela equa-

ção (28). Essa equação foi obtida para o *hardware* e *software* utilizados nessa análise, e só é válida para essa configuração.

$$t \cong (1,0 \cdot 10^{-2} + 4,0 \cdot 10^{-6} \cdot nSMMC) \cdot nRNA + 1,1 \cdot 10^{-5} \cdot nSMMC \quad (28)$$

Onde:

- t tempo de processamento das informações no comitê [s];
- $nRNA$ número de RNA no comitê;
- $nSMMC$ número de SMMC^U realizadas para os dados de entrada do comitê.

A partir da equação (28) é possível levantar os tempos de processamento aproximados para diferentes números de RNA e SMMC^U. A tabela 24 apresenta o resultado, em segundos, para esses tempos. Por essa tabela chega-se à conclusão de que qualquer configuração, que contemple mais de 700 RNA no comitê, não atende ao intervalo de tempo estabelecido para o processamento das informações obtidas na linha da produção. Percebe-se que para um comitê com 600 RNA e uma quantidade a partir de 500 SMMC^U também não atende as especificações de tempo de processamento, assim como um comitê com 500 RNA e 1000 SMMC^U.

TABELA 24: TEMPOS EM SEGUNDOS PARA O PROCESSAMENTO DAS INFORMAÇÕES

		nRNA									
		100	200	300	400	500	600	700	800	900	1000
nSMMC	100	1,04	2,08	3,12	4,16	5,20	6,24	7,28	8,32	9,36	10,40
	200	1,08	2,16	3,24	4,32	5,40	6,48	7,56	8,64	9,72	10,80
	300	1,12	2,24	3,36	4,48	5,60	6,72	7,84	8,96	10,08	11,20
	400	1,16	2,32	3,48	4,64	5,80	6,96	8,12	9,28	10,44	11,60
	500	1,21	2,41	3,61	4,81	6,01	7,21	8,41	9,61	10,81	12,01
	600	1,25	2,49	3,73	4,97	6,21	7,45	8,69	9,93	11,17	12,41
	700	1,29	2,57	3,85	5,13	6,41	7,69	8,97	10,25	11,53	12,81
	800	1,33	2,65	3,97	5,29	6,61	7,93	9,25	10,57	11,89	13,21
	900	1,37	2,73	4,09	5,45	6,81	8,17	9,53	10,89	12,25	13,61
	1000	1,41	2,81	4,21	5,61	7,01	8,41	9,81	11,21	12,61	14,01

Como não é possível a utilização da configuração que apresentou excelentes resultados no item 6.5, buscou-se verificar a influência nas alterações das quantidades de RNA e SMMC^U. Deste modo, a partir da diminuição desses dois fatores se espera encontrar uma configuração com tempo de processamento aceitável e, ainda assim, manter resultados de inferência e I-If condizentes.

Como o aumento do número de redes, dentro de um comitê, é mais significativo no tempo de processamento do que o aumento do número de SMMC^U, primeiramente foi realizada uma análise do tempo de processamento mantendo as 1000 SMMC^U e variando a quantidade de RNA no comitê.

Essa análise permite verificar o comportamento do processo de inferência e sua incerteza, bem como com quantas RNA chega-se a estabilidade. Ao final obtiveram-se os gráficos apresentados nas figuras 38 e 39.

O gráfico da figura 38, com o comportamento da resposta na saída do comitê, mostra que a partir de 300 RNA a resposta não varia mais que 0,4 W, o que corresponde à aproximadamente 0,17% em relação ao resultado apresentado para 1000 RNA. Do mesmo modo, pelo gráfico da figura 39, que mostra o comportamento da I-If, é possível observar que o valor desse intervalo parece chegar à estabilidade próxima a 300 RNA no comitê. Os gráficos são referentes a um compressor do conjunto de teste. Todos os compressores apresentaram comportamentos semelhantes.




FIGURA 38: EVOLUÇÃO DO RESULTADO DA INFERÊNCIA À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 1000 SMMC^U




FIGURA 39: EVOLUÇÃO DO VALOR ENCONTRADO PARA A I-If À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 1000 SMMC^U

Pela análise apresentada, a utilização de um modelo neural, composto por 300 RNA no comitê e 1000 SMMC^U, já seria suficiente para apresentar resultados satisfatórios tanto em relação ao resultado da inferência quanto em relação ao valor encontrado para sua incerteza, isso com um tempo de processamento de aproximadamente 4,21 segundos. Uma configuração como essa, levaria a $3,0 \cdot 10^5$ resultados distintos na saída do modelo. Porém, pela tabela 24, percebe-se que outras configurações podem chegar a uma quantidade maior de resultados. Nesse sentido, uma quantidade maior de RNA no comitê seria preferível por aumentar a representatividade das IM do conjunto de treinamento na composição da I-If.

Pela tabela 24 a configuração que apresenta maior quantidade de resultados na saída do modelo, sem extrapolar o tempo de 7 segundos, é 500 RNA e 900 SMMC^U. Tal configuração levaria a $4,5 \cdot 10^5$ resultados com uma quantidade maior de redes, porém, diminuindo a quantidade de SMMC^U. Mesmo essa configuração ficando próximo ao limite máximo de tempo estabelecido como aceitável, os avanços computacionais e a possibilidade de substituição do *hardware* por um com capacidade computacional maior permitem supor que não há problemas devido a tal proximidade.

Como a quantidade de simulações é menor, uma nova análise foi realizada para verificar o comportamento da inferência e também do valor estimado para a I-If. As figuras 40 e 41 mostraram que a redução em 100 SMMC^U não altera significativamente a resposta do modelo neural, o que permite a utilização dessa configuração.




FIGURA 40: EVOLUÇÃO DO RESULTADO DA INFERÊNCIA À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 900 SMMC^U

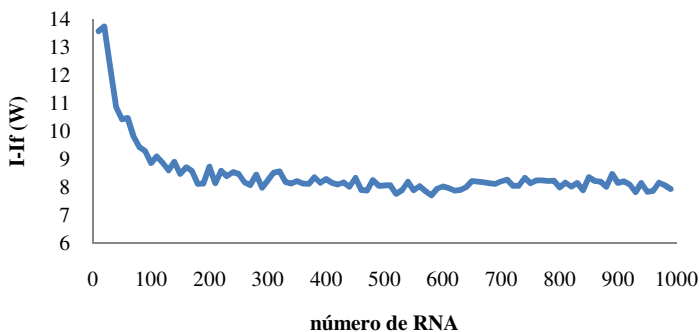



FIGURA 41: EVOLUÇÃO DO VALOR ENCONTRADO PARA A I-If À MEDIDA QUE MAIS UMA RNA É INSERIDA NO COMITÊ – 900 SMMC^U

Para verificar a viabilidade do uso dessa configuração foram comparados os valores obtidos por ela, para os 12 compressores de teste, com os valores obtidos pelo conjunto formado por 1000 RNA e 1000 SMMC^U, apresentados anteriormente na tabela 22 (página 145). Assim, foram escolhidas aleatoriamente 500 RNA das 1000 redes treinadas anteriormente. Os resultados podem ser visualizados na tabela 25 e a figura 42 coloca lado a lado esses resultados de modo gráfico.

TABELA 25: RESULTADOS PARA DIFERENTES CONFIGURAÇÕES DE RNA E SMMC^U

compressor	1000 RNA 1000 SMMC ^U (W)	I-If (W)	I-If %	500 RNA 900 SMMC ^U (W)	I-If (W)	I-If %	diferença entre os modelos %
1	197	± 11	± 5,6	196,6	± 9,5	± 4,8	-0,2
2	202	± 13	± 6,4	202	± 13	± 6,4	0,0
3	198,0	± 8,1	± 4,1	198,1	± 8,3	± 4,2	+0,1
4	197,9	± 7,8	± 3,9	197,9	± 7,3	± 3,7	0,0
5	234,7	± 9,6	± 4,1	234,8	± 9,8	± 4,2	0,0
6	234,0	± 8,2	± 3,5	234,1	± 8,1	± 3,5	0,0
7	234,1	± 8,1	± 3,5	234,1	± 8,1	± 3,5	0,0
8	235,2	± 9,7	± 4,1	235,2	± 9,7	± 4,1	0,0
9	234,1	± 7,8	± 3,3	234,1	± 7,9	± 3,4	0,0
10	234	± 11	± 4,7	235	± 11	± 4,7	+0,4
11	275	± 15	± 5,5	275	± 15	± 5,5	0,0
12	278	± 14	± 5,0	278	± 14	± 5,0	0,0

FIGURA 42: COMPARATIVO ENTRE DIFERENTES CONFIGURAÇÕES DE RNA E SMMC^U

Essa análise mostra que o uso de um modelo neural, constituído por um comitê de 500 RNA e com a geração de 900 SMMC^U, manteve praticamente inalteradas as inferências obtidas para a capacidade de refrigeração. Os desvios encontrados entre as inferências são mínimos, como mostrado na última coluna da tabela 25. Para as respectivas I-If

também ocorreram pequenas variações e em alguns casos os valores ficaram menores que os obtidos anteriormente para o comitê com 1000 RNA. Essas variações, todavia, não indicam que os I-If encontrados estão errados, ou mesmo que esses valores sejam melhores que aqueles obtidos anteriormente. Na verdade, nessa aplicação, a I-If, assim como a IM avaliada para uma determinada medição, indica tão somente a estimativa de quanto se está próximo do valor verdadeiro da grandeza, a partir do conhecimento disponível no momento da medição (BIPM, 2008a). Nesse sentido, as pequenas variações nos valores obtidos para a I-If, tanto para mais quanto para menos, reflete apenas a perda de conhecimento com a diminuição do número de RNA e SMMC^U. Entretanto, como essas variações são pequenas e os resultados ficaram praticamente inalterados, pode-se afirmar que utilizar essa configuração não compromete o resultado da inferência em relação ao modelo formado por 1000 RNA e com 1000 SMMC^U. As análises indicam ainda que essa proposta continuou possibilitando estimar uma I-If com 2 algarismos significativos.

6.7 INFERÊNCIA DA CAPACIDADE DE REFRIGERAÇÃO EM COMPRESSORES DEFEITUOSOS

Durante o capítulo 6, diferentes análises foram realizadas no intuito de mostrar que é possível realizar inferências do valor da capacidade de refrigeração junto à linha de produção. Porém, como o processo de fabricação dos compressores é muito bem ajustado, os defeitos ocorrem na ordem de partes por milhão. Assim, nenhuma peça utilizada, seja nos treinamentos ou nas análises, apresentava indicação de capacidade abaixo do esperado. Deste modo, uma análise com peças defeituosas foi realizada para verificar o comportamento da proposta frente a esses compressores.

Com esse intuito, cinco compressores defeituosos foram fabricados. Esses defeitos foram inseridos deformando-se as válvulas, aumentando o volume morto da câmara de compressão e também através de imperfeições na placa válvula, que são defeitos típicos que ocasionam baixa capacidade de refrigeração do compressor. Essas peças foram medidas em laboratório e apresentaram resultados para a capacidade de refrigeração abaixo do esperado.

Na linha de produção, os ensaios foram realizados em temperaturas próximas aos 38,5°C, evitando deste modo os problemas de generalização relacionados com a temperatura. O comitê utilizado foi o mesmo

do item 6.6, com 500 RNA e foram realizadas 900 SMMC^U, respeitando assim o tempo estipulado para o processamento das informações.

O valor nominal para o modelo em questão é de 240 W e os valores obtidos através do processo de inferência são apresentados na tabela 26. Percebe-se que, apesar das indicações ficarem abaixo do valor nominal, as diferenças apresentadas foram elevadas, bem como suas respectivas incertezas.

TABELA 26: RESPOSTA PARA OS COMPRESSORES DEFEITUOSOS

compressor	medição no lab. (W)	IM (W)	inferência na linha (W)	I-If (W)	I-If %	difer. %
d5	184,0	± 5,6	208	± 26	± 13	+13
d4	222,7	± 6,7	232	± 12	± 5,2	+4,8
d3	219,1	± 6,6	232	± 13	± 5,6	+5,9
d2	192,0	± 5,8	213	± 30	± 14	+11
d1	201,5	± 6,1	220	± 26	± 12	+9,2

A figura 43 permite visualizar os resultados para as medições em laboratório e para as inferências na linha. É possível perceber que 3 compressores apresentaram valores para a I-If demasiadamente elevados.




FIGURA 43: RESPOSTA PARA OS COMPRESSORES DEFEITUOSOS

Pode-se extrair dessa análise, que o modelo neural artificial apresentou baixo poder de generalização, situação que se refletiu não só nas

diferenças apresentadas, mas também nos valores das suas respectivas incertezas. Tal constatação pode ser visualizada através da figura 44, que mostra a distribuição dos valores na saída do comitê para o compressor defeituoso d5. A resposta para os demais compressores defeituosos são apresentadas no apêndice H.




FIGURA 44: HISTOGRAMA COM A RESPOSTA APRESENTADA PARA O COMPRESSOR DEFEITUOSO D5

Mesmo que existam compressores no conjunto de treinamento com capacidade de refrigeração próximas àquelas medidas para essas peças defeituosas, ainda assim esses ficam em uma região onde as RNA tendem a extrapolar os dados. Isso ocorre, porque além da capacidade de elevação da pressão, parâmetros como a potência elétrica consumida, que também é diretamente proporcional à capacidade de refrigeração, e a classe do compressor também são utilizados como entradas do modelo neural. Deste modo, durante o treinamento não foram introduzidos exemplos que possibilitassem a obtenção de inferências e incertezas adequadas para tais situações.

Do mesmo modo que foi possível melhorar o desempenho do comitê com a inserção de dados obtidos através de ensaios variando a temperatura, o modelo neural artificial também pode ser melhorado através da inserção de dados de ensaios de compressores defeituosos. Assim, um único compressor defeituoso teve seus dados incorporados ao conjunto de treinamento. A partir dessa inserção novas RNA foram treinadas, e 500 foram tomadas para formar um novo comitê. A mesma

arquitetura e os mesmos parâmetros definidos para todas as análises realizadas anteriormente foram mantidos.

De posse desse novo modelo neural artificial, foram reprocessadas as informações dos 5 compressores defeituosos. Os resultados podem ser visualizados pela tabela 27 e pela figura 45. As novas inferências foram significativamente melhoradas. Agora todas as indicações ficaram próximas àquelas obtidas em laboratório e os valores para a I-If foram adequados para fornecer confiabilidade nos resultados. A figura 46 mostra o histograma para o mesmo compressor da figura 44, é possível verificar que a PDF formada na saída do comitê tende agora para uma distribuição normal, fato indicativo de que o modelo neural aumentou seu poder de generalização para os compressores com capacidade abaixo do esperado. O apêndice I apresenta também os resultados para os demais compressores.

TABELA 27: RESPOSTA PARA COMPRESSORES DEFEITUOSOS APÓS NOVO TREINAMENTO

compressor	medição no lab. (W)	IM (W)	medição na linha (W)	I-If (W)	I-If %	difer %
d5	184,0	± 5,6	194	± 10	± 5,2	+5,4
d4	222,7	± 6,7	227	± 12	± 5,3	+1,9
d3	219,1	± 6,6	226	± 12	± 5,3	+3,4
d2	192,0	± 5,8	196	± 12	± 6,3	+2,1
d1	201,5	± 6,1	204	± 15	± 7,4	+1,2




FIGURA 45: RESPOSTA PARA OS COMPRESSORES DEFEITUOSOS A PARTIR DO NOVO TREINAMENTO




FIGURA 46: HISTOGRAMA COM A RESPOSTA APRESENTADA PARA O COMPRESSOR DEFEITUOSO D5 APÓS NOVO TREINAMENTO

Como novas rodadas de treinamento foram necessárias para melhorar o modelo neural artificial, faz-se necessário verificar se houve mudança significativa nos resultados apresentados anteriormente. Assim, os dados referentes aos compressores de teste foram reprocessados pelo novo comitê. Os resultados podem ser visualizados através da tabela 28 que a coloca lado a lado, os resultados obtidos pelo comitê composto por RNA treinadas sem nenhum compressor com capacidade de refrigeração abaixo do esperado, e os novos resultados, obtidos a partir do comitê composto por RNA treinadas com a inclusão de um único compressor com baixa capacidade de refrigeração. Os resultados obtidos não foram significativamente afetados pela inclusão dos novos dados no conjunto de treinamento e as diferenças encontradas para as indicações desses dois modelos ficaram dentro dos limites anteriormente apresentados pela I-If.

Ao final, este item mostrou que a proposta pode sim ser utilizada para realizar inferências em compressores com capacidade abaixo do esperado. Porém, é necessário ajustar o modelo neural através da escolha adequada de exemplos no conjunto de treinamento.

Ajustes no modelo neural são importantes e devem sempre ser realizados quando alguma situação mostrar que o modelo neural possa estar incompleto. Nesse sentido, a aplicação da propagação das distribuições durante o uso do modelo neural artificial para todas as peças ensaiadas na linha de produção permite verificar se há peças para as quais o modelo não responde adequadamente. Isso seria um bom indicativo de extra-

polação, ou seja, o modelo neural está sendo utilizado para inferir em condições fora da faixa em que ele foi treinado. Nessa situação, quando esses dados são apresentados ao modelo neural artificial, os valores obtidos para a I-If são demasiadamente elevados.

O apêndice J apresenta uma proposição de estratégia para a manutenção da qualidade e melhoria contínua da proposta apresentada neste trabalho. Esse apêndice foca na intercomparação entre os resultados obtidos pelos ensaios na linha de produção e em laboratório, dando ênfase na melhoria do modelo neural através de novos processos de aprendizagem de RNA a partir da inclusão de dados no conjunto de treinamento. Desse modo, a cada etapa na melhoria contínua, um novo modelo neural é desenvolvido para substituir o modelo existente com I-If reduzidas.

TABELA 28: COMPARATIVO ENTRE RESULTADOS DOS COMPRESSORES DE TESTE PARA COMITÊS TREINADOS COM COMPRESSORES SEM E COM DEFEITO

compressor	comitê anterior (W)	I-If (W)	I-If %	novo comitê (W)	I-If (W)	I-If %	diferença entre os modelos %
1	196,6	± 9,5	± 4,8	197	± 10	± 5,1	+0,2
2	202	± 13	± 6,4	203	± 11	± 5,4	+0,5
3	198,1	± 8,3	± 4,2	198	± 8,8	± 4,4	-0,1
4	197,9	± 7,3	± 3,7	198	± 7,2	± 3,6	+0,1
5	234,8	± 9,8	± 4,2	238	± 11	± 4,6	+1,4
6	234,1	± 8,1	± 3,5	233,2	± 9,2	± 3,9	-0,4
7	234,1	± 8,1	± 3,5	233,5	± 8,3	± 3,6	-0,3
8	235,2	± 9,7	± 4,1	236,4	± 9,3	± 3,9	+0,5
9	234,1	± 7,9	± 3,4	234,1	± 8,4	± 3,6	0,0
10	235	± 11	± 4,7	238	± 11	± 4,6	+1,3
11	275	± 15	± 5,5	275	± 14	± 5,1	0,0
12	278	± 14	± 5,0	277	± 13	± 4,7	-0,4

Este capítulo apresentou uma análise sobre a aplicação da proposta para estimar a capacidade de refrigeração integrável à linha de produção de compressores herméticos.

Acerca do estudo de caso, pode se concluir que:

- independentemente dos métodos utilizados nos itens 6.2, 6.3 e 6.4, as indicações de inferência pouco se modificaram entre elas, havendo diferenças significativas somente em relação aos limites da incerteza;
- a inclusão da informação da classe do compressor possibilitou que o modelo neural apresentasse melhores resultados;
- a análise realizada no item 6.2 permitiu verificar que a utilização de um comitê de redes neurais favorece a minimização do erro;
- na análise realizada no item 6.3, os resultados mostraram que as incertezas, obtidas exclusivamente para o modelo neural treinado usando o MMC, foram maiores que os intervalos de confiança apresentados pelo método *bootstrap*, situação indicativa de que as incertezas das medições dos dados de treinamento são mais significativas que a variabilidade dos dados desse conjunto;
- na análise realizada no item 6.4, onde foi aplicada a proposta para expressar a I-If, as incertezas apresentaram valores maiores que aqueles obtidos no item 6.3, indicativo de que existia, até então, incompletude significativa no conjunto de treinamento;
- os compressores ensaiados na linha de produção com diferentes temperaturas podem ser utilizados, com bastante segurança, para contornar os problemas da extrapolação devido à temperatura de ensaio do compressor na linha de produção;
- a aplicação do método de Monte Carlo para propagar as distribuições durante o uso do modelo neural possibilita verificar situações nas quais a RNA esteja submetida à extrapolações em relação ao treinamento;
- a solução proposta neste trabalho se mostra promissora também para a inferência de compressores com capacidade de refrigeração abaixo do esperado;

- as inferências obtidas no estudo de caso, para os compressores do conjunto de teste, apresentaram diferença máxima de 3,2% entre os resultados obtidos em linha e laboratório, sendo o valor típico encontrado de 1% e I-If de aproximadamente $\pm 4,5\%$. Cabe destacar que a norma ISO 917 estabelece que a diferença entre valores de capacidade de refrigeração para um mesmo compressor, obtidos por métodos distintos, não pode ser maior que 4%. Vale destacar também, que as bancadas de laboratório utilizadas para a medição da capacidade de refrigeração neste trabalho possuem IM da ordem de $\pm 3\%$.

7 CONSIDERAÇÕES FINAIS

No âmbito da presente tese de doutorado foi desenvolvido um método para estimar a capacidade de refrigeração de compressores herméticos integrável à linha de produção. O desenvolvimento do trabalho permitiu ao autor chegar a uma série de conclusões, as quais são apresentadas na sequência. Frentes de trabalho que não puderam ser exploradas de forma satisfatória nesta tese são apresentadas como sugestões de trabalhos futuros.

7.1 CONCLUSÕES

7.1.1 QUANTO À REVISÃO BIBLIOGRÁFICA

Durante a realização do levantamento bibliográfico, inúmeros trabalhos que fazem uso de redes neurais artificiais foram encontrados. Isso mostra que essa ferramenta da inteligência artificial vem ganhando espaço nas mais diferentes áreas do conhecimento. Até o presente momento, não foi encontrada na literatura qualquer referência que descreva sistema capaz de estimar a capacidade de refrigeração do compressor através de sua capacidade de elevar a pressão de ar num volume fechado. Aparentemente, o único relato de aplicação dessa técnica de ensaio para estimar a capacidade de refrigeração integrável à linha de produção é o artigo oriundo desta tese (CORAL, 2014). Também não foi encontrado na bibliografia, tanto no que concerne à RNA, como no que diz respeito à avaliação da incerteza de medição, meios para considerar a incerteza dos dados de medição do conjunto de treinamento, o que é necessário para se alcançar resultados mais adequados aos preceitos metrológicos de avaliação da incerteza de medição.

7.1.2 QUANTO À OBTENÇÃO DA CAPACIDADE DE REFRIGERAÇÃO DE FORMA INTEGRÁVEL À LINHA DE PRODUÇÃO

Durante o trabalho foi evidenciado que uma solução que apontasse para os métodos tradicionais de medição da capacidade de refrigeração seria inviável para uma aplicação integrável à linha de produção de compressores herméticos. Nesse sentido, buscou-se uma solução que se afasta do conceito tradicional utilizado em laboratório. Resultados experimentais obtidos neste trabalho confirmaram a validade da tese de que a capacidade do compressor deslocar massa de ar para o interior de um

recipiente fechado, em um determinado intervalo de tempo, pode ser correlacionada com a capacidade de refrigeração desse compressor. Esses resultados também indicaram que a curva de elevação da pressão de ar sobre um pequeno vaso, obtida pela capacidade do compressor realizar esse trabalho em um curto espaço de tempo, é bem comportada e não apresenta aleatoriedade que inviabilize o uso do método. Essas análises permitiram concluir que a partir da capacidade de elevação da pressão é viável obter um modelo capaz de fornecer o valor da capacidade de refrigeração do compressor através de inferências realizadas junto à linha de produção em tempo extremamente reduzido.

7.1.3 QUANTO À AVALIAÇÃO DA INCERTEZA NA APLICAÇÃO DE MODELOS NEURAI

O uso de redes neurais artificiais para a tarefa de estimar a capacidade de refrigeração dos compressores junto à linha de produção exigiu a busca de meios para se estabelecer a incerteza da inferência apresentada pelo modelo neural. Concluiu-se que os métodos encontrados na literatura não abordam os aspectos metrológicos de modo suficiente para a aplicação pretendida. O apêndice E deste documento apresentou experimentos simulados, nos quais os dados obtidos indicaram que quando modelos neurais são formados por dados de medição, tanto os erros aleatórios quanto os erros sistemáticos não compensados podem levar a intervalos de confiança inadequados quando se utiliza um método tradicional, como a reamostragem *bootstrap*. Dados extraídos desses exemplos também possibilitaram a conclusão de que a proposta apresentada nesta tese de doutorado para expressar a incerteza da inferência é mais adequada nas aplicações em que redes neurais são utilizadas em processos metrológicos, pois além de considerar os erros provenientes do processo de aprendizagem, considera também as incertezas das medições durante o treinamento e uso do modelo neural. Cabe ressaltar que o método proposto para expressar a incerteza da inferência não se limita à aplicação abordada nesta tese de doutorado, podendo ser utilizado em qualquer processo de inferência que envolva dados de medição no treinamento e no uso de redes neurais como as utilizadas neste trabalho.

7.1.4 QUANTO AO ESTUDO DE CASO

Resultados experimentais obtidos em uma das linhas de produção da empresa que serviu de estudo de caso forneceram resultados de inferências, para compressores considerados bons, que se desviaram do

valor de laboratório em, no máximo, 3,2%. Tipicamente o desvio encontrado foi de aproximadamente 1% e a incerteza da inferência ficou em torno de $\pm 4,5\%$. Para compressores considerados ruins, o desvio típico em relação ao resultado de laboratório foi de aproximadamente 2%, com incerteza da inferência em torno de $\pm 5,5\%$. Isso com um único exemplo de compressor defeituoso no conjunto de treinamento. Para o lote de compressores testado, a inferência média foi obtida para 100% dos compressores produzidos, já para os testes em laboratório, a amostra ensaiada foi de 5 peças. A diferença encontrada para as médias foi de 0,5%, como uma incerteza da inferência de $\pm 4,0\%$. Para a inferência na linha de produção, o tempo médio foi de 7 segundos, o que representa menos de um milésimo do tempo de ensaio em uma bancada no laboratório. No entanto, para o ensaio em laboratório, caso seja contabilizado o tempo de envio do compressor da linha de produção para o laboratório (que pode levar horas), o tempo de espera na fila para o ensaio (que pode levar dias), o tempo de amaciamento realizado no compressor antes do ensaio (aproximadamente oito horas) e o tempo de preparação do compressor para o ensaio na bancada (incluindo o tempo para a realização de vácuo no sistema), essa comparação na redução do tempo, que já é extremamente significativa, será muito superior. Além disso, o método proposto possibilita expressiva redução de custo em relação aos métodos tradicionais.

O estudo de caso também possibilitou ao autor concluir que é possível melhorar a incerteza da inferência apresentada pelo modelo neural. Tal melhora pode ser obtida pela redução das incertezas dos instrumentos utilizados na linha de produção e pela redução da incerteza de medição da capacidade de refrigeração dos compressores em laboratório. Para as incertezas encontradas na linha de produção, a redução passa pela troca dos instrumentos atualmente utilizados no ensaio de capacidade de elevação da pressão e pela implementação de uma sistemática de calibração e ajuste mais adequada à aplicação pretendida. Para as incertezas na medição da capacidade de refrigeração, a redução pode ser alcançada através de ensaios em painéis que representam o estado da arte na medição da capacidade de refrigeração. Tais painéis possuem incertezas da ordem de $\pm 1\%$ do valor medido.

Por fim, pode-se concluir que todos os objetivos traçados para o trabalho de doutorado foram alcançados.

7.2 SUGESTÕES DE TRABALHOS FUTUROS

Durante a realização deste trabalho foram vislumbradas oportunidades de melhoria. Aquelas que não puderam ser exploradas são apresentadas na sequência como sugestões de trabalhos futuros.

- Nos processos de avaliação de desempenho energético de compressores em laboratório (conhecido no meio industrial por desempenho em calorímetro), além da capacidade de refrigeração, são avaliados também o consumo e o COP. Esses parâmetros são importantes para caracterizar o desempenho dessas máquinas e não puderam ser abordados neste trabalho. Sugere-se explorar meios para realizar inferências junto à linha de produção para a potência elétrica consumida pelo compressor em regime permanente e seu COP.
- Neste trabalho foi proposto procedimento para avaliação da I-If mais adequado do que os métodos encontrados na literatura para estimar IC. Ainda assim, são necessários estudos adicionais além dos realizados nesta tese de doutorado para garantir que essa proposta seja considerada metrologicamente válida, a ponto de se poder afirmar que a I-If seja a IM do método proposto. Propõe-se um estudo investigativo nessa linha de atuação para verificar os limites em que a I-If, obtidas da forma proposta neste trabalho, possam ser consideradas como a IM para a resposta do modelo neural.
- Neste trabalho foi apresentada uma bancada de capacidade de elevação da pressão disponível nas linhas de produção de uma empresa. Propõe-se o desenvolvimento de uma bancada específica, com instrumentos de melhor qualidade metrológica, condições de operação mais bem controladas e com medições de outras grandezas que possam ser relacionadas com parâmetros de desempenho do compressor, como mínima tensão de partida, vibração e potência sonora gerada pelo compressor.

REFERÊNCIAS

- ABDELWAHED, M. S.; EL-BAZ, M. A.; EL-MIDANY, T. T. A proposed performance prediction approach for manufacturing using ANNs. **World Academy of Science, Engineering and Technology**. Vol. 6. Jan. 2012. p. 778 – 783.
- ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Condições de ensaio para determinação da capacidade de refrigeração nominal de compressores herméticos e semi-herméticos para refrigeração**. NBR 13410, Rio de Janeiro, jun. 1995.
- AGUIRRE, L. A.; PINTO, A.; SILVA, A. **Enciclopédia de automática: controle e automação**. 3. ed. São Paulo: Blücher, 2007. 469 p.
- AHMAD, Z.; ZHANG, J. A comparison of different method for combining multiple neural network models. **IEEE**, 2002. Disponível em <<http://nguyendangbinh.org/Proceedings/WCCI/2002/IJCNN02/PDFFiles/Papers/1171.pdf>>, acessado em 12 de dezembro de 2011.
- AIAG Automotive Industry Action Group. **Measurement Systems Analysis – MSA: Reference manual**. 4 th edition, 2010. 240 p.
- AKISHINO, A. S.; FERNANDES, T. S. P. **Manual didático**. introdução a circuitos elétricos. Universidade Federal do Paraná. Departamento de Engenharia Elétrica. 2006, 11 p.
- ALBERTAZZI, A.; SOUSA, A. R. **Fundamentos de metrologia científica e industrial**. Malone, 2008. 407p.
- ALLENDE, H.; ÑANCULEF, R.; SALA, R. **Robust bootstrapping neural networks**. MICAI 2004. Berlin, 2004, p. 813-822.
- ARBIB, M. A. Backpropagation: general principles. **The handbook of brain theory and neural networks**. MIT press, 2003, p. 144-147.
- ARCAKLIOĞLU, E.; ÇAVUŞOĞLU, A.; ERIŞEN, A. Thermodynamic analyses of refrigerant mixtures using artificial neural networks. **Applied Energy**, n 78, 2004, p. 219-230.
- ASHRAE STANDARD. **ANSI/ASHRAE 23-2005: Methods of testing for rating positive displacement refrigerant compressors and condensing units**. Atlanta, EUA, 2005.

BARBOSA, F. Q. **Redução de incertezas nas medições de grandezas elétricas em uma bancada de ensaio de desempenho de compressores.** Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

BARHEN, J. Reduction of uncertainties in neural network prediction of oil well logs. **Proceedings of the IJCNN 02 International Joint Conference on Neural Networks**, 12-17 May 2002.

BARRON, W. R. **Princípios de termometria com infravermelho.** Manual de referência técnica de temperatura. OMEGA, 2014. p. 68-71.

BELLAZZI, R.; ABU-HANNA, A.; HUNTER, J. **Artificial Intelligence in medicine.** 11 th Conference on artificial intelligence in medicine. July, 7-11, 2007. Amsterdam.

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.

BIPM, IEC, IFCC, ILAC, ISO, IUPAC, IUPAP, OIML. **JCGM 200:** International vocabulary of metrology – Basic and general concepts and associated terms. 2008c. 104 p.

BRABANTER, K. DE; BRABANTER, J. DE; SUYKENS, J. A. K. Approximate confidence and prediction intervals for least squares support vector regression. **IEEE Transaction on Neural Networks**. Jan 2011. p 110-120

BRASZA, H. P. Benefits of using neural networks in price & promotional demand forecaster. **Churchill Systems Inc.** white paper #9. 2010.

CARDOSO, R. B. **Avaliação da economia de energia atribuída ao programa selo Procel em freezers e refrigeradores.** Itajubá, 2008. Dissertação (Mestrado em Engenharia da Energia) – Programa de Pós-graduação em Ciências me Engenharia da Energia, Universidade Federal de Itajubá.

CASELLA, A. V. **Ferramenta fuzzy-bayesiana para identificação do instante de entrada no regime permanente em ensaios de desempenho de compressores.** Florianópolis, 2008. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

CHRYSSOLOURIS, G.; LEE, M.; RAMSEY, A. Confidence interval prediction for neural network models. *IEEE Transactions on Neural Networks*, v. 7, i. 1, Jan. 1996.

COLORADO, D.; HERNÁNDEZ, J. A.; HAMZAOUI, Y.; BASSAN, A.; SIQUEIRO, J.; ANDEVERDE, J. 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. p. 1315-1322.

COPPIN, B. **Inteligência artificial.** Rio de Janeiro, LTC, 2012.

CORAL, R.; FLESCHE, C. A.; PENZ, C. A.; BORGES, M. R. Development of a committee of artificial neural networks for the performance testing of compressors for thermal machines in very reduced times. **Metrology and Measurement Systems**, 2014. Manuscrito submetido e aceito.

CORRÊA, L. C. **Validação experimental de um conceito de padrão de capacidade de refrigeração para ensaio de desempenho de compressores.** Florianópolis, 2013. Dissertação (Mestrado em Engenharia Mecânica) - Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

COSTA, E. C. **Refrigeração.** 3. ed. São Paulo. Editora Edgard Blücher, 1982. 321 p.

COSTA, V. M. **Análise das variáveis de entrada de uma rede neural usando teste de correlação e análise de correlação canônica.** São Paulo, 2011. Dissertação (Mestrado em Ciência de Tecnologia Nuclear) – Programa de Pós-graduação em Engenharia em Ciência de Tecnologia Nuclear, Universidade de São Paulo.

DAQSYS. Sistema de teste de compressores: manual do usuário, 2008.

DENCKER, F. A.; LENZI, A.; DIAS, A.. IV Congresso Brasileiro de **Desenvolvimento de Produtos. Detecção de falha na montagem de compressores herméticos por redes neurais artificiais.** Gramado, Brasil, out. 2003, p. 10

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 13771-1:** Compressors and condensing units for refrigeration – Performance testing and test methods – Part 1: Refrigerant compressors. Germany, Aug. 2008

EDWARDS, P. J.; PEACOCK, A. M.; RENSHAW, D.; HANNAH, J. M.; MURRAY, A. F. 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.; TIBSHIRANI, R. An introduction to the bootstrap. Chapman & Hall, NY, 1993. 450 p.

EMBRACO. **Embraco renova sua marca.** Joinville, jul. 2011. Disponível em <http://www.embraco.com/default.aspx?idNoticia=171&tabid=99>> acesso: mar 2013.

ERDOGMUS, H. Diversity and Software Development. **IEEE Software**, vol. 26, no. 3, pp. 2-4, May/June 2009, doi:10.1109/MS.2009.62.

ERTUNC, H. M.; HOSOZ, M. **Artificial neural network analysis of a refrigeration system with an evaporative condenser.** Applied Thermal Engineering. (2005), p. 9

FELÍCIO, L. C. **Modelagem da dinâmica de sistemas e estudo da resposta.** 2ª edição, São Carlos: RiMa 2010. 568 p.

FLESCHE, 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.

FLESCHE, R. C. C.; TORRICO, B. C.; NORMEY-RICO, J. E.; CAVALCANTE, M. U. Unified approach for minimal output dead time compensation in MIMO processes. **Journal of Process Control**, v. 21, n. 7, Aug. 2011, p. 1080-1091.

FLUKE CORPORATION. Calibration: Philosophy in Practice. 2. ed. Everett, WA: Fluke Corporation, Everett, Wa, U.S.A ,1994. 528 p.

FORTUNA, L.; GIANNONE, P.; GRAZIANI, S.; XIBILIA, M. G. 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.

GAVILON, I. **Desenvolvimento de um sistema para avaliação de incertezas em bancadas de ensaio de desempenho de compressores de refrigeração**. Florianópolis, 2008. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

GAYESKI, N. T.; ZAKULA, T.; ARMSTRONG, P. R. **Empirical modeling of a rolling-piston compressor heat pump for predictive control in low lift cooling**. TRNS, oct, 2010.

GEMAN, S.; BIENENSTOCK, E.; DOURSAT, R. Neural networks and the bias/variance dilemma. **Neural Computation**, v. 4, 1992.

GHEYAS, Iffat A.; SMITH, Leslie S.. A Neural Network Approach to Time Series Forecasting. In: WORLD CONGRESS ON ENGINEERING, 2009, London. **Proceedings...** . London: Wce, 2009. v. 2, p. 5.

GHOBIADIAN, 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, 2009, p. 976-982.

GOVINDARAJAN, M.; CHANDRASEKARAN, R. M. Classifier based text mining for neural network. **World Academy of Science, Engineering and Technology**, v. 27, 2007, p. 200-205.

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.

GUPTA, M. M.; JIN, L.; HOMMA, N. **Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory**. John Wiley & Sons, 2003. 722 p.

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.

GUSTAFSON, S.; LITTLE, G. R. Proceedings of AutoTest Conference 92. **Correlation of transient and steady-state compressor performance using neural networks.** United States, 1992. p. 4.

GOMES, G. S. da S.; LUDERMIR, T. B. Redes neurais artificiais com funções de ativação complement log-log e probit para aproximar funções na presença de observações extremas. **Learning and Nonlinear Models**, vol. 6 n. 2, 2008. p. 142-153.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward network with Marquadt algorithm. **IEEE Transaction on neural network**, vol 5, n. 6, nov. 1994. p. 989 – 992.

HANSEN, L. D.; HART, R. M. **The art of calorimetry.** Departamento de Química e Bioquímica. University of Brigham Young. EUA, 2003.

HASHEM, S.; ASHOUR, Z.H.; ABDEL GAWAD, E.F.; ABDEL HAKEEM, A. IJCNN '99. International Joint Conference on Neural Networks, 1999. **A novel approach for training neural networks for long-term prediction.** volume 3, 10-16 July 1999 p. 6

HAYKIN, S. **Neural Networks: a comprehensive foundation**, NJ: Pearson Education, 1999.

HECKMANN, J. R. **Identificação de potenciais aplicações da inteligência artificial na metrologia.** Florianópolis, 1999. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

HENKLEIN, P. **Análise de ensaios de desempenho de compressores herméticos durante o transitório.** Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

HIGGINS, J. **The radical statistician.** 5th edition. 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.

INMETRO – INSTITUTO NACIONAL DE METROLOGIA, NORMALIZAÇÃO E QUALIDADE INDUSTRIAL. **Vocabulário internacional de metrologia**: Conceitos fundamentais e gerais e termos associados – Versão Brasileira do “International Vocabulary of Metrology - Basic and general concepts and associated terms” 1a ed. Brasileira do VIM 2008, Rio de Janeiro, 2009. 92 p.

INMETRO. **Sistema internacional de unidades – SI**. 8. ed. (revisada), Rio de Janeiro. 2007. 114 p.

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. Geometrical product Specifications (GPS) – Inspection by measurement of workpieces and measuring equipment. Part 1 Decision rules for Proving Conformance or Non-conformance with Specifications. **ISO 14253-1**, 1a. ed. nov.1998. 14 p

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO/IEC 17025**: General requirements for the competence of testing and calibration laboratories. 2nd ed. Switzerland, 2005.

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 917**: Testing of refrigerant compressors. 2. ed. Switzerland, 1989.

ISO/ABNT – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. Sistemas de gestão da medição: Requisitos para os processos de medição e equipamento de medição. **NBR/ISO 10012**, 1a. ed. Abr 2004. 26 p.

ISO. INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. Sistemas de gestão da qualidade: Requisitos. Tradução. **ISO 9001**, nov. 2008. 46 p.

KHAWAJA, T.; VACHTSEVANOS, G.; WU, B. Reasoning about uncertainty in prognosis: a confidence prediction neural network approach. **Annual Meeting of the North American Fuzzy Information Processing Society**, June 2005.

KIM, T.; LI, C. J. Feedforward neural networks for fault diagnosis and severity assessment of a screw compressor. **Mechanical Systems and Signal Processing**. v.9, n. 5, 1995, p. 485-496.

KÓVACS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. 4. ed., São Paulo, editora Livraria da Física, 2006.

KUEHN, T. H.; RAMSEY, J. W.; THRELKELD, J. L. **Thermal environmental engineering**. Editor Prentice Hall, New Jersey. Third edition. 1998.

LIMA, L. C. A. **Controle da alimentação elétrica para a redução de tempo demandado por ensaios de desempenho de compressores e avaliação da influência da qualidade de energia elétrica nos resultados dos ensaios**. Florianópolis, 2010b. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

LIMA, V. R. **Desenvolvimento e avaliação de sistema neural para redução de tempo de ensaio de desempenho de compressores**. Florianópolis, 2010a. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

LIRA, S. A. **Efeitos do erro amostral nas estimativas dos parâmetros do modelo fatorial ortogonal**. Curitiba, 2008. Tese (Doutorado em Ciências) – Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná.

MARINS, E.F.; FLESCHE, C.A.; FLESCHE, R.C.; BORGES, M. R. Conception of a bench to generate known and controlled condition of refrigerant mass flow. ISA Transactions, 2011. p. 513-520.

MATHWORKS. **Neural networks toolbox – user’s manual**. Versão 5, 2007.

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

MICHAELIS. Dicionário eletrônico on-line da língua portuguesa. Editora Melhoramentos, 2011. Disponível em <<http://michaelis.uol.com.br/>>, acesso em 19/11/2011.

MIDANY, T. T. El; BAZ, M. A. El; ADBELWAHED, M. S. Improve characteristics of manufactured products using artificial neural network performance prediction model. **IJMECH**, vol 2. n. 4. Nov. 2013.

MINITAB. **User manual**. Versão 16, 2010.

MME – MINISTÉRIO DE MINAS ENERGIA. **Plano nacional de eficiência energética**. Brasília, out. 2011.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. Tradução de Verônica Calado. Editora LTC, Rio de Janeiro, 2003.

MOSCATI, G.; MEZZALIRA, L. G.; SANTOS, F. D. Incerteza de medição pelo método de monte carlo no contexto do “Suplemento 1” do GUM. ENQUALAB, jun, 2004.

NAVARRO, E.; URCHUEGUÍA, J. F.; GONZÁLVEZ, J.; CORBERÁN, J. M. Test results of performance and oil circulation rate of commercial reciprocating compressors of different capacities working with propane (R290) as refrigerant. **International Journal of Refrigeration**, 28(6), 2005, p. 881–888.

NETO, A. C. R.; NEVES, C. A. M.; ROISEMBERG, M. Comparative study on local and global strategies for confidence estimation in neural networks and extensions to improve their predictive power. *Neural Comput & Applic*, 2012.

NI – National Instruments Corporation. NI 6030E/6031E/6032E/6033E/ family specifications. User manual. Dec. 2005.

NYGREN, K. **Stock prediction: a neural network approach**. 2004. Master thesis. – Royal Institute of Technology, KTH.

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.

PENZ, C. A. **Procedimentos para prover confiabilidade ao uso de inteligência artificial em ensaios de desempenho de compressores herméticos de refrigeração**. Florianópolis, 2011. Tese (Doutorado em Engenharia Mecânica) – Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina.

PERILLO, S. R. P. **Determinação do tempo de resposta de transdutores de pressão utilizando o método da medida direta**. São Paulo, 1994. Dissertação (Mestrado em Ciências na Área de Reatores Nucleares de Potência e Tecnologia de Combustível Nuclear) – Universidade de São Paulo.

PETROVICIC, S. A. B. **Proposta de arquitetura do sistema de automação aplicado a ensaios de desempenho de compressores herméticos de refrigeração.** Florianópolis, 2007. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

POLETTI, E. L. **Aprimoramento de uma bancada de ensaios de desempenho de compressores herméticos visando reduzir incertezas de medição.** Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

PORKHIAL, S; KHASTOO, B; MODARRES RAZAVI, M.R. Transient characteristic of reciprocating compressors in household refrigerators. **Applied Thermal Engineering**, v. 22, 2002. 13 p.

RUSSEL, S.; NORVIG, P.; **Inteligência artificial.** Rio de Janeiro, Elsevier, 2013.

SCUSSEL, J. N. **Proposta de ações para reduzir o tempo demandado por ensaio de desempenho de compressores.** Florianópolis, 2006. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

SHARKEY, A.J.C. **Combining artificial neural networks: ensemble and modular multi-net systems.** London: Springer-Verlag, 1999.

SILVA JR, H. X. **Aplicação das metodologias de análise estática e de análise do custo de vida (ACCV) para o estabelecimento de padrões de eficiência energética: Refrigeradores Brasileiros.** Campinas, 2005. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-graduação em Eng. Mecânica, Universidade Estadual de Campinas.

SILVA, J. G. **Introdução à tecnologia da refrigeração e da climatização.** São Paulo. Editora Artliber. 2003.

SILVEIRA, A. N. **Diminuição do tempo de transitório em ensaios de desempenho de compressores utilizando injeção de corrente contínua.** Florianópolis, 2010. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

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, sep. 2011, p 337-345.

STEINBACH, K. **Identificação do instante de entrada em condições de regime permanente em ensaios de desempenho de compressores**. Florianópolis, 2008. Dissertação (Mestrado em Metrologia Científica e Industrial) – Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.

STOECKER, W. J.; JABARDO, J. M. S. **Refrigeração industrial**. 2. ed. São Paulo: Edgard Blücher, 2002. 371 p.

SUMATHI, S.; PANEERSELVAN, S. **Computational intelligence paradigms: theory & applications using Matlab**. CRC Press, 2009, 829 p.

SVOZIL, D.; KVASNIČKA, V.; POSPÍČHAL, J. Introduction to multi-layer feed-forward neural networks. **Chemometrics and Intelligent Laboratory Systems**, v. 39, June, 1997, p. 43-62.

SWIDER, D. J.; BROWNE, P. K.; BANSAL, V. Modelling of vapour-compression liquid chillers with neural networks. **Applied Thermal Engineering**, n. 21, 2001, p. 311-329

TIBSHIRANI, R. A comparison of some error estimates for neural network models. Department of Preventive Medicine and Biostatistics, University of Toronto, 1994.

TRANSTEC. Transdutor de pressão HMI 2310: especificações. São Paulo. 2014.

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; SCHWEINSBERG, J.; SCHUMI, J.; UNGAR, L. H. Prediction intervals for neural networks via nonlinear regression. **Technometrics**, v. 40, n. 4, Nov. 1998.

WATANABE, J.; YAMAMOTO, J. K.; ROCHA, M. M.; FONSECA, P. P. Estudo da influência da correlação inicial entre variáveis nos resultados de co-estimativas. **Geociências**, v. 8, n. 4, UNESP – São Paulo, 2009, p. 467-484.

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.

WYLEN, G. VAN; SONNTAG, R. BORGNACKE, C. **Fundamentos da termodinâmica clássica**. 4ª edição traduzida. Editora Edgard Blücher. 1995, 589 p.

YANG, B. S.; HWANG, W. W.; KIM, D. J.; TAN, A. C. **Condition classification of small reciprocating compressor for refrigerators using artificial neural networks and support vector machines**. Mechanical Systems and Signal Processing 19 (2005), 371 – 390 2005 p. 20.

YU, H Yu; WILAMOWSKI, B. M. “Levenberg–Marquardt Training” **Industrial Electronics Handbook**, vol. 5 – Intelligent Systems, 2nd Edition, 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.

ZAPRANIS, A. LIVANIS, E. Prediction intervals for neural network models. In Proceedings of the 9th WSEAS International Conference on Computers (Athens, Greece, July 14 – 16, 2005). N. E. Mastorakis, Ed. World Scientific and Engineering Academy and Society (WSEAS), Stevens Point, Wisconsin, 1-7.

ZHANG, J. Developing robust non-linear models through bootstrap aggregated neural networks. **Neurocomputing**, v. 25, 1999. 11 p.

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 – CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR E COMPRESSORES HERMÉTICOS DE REFRIGERAÇÃO

Um sistema de refrigeração pode ser definido como um conjunto de elementos operando de forma integrada com o objetivo de transferir calor de um ambiente de menor temperatura para um de temperatura maior, operando de modo contrário ao comportamento natural de transferência de calor, o que torna necessário uma fonte externa de energia para realização desse processo (SCUSSEL, 2006; POLETTO, 2006). Existem diferentes sistemas de refrigeração, entre eles podemos destacar sistemas de refrigeração por absorção, termoelétrico e por ciclo de compressão de vapor (SILVA, 2003; WYLEN, 1995), sendo este último o mais empregado (KUEHN, 1998).

O ciclo de refrigeração por compressão de vapor é assim chamado, pois, tanto o calor retirado do ambiente de menor temperatura como o calor cedido para o de maior temperatura, ocorre através do calor envolvido nas mudanças de fases (calor latente³⁸) do fluido refrigerante que circula pelo sistema (COSTA, 1982). Desse modo, o compressor atua como elemento que desloca o fluido refrigerante através do circuito. Isso ocorre através da compressão do refrigerante na forma de vapor.

A vantagem de se resfriar um ambiente utilizando mudança de fase, reside no fato do calor latente ser muito maior que o calor sensível³⁹. Essa vantagem reflete-se principalmente no dimensionamento do compressor, que pode ser significativamente menor na primeira situação em relação à segunda (COSTA, 1982).


Para sistemas de refrigeração, o conhecimento dos parâmetros de todos os elementos envolvidos no circuito é imprescindível para o correto dimensionamento. Assim, tendo o compressor como único elemento ativo⁴⁰ do sistema, a medição de seus parâmetros de desempenho é ainda mais significativa.

³⁸ Calor latente – calor associado com uma mudança de fase de uma substância em temperatura constante (KUEHN, 1998 p. 12).

³⁹ Calor sensível – calor adicionado a uma substância resultando em um aumento de temperatura da mesma (KUEHN, 1998 p. 12).

⁴⁰ Elemento ativo – elemento que fornece potência para o circuito (AKISHINO, 2006).

A figura 47 ilustra o ciclo de refrigeração por compressão de vapor de modo mais detalhado.



legenda:

Q_a - calor absorvido

Q_r - calor rejeitado

P_{el} - potência elétrica

1 - região de baixa pressão e vapor superaquecido

2 - região de alta pressão e vapor superaquecido

3 - região de alta pressão e líquido subresfriado

4 - região de baixa pressão e líquido superaquecido

FIGURA 47: CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR

Um circuito de refrigeração pode ser resumido em seis elementos básicos: compressor, condensador, dispositivo de expansão, evaporador, tubulações e o fluido refrigerante (SCUSSEL, 2006). Na figura 47 esses elementos são apresentados em um circuito fechado para mostrar como se dá o ciclo de refrigeração. O funcionamento ocorre da seguinte forma:

- 1 – o ciclo inicia na região 1 com o refrigerante a baixa pressão (pressão de evaporação) e no estado de vapor saturado e superaquecido, dado a absorção de calor proveniente da passagem pelo evaporador;
- 1→2 – o refrigerante é então sucionado pelo compressor e comprimido ainda no estado de vapor saturado e superaquecido, passando então para a região 2;

- 2 – na região 2 o refrigerante encontra-se a alta pressão (pressão de condensação) e no estado de vapor saturado e superaquecido, porém a uma temperatura mais alta do que a região anterior, devido ao processo de compressão;
- 2→3 – na passagem para a região 3 o refrigerante atravessa o condensador, onde é resfriado, liberando assim o calor absorvido no evaporador e também no processo de compressão;
- 3 – na região 3 o refrigerante encontra-se a alta pressão (pressão de condensação) e no estado de líquido saturado e subresfriado, mantendo assim a mesma pressão da região anterior, mas não a mesma temperatura;
- 3→4 – o refrigerante passa então pelo dispositivo de expansão com o intuito de baixa a pressão e consequentemente baixando sua temperatura nesse processo;
- 4 – na região 4 o refrigerante encontra-se a baixa pressão (pressão de evaporação) e no estado de líquido saturado, neste ponto qualquer acréscimo de calor fará com que o fluido mude do estado líquido para o estado de vapor;
- 4→1 – na passagem da região 4 para a região 1, o refrigerante passa do estado de líquido saturado, para o estado de vapor saturado, essa mudança ocorre sobre condições constantes de temperatura e pressão, sendo que o calor é absorvido do ambiente exclusivamente pela mudança de estado do fluido, e o ciclo é iniciado novamente ao final dessa passagem.

COMPRESSORES HERMÉTICOS DE REFRIGERAÇÃO

Existem diferentes tipos de compressores destinados a refrigeração por compressão de vapor. Em geral podem ser divididos em rotativos e alternativos (SCUSSEL, 2006; COSTA, 1982). Para um determinado sistema de refrigeração, a escolha do compressor depende muito da capacidade de refrigeração e também do fluido refrigerante a ser utilizado (COSTA, 1982).

O compressor alternativo é, sem dúvida, o mais aplicado à refrigeração doméstica, de condicionadores de ar e refrigeração industrial (STOECKER, 2002). Este trabalho apresentará uma breve abordagem

dos compressores herméticos alternativos. Pois, além de serem os mais utilizados em sistemas de refrigeração, também são utilizados como estudo de caso neste documento.

Compressores alternativos possuem essa denominação dado o movimento alternativo⁴¹ utilizado na compressão (SILVA, 2003). Em geral são compressores a pistão, podendo possuir um ou mais deles (COSTA, 1982). Eles possuem uma câmara de compressão, um pistão conectado ao eixo de um motor através de uma biela⁴², o qual converte o movimento rotativo do motor em movimento linear, o que permite o fluxo do fluido refrigerante através das válvulas. O princípio de funcionamento da compressão do fluido refrigerante pode ser observado na figura 48, que mostra os cinco estágios para a compressão do fluido refrigerante em um mesmo pistão.




FIGURA 48: ESTÁGIOS DE COMPRESSÃO PROPORCIONADO PELO PISTÃO DE UM COMPRESSOR ALTERNATIVO DE REFRIGERAÇÃO (SILVEIRA, 2010)

⁴¹ Movimento alternativo – movimento que se realiza ora num sentido e ora noutro, com regularidade (MICHAELLIS, 2011).

⁴² Existem compressores alternativos que fazem uso de motores lineares, dispensando desse modo o sistema de biela ou mecanismo scotch-yoke. Porém, mantém o mesmo princípio de funcionamento de compressão do fluido refrigerante.

As etapas de compressão são:

- Etapa A – o pistão se encontra no curso máximo, ficando assim o mais próximo da placa de válvulas de sucção e descarga. É possível notar que existe um pequeno volume dentro da câmara de compressão; isso porque o pistão não toca na placa de válvulas. A esse volume é dado o nome de volume morto. Nessa etapa não existe nenhum deslocamento de fluido;
- Etapa B – com o movimento do pistão no sentido descendente⁴³, inicia-se a expansão do fluido que se encontrava no volume morto da câmara de compressão. A expansão desse termina, em tese, no momento em que a pressão no interior da câmara de compressão, se iguala a pressão externa do terminal de sucção. É possível notar que nessa etapa não existe nenhum deslocamento de fluido para o interior da câmara de compressão;
- Etapa C – com o pistão ainda em movimento descendente, a pressão no interior da câmara de compressão torna-se menor que a pressão externa do terminal de sucção, o que propicia a abertura da válvula desse terminal, permitindo o deslocamento do fluido refrigerante para o interior da câmara;
- Etapa D – com a chegada do pistão ao seu curso mínimo, o movimento muda de sentido e é iniciado o processo de compressão do fluido. A válvula de sucção fecha-se devido ao aumento da pressão no interior da câmara, pois essa é maior que a pressão externa ao terminal de sucção, evitando que o refrigerante volte por esse caminho. Durante o processo de compressão a válvula de descarga permanece fechada até o momento em que a pressão no interior da câmara de compressão se iguale a pressão externa do terminal de descarga. É possível notar que nessa etapa não existe nenhum deslocamento de fluido para o exterior da câmara de compressão;
- Etapa E – com o pistão ainda se deslocando no sentido da placa de válvulas, a pressão fica maior que a pressão

⁴³ Foi adotado o termo movimento descendente para melhor entendimento da figura, porém na prática, o pistão não necessariamente se encontra na posição mostrada na figura.

externa ao terminal de descarga, permitindo assim que a válvula de descarga abra e o fluido se desloque para fora pelo terminal de descarga até que o pistão chegue ao seu curso máximo, iniciando novamente o ciclo de compressão.

A figura 49 apresenta um modelo de compressor hermético alternativo utilizado largamente em ciclos de refrigeração por compressão de vapor (STOECKER, 2002). É possível notar que o motor elétrico encontra-se no mesmo ambiente do sistema de compressão, o que permite o contato dele com o óleo de lubrificação do sistema mecânico e do fluido proveniente do terminal de sucção, desse modo auxilia no resfriamento do motor, porém o compressor perde eficiência devido ao aquecimento do refrigerante promovido pelas perdas elétricas dos enrolamentos (SILVEIRA, 2010; STOECKER, 2002).





FIGURA 49: COMPRESSOR HERMÉTICO DE REFRIGERAÇÃO (SCUSSEL, 2006)

Em um ciclo de refrigeração, o compressor tem como função principal levar o fluido que se encontra de a baixa pressão (pressão de evaporação) para alta pressão (pressão de condensação), e consequentemente realizar a movimentação de massa do refrigerante durante esse processo. O fluido refrigerante é o meio de transporte de energia entre os trocadores de calor (SCUSSEL, 2006).

APÊNDICE B – MÉTODOS DE ENSAIO DE DESEMPENHO DE COMPRESSORES APRESENTADOS PELA NORMA ISO 917

Esse apêndice apresenta os sete métodos de ensaio de desempenho de compressores da norma ISO 917 (ISO, 1989), os quais não foram apresentados no item 2.1. Os métodos aparecem na ordem com que a norma os apresenta.

MÉTODO B: CALORÍMETRO INUNDADO



Legenda:

f_1, g_1 – pontos de medição de entalpia

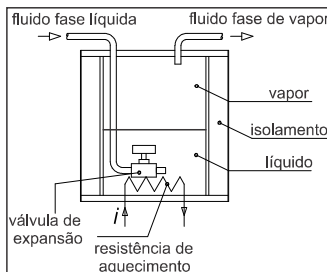
f – fluido refrigerante em fase líquida

g – fluido refrigerante em fase gasosa

1 – variáveis lidas próximo ao compressor

2 – variáveis lidas próximo ao calorímetro

(a) - diagrama do circuito



(b) - calorímetro inundado

FIGURA 50: CALORÍMETRO INUNDADO.

O método do calorímetro inundado, assim como o método do calorímetro de fluido secundário, consiste em um ciclo de refrigeração por compressão de vapor, só que a evaporação do refrigerante ocorre dentro do vaso de pressão, e não em uma serpentina isolada, inexistindo


assim fluido secundário. Deste modo o vaso de pressão, que deve ser termicamente isolado, é o próprio evaporador do sistema de refrigeração, na qual o fluido refrigerante entra no mesmo na fase líquida e expande ali dentro, passando assim para a fase de vapor saturado ainda dentro do vaso, como é possível visualizar na figura 50 (a) e (b). Nesse método a resistência de aquecimento fica imersa no fluido refrigerante depositado no inferior do vaso, por esse motivo recebe a denominação de calorímetro inundado.

Nesse método, o balanço de energia depende da medição da energia entregue pela resistência ao o trocador e as demais variáveis que devem ser controladas e monitoradas, permitindo assim obter a vazão mássica através da equação (3) (pág.49) e a capacidade de refrigeração através da equação (1) (pág. 47). Medindo a potência elétrica consumida pelo compressor também é possível determinar o COP do mesmo.

MÉTODO C: CALORÍMETRO A SECO

Para o método do calorímetro a seco também é necessário a implementação de um ciclo completo de refrigeração por compressão de vapor. O princípio de funcionamento do circuito é o mesmo que os apresentados nos métodos A e B, diferindo apenas no modo como é realizada a troca de calor necessário para fazer o fluido refrigerante passar do estado líquido para vapor saturado. No método de calorímetro a seco, o fornecimento de calor deve ser realizado por meio de uma resistência, o que permite a presença de um evaporador, mas elimina a necessidade do fluido secundário. A resistência deve estar em contato direto com o evaporador e disposta de tal forma que possa permitir uma boa troca de calor entre ambos, como ilustrado na figura 51 (b). Também deve haver isolamento térmico entre os trocadores de calor e o ambiente externo, de modo a minimizar as perdas.

Do mesmo modo que nos métodos A e B, para esse, o balanço de energia depende da medição da energia entregue pela resistência ao o trocador e as demais variáveis que devem ser controladas e monitoradas, permitindo assim obter a vazão mássica através da equação (3) (pág.49) e a capacidade de refrigeração através da equação (1) (pág. 47). Medindo a potência elétrica consumida pelo compressor também é possível determinar o COP do mesmo.



Legenda:

f_i, g_i – pontos de medição de entalpia;


f – fluido refrigerante em fase líquida;

g – fluido refrigerante em fase gasosa;

1 – variáveis lidas próximo ao compressor;

2 – variáveis lidas próximo ao calorímetro.

(a) - diagrama do circuito



(b) - calorímetro a seco

FIGURA 51: CALORÍMETRO A SECO.

MÉTODO D2: MEDIÇÃO DO FLUXO DE MASSA DE VAPOR DE REFRIGERANTE

Nesse método, o fluxo de massa, necessário para o cálculo da capacidade de refrigeração do compressor através da equação (1) (pág. 47), se dá por meio da medição direta de vapor do refrigerante na linha de descarga do mesmo (método D2 – figura 52). Desse modo, não é necessário o balanço de energia como realizado através de calorímetro.

Para ensaios com esse método, é necessário um meio de impor a pressão de trabalho adequada no terminal de descarga do compressor, e um meio de reduzi-la à pressão de trabalho adequada no terminal de

sucção. Para esse método não é necessário que o refrigerante mude de fase, podendo o mesmo se manter sempre no estado de vapor. Porém, a medição deve ser isenta de óleo proveniente do compressor. Para a determinação do COP, basta medir a potência elétrica consumida pelo compressor.


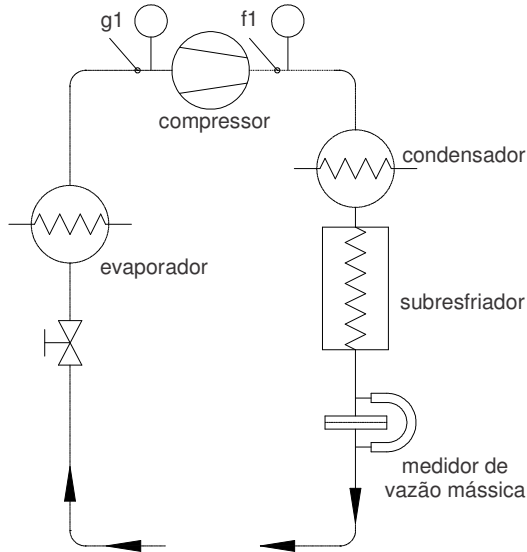


FIGURA 52: MEDIÇÃO FLUXO DE MASSA NA LINHA DE DESCARGA DO COMPRESSOR

MÉTODO F: MEDIÇÃO DE FLUXO DE MASSA NA FASE LÍQUIDA

Para esse método, o fluxo de massa do fluido refrigerante é medido na fase líquida, o que requer obrigatoriamente a implementação de um ciclo completo de refrigeração por compressão de vapor. Isso se deve à necessidade de mudança de fase do refrigerante, devido à impossibilidade de se determinar a capacidade do compressor com o mesmo trabalhando com o fluido na fase líquida. Deste modo, o medidor de vazão mássica é colocado após o condensador, e para impedir a presença de qualquer bolha de refrigerante na fase de vapor, o fluido é subresfriado. A capacidade de refrigeração do compressor é dada através da equação (1) (pág. 47). Deve existir uma boa separação do óleo proveniente do compressor e medindo-se a potência consumida pelo compressor é possível determinar o COP.



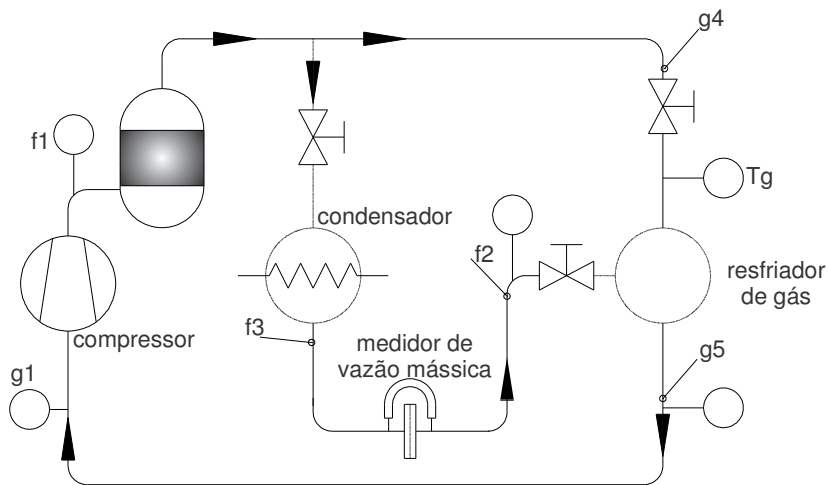
Legenda:

- f_i, g_i – pontos de medição de entalpia;
- f – fluido refrigerante em fase líquida;
- g – fluido refrigerante em fase gasosa;
- l – variáveis lidas próximo ao compressor.

FIGURA 53: MEDIÇÃO DE FLUXO DE MASSA NA FASE LÍQUIDA DO REFRIGERANTE

MÉTODO G: CONDENSADOR RESFRIADO A ÁGUA

O método do condensador resfriado a água, possui a mesma concepção apresentadas para os métodos de calorímetro, onde o fluxo de massa é determinado pelo balanço de energia envolvida na mudança de fase do fluido refrigerante. Porém, para esse método, o balanço é realizado no condensador, quando o refrigerante está entregando calor para o ambiente. Assim, conhecendo o fluxo de massa e a temperatura de entrada e saída da água no trocador de calor, é possível determinar o fluxo de massa do fluido refrigerante. Conseqüentemente é possível determinar a capacidade de refrigeração do compressor através da equação (1) (pág. 47) e, da mesma forma que os outros métodos, o COP pode ser determinado através da medição da potência elétrica consumida pelo compressor.



Legenda:

f_i, g_i – pontos de medição de entalpia;
 f – fluido refrigerante em fase líquida;
 g – fluido refrigerante em fase gasosa;
 1 – variáveis do fluido de trabalho próximo ao compressor;
 2, 4 – variáveis do fluido de trabalho na entrada do resfriador;
 3 – variáveis do fluido de trabalho na saída do condensador;
 5 – variáveis do fluido de trabalho na saída do resfriador;
 T_g – temperatura do fluido refrigerante em fase gasosa.

FIGURA 54: CONDENSADOR RESFRIADO A ÁGUA

Para esse método o fluxo de massa é dado por:

$$q_{mf} = \frac{c(T_2 - T_1)q_{mc} + F_l(T_r - T_a)}{h_{g3} - h_{f3}} \quad (29)$$

Onde:

q_{mf}	Fluxo de massa do fluido refrigerante	[kg/s];
c	Calor específico da água	[J/(kg.K)];
T_1	Temperatura de entrada no trocador	[K];
T_2	Temperatura de saída do trocador	[K];
q_{mc}	Fluxo de massa de água no condensador	[kg/s];
F_l	Fator de perda	[W/K];
T_r	Temperatura de saturação do líquido	[K];

T_a	Temperatura ambiente	[K];
h_{g3}	Entalpia específica do vapor de refrigerante entrando no condensador	[J/kg];
h_{f3}	Entalpia específica do líquido de refrigerante saindo do condensador	[J/kg].

MÉTODO J: RESFRIAMENTO PARCIAL DO VAPOR DE REFRIGERANTE




FIGURA 55: RESFRIAMENTO PARCIAL DO VAPOR DE REFRIGERANTE

Neste método, apenas uma parte do refrigerante é condensada e muda para a fase líquida, a outra parte, que continua na fase de vapor, passa por uma válvula que diminui a pressão e segue para o resfriador, onde junta-se novamente com a parcela que foi condensada. No resfriador a parcela na fase líquida muda novamente de fase, absorvendo calor do refrigerante não condensado e superaquecido, resfriando assim todo o sistema. Após a correção das perdas, a razão entre o fluido refrigerante condensado e o não condensado, é o inverso da razão das entalpias específicas dos dois fluxos misturados no resfriador.

Com o controle e a medição das variáveis do sistema, a capacidade de refrigeração pode ser encontrada através da equação (1) (pág. 47), com o fluxo de massa dado pela equação (30).

$$q_{mf} = q_{ml} \left[1 + \frac{(h_{g5} - h_{f2}) - F_l/q_{ml} (T_a - T_f)}{(h_{g4} - h_{g5})} \right] \quad (30)$$

Onde:


q_{mf}	Fluxo de massa do fluido refrigerante	[kg/s];
q_{ml}	Fluxo de massa do refrigerante na fase líquida	[kg/s];
h_{g5}	Entalpia específica do vapor de refrigerante resfriado saindo do trocador	[kJ/kg];
h_{f2}	Entalpia específica do refrigerante líquido entrando na válvula de expansão	[kJ/kg];
F_l	Fator de perda	[W/K];
T_a	Temperatura ambiente	[K]
T_f	Temperatura de saturação correspondente a pressão de descarga do compressor	[K];
T_a	Temperatura ambiente	[K];
h_{g4}	Entalpia específica do vapor de refrigerante entrando no trocador	[J/kg].

MÉTODO K: CALORÍMETRO NA LINHA DE DESCARGA

A diferença do método do calorímetro na linha de descarga para os outros métodos apresentado com calorímetro, é que nesse caso não ocorre mudança de fase do fluido refrigerante no interior do calorímetro. O trocador de calor é inserido na linha de descarga do compressor logo após o separador de óleo e por ele passa o refrigerante como vapor superaquecido, como pode ser observado na figura 56. Pelo trocador circula fluido capaz de esfriar ou aquecer o refrigerante proveniente do compressor. Nesse método, a temperatura mais baixa que pode ser imposta no interior do calorímetro, deve ficar acima da temperatura de condensação, evitando assim condensação do refrigerante no interior do calorímetro. Para esse método, também não existe a necessidade de mudan-

ça de fase do fluido refrigerante, mas o fluido refrigerante deve ser condicionado novamente antes da sucção pelo compressor.

Do mesmo modo que os métodos A, B e C, o fluxo de massa, necessário para o cálculo da capacidade de refrigeração do compressor através da equação (1) (pág. 47), se dá por meio do balanço energético da quantidade de calor trocado no interior do calorímetro pela diferença de entalpias entre a entrada e a saída do mesmo.



Legenda:

- f_i, g_i – pontos de medição de entalpia;
- f – fluido refrigerante em fase líquida;
- g – fluido refrigerante em fase gasosa;
- 1 – variáveis do fluido de trabalho próximo ao compressor;
- 6,7 – variáveis do fluido de trabalho próximas ao calorímetro;
- T¹ – temperatura do fluido de arrefecimento ou aquecimento na saída;
- T² – temperatura do fluido de arrefecimento ou aquecimento na saída.

FIGURA 56: CALORÍMETRO NA LINHA DE DESCARGA

O fluxo de massa é obtido pela equação (31)

$$q_{mf} = \frac{q_{ml}c(T_2 - T_1) + F_l(T_c - T_a)}{h_{g6} - h_{g7}} \quad (31)$$

Onde:

- | | | |
|----------|---|---------|
| q_{mf} | Fluxo de massa do fluido refrigerante | [kg/s]; |
| q_{ml} | Fluxo de massa de fluido de aquecimento ou resfriamento | [kg/s]; |
| c | Calor específico do fluido de aquecimento ou resfriamento | [kJ/K]; |

T_1	Temperatura de entrada no calorímetro do fluido de aquecimento ou resfriamento	[K];
T_2	Temperatura de saída do calorímetro do fluido de aquecimento ou resfriamento	[K]
F_l	Fator de perda	[W/K];
T_a	Temperatura ambiente	[K];
T_c	Temperatura do corpo de calorímetro	[K];
h_{g6}	Entalpia do refrigerante entrando no calorímetro	[kJ/kg];
h_{f2}	Entalpia do refrigerante saindo do calorímetro	[kJ/kg].

APÊNDICE C - RESULTADO DA REGRESSÃO DA CAPACIDADE DE REFRIGERAÇÃO VERSUS OS RESULTADOS DOS ENSAIOS DE LINHA DE PRODUÇÃO

Regression Analysis: Capacidade_r versus Capacidade_e; consumo_linh; ...

The regression equation is

$$\text{Capacidade_refrig} = 81 + 0,0527 \text{ Capacidade_elev} + 1,00 \text{ consumo_linha} \\ + 1,09 \text{ temperatura} + 0,043 \text{ bl_rf_total} - 0,607 \text{ bl_rp_total}$$

Predictor	Coef	SE Coef	T	P
Constant	81,0	106,7	0,76	0,451
Capacidade_elev	0,05272	0,01513	3,48	0,001
consumo_linha	1,0002	0,2685	3,73	0,000
temperatura	1,0885	0,3584	3,04	0,004
bl_rf_total	0,0434	0,9848	0,04	0,965
bl_rp_total	-0,6070	0,6605	-0,92	0,362

S = 14,7958 R-Sq = 82,3% R-Sq(adj) = 80,5%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	5	51767	10353	47,29	0,000
Residual Error	51	11165	219		
Total	56	62932			

Source	DF	Seq SS
Capacidade_elev	1	44324
consumo_linha	1	5332
temperatura	1	1918
bl_rf_total	1	8
bl_rp_total	1	185

Best Subsets Regression: Capacidade_r versus Capacidade_e; consumo_linh; ...

Response is Capacidade_refrig

Vars	R-Sq	R-Sq(adj)	Mallows		S	C a p c a o c n t b b i s e l l d u m _ _ a m p r r d o e f p e _ r _ _ _ l a t t e i t o o l n u t t e h r a a v a a l l
			C-p	S		
1	74,2	73,8	21,1	17,173		X
1	70,4	69,9	32,0	18,394		X
2	78,9	78,1	9,6	15,680		X X
2	76,9	76,0	15,5	16,422		X X
3	82,0	80,9	2,9	14,639		X X X
3	79,0	77,8	11,3	15,778		X X X
4	82,3	80,9	4,0	14,653		X X X X
4	82,0	80,6	4,8	14,774		X X X X
5	82,3	80,5	6,0	14,796		X X X X X

APÊNDICE D – MÉTODOS DE AVALIAÇÃO DA INCERTEZA DE MEDIÇÃO

A qualidade do resultado de uma medição de uma determinada grandeza física é dada por sua incerteza de medição (IM), que é definida no Vocabulário Internacional Metrologia (BIPM, 2008c) como: parâmetro, associado ao resultado de uma medição, que caracteriza a dispersão dos valores que podem ser razoavelmente atribuídos ao mensurando⁴⁴. A IM é uma faixa de valores que indica, com certo grau de probabilidade, onde se espera que o valor verdadeiro do mensurando esteja. Dessa maneira, a IM reflete a falta de conhecimento sobre o exato valor da grandeza e deve sempre ser apresentada, pois é impossível determinar o valor de qualquer grandeza sem que exista dúvida sobre o resultado da medição.

Para melhor ilustrar esse conceito, pode-se tomar como exemplo a medição de tensão realizada por um voltímetro. Para que esse instrumento apresente a indicação da tensão, é necessário que o mesmo seja introduzido no circuito elétrico a ser monitorado. Quando isso ocorre, a impedância de entrada do voltímetro introduz um erro na medição em relação ao valor verdadeiro da tensão. A correção desse erro pode ser realizada conhecendo-se o valor da impedância de entrada do voltímetro. Entretanto, o valor dessa impedância só pode ser conhecido através de medidas, e que por sua vez possuem, elas mesmas, erros. Deste modo, é impossível a realização de uma medição livre de erros. Logo, essa falta de conhecimento sobre o valor exato dos erros presentes na medição deve ser expressa através da sua IM (BIPM, 2008a).

Cabe ressaltar que a IM não está presente apenas na indicação direta apresentada por um instrumento. Em medições indiretas, onde os resultados de diferentes instrumentos são combinados através de um modelo matemático para a obtenção de um resultado final, as IM provenientes de cada uma das medições devem ser combinadas através desse modelo. Assim, será possível que o resultado final também seja expresso com sua respectiva IM. Como exemplo, pode ser tomado o caso da medição indireta da potência ativa em um circuito eletrônico, a qual pode ocorrer através do produto das medições da tensão e da corrente contínua. Dessa forma, as incertezas provenientes das medições da tensão e da corrente são combinadas e, desse modo, é possível estimar a faixa de valores na qual se encontra o valor verdadeiro da potência. Para

⁴⁴ Mensurando: grandeza específica submetida à medição (INMETRO, 2009).

esses casos existem métodos muito bem definidos e internacionalmente aceitos, como apresentado a seguir.

Métodos de avaliação da incerteza de medição internacionalmente aceitos

Erros são gerados pelo próprio processo de medição e dependem das condições específicas de cada medição. Os erros podem ser classificados em sistemáticos e aleatórios, sendo o primeiro, um valor constante e repetido em todos os resultados, e o segundo, puramente aleatório com valor médio igual a zero. Existem ainda os erros ocasionados pela execução errada dos procedimentos de medição, avarias ou má operação dos sistemas de medição, problemas no tratamento ou transcrição dos dados, entre outros. Tais erros são considerados erros grosseiros e ocasionam dados espúrios. Os resultados inerentes a eles devem ser desconsiderados, não cabendo assim a avaliação da IM.

Devido a sua própria natureza, o erro de medição não pode ser conhecido com exatidão. Assim, o reconhecimento desse fato levou a comunidade metrológica internacional a formular o conceito de IM. Nesse sentido, apesar da análise de erro ser, há muito, uma prática da ciência da medição, é agora reconhecido que, mesmo que todos os componentes de erro conhecidos tenham sido corrigidos, ainda permanece uma incerteza de quão correto é o resultado declarado (BIPM, 2008a).

O Guia para a Expressão da Incerteza de Medição (GUM) estabelece regras gerais para avaliar e expressar a IM. Dois são os métodos propostos: o primeiro dado pelo documento JCGM 100 (BIPM, 2008a), que toma como base a propagação de incertezas (desvios padrões) através do modelo matemático utilizado na medição; o segundo dado pelo documento JCGM 101 (BIPM, 2008b), que trata da propagação das distribuições de probabilidade⁴⁵ através do modelo matemático utilizando o Método de Monte Carlo (MMC).

⁴⁵ A propagação das distribuições de probabilidade utilizando o MMC é um meio para se avaliar a IM, onde as PDF, referentes a cada incerteza envolvida na medição, são propagadas através do modelo matemático da medição por simulações numéricas, a fim de obter na saída uma PDF que represente a IM do resultado (BIPM, 2008b). A partir desse ponto, o termo propagação das distribuições, ou simplesmente, propagação das PDF, será utilizado em um contexto específico, referindo-se ao método numérico de Monte Carlo para propagação das distribuições de probabilidade das IM através de um modelo matemático ou neural.

A) Método de propagação das incertezas de medição (método clássico)

A propagação das IM através do modelo matemático pelo método clássico é dada pela combinação das incertezas das grandezas de entrada para a obtenção da incerteza da grandeza de saída. As incertezas das grandezas de entrada, também chamadas de incertezas padrão, são obtidas através dos desvios padrões das distribuições de probabilidade das IM de cada uma das medidas de entrada. Para obtenção da incerteza padrão combinada da grandeza de saída é utilizada a lei de propagação de incertezas, equação (32).

$$u_c(y) = \sqrt{\sum_{i=1}^N \left[\frac{\partial f}{\partial x_i} \right]^2 \cdot u^2(x_i)} \quad (32)$$

Onde:

- $u_c(y)$ incerteza padrão combinada da grandeza de saída y ;
- $u(x_i)$ incerteza padrão da grandeza de entrada x_i ;
- $\frac{\partial f}{\partial x_i}$ coeficiente de sensibilidade da grandeza de entrada x_i .

Na prática, as incertezas de entrada possuem, geralmente, distribuições de probabilidades simétricas. Desse modo, pelo teorema central do limite, é esperado que a distribuição de probabilidade para a incerteza da grandeza de saída tenda para uma distribuição normal (ALBERTAZZI, 2008). Assim, a incerteza padrão combinada, nada mais é do que o desvio padrão dessa distribuição e representa uma probabilidade 68,2%. No entanto, na prática é necessário apresentar um intervalo com maior probabilidade de abrangência. A medida adicional que satisfaz esse requisito é denominada incerteza expandida, a qual é dada pela equação (33) (BIPM, 2008a).

$$U = k \cdot u_c(y) \quad (33)$$

Onde:

- U incerteza expandida;

- k fator de abrangência da distribuição de probabilidade *t-student*;
- $u_c(y)$ incerteza padrão combinada da grandeza de saída y .

Tipicamente, a abrangência para U é dada de modo a se obter um nível de confiança de aproximadamente 95% e os graus de liberdade efetivos são calculados a partir da fórmula de Welch-Satterthwaite, equação (34).

$$v_{\text{eff}} = \frac{u_c^4(y)}{\sum \frac{(\partial f / \partial x_i \cdot u(x_i))^4}{v_i}} \quad (34)$$

Onde:

- v_{eff} graus de liberdade efetivos para a grandeza de saída;
- v_i graus de liberdade da grandeza de entrada x_i .

B) Método de propagação de distribuições de probabilidade (Método de Monte Carlo)

Avaliação da IM empregando o MMC, nada mais é do que a propagação das distribuições de probabilidade a partir de simulações numéricas de prováveis valores de entrada. Assim, o método trata as grandezas de entrada como variáveis aleatórias e suas respectivas IM como as funções densidade de probabilidade (PDF). Desse modo, são gerados valores aleatórios respeitando-se as PDF das incertezas das grandezas de entrada, que são propagados pelo modelo matemático para que formem a PDF da grandeza de saída, a qual será usada para definir os limites da IM. O MMC parte da premissa de que a IM representa a dúvida sobre o resultado da medição, logo, cada valor obtido através da geração aleatória é tão legítimo quanto qualquer valor indicado pelo instrumento de medição (MOSCATI, 2004).

É importante lembrar que o número de medições simuladas possui forte influência no erro amostral⁴⁶ esperado para a grandeza de saída. Nesse sentido, é importante fazer um balanço entre a quantidade de simulações desejada, a disponibilidade de *hardware* e o tempo de simulação (BIPM, 2008b).

Assim como no método clássico, tipicamente a IM é apresentada com um nível de confiança de aproximadamente 95% quando o MMC é utilizado. Porém, devido à impossibilidade de se conhecer com exatidão a PDF formada após a avaliação da incerteza no método clássico, o nível de confiança é definido assumindo que a distribuição na saída tende a uma normal. Já para o MMC, a geração aleatória permite o conhecimento aproximado da PDF formada na saída do modelo matemático. Desse modo é possível encontrar o modelo de distribuição que melhor se adapte para cada caso (BIPM, 2008b).

Até aqui, este documento contextualizou e definiu os objetivos desta tese; apresentou os métodos normatizados para medição da capacidade de refrigeração; contextualizou o emprego de redes neurais artificiais; os métodos para a propagação da incerteza de medição e propagação das distribuições. Agora, esta tese mostrará que os atuais métodos de ensaio possuem particularidades, as quais são incompatíveis com as demandas das linhas de produção de compressores herméticos. Para contornar essas incompatibilidades, é proposto um novo método de medição da capacidade de refrigeração para uso em linha de produção.

⁴⁶ O termo erro amostral nesse trabalho representa o erro devido à natureza aleatória do processo de amostragem (LIRA, 2008).

APÊNDICE E – EXEMPLO SIMULADO PARA COMPROVAR A VIABILIDADE DA PROPOSTA PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA

O presente apêndice tem como objetivo mostrar que os métodos, atualmente encontrados na literatura, para expressar a dúvida sobre o valor da inferência de um modelo neural artificial, podem apresentar resultados de incerteza inadequados quando os erros sistemáticos não são compensados, mas sim incorporados às IM. Também tem por objetivo mostrar que a proposta para expressar a I-If, apresentada nesta tese de doutorado no item 5.4, é metrologicamente mais adequada.

O presente apêndice não apresenta o método proposto em si, somente a aplicação em determinadas situações simuladas e serve como auxílio no entendimento dos conceitos apresentados no capítulo 5 – proposta de método metrologicamente embasado para expressão da incerteza na inferência de modelos neurais artificiais.

Para tal, serão realizados experimentos simulados em duas situações distintas:

- Dados de medição contaminados com erros sistemáticos não compensados;
- Dados de medição contaminados com erros aleatórios.

Os experimentos contaminados com erros sistemáticos nas medições mostrará a necessidade de considerar esses erros, tanto no treinamento quanto no uso do modelo neural, e mostrará também que um conceituado método para estimar IC em redes neurais, como o método *bootstrap*, não é capaz considerar esses desvios.

Os experimentos contaminados com erros aleatórios mostram que se esses erros forem maiores durante o uso do modelo neural do que durante o treinamento, o método *bootstrap* não é capaz de apresentar resultados metrologicamente condizentes, já o método proposto sim.

Os experimentos simulados consistem na representação do modelo matemático dado pela equação (35) através de modelos neurais artificiais treinados pelas diferentes técnicas apresentadas no capítulo 5.

$$P = V.I \tag{35}$$

Onde:

P Potência ativa [W];

V	Tensão contínua	[V];
I	Corrente contínua	[A].

A utilização de um modelo matemático conhecido, para a medição indireta da potência elétrica, através da tensão e corrente elétrica, possibilita que as técnicas de modelagem neural sejam comparadas com dados de valor verdadeiro para a potência, o que em essência permite verificar a validade da proposta.

Experimentos simulados com predomínio de erros sistemáticos não compensados nos dados de medição

Neste ponto do apêndice, para a construção dos modelos neurais serão utilizados dados obtidos através de medições simuladas de um wattímetro, um voltímetro e um amperímetro. Para esse exemplo algumas suposições serão feitas:

- os instrumentos utilizados possuem as seguintes especificações: wattímetro $3^{1/2}$ dígitos com resolução de 1 W e erro máximo de $\pm(1,5\%$ da indicação + 3 vezes a resolução) W; voltímetro $3^{1/2}$ dígitos com resolução de 10 mV e erro máximo de $\pm(0,5\%$ da indicação + 4 vezes a resolução) V; amperímetro $3^{1/2}$ dígitos com resolução de 10 mA e erro máximo de $\pm(2\%$ da indicação + 6 vezes a resolução) A;
- todos os instrumentos possuem erros sistemáticos dentro dos valores especificados para os erros máximos admissíveis, que são: +2 W, -0,04 V e -0,06 A;
- os erros máximos admissíveis são a representação da IM para cada indicação;
- independente do instrumento, as IM é definida como uma PDF uniforme;
- erros aleatórios são insignificantes para essas medições;
- os instrumentos são os mesmos encontrados na formação do conjunto de treinamento e durante o uso do modelo neural artificial, com exceção da wattímetro que está presente somente na formação do conjunto de treinamento.

Assim, os exemplos do conjunto de treinamento foram obtidos através de medições simuladas como as apresentadas pela tabela 29. É possível observar que matematicamente os dados de treinamento estão errados, porém, metrologicamente as medições não. Isso se deve ao fato de que o wattímetro, o voltímetro e o amperímetro possuem erros sistemáticos, os quais ficam dentro da faixa de erro máximo declarado pelo fabricante de cada instrumento. Deste modo, quando o voltímetro apresenta uma indicação de 7,00 V e o amperímetro de 7,00 A, o valor verdadeiro para as grandezas são 7,04 V e 7,06 A, o que resulta em um valor verdadeiro para a potência de 49,7024 W. No entanto, como o wattímetro também possui erro sistemático de +2 W, esse indicará 52 W e não os 50 W que seria esperado.

TABELA 29: DADOS DO CONJUNTO DE TREINAMENTO

Tensão (V)	5,00	6,00	7,00	8,00	9,00	5,00	6,00	7,00	8,00
Corrente (A)	5,00	5,00	5,00	5,00	5,00	6,00	6,00	6,00	6,00
Potência (W)	28	33	38	43	48	33	39	45	51
Tensão (V)	9,00	5,00	6,00	7,00	8,00	9,00	5,00	6,00	7,00
Corrente (A)	6,00	7,00	7,00	7,00	7,00	7,00	8,00	8,00	8,00
Potência (W)	57	38	45	52	59	66	43	51	59
Tensão (V)	8,00	9,00	5,00	6,00	7,00	8,00	9,00		
Corrente (A)	8,00	8,00	9,00	9,00	9,00	9,00	9,00		
Potência (W)	67	75	48	57	66	75	84		

Para o desenvolvimento dos modelos neurais, as mesmas configurações de rede e parâmetros de treinamento foram utilizados, bem como o mesmo conjunto de treinamento. Deste modo, as diferenças encontradas devem-se essencialmente aos métodos utilizados.

a) Método *bootstrap*

Após o treinamento utilizando a técnica de reamostragem apresentada pelo método *bootstrap*, os dados mostrados na tabela 30 foram inseridos no modelo neural, que foi formado por 1000 RNA. As respos-

tas podem ser visualizadas nesse mesmo quadro, seguidas de seus respectivos IC obtidos para um nível de confiança de 95%.

Como nesse exemplo o modelo matemático é conhecido, bem como os erros das medições, pode-se então saber o valor verdadeiro para a potência e, deste modo, calcular os desvios percentuais em relação aos valores fornecidos pelo modelo.

TABELA 30: RESPOSTAS PARA O MÉTODO *BOOTSTRAP*

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	IC %	tensão (V)	corrente (A)	potência (W)	desvio %
5,50	5,00	30,9	±3,2	5,54	5,06	28,0	+9,1
6,50	5,00	35,4	±1,2	6,54	5,06	33,1	+6,4
5,50	6,00	35,5	±1,1	5,54	6,06	33,6	+5,6
7,00	5,00	37,9	±1,8	7,04	5,06	35,6	+6,1
7,50	5,00	40,4	±2,6	7,54	5,06	38,2	+5,6
6,50	6,00	41,7	±1,1	6,54	6,06	39,6	+4,8
7,00	6,00	44,7	±0,8	7,04	6,06	42,7	+4,6
8,50	5,00	45,7	±3,0	8,54	5,06	43,2	+5,3
5,50	8,00	46,8	±0,8	5,54	8,06	44,7	+4,6
7,50	6,00	47,7	±1,5	7,54	6,06	45,7	+4,3
5,50	9,00	52,2	±1,2	5,54	9,06	50,2	+3,9
8,50	6,00	53,7	±1,3	8,54	6,06	51,8	+3,7
6,50	8,00	54,7	±1,6	6,54	8,06	52,7	+3,7
7,00	8,00	58,9	±3,6	7,04	8,06	56,7	+3,6
6,50	9,00	61,3	±0,8	6,54	9,06	59,3	+3,3
7,50	8,00	62,6	±1,5	7,54	8,06	60,8	+3,0
7,00	9,00	65,8	±0,5	7,04	9,06	63,8	+3,0
7,50	9,00	70,2	±0,8	7,54	9,06	68,3	+2,7
8,50	8,00	70,6	±0,7	8,54	8,06	68,8	+2,5
8,50	9,00	79,4	±0,7	8,54	9,06	77,4	+2,6

Pela tabela 30 é possível visualizar que os IC são percentualmente menores em relação aos desvios encontrados para o valor verdadeiro da potência. Isso significa que o método *bootstrap*, por si só, não foi suficientemente adequado para prover confiabilidade metrológica na saída do modelo neural.

Para melhor visualização dos dados, eles foram apresentados de forma gráfica na figura 57.




FIGURA 57: RESPOSTA APRESENTADA PARA O MÉTODO *BOOTSTRAP*

b) Método *bootstrap* com MMC para a propagação das distribuições durante o uso do modelo neural

Como não existe impedimento para que o MMC seja utilizado para propagar as distribuições durante o uso do modelo neural treinado a partir do método *bootstrap*, tal situação foi abordada para o modelo treinado anteriormente, possibilitando então apresentar um valor de I-If melhor que o IC apresentado exclusivamente pelo método *bootstrap*.

Para verificar tal afirmação, foram realizadas 1000 SMMC^U, respeitando as IM para cada par de dados de tensão e corrente apresentados ao modelo neural. Ao final foram obtidos 10^6 valores para a potên-

cia, os quais foram utilizados para estimar a I-If, agora propagando-se as distribuições das entradas para a saída do modelo neural. Os resultados são apresentados na tabela 31 para uma I-If com um nível de confiança de 95%.

TABELA 31: RESPOSTAS PARA O MÉTODO *BOOTSTRAP* COM PROPAGAÇÃO DAS DISTRIBUIÇÕES DAS ENTRADAS PARA A SAÍDA DO MODELO NEURAL

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	I-If %	tensão (V)	corrente (A)	potência (W)	desvio %
5,50	5,00	30,9	±3,9	5,54	5,06	28,0	+9,3
6,50	5,00	35,3	±3,6	6,54	5,06	33,1	+6,4
5,50	6,00	35,5	±3,6	5,54	6,06	33,6	+5,5
7,00	5,00	38	±3,7	7,04	5,06	35,6	+6,2
7,50	5,00	40,4	±4,4	7,54	5,06	38,2	+5,6
6,50	6,00	41,6	±3,6	6,54	6,06	39,6	+4,8
7,00	6,00	44,7	±3,6	7,04	6,06	42,7	+4,6
8,50	5,00	45,6	±4,5	8,54	5,06	43,2	+5,3
5,50	8,00	46,8	±3,3	5,54	8,06	44,7	+4,6
7,50	6,00	47,7	±4,0	7,54	6,06	45,7	+4,2
5,50	9,00	52,3	±3,4	5,54	9,06	50,2	+4,0
8,50	6,00	53,7	±3,5	8,54	6,06	51,8	+3,6
6,50	8,00	54,8	±3,5	6,54	8,06	52,7	+3,8
7,00	8,00	58,8	±4,6	7,04	8,06	56,7	+3,5
6,50	9,00	61,2	±5,1	6,54	9,06	59,3	+3,2
7,50	8,00	62,6	±5,2	7,54	8,06	60,8	+2,9
7,00	9,00	65,7	±3,4	7,04	9,06	63,8	+3,0
7,50	9,00	70,2	±3,4	7,54	9,06	68,3	+2,7
8,50	8,00	70,6	±3,3	8,54	8,06	68,8	+2,5
8,50	9,00	79,4	±3,5	8,54	9,06	77,4	+2,5

Pode-se perceber que os valores para a I-If são maiores que os IC apresentados anteriormente na tabela 30, o que já era esperado, dado que modelo neural formado pelo método *bootstrap* não foi alterado. Nesse caso, apenas informações sobre a dúvida de cada medição apresentada nas entradas do modelo durante o uso é que foram adicionadas ao IC anteriormente obtido.

Mesmo com a inclusão dessas informações, os intervalos apresentaram respostas adequadas para apenas 35% dos pontos simulados, sendo que para 65% dos casos o valor verdadeiro da potência elétrica ficou fora dos limites encontrados para a I-If.

Vale aqui destacar que a aplicação do MMC para a propagação das distribuições não altera significativamente o resultado médio das respostas apresentadas pelo modelo neural artificial. As pequenas variações se devem pelo processo de geração aleatória dos dados.

A figura 58 apresenta, de modo gráfico, a resposta do modelo neural treinado a partir do método *bootstrap*, formado por 1000 RNA, e com 1000 SMMC^U para propagar as distribuições das entradas para a saída.




FIGURA 58: RESPOSTA APRESENTADA PELO MÉTODO *BOOTSTRAP* EM CONJUNTO COM O MMC PARA PROPAGAR AS DISTRIBUIÇÕES DURANTE O USO DO COMITÊ

A comparação entre o IC, encontrado exclusivamente pela aplicação do método *bootstrap*, com a I-If, obtida com esse método em conjunto com o MMC para propagar as distribuições durante o uso do modelo neural, mostrou que é imprescindível que sejam consideradas as incertezas dos dados de medição para obtenção de valores de I-If metrologicamente mais adequados. No entanto, o método *bootstrap* não contribuiu para que as IM provenientes dos dados do conjunto de treinamento sejam consideradas na expressão da I-If.

c) Método de Monte Carlo para propagar as distribuições no treinamento e uso do modelo neural

Para poder considerar todas as IM, tanto dos dados do conjunto de treinamento quanto aqueles que serão inseridos no modelo durante o uso, esta tese propõe que o MMC para propagar as distribuições seja utilizado durante o treinamento e uso do modelo neural.

Nesse exemplo, inicialmente foram treinadas 10^5 RNA através de $SMMC^T$ e foram realizadas 10^5 $SMMC^U$, uma para cada RNA treinada. Assim, foram obtidos 10^5 valores distintos para a potência elétrica.

Os resultados obtidos são apresentados na tabela 32 e na figura 59, com a I-If com um nível de confiança de 95%.

A aplicação do MMC no treinamento e no uso permitiu que 90% dos resultados apresentassem intervalos para a I-If onde o valor verdadeiro da potência encontrava-se dentro de seus limites. Esse número é bem superior aos 35% alcançados anteriormente com a aplicação do método *bootstrap* com a propagação da IM dos dados de entrada durante o uso do modelo neural. Vale lembrar que quando utilizado o método *bootstrap* sem a propagação das distribuições, nenhuma resposta foi satisfatória do ponto de vista metrológico.

TABELA 32: RESPOSTA DO MODELO NEURAL APLICANDO O MMC NO TREINAMENTO E USO 10^5 RNA E 10^5 SMMC^U

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	I-If %	tensão (V)	corrente (A)	potência (W)	desvio %
5,50	5,00	30,8	±6,8	5,54	5,06	28,0	+8,9
6,50	5,00	35,5	±6,7	6,54	5,06	33,1	+6,8
5,50	6,00	35,6	±6,0	5,54	6,06	39,6	+5,6
7,00	5,00	38,1	±6,5	7,04	5,06	33,6	+6,4
7,50	5,00	40,7	±6,4	7,54	5,06	35,6	+6,2
6,50	6,00	41,7	±5,3	6,54	6,06	42,7	+4,8
7,00	6,00	44,7	±5,3	7,04	6,06	43,2	+4,6
8,50	5,00	45,8	±6,3	8,54	5,06	38,2	+5,5
5,50	8,00	46,8	±5,2	5,54	8,06	50,2	+4,7
7,50	6,00	47,8	±5,1	7,54	6,06	44,7	+4,3
5,50	9,00	52,2	±5,5	5,54	9,06	60,8	+3,9
8,50	6,00	53,7	±5,2	8,54	6,06	45,7	+3,7
6,50	8,00	54,7	±5,0	6,54	8,06	51,8	+3,7
7,00	8,00	58,7	±4,8	7,04	8,06	52,7	+3,3
6,50	9,00	61,2	±5,0	6,54	9,06	63,8	+3,2
7,50	8,00	62,6	±4,8	7,54	8,06	56,7	+2,9
7,00	9,00	65,7	±5,1	7,04	9,06	68,3	+2,9
7,50	9,00	70,1	±5,1	7,54	9,06	68,8	+2,5
8,50	8,00	70,7	±4,9	8,54	8,06	59,3	+2,6
8,50	9,00	79,4	±5,2	8,54	9,06	77,4	+2,5




FIGURA 59: RESPOSTA DO MODELO NEURAL PARA O MMC APLICADO NO TREINAMENTO E USO

Um problema encontrado nesse exemplo de aplicação do MMC para propagar as distribuições no treinamento e no uso é o tempo de processamento, pois uma grande quantidade de redes neurais é necessária. Para contornar esse problema, o item 5.3 propõe que, ao invés de ser realizada uma $SMMC^U$ para cada RNA que compõe o comitê, sejam realizadas k $SMMC^U$ para os dados de entrada e esse conjunto propagado em cada uma das n RNA, fornecendo assim k vezes n resultados distintos na saída do modelo neural.

Para esse exemplo, foram então treinadas 1000 RNA, e foram realizadas 1000 $SMMC^U$ para cada par de dados de tensão e corrente. Assim, foram obtidos 10^6 valores distintos de potência para cada resposta, os quais foram utilizados para expressar a I-If com 95% de nível de confiança.

Os resultados podem ser visualizados na tabela 33 e no gráfico da figura 60. Comparando esses resultados, com aqueles encontrados anteriormente na tabela 32, percebe-se que essa técnica foi capaz de apresentar resultados condizentes. Variações mínimas foram encontradas para as duas técnicas apresentadas neste item.

TABELA 33: RESPOSTA DO MODELO NEURAL APLICANDO MMC NO TREINAMENTO E USO - 1000 RNA E 1000 SMMC^U

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	I-If %	tensão (V)	corrente (A)	potência (W)	desvio %
5,50	5,00	30,8	±7,1	5,54	5,06	28,0	+8,9
6,50	5,00	35,6	±7,0	6,54	5,06	33,1	+6,9
5,50	6,00	35,7	±7,8	5,54	6,06	33,6	+6,0
7,00	5,00	38,2	±6,8	7,04	5,06	35,6	+6,7
7,50	5,00	40,8	±6,9	7,54	5,06	38,2	+6,4
6,50	6,00	41,7	±5,5	6,54	6,06	39,6	+5,0
7,00	6,00	44,8	±6,0	7,04	6,06	42,7	+4,7
8,50	5,00	46	±5,7	8,54	5,06	43,2	+6,1
5,50	8,00	46,9	±5,2	5,54	8,06	44,7	+4,7
7,50	6,00	47,8	±4,8	7,54	6,06	45,7	+4,5
5,50	9,00	52,4	±5,5	5,54	9,06	50,2	+4,2
8,50	6,00	53,8	±5,0	8,54	6,06	51,8	+3,7
6,50	8,00	54,8	±4,9	6,54	8,06	52,7	+3,7
7,00	8,00	58,6	±4,4	7,04	8,06	56,7	+3,2
6,50	9,00	61,2	±4,7	6,54	9,06	59,3	+3,2
7,50	8,00	62,5	±4,6	7,54	8,06	60,8	+2,8
7,00	9,00	65,9	±4,9	7,04	9,06	63,8	+3,2
7,50	9,00	70,1	±4,8	7,54	9,06	68,3	+2,6
8,50	8,00	70,8	±4,5	8,54	8,06	68,8	+2,7
8,50	9,00	79,7	±4,8	8,54	9,06	77,4	+2,9




FIGURA 60: RESPOSTA DO MODELO NEURAL PARA O MMC APLICADO NO TREINAMENTO E USO

d) Método proposto para expressar a incerteza da inferência do modelo neural artificial

Apesar da aplicação do MMC para propagar as distribuições no treinamento e no uso se mostrar metrologicamente mais adequado que o método *bootstrap*, ainda assim ele não foi capaz de considerar todas as fontes de erros em um processo metrológico envolvendo RNA. Nesse sentido, no item 5.4 desta tese de doutorado foi proposto um método que integra a reamostragem *bootstrap* e a propagação das distribuições através do MMC no treinamento e uso do modelo neural.

Nesse exemplo foram treinadas 1000 RNA utilizando o método proposto e foram realizadas 1000 SMMC^U. Os resultados obtidos são apresentados na tabela 34 e na figura 61. Para uma I-If utilizou-se um nível de confiança de 95%.

Para esse exemplo, todos os resultados apresentaram intervalos de I-If adequados do ponto de vista metrológico.

TABELA 34: RESPOSTA DO MODELO NEURAL PARA O MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	I-If %	tensão (V)	corrente (A)	potência (W)	desvio %
5,50	5,00	30,9	9,6	5,54	5,06	28,0	+9,4
6,50	5,00	35,5	11,0	6,54	5,06	33,1	+6,8
5,50	6,00	35,6	7,7	5,54	6,06	33,6	+5,5
7,00	5,00	38,0	8,0	7,04	5,06	35,6	+6,4
7,50	5,00	40,6	7,4	7,54	5,06	38,2	+6,0
6,50	6,00	41,6	5,5	6,54	6,06	39,6	+4,9
7,00	6,00	44,7	5,4	7,04	6,06	42,7	+4,4
8,50	5,00	45,8	7,3	8,54	5,06	43,2	+5,7
5,50	8,00	46,8	6,1	5,54	8,06	44,7	+4,5
7,50	6,00	47,7	5,1	7,54	6,06	45,7	+4,3
5,50	9,00	52,2	5,6	5,54	9,06	50,2	+3,8
8,50	6,00	53,7	5,3	8,54	6,06	51,8	+3,6
6,50	8,00	54,8	4,9	6,54	8,06	52,7	+3,8
7,00	8,00	58,6	4,5	7,04	8,06	56,7	+3,3
6,50	9,00	61,3	5,1	6,54	9,06	59,3	+3,2
7,50	8,00	62,6	4,8	7,54	8,06	60,8	+2,9
7,00	9,00	65,7	4,7	7,04	9,06	63,8	+2,8
7,50	9,00	70,0	4,6	7,54	9,06	68,3	+2,4
8,50	8,00	70,7	4,6	8,54	8,06	68,8	+2,7
8,50	9,00	79,4	5,0	8,54	9,06	77,4	+2,5




FIGURA 61: REPOSTA DO MODELO NEURAL PARA O MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA

Experimento simulado com predomínio de erros aleatórios nos dados de medição

Da mesma forma que as análises anteriores, neste ponto do apêndice, para a construção dos modelos neurais serão utilizados dados obtidos através de medições simuladas de um wattímetro, um voltímetro e um amperímetro. Porém, diferente dos exemplos anteriores, onde os dados eram contaminados com erros sistemáticos, nos próximos exemplos os dados serão contaminados exclusivamente com erros aleatórios. Para esse exemplo algumas suposições serão feitas:

- os instrumentos utilizados possuem as seguintes especificações: wattímetro $3\frac{1}{2}$ dígitos com resolução de 1 W e erro máximo de $\pm(1,5\%$ da indicação + 3 vezes a resolução) W; voltímetro $3\frac{1}{2}$ dígitos com resolução de 10 mV e erro máximo de $\pm(0,5\%$ da indicação + 4 vezes a resolução) V; amperímetro $3\frac{1}{2}$ dígitos com resolução de 10 mA e erro máximo de $\pm(2\%$ da indicação + 6 vezes a resolução) A;

- todos os instrumentos utilizados na formação do conjunto de treinamento possuem erros aleatórios dentro dos valores especificados para os erros máximos admissíveis, distribuídos uniformemente em torno do valor verdadeiro e com os seguintes limites para essa distribuição: ± 2 W, $\pm 0,04$ V e $\pm 0,06$ A;
- todos os instrumentos utilizados durante o uso do modelo neural possuem erros aleatórios dentro dos valores especificados para os erros máximos admissíveis, distribuídos uniformemente em torno do valor verdadeiro e com os seguintes limites para essa distribuição: $\pm(0,5\%$ do valor verdadeiro + $0,04)$ V e $\pm(2\%$ do valor verdadeiro + $0,06)$ A;
- os erros máximos admissíveis são a representação da IM para cada indicação;
- independente do instrumento, a IM é definida como uma PDF uniforme;
- erros sistemáticos são insignificantes para essas medições;
- os instrumentos utilizados na formação do conjunto de treinamento e durante o uso do modelo neural podem ser considerados diferentes.

Para o desenvolvimento dos modelos neurais, as mesmas configurações de rede e parâmetros de treinamento foram utilizados, bem como o mesmo conjunto de treinamento. Deste modo, as diferenças encontradas devem-se essencialmente aos métodos utilizados.

Assim, o conjunto de treinamento foi obtido através de medições simuladas como as apresentadas pela tabela 35. Por essa tabela é possível perceber que os dados de treinamento estão contaminados com erros aleatórios.

TABELA 35: DADOS DO CONJUNTO DE TREINAMENTO

Tensão (V)	5,04	5,95	7,04	8,03	8,95	5,01	6,00	6,96	7,99
Corrente (A)	5,09	5,00	5,03	4,98	5,05	6,02	5,96	6,04	5,98
Potência (W)	24	31	36	41	42	29	36	40	49
Tensão (V)	9,05	4,99	6,00	6,99	7,99	9,04	4,97	6,00	7,00
Corrente (A)	5,92	7,05	6,99	7,01	6,98	7,06	7,96	7,97	8,02
Potência (W)	57	35	42	47	58	65	41	49	55
Tensão (V)	8,03	9,02	4,99	6,02	7,03	7,93	8,94		
Corrente (A)	8,07	8,01	9,05	8,91	9,05	9,02	9,06		
Potência (W)	64	70	45	54	64	72	78		

a) Método *bootstrap*

Após o treinamento utilizando a técnica de reamostragem *bootstrap*, os dados mostrados na tabela 36 foram inseridos no modelo neural, que foi formado por 1000 RNA. As respostas podem ser visualizadas nesse mesmo quadro, seguidas de seus respectivos IC obtidos para um nível de confiança de 95%.

Como o modelo matemático é conhecido, bem como os erros das medições, pode-se então saber o valor verdadeiro para a potência e, deste modo, calcular os desvios percentuais em relação aos valores fornecidos pelo modelo.

Por essa tabela é possível perceber que para 20% dos resultados, os desvios encontrados entre o valor verdadeiro e a inferência são maiores que os IC apresentados. Tal fato indica que o método *bootstrap* não é capaz de apresentar resultados metrologicamente confiáveis quando os erros aleatórios, dos instrumentos de medição, são diferentes no treinamento e no uso do modelo neural.

Para melhor visualização dos dados, eles foram apresentados de forma gráfica na figura 62.

TABELA 36: RESPOSTAS PARA O MÉTODO *BOOTSTRAP*

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	IC %	tensão (V)	corrente (A)	potência (W)	desvio %
5,54	5,09	27,5	±6,8	5,50	5,00	27,5	0,0
6,46	4,94	32,0	±15,6	6,50	5,00	32,5	+1,7
5,49	5,95	33,1	±4,3	5,50	6,00	33,0	-0,3
6,99	5,09	35,5	±5,2	7,00	5,00	35,0	-1,3
7,43	4,84	36,3	±16,2	7,50	5,00	37,5	+3,3
6,45	6,09	38,6	±3,7	6,50	6,00	39,0	+1,0
7,03	6,05	41,9	±2,9	7,00	6,00	42,0	+0,3
8,56	5,14	43,7	±5,3	8,50	5,00	42,5	-2,8
5,45	7,84	42,7	±2,5	5,50	8,00	44,0	+3,0
7,48	6,07	44,7	±2,8	7,50	6,00	45,0	+0,6
5,55	8,96	50,3	±2,7	5,50	9,00	49,5	-1,6
8,56	5,88	49,8	±4,6	8,50	6,00	51,0	+2,4
6,47	7,88	50,7	±4,1	6,50	8,00	52,0	+2,5
6,97	8,22	57,2	±1,9	7,00	8,00	56,0	-2,2
6,50	8,86	57,7	±3,6	6,50	9,00	58,5	+1,4
7,51	7,87	59,0	±2,1	7,50	8,00	60,0	+1,6
7,00	8,82	61,6	±1,8	7,00	9,00	63,0	+2,2
7,46	8,95	66,6	±2,4	7,50	9,00	67,5	+1,4
8,46	7,88	66,4	±1,7	8,50	8,00	68,0	+2,4
8,46	9,10	77,5	±2,0	8,50	9,00	76,5	-1,2




FIGURA 62: RESPOSTA APRESENTADA PARA O MÉTODO *BOOTSTRAP*

b) Método proposto para expressar a incerteza da inferência do modelo neural artificial

Para esse exemplo as mesmas condições apresentadas no exemplo anterior foram impostas na utilização do método proposto no item 5.4 desta tese de doutorado.

Nesse exemplo foram treinadas 1000 RNA e foram realizadas 1000 SMMC^U. Os resultados obtidos são apresentados na tabela 37 e figura 63 para uma I-If com um nível de confiança de 95%.

Diferente do método do método *bootstrap*, aqui os desvios encontrados, em 100% das respostas obtidas, ficaram dentro dos limites estabelecidos para a I-If. Mesmo que os instrumentos tenham sido modificados e apresentem erros distintos daqueles que foram utilizados para formar o conjunto de treinamento, ainda assim esse método é capaz de considerar essas diferenças, desde que esses erros sejam considerados na avaliação da IM.

Deste modo, novamente esse método possui vantagens metrológicas e pode se dizer que ele é mais adequado aos preceitos da avaliação da IM que outros atualmente encontrados na literatura.

TABELA 37: RESPOSTAS OBTIDAS PELO MÉTODO PROPOSTO

entrada do modelo (dados de medições)		resposta do modelo neural		valor verdadeiro			
tensão (V)	corrente (A)	potência (W)	I-If %	tensão (V)	corrente (A)	potência (W)	desvio %
5,54	5,09	27,9	±14,0	5,50	5,00	27,5	-1,4
6,46	4,94	32,2	±10,7	6,50	5,00	32,5	+0,9
5,49	5,95	33,0	±8,2	5,50	6,00	33,0	+0,1
6,99	5,09	35,4	±9,8	7,00	5,00	35,0	-1,2
7,43	4,84	36,5	±8,8	7,50	5,00	37,5	2,7
6,45	6,09	38,7	±6,5	6,50	6,00	39,0	+0,9
7,03	6,05	41,9	±6,4	7,00	6,00	42,0	+0,3
8,56	5,14	43,8	±8,3	8,50	5,00	42,5	-3,0
5,45	7,84	42,7	±6,5	5,50	8,00	44,0	+3,0
7,48	6,07	44,7	±6,0	7,50	6,00	45,0	+0,7
5,55	8,96	50,1	±6,1	5,50	9,00	49,5	-1,2
8,56	5,88	49,9	±6,0	8,50	6,00	51,0	+2,2
6,47	7,88	50,6	±5,7	6,50	8,00	52,0	+2,7
6,97	8,22	57,0	±5,1	7,00	8,00	56,0	-1,8
6,50	8,86	57,4	±5,2	6,50	9,00	58,5	+1,8
7,51	7,87	58,8	±4,9	7,50	8,00	60,0	+2,0
7,00	8,82	61,4	±4,9	7,00	9,00	63,0	+2,5
7,46	8,95	66,5	±5,2	7,50	9,00	67,5	+1,5
8,46	7,88	66,3	±4,9	8,50	8,00	68,0	+2,5
8,46	9,10	77,2	±5,6	8,50	9,00	76,5	-1,0




FIGURA 63: REPOSTA DO MODELO NEURAL PARA O MÉTODO PROPOSTO PARA EXPRESSAR A INCERTEZA DA INFERÊNCIA

Por fim, os resultados encontrados neste apêndice mostraram que a proposta apresentada no item 5.4 é mais adequada, do ponto de vista metrológico, que os métodos apresentados nos itens 5.1, 5.2 e 5.3.

Para o exemplo com medições contaminadas com erros sistemáticos não compensados, 100% das inferências apresentaram limites de incerteza capazes de contemplar os valores verdadeiros para a potência elétrica. Também para o exemplo com medições contaminadas com erros aleatórios, 100% das inferências apresentaram limites de incerteza capazes de contemplar os valores verdadeiros para a potência elétrica.

Esses resultados reforçam a tese de que a proposta desenvolvida neste trabalho é adequada para processos de medição que fazem uso de modelos neurais artificiais.

APÊNDICE F – ANÁLISE DAS INCERTEZAS DE MEDIÇÃO ENVOLVIDAS NA EXPRESSÃO DA INCERTEZA DA INFERÊNCIA

Para o levantamento das IM, necessárias para expressar a I-If no estudo de caso, foi utilizado como base as informações declaradas pela empresa que participou desse estudo e dados dos fabricantes dos instrumentos. É importante ressaltar que essa empresa mantém elevados níveis de confiabilidade metrológica em seus sistemas de medição, que podem ser comprovados através de elaborado sistema de gestão da medição, que fornece meios para o atendimento aos requisitos impostos pela norma ISO 9001 (ISO, 2008). A empresa conta ainda com pessoal especializado e laboratório próprio, capazes de realizar calibrações e ensaios necessários para as grandezas envolvidas nesta tese. Normas e documentos internacionais, como o ISO GUM (BIPM, 2008a) e seu suplemento (BIPM, 2008b), são utilizados pela empresa como referências para declarar as incertezas das medições.

Para pressão, potência elétrica consumida e temperatura do compressor, que são medições realizadas na linha de produção, utilizam-se transdutores, uma placa de aquisição de dados e um software desenvolvido especificamente para essa tarefa. A garantia metrológica é obtida através de calibrações periódicas, onde são utilizados métodos adequados e padrões rastreáveis. Para essas medições, a avaliação da IM considera as informações da calibração, dados de manuais dos instrumentos, as condições de uso dos sistemas de medição e o conhecimento tácito dos especialistas da empresa.

A capacidade de elevação da pressão é dada pela taxa da elevação da pressão em função do tempo. Logo, a determinação desse parâmetro envolve a medição da pressão e do tempo. Assim, as contribuições para a incerteza desses dois parâmetros devem ser avaliadas no processo de expressão da IM. Nesse sentido, é importante verificar como essas duas grandezas se relacionam para apresentar o valor da capacidade de elevação.

Para a indicação dessa taxa são adquiridos 400 pontos durante o intervalo de 0,8 segundo. Tais pontos são processados pelo método dos mínimos quadrados para obtenção do coeficiente de inclinação da reta, que é, por si, a capacidade de elevação da pressão.

Análises realizadas através de simulações pelo Método de Monte Carlo indicaram que durante a utilização do método dos mínimos quadrados, para essa quantidade de pontos adquiridos, os erros aleatórios, tanto para a pressão quanto para o tempo, são minimizados a ponto

de sua influência ser considerada insignificante na formação da IM. No entanto, os erros sistemáticos devem ser considerados. Como nenhuma correção é efetuada durante o processo de medição, as estimativas dos erros sistemáticos devem ser incorporadas no processo de avaliação da IM (ALBERTAZZI, 2008).

Através das especificações fornecidas pelo fabricante e já considerando as condições de uso do transdutor, pode-se dizer que o desvio de inclinação encontrado, entre a curva de resposta nominal e a melhor reta (sensibilidade), é de no máximo 1%. O efeito da deriva térmica sobre a sensibilidade, também é de 1% para variações de temperatura de $\pm 5^{\circ}\text{C}$ em relação à nominal da fábrica (21°C). Dados do fabricante indicam também que o erro de linearidade é de $\pm 0,25\%$ em relação ao final da faixa de medição (TRANSTEC, 2014) e que o transdutor é caracterizado do ponto de vista dinâmico por uma constante de tempo que não excede 1 ms (informação obtida através de contato direto com o fabricante).

Sabendo que o transdutor possui uma característica de resposta dinâmica de primeira ordem e que o estímulo empregado durante a medição é uma rampa de pressão, é importante avaliar se a diferença entre o estímulo e a resposta pode apresentar erro significativo. A figura 64 apresenta o gráfico para a resposta de um sistema de primeira ordem à entrada em rampa. Uma característica desse sistema é que a partir de 5 vezes o valor da constante de tempo, a resposta pode ser considerada uma reta com inclinação praticamente igual à do estímulo (FELÍCIO, 2010; PERILLO, 1994), ou seja, com erro desprezível. Como a capacidade de elevação é obtida pelo coeficiente de inclinação da reta, a constante de tempo do transdutor é da ordem de 1 ms e os primeiros instantes da medição da pressão são desprezados (cerca de 400 vezes o valor da constante de tempo) é possível estabelecer que o erro, devido à resposta do transdutor, não é significativo na composição do valor de IM. Erro de histerese e de desvio de zero também não afetam significativamente a inclinação da reta e também podem ser considerados desprezíveis.




FIGURA 64: RESPOSTA DE UM SISTEMA DE PRIMEIRA ORDEM A ENTRADA EM RAMPA

Para o tempo de aquisição de dados da pressão, necessário para obtenção da capacidade de elevação da pressão, que é dada em mbar/s, o erro máximo apontado pelo fabricante é de $\pm 0,01\%$ (NI, 2005). Como esse valor é muito inferior em relação àqueles indicados para o transdutor de pressão, é possível considerá-lo desprezível no processo de avaliação da IM.

Assim, para a avaliação da incerteza da medição da capacidade de elevação da pressão foi considerada a composição dos erros máximos de linearidade, sensibilidade e respectiva deriva térmica. Para a faixa nominal do transdutor de pressão, o erro máximo para a capacidade de elevação da pressão é de 150 mbar/s e esse valor será utilizado como incerteza na medição desse parâmetro.

Para a medição da temperatura é utilizado um instrumento de medição do tipo termômetro infravermelho. Barron (2014) alerta para o fato de que tais instrumentos exigem um conhecimento adequado nas diretrizes básicas da medição de temperatura sem contato e que, por vezes, tais equipamentos tem seu uso descartado na indústria por apresentarem elevados erros sistemáticos na medição. Barron (2014) alerta ainda para o fato de que inúmeros são os fatores que afetam uma medição de temperatura através de termômetros infravermelhos, entre elas estão o tipo, forma, cor e brilho da superfície. Em seu documento, Barron (2014) indica que erros sistemáticos da ordem de $\pm(5 \text{ até } 10)^\circ\text{C}$ são

comuns devido a emissividade do objeto, aliado à falta de um ajuste adequado dos parâmetros do instrumento, e que, no mundo real da termometria com infravermelho, a repetibilidade é o parâmetro fundamentalmente utilizado para o controle dos processos. Adicionalmente, para aplicações sem erros sistemáticos significativos, cuidados com a calibração e com o erro de aplicação em função da emissividade da superfície são fundamentais (BARRON, 2014). O trabalho citado neste parágrafo é respaldado pelo fabricante OMEGA *Engineering*, que é um importante fornecedor de tecnologia para medição e controle da temperatura (OMEGA, 2014).

O fato é que, no painel de linha de produção da Embraco, a temperatura do compressor é um parâmetro que não é atualmente utilizado em qualquer processo de controle, sendo apenas uma medição meramente indicativa, situação que, a princípio, não requer rigor metrológico para a garantia do resultado, sendo dispensada inclusive sua calibração segundo normas de gestão da qualidade como ISO 9001 (ISO, 2008). Através das informações do fabricante e dos especialistas da empresa, sabe-se que existe um erro sistemático significativo nesta medição na linha. No entanto, é garantido que o erro de medição não é maior que $\pm 6^{\circ}\text{C}$, por esse motivo e por não ter sido possível melhorar a medição da temperatura no decorrer deste trabalho, esse valor foi admitido como a incerteza na medição da temperatura dos compressores ensaiados no painel da linha de produção durante o estudo de caso. Sabe-se que esse valor é elevado para as faixas de temperatura que estão sendo medidas, porém, como não se tem o conhecimento exato do erro sistemático, não há outra solução a não ser considerar esse erro na incerteza de medição.

Para a medição da potência elétrica consumida pelo compressor durante o ensaio na linha de produção foi informado pelos especialistas da empresa que a IM para esse parâmetro na linha de produção é de ± 6 watts.

Para a medição da capacidade de refrigeração em laboratório, através dos tradicionais métodos de ensaio, são utilizadas complexas bancadas de ensaio, as quais contam com diferentes transdutores para a medição de diferentes grandezas. Individualmente os transdutores são calibrados para a garantia metrológica e, recentemente, uma proposta de compressor padrão foi desenvolvida para verificar o desempenho metrológico das bancadas (CORRÊA, 2013; MARTINS, 2011). A empresa realiza ainda intercomparações entre as bancadas de ensaio para verificar a coerências dos resultados. Assim, através das calibrações periódicas, dos métodos utilizados para a garantia dos resultados e do profundo

conhecimento dos sistemas de medição utilizados, a empresa declara, para as bancadas de avaliação de desempenho utilizadas neste trabalho, que a IM para a capacidade de refrigeração é de $\pm 3\%$ em relação à indicação obtida no ensaio.

A tabela 38 apresenta um quadro com os valores de incerteza utilizados neste trabalho para os parâmetros envolvidos no estudo de caso.

TABELA 38: INCERTEZAS PARA OS DADOS DO CONJUNTO DE TREINAMENTO

IM para as entradas da RNA			IM para a saída da RNA	
capacidade de elevação da pressão (mbar/s)	consumo (W)	temperatura ($^{\circ}\text{C}$)	capacidade de refrigeração (W)	
IM ± 150 mbar/s	IM ± 6 W	IM $\pm 6^{\circ}\text{C}$	IM	$\pm 3\%$ da indicação
PDF retang.	PDF retang.	PDF retang.	PDF	normal

APÊNDICE G – RESULTADOS DA APLICAÇÃO DO MMC NO USO DO MODELO NEURAL ARTIFICIAL




FIGURA 65: HISTOGRAMA COM AS RESPOSTAS DO MODELO NEURAL APLICANDO O MMC PARA AS IM DAS GRANDEZAS DE ENTRADA NOS COMPRESSORES DE TESTE DE 1 ATÉ 6




FIGURA 66: HISTOGRAMA COM AS RESPOSTAS DO MODELO NEURAL APLICANDO O MMC PARA AS IM DAS GRANDEZAS DE ENTRADA NOS COMPRESSORES DE TESTE DE 7 ATÉ 12

APÊNDICE H - RESULTADOS DA MEDIÇÃO DA CAPACIDADE DE REFRIGERAÇÃO DOS COMPRESSORES DEFEITUOSOS

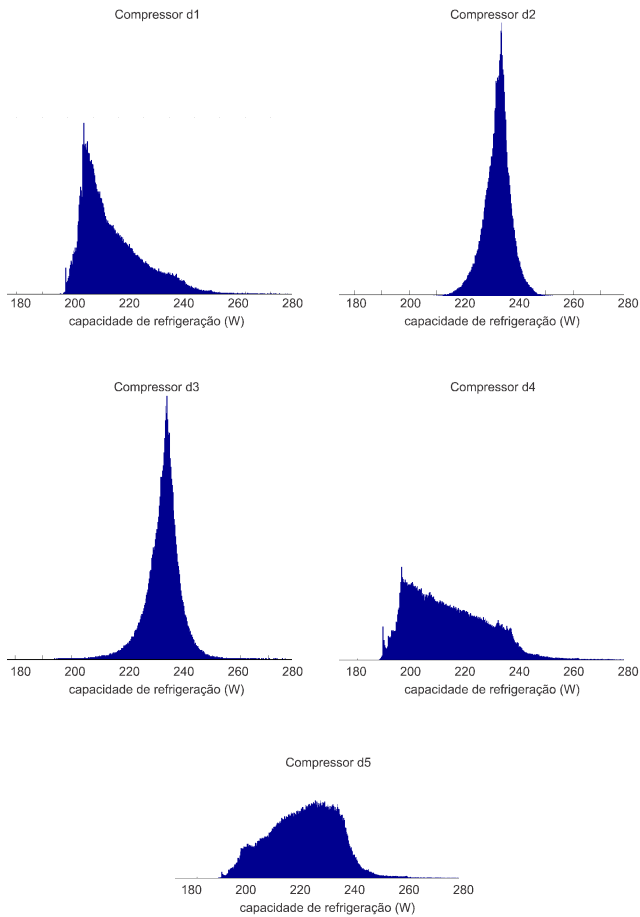


FIGURA 67: RESULTADO DA CAPACIDADE DE REFRIGERAÇÃO SOBRE COMPRESSORES DEFEITUOSOS

APÊNDICE I - RESULTADO DA CAPACIDADE DE REFRIGERAÇÃO DOS COMPRESSORES DEFEITUOSOS APÓS NOVO TREINAMENTO

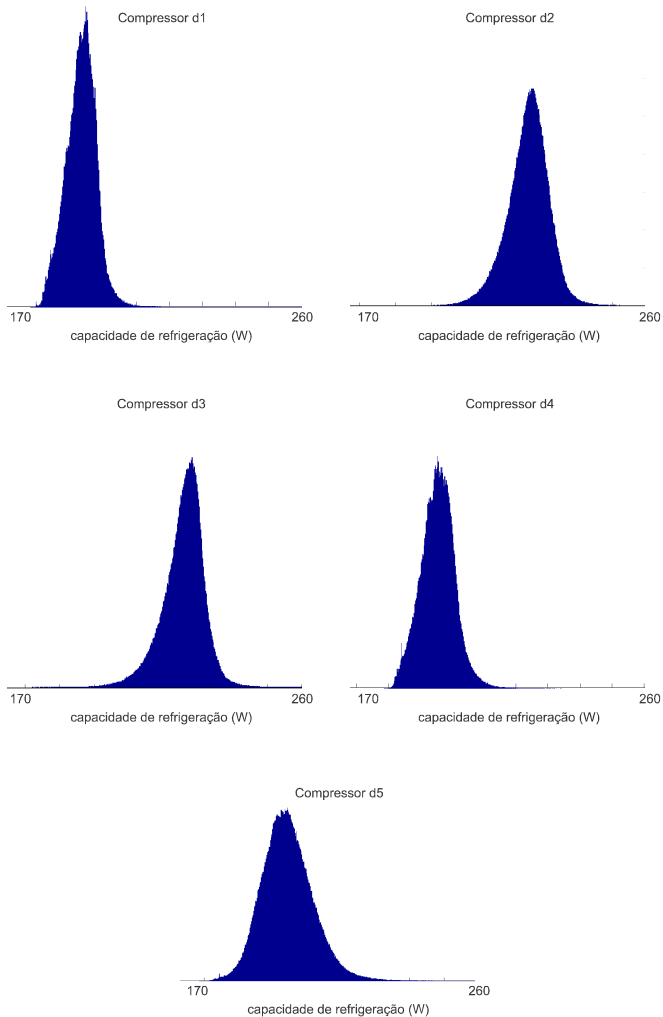


FIGURA 68: RESULTADO DA CAPACIDADE DE REFRIGERAÇÃO DOS COMPRESSORES DEFEITUOSOS APÓS NOVO TREINAMENTO

APÊNDICE J – SISTEMÁTICA PARA A MANUTENÇÃO DA CONFIABILIDADE DAS INFERÊNCIAS E MELHORIA CONTÍNUA DO MODELO NEURAL

Como a proposta apresentada nesta tese de doutorado engloba uma bancada, a qual realiza medições na linha de produção, um modelo neural artificial e um método capaz de expressar a I-If, a adoção de um sistema de gestão da medição é o caminho lógico para a manutenção da confiabilidade e melhoria contínua dos resultados obtidos através das inferências.

Dentre as normas ISO que estabelecem meios para tal, destacam-se as normas ISO 17025 (2005) e ISO 10012 (2004). Ambas contém requisitos gerais para a gestão metrológica. Porém, a primeira é destinada à acreditação de laboratórios de ensaio e calibração, e por tanto, não aborda particularidades de sistemas de medição que atuem em ambientes fabris. Já a segunda é referência metrológica para o atendimento dos requisitos da norma ISO 9001 (2008), logo, sua atuação abrange também a área industrial.

Como elaborada, a proposta pode ser integrada a um sistema de gestão da medição como o estabelecido pela norma ISO 10012 (2004). No entanto, deve se ter o entendimento que o processo de inferência atua como um sistema único, assim, os diferentes instrumentos e o modelo neural artificial funcionam conjuntamente. Nesse sentido, o ensaio na linha deve ser avaliado como um todo, possibilitando que os resultados das inferências sejam comparados com os requisitos metrológicos propostos, tanto para as inferências da capacidade de refrigeração como para sua incerteza.

É importante aqui relatar, que esta tese não avalia ou propõe a adoção de um sistema de gestão da medição em si, essa tarefa é designada exclusivamente as empresas que venham a adotar esse método de inferência da capacidade de refrigeração do compressor. O que se propõe neste apêndice é verificar como a proposta atende aos requisitos encontrados na norma ISO 10012 e, assim, buscar meios de se alcançar continuamente a confiabilidade nos resultados apresentados na saída do modelo neural. Nessa lógica, não se pretende fazer uma revisão ou alteração de qualquer requisito da norma, apenas atentar para pontos importantes e propor meios para a manutenção da confiabilidade da proposta onde existam lacunas.

A norma ISO 10012 (2004) estabelece requisitos para gestão dos instrumentos, transdutores e *software* envolvidos nos sistemas de medi-

ção. Basicamente ela foca sua sistemática na calibração com uso de padrões de referência.

Vale destacar, que mesmo não existindo um padrão adequado para avaliar a proposta como um sistema de medição único, a calibração dos instrumentos utilizados para as medições de pressão, consumo e temperatura é essencial para garantir a confiabilidade dessas grandezas. Como elas são utilizadas no processo de inferência, devem seguir os preceitos apresentados pela norma, assim como o *software* que comporta o modelo neural artificial também deve seguir. No entanto, mesmo baseando suas atividades de confiabilidade na calibração, a norma deixa aberto para que outros meios sejam utilizados nessa tarefa. Nesse sentido, propõe-se que a comprovação dos resultados de inferência obtidos na linha de produção seja realizada através da comparação com os resultados obtidos pelos métodos tradicionais.

A comparação através de outros métodos é uma técnica reconhecida para validação de ensaios (ISO, 2005). Consiste basicamente em comparar os resultados obtidos para um mesmo mensurando através de métodos distintos, assim como foi realizado ao longo de todo o capítulo 6 para os compressores de teste. Entretanto, por esta ser uma solução inovadora e não existirem padrões para a calibração, a sistemática de comparação deve ser estabelecida de modo continuado e não apenas em uma análise inicial.

A sistemática continuada além de proporcionar a validação periódica dos resultados de inferência, também pode ser utilizada para a melhoria contínua do modelo neural artificial. Como os tradicionais métodos de ensaio são reconhecidos internacionalmente como o estado da arte na medição da capacidade de refrigeração e como foram utilizados para o estabelecimento do modelo neural artificial, eles também podem ser utilizados, de modo contínuo, como referência para a correção de desvios encontrados no modelo neural.

Assim como um instrumento de medição pode ser ajustado através dos valores de referência obtidos pela calibração, também é possível realizar ajustes no método proposto. O ajuste pode ocorrer tanto no que tange os transdutores utilizados na medição da pressão, consumo elétrico e temperatura, quanto no modelo neural artificial. Para os transdutores é possível realizar a calibração e existem metodologias bem definidas e reconhecidas para a realização de tais ajustes, sendo que a recalibração deve ser realizada sempre que um ajuste for feito (ISO, 2004). Já para o modelo neural os ajustes devem ocorrer com a incorporação de exemplos no conjunto de treinamento, do mesmo modo como ocorreu

no capítulo 6 em relação aos compressores ensaiados com baixa temperatura e aqueles com capacidade de refrigeração abaixo do esperado.

Penz (2011), em sua tese de doutorado, estabeleceu uma sistemática de melhoria contínua através do uso de rotinas de comparação com os tradicionais métodos de ensaio, porém essa sistemática ficou voltada para ferramentas de inteligência artificial utilizadas no prognóstico da capacidade de refrigeração em laboratório. No entanto, o mesmo princípio pode ser adaptado às condições encontradas no que tange esta tese.

Suponha-se que ao longo do tempo de utilização de um comitê, diversas comparações são realizadas para a manutenção da confiabilidade do mesmo. Nesse período é coletada uma série de informações pertinentes e que podem ser utilizadas para o ajuste de modelo neural artificial. A partir da inclusão desses dados no conjunto de treinamento um novo processo de aprendizagem é realizado e outro comitê é gerado. Em tese, como o último modelo neural incorpora um número maior de informações pertinentes, terá então condições de apresentar resultados com I-If menores que o anterior, como apresentado na figura 69.




FIGURA 69: SISTEMÁTICA DE MELHORIA CONTÍNUA

O processo como apresentado na figura 69 poderá ser repetido até o ponto em que o custo para a melhoria do comitê seja maior do que o ganho gerado em relação ao decréscimo dos níveis de incerteza.

Vale ressaltar ainda, que assim como a recalibração é necessária quando um instrumento de medição que é ajustado, processo semelhante deve ser realizado para cada comitê gerado. Isso é essencial, pois, a cada

novo treinamento as RNA são alteradas, e não há garantias de que as inferências se mantêm adequadas nos pontos onde anteriormente eram consideradas válidas. De modo análogo ao que ocorreu no capítulo 6, resultados devem ser mantidos para compressores de teste, assim será possível verificar se o ajuste afetou o desempenho global do modelo neural artificial.