

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

Cesar Alberto Penz

**PROCEDIMENTOS PARA PROVER CONFIABILIDADE  
AO USO DE INTELIGÊNCIA ARTIFICIAL EM ENSAIOS  
DE DESEMPENHO DE COMPRESSORES HERMÉTICOS  
DE REFRIGERAÇÃO**

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.

Florianópolis  
2011

Catálogo na fonte pela Biblioteca Universitária  
da  
Universidade Federal de Santa Catarina

P419p Penz, Cesar Alberto

Procedimentos para prover confiabilidade ao uso de inteligência artificial em ensaios de desempenho de compressores herméticos de refrigeração [tese] / Cesar Alberto Penz ; orientador, Carlos Alberto Flesch. - Florianópolis, SC, 2011.

180 p.: il., grafs., tabs.

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

Inclui referências

1. Engenharia mecânica. 2. Compressores - Desempenho. 3. Compressores - Inteligência artificial - Confiabilidade (Engenharia). 4. Redes neurais (Computação). 5. Medição - Inteligência artificial. I. Flesch, Carlos Alberto. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Mecânica. III. Título.

CDU 621

Cesar Alberto Penz

**PROCEDIMENTOS PARA PROVER CONFIABILIDADE  
AO USO DE INTELIGÊNCIA ARTIFICIAL EM ENSAIOS  
DE DESEMPENHO DE COMPRESSORES HERMÉTICOS  
DE REFRIGERAÇÃO**

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, 25 de novembro de 2011.

Prof. Júlio César Passos, Dr.  
Coordenador do Programa de Pós-Graduação em Engenharia Mecânica

Prof. Carlos Alberto Flesch, Dr. Eng.  
Orientador

**Banca Examinadora:**

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

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

Prof. Arcanjo Lenzi, Ph.D.  
Universidade Federal de Santa Catarina

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

Prof.<sup>a</sup> Silvia Modesto Nassar, Dr.Eng.  
Universidade Federal de Santa Catarina



## AGRADECIMENTOS

À minha família, especialmente à minha mãe Jussara e meu pai Ernani (*in memoriam*), pelo incentivo para enfrentar os desafios e o apoio irrestrito ao caminho escolhido.

À minha namorada, Carol, pelo carinho e apoio de todos esses anos.

Ao professor Carlos Alberto Flesch, agradeço pela confiança e inúmeras oportunidades de crescimento profissional e pessoal em quase uma década de convivência.

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 os colaboradores: André Paz, Marco Aurélio, Ronsani, João Paulo e Filipe.

Aos parceiros e amigos: Coral, Kleber, Miguel, Pacheco, Rodolfo, Scussel, Tobias e Xavier, sempre dispostos a colaborar com o trabalho ou pescar ou tomar umas cervejas.

Ao LABMETRO e LIAE, professores e colaboradores que garantem o suporte para o desenvolvimento de trabalhos tanto de graduação quanto pós-graduação.

À UFSC, EMC e PosMEC, pela infraestrutura invejável para execução de projetos científicos e tecnológicos.

Ao CNPq, FINEP e BNDES, pelo suporte financeiro durante toda a execução do projeto.



## RESUMO

Técnicas de inteligência artificial têm sido usadas com sucesso nos mais diversos campos do conhecimento. Uma aplicação ainda incipiente, mas altamente promissora, é a inferência de resultados de regime a partir de dados de transitório em ensaios de desempenho de compressores de refrigeração com emprego de redes neurais. Os parâmetros de desempenho usuais são capacidade de refrigeração, consumo e coeficiente de performance. Tais ensaios são realizados em larga escala nas indústrias fabricantes de compressores, tanto no desenvolvimento e na determinação de dados de catálogo, quanto no dia-a-dia do controle da qualidade. Pesquisas recentes que tiveram a participação do autor demonstraram que com o emprego de redes neurais é possível se conseguir redução significativa no tempo médio de ensaio por compressor, que de quatro a cinco horas passa para cerca de uma hora. O problema está em garantir a confiabilidade dos resultados, para que a aplicação de tais métodos possa ser aceita pelas comunidades técnico-científica e industrial. Nesse contexto, o presente trabalho de doutorado propõe uma abordagem inédita de conjugação de ferramentas de inteligência artificial com técnicas que representam o estado-da-arte em metrologia, objetivando garantir confiabilidade aos resultados de ensaios de desempenho de compressores de refrigeração. A abordagem proposta contempla tanto as incertezas inerentes à medição das grandezas envolvidas, quanto os processos de treinamento e aplicação das redes neurais. Como contribuições adicionais são propostas: utilização de redes *fuzzy*-bayesianas para inferência do regime permanente de variáveis relacionadas ao desempenho de compressores; aplicação simultânea de meios físicos de aceleração de transitórios e das ferramentas desenvolvidas. Para analisar a efetividade das propostas, foram realizados 210 ensaios em condições normais de transitório e 65 em condições de transitório acelerado. Por normas vigentes aplicáveis a ensaios de desempenho de compressores, quando aplicados dois métodos de medição independentes, os resultados são admitidos válidos quando não divergirem entre si de mais do que 4%. Os resultados deste trabalho mostram que em 100% dos casos de aplicação das técnicas a ensaios com redução do transitório se alcançaram diferenças menores que 1,5% em relação a resultados de ensaios realizados pelos meios tradicionais. O tempo médio de ensaio passou para 48 minutos. Os resultados alcançados mostram que o conjunto de técnicas propostas, além de agregar confiabilidade ao processo, permite reduzir de forma substancial o tempo demandado por tais ensaios.





## ABSTRACT

Artificial Intelligence (AI) has been playing a successful role in different fields of engineering and science. An incipient AI application, but highly promising, is the steady-state prediction of refrigeration compressor performance tests based on unsteady-state data analysis. Neural networks are used for such prediction. Performance tests are typical experimental activities which aim in measuring fundamental compressor performance characteristics such as: refrigerating capacity; power consumption and coefficient of performance. These tests have three main purposes: research and development activities, determination of catalog parameters, and quality control. Recent research projects demonstrate that neural networks techniques can be used to reduce performance test time from the typical 4-5 hour to less than one hour. The main issue is ensuring confidence to the predictions and therefore making them acceptable to scientific and industrial communities. In this sense, the present doctoral thesis conceives a novel way for integrating AI and metrological tools aiming confidence assurance on refrigeration compressor performance tests. In this sense, measurement uncertainties – related to quantities used for prediction – are taken into account during training and operation phases of neural networks. Additional contributions are: a fuzzy-bayesian network to infer steady-state during compressor performance tests; simultaneous use of unsteady-state reduction tools and the AI tools developed in this thesis. The proposal's effectiveness is evaluated on 210 performance tests run under typical unsteady-state conditions and 65 tests run under reduced unsteady-state conditions. The standards – related to refrigeration compressor performance tests – impose the use of two independent methods for refrigerating capacity measurement which results must not disagree more than 4%. The results – obtained using AI tools enhanced by this thesis proposed techniques – show that all reduced unsteady-state tests achieved differences to standards methods within 1.5%. Moreover, the mean test duration was reduced to 48 minutes. The achieved results show that more than ensuring confidence the proposed techniques allow substantial reduction in test duration.



## LISTA DE FIGURAS

Figura 1 – Panoramas de incertezas de medição	30
Figura 2 – Incerteza da medição na validação de ganhos de desempenho	30
Figura 3 – Resultados obtidos na redução do tempo de ensaio	31
Figura 4 – Diagrama esquemático da bancada de ensaio disponível	39
Figura 5 – Diagrama simplificado do calorímetro a seco	40
Figura 6 – Exemplos de comportamentos de grandezas de compressores	42
Figura 7 – Comportamentos da capacidade de refrigeração	43
Figura 8 – Comportamentos da temperatura do corpo do compressor	43
Figura 9 – Comportamentos da pressão de sucção (entrada)	44
Figura 10 – Comportamentos do sinal de controle da pressão de sucção	44
Figura 11 – Modelo de neurônio	48
Figura 12 – Exemplo de rede neural <i>feedforward</i>	50
Figura 13 – Rede bayesiana hipotética para avaliação de compressores	52
Figura 14 – Rede aumentada, adaptada de PAPADOPOULOS (2001)	61
Figura 15 – Exemplo de comportamento da capacidade e saída ideal da ferramenta de inferência de regime	68
Figura 16 – Esquema geral da estratégia para a inferência de regime da capacidade de refrigeração	70
Figura 17 – Arquitetura das redes neurais para inferência de regime	71
Figura 18 – Entradas da rede de inferência de regime da capacidade	72
Figura 19 – Probabilidade de indicação de estabilidade pelas redes treinadas	74
Figura 20 – Probabilidade de não indicação de estabilidade pelas redes treinadas	74
Figura 21 – Histograma das correlações das indicações corretas de estabilidade	77
Figura 22 – Histograma das correlações das indicações erradas de estabilidade	78
Figura 23 – Erro médio das 15 amostras precedentes à indicação de estabilidade (ensaios sem aceleração de transitório)	79



Figura 24 – Erro médio das 15 amostras precedentes à indicação de estabilidade (ensaios com aceleração de transitório)	80
Figura 25 – Erro médio percentual versus tempo de espera para 1 rede	81
Figura 26 – Erro médio percentual versus tempo de espera para 5 redes	81
Figura 27 – Erro médio percentual versus tempo de espera para 10 redes	81
Figura 28 – Erro médio percentual versus tempo de espera para 15 redes	82
Figura 29 – Erro médio percentual versus tempo de espera para 20 redes	82
Figura 30 – Erro médio percentual versus tempo de espera para 25 redes	82
Figura 31 – Relação entre quantidade de redes e tempo de espera	83
Figura 32 – Erro percentual da capacidade na inferência, sem aceleração	83
Figura 33 – Erro percentual da capacidade na inferência, com aceleração	84
Figura 34 – Quantidade de ensaios para cada regra adotada	84
Figura 35 – Representação gráfica da identificação da estabilidade	85
Figura 36 – Diagrama esquemático da rede <i>fuzzy</i> -bayesiana de inferência do regime	86
Figura 37 – Comportamentos típicos da temperatura do corpo relativa (TCr)	88
Figura 38 – Comportamentos típicos da variação do controle da pressão ( $\Delta$ CPS)	89
Figura 39 – Probabilidades condicionais da temperatura do corpo relativa	90
Figura 40 – Probabilidades condicionais do controle da pressão de sucção	90
Figura 41 – Funções de pertinência da temperatura do corpo relativa (TCr)	91
Figura 42 – Funções de pertinência da variação do controle da pressão ( $\Delta$ CPS)	92
Figura 43 – Capacidade de refrigeração para um ensaio de desempenho	93
Figura 44 – Saída da rede híbrida para o ensaio da figura 43	93
Figura 45 – Capacidade de refrigeração para um ensaio de desempenho	94
Figura 46 – Saída da rede híbrida para o ensaio da figura 45	94
Figura 47 – Erro absoluto médio para rede híbrida - ensaios sem aceleração	95
Figura 48 – Erro absoluto médio para rede híbrida - ensaios com aceleração	96



Figura 49 – Erro médio no tempo de regime - ensaios sem aceleração	96
Figura 50 – Erro médio no tempo de regime - ensaios sem aceleração	96
Figura 51 – Erro da capacidade, solução neural e integrada, sem aceleração	98
Figura 52 – Erro da capacidade, solução neural e integrada, com aceleração	98
Figura 53 – Ferramenta para o prognóstico da capacidade de refrigeração	99
Figura 54 – Arquitetura da rede neural para prognóstico	100
Figura 55 – Entradas da rede de prognóstico da capacidade	101
Figura 56 – Histograma dos erros de prognóstico - sem aceleração	102
Figura 57 – Histograma dos erros de prognóstico - com aceleração	103
Figura 58 – Resumo dos resultados de prognóstico da solução proposta	104
Figura 59 – Tempos de ensaios para casos sem aceleração de transitório	105
Figura 60 – Tempos de ensaios para casos com aceleração de transitório	105
Figura 61 – Exemplo de ensaio com identificação do regime permanente	106
Figura 62 – Etapas de análise e melhoria contínua	111
Figura 63 – Fontes típicas de erros em sistemas de medição	113
Figura 64 – Esquema de contaminação de incertezas para experimentos	119
Figura 65 – Contaminação de linearidade para experimentos	119
Figura 66 – Arranjo ortogonal de experimentos para treinamento das redes	120
Figura 67 – Efeitos principais da capacidade	121
Figura 68 – Efeitos principais da temperatura do corpo	122
Figura 69 – Efeitos principais da pressão de sucção	122
Figura 70 – Efeitos principais da capacidade, com 2 desvios padrão	123
Figura 71 – Efeitos principais da temperatura do corpo, com 2 desvios padrão	123
Figura 72 – Efeitos principais da pressão de sucção, com 2 desvios padrão	123
Figura 73 – Estatística descritiva dos resultados das redes originais e experimentos selecionados	124





Figura 74 – Gráfico <i>boxplot</i> para redes originais e experimentos selecionados	125
Figura 75 – Comportamento do experimento 1 para os 65 ensaios analisados	126
Figura 76 – Efeitos principais da capacidade	127
Figura 77 – Efeitos principais da temperatura do corpo	128
Figura 78 – Efeitos principais da pressão de sucção	128
Figura 79 – Efeitos principais da capacidade, com 2 desvios padrão	129
Figura 80 – Efeitos principais da temperatura do corpo, com 2 desvios padrão	129
Figura 81 – Efeitos principais da pressão de sucção, com 2 desvios padrão	129
Figura 82 – Estatística descritiva dos resultados dos experimentos selecionados	130
Figura 83 – Gráfico <i>boxplot</i> dos resultados dos experimentos selecionados	131
Figura 84 – Erro percentual na identificação do regime	132
Figura 85 – Influência da incerteza de medição na rede <i>fuzzy</i> -bayesiana	133
Figura 86 – Efeitos principais da capacidade	134
Figura 87 – Efeitos principais da capacidade com 2 desvios padrão	135
Figura 88 – Efeitos principais da temperatura do corpo	135
Figura 89 – Efeitos principais da pressão de sucção	136
Figura 90 – Efeitos principais da temperatura do corpo, com 2 desvios padrão	136
Figura 91 – Efeitos principais da pressão de sucção, com 2 desvios padrão	136
Figura 92 – Prognóstico original e os máximos desvios devido à incerteza	137
Figura 93 – Prognóstico versus valor final – sem aceleração	138
Figura 94 – Erro do prognóstico versus valor final – sem aceleração	138
Figura 95 – Prognóstico versus valor final – com aceleração	139
Figura 96 – Erro do prognóstico versus valor final – com aceleração	140
Figura 97 – Gráfico de probabilidade normal (influência no treinamento)	159
Figura 98 – Gráfico dos resíduos versus valores ajustados (influência no treinamento)	159
Figura 99 – Histograma dos resíduos (influência no treinamento)	160



Figura 100 – Gráfico dos resíduos versus a ordem de observação (influência no treinamento)	160
Figura 101 – Gráfico de probabilidade normal (influência no uso)	163
Figura 102 – Gráfico dos resíduos versus valores ajustados (influência no uso)	163
Figura 103 – Histograma dos resíduos (influência no uso)	163
Figura 104 – Gráfico dos resíduos versus a ordem de observação (influência no uso)	164
Figura 105 – Resultado do experimento Taguchi 1	171
Figura 106 – Resultado do experimento Taguchi 2	171
Figura 107 – Resultado do experimento Taguchi 3	172
Figura 108 – Resultado do experimento Taguchi 4	172
Figura 109 – Resultado do experimento Taguchi 5	172
Figura 110 – Resultado do experimento Taguchi 6	173
Figura 111 – Resultado do experimento Taguchi 7	173
Figura 112 – Resultado do experimento Taguchi 8	173
Figura 113 – Resultado do experimento Taguchi 9	174
Figura 114 – Resultado do experimento Taguchi 10	174
Figura 115 – Resultado do experimento Taguchi 11	174
Figura 116 – Resultado do experimento Taguchi 12	175
Figura 117 – Resultado do experimento Taguchi 13	175
Figura 118 – Resultado do experimento Taguchi 14	175
Figura 119 – Resultado do experimento Taguchi 15	176
Figura 120 – Resultado do experimento Taguchi 16	176
Figura 121 – Resultado do experimento Taguchi 17	176
Figura 122 – Resultado do experimento Taguchi 18	177
Figura 123 – Resultado do experimento Taguchi 19	177
Figura 124 – Resultado do experimento Taguchi 20	177
Figura 125 – Resultado do experimento Taguchi 21	178
Figura 126 – Resultado do experimento Taguchi 22	178
Figura 127 – Resultado do experimento Taguchi 23	178
Figura 128 – Resultado do experimento Taguchi 24	179
Figura 129 – Resultado do experimento Taguchi 25	179



## LISTA DE ABREVIATURAS

BIPM	<i>Bureau International Des Poids Et Mesures</i>
CAP	Capacidade de refrigeração
GUM	Guia para a expressão da incerteza de medição
IA	Inteligência artificial
IEC	International Electrotechnical Commission
ISO	International Organization for Standardization
Labmetro	Laboratório de Metrologia e Automatização da UFSC
P&D	Pesquisa e desenvolvimento
RFB	Rede <i>fuzzy</i> -bayesiana
RNA	Rede neural artificial
TCr	Temperatura do corpo do compressor relativa
VIM	Vocabulário Internacional de Termos Fundamentais e Gerais de Metrologia
$\Delta$ CPS	Variação do controle da pressão de sucção



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>29</b>
1.1	PROPOSTA DE TRABALHO	33
1.1.1	Objetivo	33
1.1.2	Método de abordagem	33
1.1.3	Inovações concretizadas	34
1.2	ESTRUTURA DO DOCUMENTO	34
<b>2</b>	<b>ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS</b>	<b>37</b>
2.1	DEFINIÇÃO DAS CARACTERÍSTICAS DE DESEMPENHO	37
2.2	BANCADA DE ENSAIO DE DESEMPENHO	38
2.3	ACELERAÇÃO DE TRANSITÓRIO EM ENSAIOS DE DESEMPENHO	44
<b>3</b>	<b>INTELIGÊNCIA ARTIFICIAL NO ÂMBITO DESTE TRABALHO</b>	<b>47</b>
3.1	REDES NEURAIS ARTIFICIAIS	48
3.1.1	Modelo geral de neurônio	48
3.1.2	Arquitetura de redes neurais	49
3.1.3	Aprendizado em redes neurais	50
3.2	SISTEMAS <i>FUZZY</i> -BAYESIANOS	51
3.2.1	Redes probabilísticas ou bayesianas	52
3.2.2	Hibridismo <i>fuzzy</i> -bayesiano	53
<b>4</b>	<b>CONFIABILIDADE DE REDES NEURAIS ARTIFICIAIS</b>	<b>57</b>
4.1	ASPECTOS GERAIS DA CONFIABILIDADE	57
4.2	ABORDAGENS APRESENTADAS NA LITERATURA	58





<b>5</b>	<b>PROPOSTA DE MÉTODOS E PROCEDIMENTOS PARA GERAÇÃO DE INFERÊNCIAS E PROGNÓSTICOS MAIS CONFIÁVEIS</b>	<b>65</b>
5.1	PANORAMA	65
5.2	INFERÊNCIA DO REGIME PERMANENTE DA VARIÁVEL DE INTERESSE	67
5.2.1	Estratégia baseada em redes neurais	69
5.2.1.1	Caracterização das redes neurais	70
5.2.1.2	Uso de múltiplas redes	71
5.2.2	Estratégia baseada em rede <i>fuzzy</i> -bayesiana	84
5.2.2.1	Caracterização da rede proposta	86
5.2.2.2	Integração <i>fuzzy</i> -bayesiana	92
5.2.3	Integração das ferramentas neural e <i>fuzzy</i> -bayesiana	97
5.3	PROGNÓSTICO DO VALOR FINAL DA VARIÁVEL DE INTERESSE	99
5.3.1	Caracterização da rede	100
5.3.1.1	Arquitetura e treinamento	100
5.3.1.2	Variáveis de entrada e saída	101
5.3.2	Uso de múltiplas redes	101
5.3.3	Resultados obtidos	102
5.4	INFORMAÇÕES A <i>PRIORI</i> COMO FERRAMENTA DE INCREMENTO DA CONFIABILIDADE	106
<b>6</b>	<b>PROPOSTAS DE MÉTODOS E PROCEDIMENTOS PARA AVALIAÇÃO DA CONFIABILIDADE</b>	<b>109</b>
6.1	FERRAMENTAS DA INTELIGÊNCIA ARTIFICIAL EM MÉTODOS DE ENSAIO	109
6.2	PROPOSTA DE MÉTODO PARA AVALIAÇÃO DA INFLUÊNCIA DA INCERTEZA DE MEDIÇÃO	116
6.2.1	Estudo de Caso 1: Treinamento das redes neurais de inferência	118
6.2.2	Estudo de Caso 2: Uso das redes neurais de inferência	126
6.2.3	Estudo de Caso 3: Uso da rede <i>fuzzy</i> -bayesiana de inferência	132
6.2.4	Estudo de Caso 4: Uso das redes neurais de prognóstico	133
6.3	RELAÇÃO ENTRE ERRO DE PROGNÓSTICO E CAPACIDADE DE REFRIGERAÇÃO	137



<b>7</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>143</b>
7.1	CONCLUSÕES	143
7.1.1	Quanto à revisão bibliográfica realizada	143
7.1.2	Quanto às inovações concretizadas neste trabalho	144
7.1.3	Quanto à avaliação experimental das ferramentas propostas	146
7.2	SUGESTÕES DE TRABALHOS FUTUROS	147
	<b>REFERÊNCIAS</b>	<b>149</b>
	<b>APÊNDICE A</b>	
	<b>RESULTADOS DAS ANÁLISES ESTATÍSTICAS</b>	<b>159</b>
	<b>APÊNDICE B</b>	
	<b>RESULTADOS DOS EXPERIMENTOS TAGUCHI</b>	<b>171</b>



# 1 INTRODUÇÃO

A avaliação do desempenho de compressores herméticos utilizados em sistemas de refrigeração é atividade típica das empresas fabricantes desses produtos. Para tal, são realizados ensaios que fornecem resultados tanto para os setores de pesquisa e desenvolvimento quanto aos responsáveis pelo controle da qualidade dos processos produtivos.

O aprimoramento tecnológico é responsabilidade principal dos setores de pesquisa e desenvolvimento. Considerando que muitas vezes esse aprimoramento é alcançado com pequenos incrementos nas características de desempenho, os resultados dos ensaios devem apresentar incerteza de medição compatível para comprovação dessas melhorias.

Em relação ao controle da qualidade do processo produtivo, os ensaios devem fornecer resultados com confiabilidade suficiente para garantir os valores das características de desempenho apresentados aos clientes.

É típico dos ensaios de desempenho um longo tempo de execução, decorrente do demorado regime transitório de diversas grandezas monitoradas. Relatos apontam para tempos próximos a 3 horas para estabelecimento do regime permanente (BARBOSA, 2006; FLESCHE, 2006; POLETTI, 2006; SCUSSEL, 2006). Ao tempo necessário para o sistema atingir o regime permanente deve-se adicionar no mínimo mais uma hora, tempo definido por norma para realização das medições com o sistema estável (ISO, 1989; ASHRAE, 2005), totalizando um tempo médio de ensaio superior a 4 horas.

Com o intuito de melhorar as características de incerteza de medição e reduzir o tempo necessário para execução dos ensaios a Embraco – maior fabricante mundial de compressores de refrigeração – estabeleceu parceria com o Labmetro – Laboratório de Metrologia e Automação da Universidade Federal de Santa Catarina.

Para o desenvolvimento das pesquisas a Embraco disponibilizou ao Labmetro uma bancada de ensaios de desempenho em compressores. Diversos trabalhos foram realizados até o presente momento, sendo que os resultados se relacionam fortemente ora com a redução da incerteza de medição, ora com a redução do tempo de ensaio, ora com ambos.

A otimização da bancada de ensaio, a realização de processos de medição no estado-da-arte em metrologia e a utilização de técnicas modernas de controle têm contribuído para ambas as frentes de atuação (BARBOSA, 2006; FLESCHE, 2006; POLETTI, 2006; PETROVIC, 2007;

FLESCH, 2010). A avaliação e a implementação de estratégias de aceleração do regime transitório, realizadas por SCUSSEL (2006), LIMA (2010a) e SILVEIRA (2010), caracterizaram-se como trabalhos ligados fortemente à questão da redução do tempo de ensaio.

A figura 1 apresenta os panoramas de incertezas de medição para três características típicas de desempenho – capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de performance. Os valores apresentados são relacionados ao painel disponível no Labmetro em três condições típicas de ensaio – antes e depois da realização dos trabalhos (BARBOSA, 2006; FLESCH, 2006; POLETTTO, 2006; PETROVICIC, 2007; FLESCH, 2010). Podem ser notadas reduções significativas nos níveis de incerteza.

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

Figura 1 – Panoramas de incertezas de medição

A figura 2 apresenta uma tabela que relaciona o número de amostras (compressores) a testar para validar estatisticamente ganhos em características de desempenho, considerando duas situações de incerteza de medição. Segundo BORGES (2008) os valores de ganhos incrementais a validar apresentados na figura 2 são típicos na maior fabricante mundial de compressores herméticos. Nota-se que a redução da incerteza diminui fortemente o esforço experimental relacionado à quantidade de amostras a testar.

Incerteza da medição praticada	Ganho a validar			Número de <sup>1</sup> amostras
	0,5%	0,8%	1,5%	
3%	155	61	18	Número de <sup>1</sup> amostras
1%	18	8	3	

Figura 2 – Incerteza da medição na validação de ganhos de desempenho

<sup>1</sup> Para o cálculo do número de amostras foi utilizado o teste de hipóteses para diferença entre duas médias com variâncias conhecidas. O nível de significância é 0,05 e a potência do teste é de 0,9 (MONTGOMERY, 2003).

A figura 3 mostra a redução do tempo médio de ensaio frente aos resultados obtidos pelos trabalhos desenvolvidos no Labmetro desde o início da parceria (BARBOSA, 2006; FLESCHE, 2006; POLETO, 2006; SCUSSEL, 2006; PETROVIC, 2007; FLESCHE, 2010). A redução média de tempo de ensaio é de aproximadamente 50%. As variações na duração dos ensaios são relacionadas, principalmente, à capacidade de refrigeração do compressor e condição de avaliação.

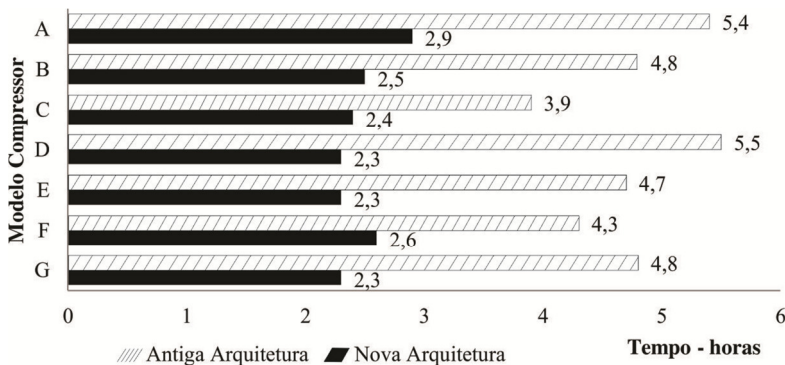


Figura 3 – Resultados obtidos na redução do tempo de ensaio

Unindo as informações das figuras 1, 2 e 3 pode-se estabelecer um panorama no qual o tempo necessário para validação de ganhos incrementais, mesmo com os avanços alcançados, torna os processos de pesquisa e desenvolvimento pouco eficientes. No caso do controle da qualidade do processo produtivo, a avaliação tardia de amostras de lotes implica riscos significativos de produtos não conformes.

Quanto ao tempo de ensaio, a redução é relativamente pequena devido às características próprias dos sistemas térmicos que implicam longos períodos de acomodação das grandezas envolvidas. Dessa forma outra abordagem foi realizada visando redução drástica do tempo de ensaio.

Essa abordagem se apresenta na utilização de técnicas para estabelecimento de prognósticos<sup>2</sup> e inferências<sup>3</sup> de valores ou estado (estabilizado ou não estabilizado) das características de interesse dos compressores herméticos. Através da análise do comportamento de grande-

<sup>2</sup> Prognóstico – suposição, baseada em dados da realidade, sobre o que deve acontecer no futuro (HOUAISS, 2002).

<sup>3</sup> 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).

zas presentes nos ensaios durante o período pré-estabilização (transitório) estima-se um valor ou o estado da característica do compressor.

Sob esse enfoque, a utilização de técnicas de inteligência artificial (IA) demonstrou forte aplicabilidade. Até o presente momento, quatro dissertações de mestrado foram desenvolvidas, no grupo de pesquisa do qual o autor deste trabalho é integrante, com o intuito de explorar diferentes técnicas de IA para obtenção de previsões em ensaios de compressores herméticos.

HENKLEIN (2006) evidenciou o enorme potencial das redes neurais artificiais, aliadas aos conceitos da lógica *fuzzy*, na tarefa de prognóstico do desempenho dos compressores herméticos. Tal prognóstico realizou o enquadramento de características importantes dos compressores (capacidade de refrigeração e potência elétrica ativa consumida) em classes predefinidas.

STEINBACH (2008) aplicou redes neurais artificiais para avaliar a estabilidade do ensaio a partir da inferência do instante de entrada em regime permanente e no prognóstico dos valores de capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de performance.

CASELLA (2008), com co-orientação do autor do presente trabalho, avaliou a aplicação de redes *fuzzy*-bayesianas para análise da estabilidade do ensaio a partir da inferência do instante de entrada em regime permanente da capacidade de refrigeração.

LIMA (2010b) desenvolveu e implantou – em bancadas de avaliação de desempenho de compressores – a primeira versão de um conjunto de ferramentas composto por redes de inferência e prognóstico para potência elétrica ativa consumida, capacidade de refrigeração e coeficiente de performance.

Os trabalhos mostraram que o uso de redes neurais e *fuzzy*-bayesianas pode implicar ganhos de tempo significativos e contribuir fortemente para pesquisa e desenvolvimento de novos produtos, para melhoria dos processos de manufatura em grande escala e para controle de qualidade de produtos.

Em tais aplicações, as tarefas de prognóstico e inferência se caracterizam como partes de um processo de medição. Sob esse enfoque, os resultados obtidos a partir de medições no transitório devem ser acompanhados de uma indicação sobre a sua confiabilidade metrológica.

A qualidade de resultados de ensaios é um dos focos da metrologia, que busca na expressão de um dado quantitativo – a incerteza da medição – garantir a confiança dos referidos resultados. O conhecimento da incerteza de medição em resultados de ensaios é de fundamental importância para empresas, laboratórios, seus clientes e todas as outras



instituições que utilizam esses resultados (DAR, 2002; SYDENHAM, 2003; DOUMA, 2005; LECA, 2009). No entanto, as indicações de confiabilidade obtidas para resultados decorrentes de utilização de técnicas de IA estão longe dos atuais conceitos da metrologia e de confiabilidade metrológica.

A garantia da confiabilidade dos ensaios passa pela aplicação dos atuais conceitos e métodos metrológicos em aspectos como: definição de processos de medição; confirmação metrológica de equipamentos de medição; procedimentos de medição (ISO, 2003; ISO, 2005). Desta forma, torna-se importante a utilização de técnicas consolidadas para garantir a confiabilidade dos ensaios.

Frente aos promissores resultados obtidos pelos trabalhos de HENKLEIN (2006), CASELLA (2008), STEINBACH (2008) e LIMA (2010b) e a inexistência de procedimentos metrologicamente confiáveis para tratamento das incertezas relacionadas aos métodos propostos, detectou-se a necessidade de se desenvolver meios para assegurar a confiabilidade de tais resultados. Dessa forma, o presente trabalho pretende estabelecer o elo entre as ações para redução de tempo de ensaio baseadas em IA e a necessidade de estabelecimento de valores para as incertezas de medição das mesmas.

## 1.1 PROPOSTA DE TRABALHO

### 1.1.1 Objetivo

O objetivo deste trabalho de doutorado é estabelecer métodos e procedimentos visando prover confiabilidade ao uso de recursos de inteligência artificial para inferência e prognóstico de condições de regime, a partir de dados de transitório, em ensaios de desempenho de compressores.

### 1.1.2 Método de abordagem

O encaminhamento da tese se deu pela execução das seguintes atividades:

- estudo de métodos alternativos e complementares ao ISO-GUM (BIPM, 2008a) – documento atualmente aceito como referência para estimativa da incerteza de medição – para avaliação de incertezas em processos de medição;

- estabelecimento, através de análise teórica e experimental, de procedimentos para escolha das redes neurais já treinadas para serem utilizadas nos prognósticos e inferências;
- definição de outras fontes de informação capazes de prover maior confiabilidade aos resultados obtidos por redes neurais artificiais;
- desenvolvimento e execução de experimentos em bancada própria para comprovação das soluções;
- estudo teórico e experimental da influência da incerteza de medição das grandezas de entrada das redes neurais artificiais nos prognósticos e inferências obtidos por elas.

### 1.1.3 Inovações concretizadas

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

- ferramenta *fuzzy*-bayesiana para identificação de comportamentos de regime permanente;
- análise probabilística para escolha de redes neurais treinadas com foco na aplicação;
- método de avaliação da influência da incerteza de medição no treinamento e uso de redes neurais, redes *fuzzy*-bayesianas e soluções híbridas;
- integração de informações provenientes de sistemas de controle de processos e ferramentas de inteligência artificial com foco na confiabilidade;
- integração de ferramentas de inteligência artificial e métodos de redução de transitório para diminuição drástica do tempo demandado por ensaios de desempenho.

## 1.2 ESTRUTURA DO DOCUMENTO

No capítulo 2 são apresentados os conceitos básicos relacionados aos ensaios de desempenho de compressores herméticos e suas particularidades. No capítulo 3 são apresentados conceitos e ferramentas da inteligência artificial utilizados neste trabalho. No capítulo 4 é apresentado o levantamento bibliográfico acerca da avaliação de confiabilidade de redes neurais. No capítulo 5 são expostas: a visão geral do procedimento para garantia da confiabilidade dos resultados; ferramentas e resultados para a inferência do regime permanente via redes neurais e

redes *fuzzy*-bayesianas; ferramentas e resultados para prognóstico utilizando redes neurais e informações de histórico. No capítulo 6 é proposto um método para avaliação da influência da incerteza de medição na concepção e uso de soluções baseadas em ferramentas de IA. São apresentados estudos de casos de uso do método proposto e análises complementares com foco na confiabilidade de ferramentas de inferência e prognóstico. No capítulo 7 são apresentadas as considerações finais e propostas de trabalhos futuros.



## 2 ENSAIOS DE DESEMPENHO DE COMPRESSORES HERMÉTICOS

Neste trabalho são abordados os ensaios de desempenho baseados na norma ISO 917 – *Testing of Refrigerant Compressors* (ISO, 1989). Essa norma, bem como outras semelhantes<sup>4</sup>, busca estabelecer procedimentos padronizados para avaliação e determinação de características do compressor, tornando possíveis as reproduções de resultados e comparações entre diferentes fabricantes.

Os ensaios de desempenho têm como objetivo a determinação da capacidade de refrigeração, da potência elétrica ativa consumida e do coeficiente de performance, com o compressor sob condições preestabelecidas. Os métodos de ensaio propostos na norma provêm resultados com incertezas em níveis suficientes para permitir a análise da adequação de um compressor a qualquer condição de operação requerida em um sistema de refrigeração (ISO, 1989).

### 2.1 DEFINIÇÃO DAS CARACTERÍSTICAS DE DESEMPENHO

Potência elétrica ativa consumida é a potência nos terminais do compressor, sendo composta pelo consumo do motor e de elementos auxiliares necessários para manter o compressor em operação. Essa característica é expressa em watt (ISO, 1989).

Capacidade de refrigeração de um compressor ( $\Phi_0$ ) é o produto do fluxo de massa de fluido refrigerante através do compressor pela diferença entre a entalpia específica do refrigerante na entrada (sucção) e a entalpia específica de líquido saturado na temperatura correspondente à pressão de descarga na saída do compressor (ISO, 1989), 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). A unidade da capacidade de refrigeração é watt.

---

<sup>4</sup> Existem diversas normas acerca dos ensaios de desempenho de compressores de refrigeração, todas são muito similares e apresentam os requisitos básicos para esses ensaios, pode-se citar como exemplos: ANSI/ASHRAE 23 (ANSI/ASHRAE, 2005) e DIN EN 13771 (DIN, 2008). A ISO 917 (ISO, 1989), apesar da publicação no final dos anos 80, se destaca pela aceitação internacional e pelo conteúdo bem consolidado na indústria.

$$\Phi_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}) \quad (1)$$

Onde:

$\Phi_0$	capacidade 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 <sup>3</sup> /kg]
$V_{gl}$	volume específico do refrigerante entrando no compressor estabelecido anteriormente ao ensaio	[m <sup>3</sup> /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]

O coeficiente de performance é a razão da capacidade de refrigeração pela potência consumida pelo compressor, assim é uma grandeza adimensional (ISO, 1989).

## 2.2 BANCADA DE ENSAIO DE DESEMPENHO

Os ensaios para determinação das características de desempenho são realizados em bancadas específicas capazes de estabelecer diferentes condições nas quais os compressores devem ser avaliados. A figura 4 apresenta um diagrama simplificado da bancada disponível no Labmetro<sup>5</sup>.

---

<sup>5</sup> Bancada cedida pela Embraco na qual estão implementados os métodos C (calorímetro a seco) e F (medição direta de fluxo de massa na fase líquida) previstos na ISO 917. A norma prevê outros métodos que não serão tratados neste trabalho.

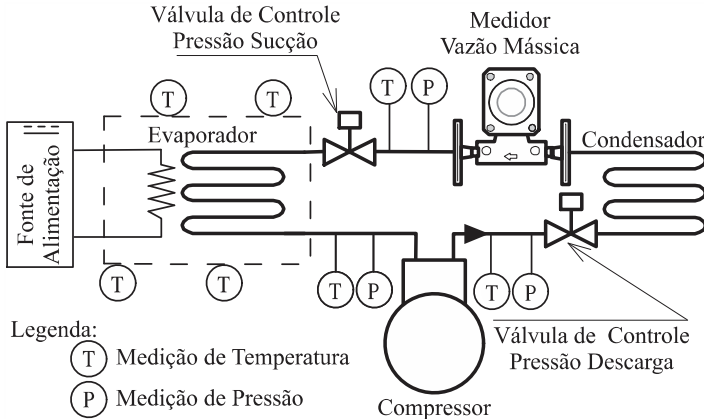


Figura 4 – Diagrama esquemático da bancada de ensaio disponível

Os procedimentos estabelecidos pela norma ISO 917 são gerais para todas as condições de operação, sendo que cada uma estabelece valores diferentes para pressão absoluta de descarga e sucção, temperatura de sucção e rotação do compressor. As demais variáveis podem ser fixas, independentemente da condição de ensaio (ISO, 1989).

A execução de um ensaio de desempenho pode ser resumida como segue.

Um determinado modelo de compressor deve ser avaliado numa das condições de temperatura de evaporação e condensação padronizadas<sup>6</sup>, por exemplo,  $T_E = -23,3 \text{ }^\circ\text{C}$  e  $T_C = +54,4 \text{ }^\circ\text{C}$ , respectivamente. Esses valores de temperatura definem os valores de pressão absoluta de sucção e descarga, respectivamente, de acordo com o fluido refrigerante empregado.

A definição da capacidade de refrigeração – apresentada no item 2.1 – exige o conhecimento da entalpia do fluido refrigerante na entrada do compressor e da entalpia específica de líquido saturado na temperatura correspondente à pressão de descarga na saída do compressor, assim como o fluxo de massa que circula por ele.

A entalpia do fluido refrigerante é obtida, no caso da bancada disponível, através dos valores de pressão e temperatura medidos nos pontos de interesse e de um software específico<sup>7</sup>.

<sup>6</sup> As condições de ensaio são definidas como representativas de condições de aplicação e para que haja comparabilidade de desempenho entre compressores de diferentes fabricantes.

<sup>7</sup> REFPROP – software de propriedades termodinâmicas de diversas substâncias (LEMMON, 2007).

O fluxo de massa de refrigerante pode ser estimado ou medido diretamente. Aqui se apresenta a principal diferença entre os dois métodos estabelecidos na bancada – denominados C e F.

No método C – calorímetro<sup>8</sup> a seco – o fluxo de massa é estimado a partir da medição do calor trocado no interior do calorímetro. No caso específico da bancada disponível, o calorímetro é o ambiente no qual se localiza o evaporador. A figura 5 apresenta um esquema do calorímetro utilizado, no qual a tubulação em forma de serpentina é envolta por um resistor para aquecimento.




Figura 5 – Diagrama simplificado do calorímetro a seco

A quantidade de calor trocada é obtida através da medição da potência dissipada no resistor. A condição de contorno desse processo é que o calor transferido deve ser capaz de mudar a fase de todo o fluido refrigerante existente na tubulação do evaporador e manter constante a temperatura de saída do calorímetro.

Com relação ao método F – medição direta do fluxo de massa na fase líquida – um equipamento específico é utilizado para a medição instantânea do fluxo de massa (figura 4). Para correta medição, o fluido refrigerante, no ponto de medição, deve estar totalmente líquido subresfriado. Essa condição implica ausência de fluido refrigerante na forma de vapor (ISO, 1989).

<sup>8</sup> A definição clássica para calorímetro é um ambiente, ou volume, dedicado à quantificação das trocas térmicas entre elementos fixos e/ou que passam por seu interior (HANSEN, 2003).



Para ambos os métodos de ensaio, além das medições necessárias para o cálculo da capacidade de refrigeração, outras medições devem ser realizadas para completa caracterização dos parâmetros do compressor. São elas:

- temperatura de descarga do compressor;
- potência elétrica ativa consumida pelo compressor;
- corrente elétrica que alimenta o compressor;
- temperatura da carcaça do compressor;
- resistência de enrolamento (final do ensaio);
- frequência rotacional (final do ensaio).

Durante o ensaio, o compressor deve operar continuamente até atingir um período no qual as flutuações em todas as variáveis fiquem dentro de limites estabelecidos e não mostrem tendência definitiva a se mover fora desses limites (ISO, 1989). Esse período é denominado de regime permanente (ISO, 1989). Enquanto não se atingir esse período, diz-se que o ensaio se encontra no regime transitório.

Os limites de variação impostos pela norma ISO 917 para caracterizar o regime permanente numa dada condição de teste são (ISO, 1989):

- as leituras de pressão não podem ter variação maior que  $\pm 1\%$  do valor de referência;
- as leituras de temperatura não podem ter variação maior do que  $\pm 3$  K em relação ao valor de referência;
- a frequência rotacional não pode ter variação maior que  $\pm 1\%$  do valor de referência: limite de variação da tensão de alimentação do compressor é de  $\pm 3\%$  e da frequência  $\pm 1\%$  dos valores nominais de placa;
- no método C, onde o aquecimento elétrico é utilizado, a potência fornecida aos resistores de aquecimento deve ser mantida constante com variação máxima de  $\pm 1\%$  do valor médio da última hora;
- no método F, o valor lido no medidor de fluxo de massa não pode exceder o limite de  $\pm 1\%$  do valor médio da última hora.

Os valores de capacidade de refrigeração, potência ativa consumida pelo compressor e coeficiente de performance são calculados tomando como base a média aritmética dos valores medidos consecutivamente na última hora de ensaio operando em regime permanente (ISO, 1989). Os limites de variação da capacidade de refrigeração, da potência

ativa consumida pelo compressor e da temperatura do corpo do compressor não são especificados em norma. Porém, esses limites são definidos por especialistas em compressores e ensaios de desempenho da seguinte forma:

- capacidade de refrigeração:  $\pm 2\%$  do valor final de ensaio;
- potência elétrica ativa consumida:  $\pm 2\%$  do valor final de ensaio;
- temperatura carcaça:  $\pm 1^\circ\text{C}$  do valor final de ensaio.

Essa necessidade faz com que os ensaios de compressores demandem longos tempos de execução. A situação pode ser agravada quando os ensaios: são realizados em bancadas com baixo grau de automação; utilizam técnicas de controle que não tratam adequadamente sistemas com atraso de transporte – característica típica de sistemas térmicos; empregam sistemas e procedimentos de medição aquém dos conceitos metrológicos atuais (FLESCHE, 2010).

A figura 6 apresenta exemplos de comportamento de grandezas inerentes aos compressores herméticos na aplicação desses num sistema de refrigeração (PORKHIAL, 2002).

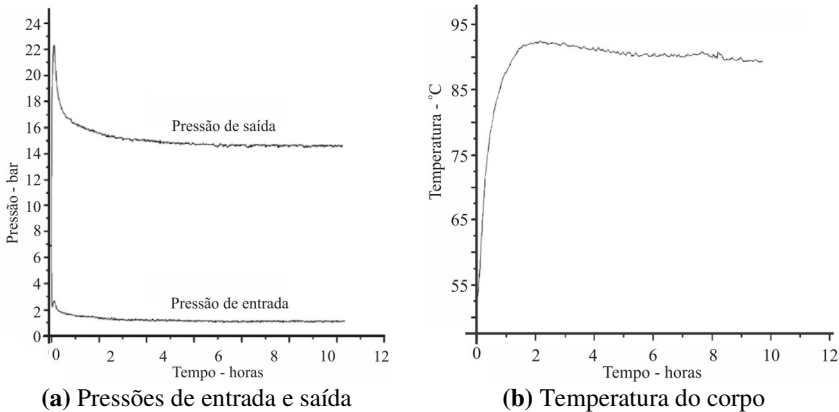


Figura 6 – Exemplos de comportamentos de grandezas de compressores

Esses exemplos refletem uma situação na qual um compressor instalado num refrigerador comercial teve suas temperaturas e pressões monitoradas durante seu funcionamento. Nenhum tipo de controle externo ao refrigerador foi adicionado para atuar em tais grandezas. Essa condição permite vislumbrar o comportamento tipicamente lento dos compressores para atingir a condição de estabilidade. Nota-se – nos

exemplos apresentados – que a estabilização das diferentes grandezas pode variar de (2 a 5) horas (PORKHIAL, 2002).

Nas bancadas de ensaio de desempenho – onde são utilizadas técnicas de projeto e controle no intuito de conduzir o compressor às condições de avaliação padronizadas – os tempos de estabilização são reduzidos. As figuras 7, 8, 9 e 10 apresentam exemplos típicos de grandezas presentes nos ensaios para quatro modelos de compressores.

Observando a figura 7 pode-se incorrer na conclusão de que em 40 minutos todos os ensaios estavam estabilizados. No entanto, tal conclusão estaria equivocada na comparação com limites de  $\pm 2\%$  do valor final do ensaio. No capítulo 5 serão apresentados exemplos que detalham o comportamento próximo à região de entrada em estabilidade.

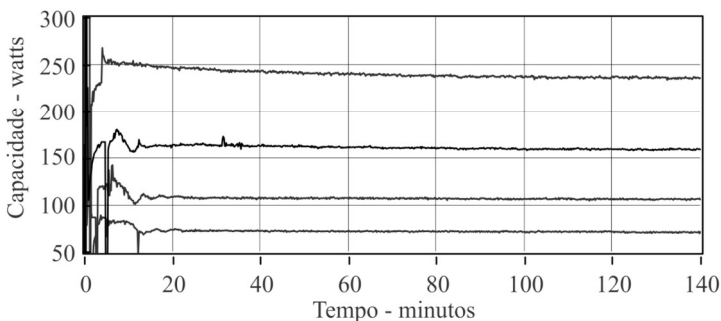


Figura 7 – Comportamentos da capacidade de refrigeração




Figura 8 – Comportamentos da temperatura do corpo do compressor

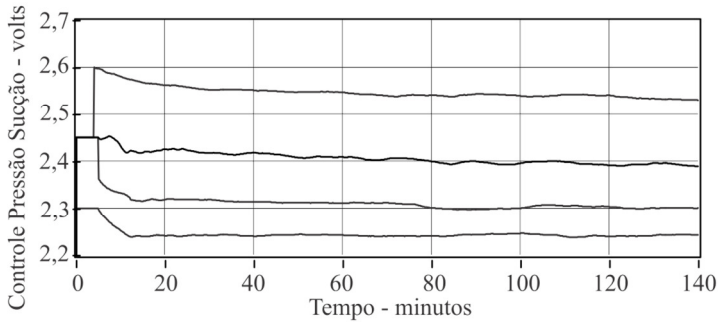


Figura 9 – Comportamentos da pressão de sucção (entrada)




Figura 10 – Comportamentos do sinal de controle da pressão de sucção

### 2.3 ACELERAÇÃO DE TRANSITÓRIO EM ENSAIOS DE DESEMPENHO

Como citado na introdução, no intuito de reduzir o tempo do ensaio de desempenho, foram realizados alguns trabalhos para avaliação e implantação de meios capazes de acelerar o período transitório.

Nos capítulos 5 e 6 deste trabalho serão apresentadas as estratégias para a garantia da confiabilidade dos resultados obtidos em prognósticos e inferências utilizando ferramentas da inteligência artificial. Para a avaliação dessas estratégias foram realizados 210 ensaios sem aceleração e 65 ensaios com aceleração de transitório. Assim, pretende-se neste item, de forma sucinta, familiarizar o leitor com os meios de aceleração de transitório desenvolvidos.

SCUSSEL (2006) avaliou alguns meios para a aceleração do transitório em ensaios de desempenho e os dividiu em dois grupos: condições termodinâmicas extremas de operação; condições diferenciadas de alimentação elétrica.

Nas condições termodinâmicas foram avaliadas diferentes combinações de níveis de pressão de sucção, pressão de descarga e temperatura de entrada de fluido refrigerante no compressor.

Nas condições de alimentação elétrica foram avaliadas formas de aumentar a geração de calor no motor do compressor e, por consequência, acelerar o aquecimento do compressor. Foram avaliadas: alimentação com tensão reduzida e nominal simulando condições de rotor bloqueado; injeção controlada de corrente contínua pura; alimentação simultânea com tensão alternada e contínua controlada.

Resultou, das avaliações de SCUSSEL (2006), que a mais promissora técnica de aceleração de transitório, dentre as analisadas, é a alimentação simultânea com tensão alternada e contínua controlada.

SILVEIRA (2010) desenvolveu e implantou em bancada de avaliação de desempenho a técnica indicada em SCUSSEL (2006). Foram avaliados comportamentos de temperatura do corpo e da bobina do compressor para que a técnica desenvolvida fosse efetiva na redução do tempo e segura na preservação da integridade do compressor sob ensaio.

Os resultados obtidos por SILVEIRA (2010) comprovaram a eficácia da técnica e apresentaram redução de até 30% no tempo total demandado em ensaios de diferentes modelos de compressores.

LIMA (2010a) avaliou técnicas de aceleração do transitório através de diferentes condições de alimentação elétrica combinando níveis de tensão com alterações na frequência dessa tensão. Tais combinações geram tanto perdas adicionais no enrolamento – efeito Joule no cobre – como perdas adicionais de magnetização. Os testes realizados apontaram significativa redução no tempo de aquecimento do compressor, 70% em média para os modelos de compressores avaliados. Em contrapartida houve influência no fluxo de massa imposto pelo compressor.

No presente trabalho, os ensaios da base de dados de teste foram realizados com aceleração de transitório segundo a técnica implantada por SILVEIRA (2010): alimentação simultânea com tensão alternada e contínua controlada.

Independentemente das reduções de tempo, alcançadas através da otimização das bancadas de ensaio e técnicas de aceleração de transitório, há necessidade de dinâmicas mais rápidas nos processos de P&D e de controle da qualidade nas indústrias de compressores. A aplicação de técnicas de inteligência artificial para realização de prognósticos e inferências acerca das características de desempenho mostrou-se promissora em diversos trabalhos já realizados. O capítulo 3 apresenta as ferramentas da inteligência artificial concernentes a este trabalho.



### 3 INTELIGÊNCIA ARTIFICIAL NO ÂMBITO DESTE TRABALHO

“A inteligência artificial (IA) é uma ciência que não busca apenas entender as entidades inteligentes, mas também como construí-las”. Esse comentário de RUSSEL (2003) define os papéis básicos da inteligência artificial que são: a busca pelo entendimento e como construir entidades inteligentes.

Segundo RUSSEL (2003) existem diversos conceitos de IA na literatura científica e esses podem ser divididos em duas vertentes que são:

- sistemas que mimetizam os pensamentos e ações humanas;
- sistemas que realizam pensamentos e ações racionais.

No contexto deste trabalho a segunda vertente se mostra mais adequada para prover o conceito de IA. Dentre os conceitos dessa vertente, WINSTON (1992) apresenta que IA é o estudo dos cálculos que tornam possíveis a percepção, a racionalização e a ação.

Neste trabalho as percepções são estabelecidas na geração de prognósticos e inferências – acerca das características de desempenho dos compressores – obtidas das medições realizadas nos ensaios e informações anteriores. A racionalização se dá na definição e análise das relações existentes entre os diversos prognósticos e inferências. As ações são firmadas no provimento dos resultados dos ensaios com confiabilidade determinada.

A aplicação de ferramentas de inteligência artificial na metrologia e instrumentação tem crescido. Diversos trabalhos têm sido apresentados com o intuito de propor e avaliar tais aplicações.

FLESCH (1998) analisa a utilização de sistemas especialistas na determinação dos intervalos de calibração de instrumentos de medição. HECKMANN (1999) realiza um estudo abrangente de identificação de potenciais aplicações de IA na metrologia. ABLAMEYKO (2003) apresenta uma série de estudos na aplicação de redes neurais para medição e instrumentação em áreas como robótica, medicina, óptica, eletricidade, entre outras.

A inteligência artificial apresenta sob seu escopo diversas ferramentas para modelar e para solucionar problemas. Este trabalho utiliza três dessas ferramentas: redes neurais artificiais, redes bayesianas e lógica *fuzzy*.

### 3.1 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) foram desenvolvidas para modelar o cérebro, que é uma estrutura de processamento de informações altamente complexa, não-linear e paralela (HAYKIN, 1999).

Estabeleceram-se como a principal ferramenta do campo da inteligência artificial e, atualmente, são utilizadas nas mais diversas áreas da engenharia e das ciências biológicas, econômicas e humanas.

A apresentação dos diferentes tipos de RNA não é objetivo deste trabalho. Devido à existência de trabalhos anteriores – motivadores para o desenvolvimento deste – que utilizam redes *feedforward* (HENKLEIN, 2006; STEINBACH, 2008; LIMA, 2010b), a análise será restrita a esse tipo de RNA.

A concepção de ferramentas baseadas em redes neurais pressupõe algumas atividades que são: definição das informações de entrada e saída da rede a partir do problema a solucionar; definição da arquitetura da rede a utilizar; definição da forma como o aprendizado da rede irá decorrer; realização do processo de validação da rede para novas informações de entrada.

#### 3.1.1 Modelo geral de neurônio

A unidade básica de uma rede neural artificial é o neurônio artificial. A figura 11 apresenta o modelo de neurônio comumente utilizado nas redes *feedforward* (HAYKIN, 1999).

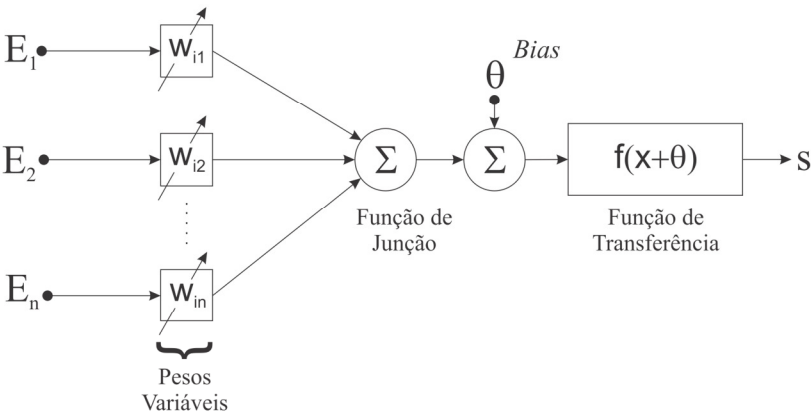


Figura 11 – Modelo de neurônio



As informações que são processadas pelo neurônio estão identificadas pelas entradas  $E_1, E_2, \dots, E_n$ . Os parâmetros  $w_{i1}, w_{i2}, \dots, w_{in}$ , chamados pesos sinápticos, são responsáveis pelo armazenamento de grande parte do conhecimento do neurônio, já que multiplicam diretamente os valores das informações que entram no neurônio. Nas redes que necessitam de treinamento, que é o caso das aplicadas neste trabalho, o aprendizado inerente ao treinamento está contido nos pesos sinápticos. O parâmetro bias  $\theta$  é obtido durante a fase de aprendizado da rede. A função de transferência  $f(\cdot)$ , também chamada de função de ativação, pode assumir várias formas. Usualmente são utilizadas funções dos tipos sigmoidal e linear (HAYKIN, 1999)<sup>9</sup>.

### 3.1.2 Arquitetura das redes neurais

A princípio, qualquer disposição organizada de neurônios pode dar origem a uma arquitetura de rede neural. A arquitetura de uma rede neural é definida por quatro características básicas: número de camadas na rede; número de neurônios por camada; tipo de conexões (diretas – *feedforward*, ciclos – *backward* ou *feedback*, laterais); grau de conectividade entre os neurônios (um a um, conectividade plena, esparsa ou randômica) (HAYKIN, 1999).

O número de neurônios por camada e o número de camadas de uma rede depende muito da aplicação e delimitam outras características como capacidade de generalização, armazenamento do conhecimento e esforço computacional.

Quanto ao tipo de conexões estabelecidas nas redes, têm-se dois grandes grupos, as redes diretas (*feedforward*) e as redes com ciclos ou realimentação (*feedback*). As redes diretas têm neurônios organizados em camadas com conexões unilaterais entre elas e sem ciclos. Frequentemente essas redes são chamadas de redes em camadas (HAYKIN, 1999).

Os neurônios que recebem os sinais de excitação compõem a camada de entrada, ou primeira camada. Neurônios que têm sua saída como saída da rede pertencem à camada de saída ou última camada da rede. Já os neurônios que não pertencem a nenhuma dessas camadas são os neurônios internos à rede e pertencem a uma ou mais camadas escondidas.

---

<sup>9</sup> O livro *Neural Networks – A Comprehensive Foundation* (HAYKIN, 1999) é uma referência mundial na apresentação dos diferentes tipos de redes neurais e conceitos relacionados. Como o foco desta seção é apresentar conceitos básicos de redes neurais, optou-se por utilizar apenas essa referência.

As redes diretas produzem um conjunto de valores de saída para uma dada excitação de entrada e são muito boas em aproximações de funções (HAYKIN, 1999).

O grau de conectividade indica como estão dispostas as conexões na rede neural – se todos os neurônios são ligados; uniformemente ou não.

A figura 12 apresenta um exemplo de rede neural *feedforward* com 7 entradas, 3 neurônios na camada escondida e 2 neurônios da camada de saída; conectividade plena.

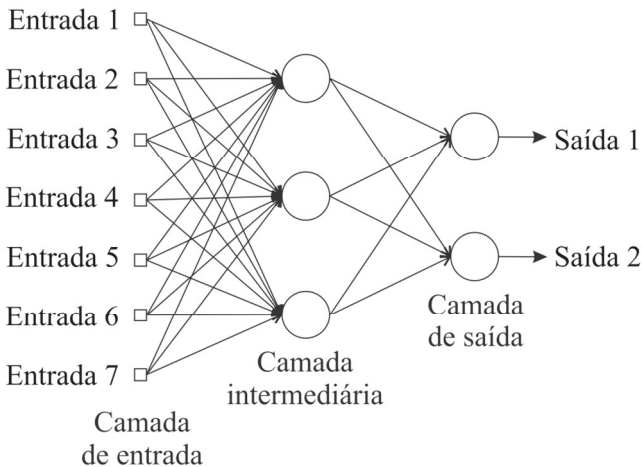


Figura 12 – Exemplo de rede neural *feedforward*

### 3.1.3 Aprendizado em redes neurais

O conhecimento adquirido por uma rede está contido nos pesos de suas conexões e a tarefa dos métodos de aprendizado é estabelecer quais são esses pesos (HAYKIN, 1999).

As redes neurais são ajustadas ou treinadas para executar tarefas específicas, podendo o aprendizado ser supervisionado ou não. O treinamento supervisionado é realizado a partir de uma série de exemplares preestabelecidos, relacionando-se variáveis de entrada e respectivas saídas. Por outro lado, o aprendizado não supervisionado busca encontrar padrões de semelhança entre os vetores de entrada – sem a necessidade de informar as saídas correspondentes – agrupando-os de modo a representarem um determinado conhecimento. Esse tipo de aprendizado

também é chamado de descobridor de regularidades devido à propriedade básica de seu funcionamento (HAYKIN, 1999).

Outras características estão associadas direta ou indiretamente ao aprendizado. São elas: a complexidade das amostras; a capacidade de armazenamento; a complexidade computacional.

A complexidade da amostra determina o número de padrões de treinamento necessários para treinar a rede de modo a garantir uma boa generalização. Poucas amostras podem fazer com que a rede decore e só consiga bons resultados quando os casos testados são os mesmos utilizados no treinamento (ABLAMEYKO, 2003).

A capacidade de armazenamento refere-se a quantos padrões podem ser armazenados e quais funções e limites de decisões uma rede neural pode formar. A complexidade computacional refere-se ao tempo requerido para que um algoritmo de aprendizado chegue a uma solução (HAYKIN, 1999).

Existem diversos tipos de regras para aprendizado em redes neurais artificiais, sendo que cada um é mais apropriado para uma determinada aplicação ou arquitetura de rede. Dentre os principais algoritmos destaca-se o de retropropagação (*backpropagation*). É uma regra de aprendizado supervisionado aplicável a redes com duas ou mais camadas e geralmente diretas, porém, eventualmente, podendo ser cíclicas. É um método de gradiente descendente que minimiza a função de erro estabelecida para a RNA (HAYKIN, 1999).

### 3.2 SISTEMAS FUZZY-BAYESIANOS

O tratamento da incerteza relacionada à informação (análise, projeto, tomada de decisão) está passando por uma mudança de paradigma. Essa migração ocorre do ponto de vista puramente probabilístico para uma abordagem mais generalizada que inclui tanto métodos probabilísticos como não-probabilísticos (AYYUB, 2006).

A partir da afirmação anterior e da identificação de uma aplicação – na qual a abordagem puramente probabilística não estabelece uma solução satisfatória – cabe a descrição das redes *fuzzy*-bayesianas.

No item 5.2.2 deste trabalho serão apresentadas propostas de utilização de redes *fuzzy*-bayesianas para realização de inferências acerca das características de desempenho de compressores. A descrição desse tipo de rede se faz então necessária para o embasamento teórico do leitor.

### 3.2.1 Redes probabilísticas ou bayesianas

O cálculo de probabilidades é uma ferramenta muito bem estabelecida para o tratamento de incertezas classificadas como aleatórias. A aleatoriedade diz respeito a fenômenos não determinísticos, ou seja, aqueles que sob as mesmas condições não se pode afirmar com certeza o que ocorrerá numa experimentação particular (AYYUB, 2006).

As redes probabilísticas ou bayesianas culminaram da junção da teoria bayesiana de probabilidade com as representações gráficas de causa e efeito dos sistemas, experimentos ou situações a modelar (PAN, 1998; PAN, 2000).

Uma rede bayesiana é uma estrutura gráfica que permite ao usuário a representação e o raciocínio sobre um domínio incerto. Nessas redes os nós representam um conjunto de variáveis aleatórias do domínio de interesse. Um conjunto de arcos diretos conecta pares de nós representando as dependências entre as variáveis. A intensidade dessas dependências é quantificada por distribuições de probabilidade condicionais associadas a cada nó (KORB, 2004).

A figura 13 apresenta um exemplo de uma rede bayesiana hipotética para avaliação do funcionamento de compressores a partir de três medições de vibração realizadas em pontos distintos da carcaça dos mesmos.




Figura 13 – Rede bayesiana hipotética para avaliação de compressores

O conhecimento dessa rede está nas probabilidades condicionais informadas *a priori* pelo especialista e são da forma:

$$p(\text{Vibração}_1 = \text{Alta} \mid \text{Compressor} = \text{Ruim})$$

Depois de informadas todas as probabilidades condicionais relacionando cada nó de entrada (Vibração\_1, Vibração\_2, Vibração\_3) com o nó de saída (Compressor) o teorema de Bayes é utilizado para compor as probabilidades da rede.

A figura 13(a) mostra a rede bayesiana quando essa não está sendo utilizada. A figura 13(b) mostra a rede sendo utilizada já que a probabilidade das entradas está em 100%, indicando a ocorrência das entradas. A saída para esse caso reflete que a probabilidade do compressor ser ruim é de 58,6% quando a Vibração\_1 = Alta, Vibração\_2 = Baixa e Vibração\_3 = Alta.

É importante salientar que as probabilidades apresentadas pelas redes bayesianas são decorrentes de informações, muitas vezes experimentais, obtidas de bases de dados. Assim como nas redes neurais, as bases de dados podem não descrever o processo de maneira completa. Dessa forma, as redes bayesianas devem ser avaliadas e as taxas de erros de classificação estimadas para os níveis de confiança considerados adequados para a aplicação (KORB, 2004; NASSAR, 2007).

Para a definição das probabilidades condicionais do exemplo anterior, o especialista definiu um limite de classificação para cada uma das 3 medidas de vibração. A análise realizada então foi: independente de quanto a vibração está acima do limite, ela é classificada como Alta; independente de quanto a vibração está abaixo do limite, ela é classificada como Baixa. Essa é a abordagem dicotômica da teoria da probabilidade – não existem estados intermediários.

Para o caso da classificação hipotética dos compressores, pode-se estabelecer que: quanto mais altos os níveis de vibração medidos – em relação aos limites estabelecidos – maior a probabilidade desses serem ruins; quanto mais baixos os níveis de vibração medidos – em relação aos limites estabelecidos – maior a probabilidade desses serem bons. Para inserir esse tipo de informação recorre-se à teoria dos conjuntos *fuzzy*.

### 3.2.2 Hibridismo *fuzzy*-bayesiano

O tratamento *fuzzy* da informação teve origem no artigo de ZADEH (1965), que descreve a essência de sua teoria como um meio natural de tratar problemas nos quais as fontes de incertezas estão na inexistência de limites dicotômicos para a classificação de dados independentemente da presença de variáveis aleatórias.

PAN (2000) descreveu da seguinte forma a diferença entre as abordagens probabilística e *fuzzy*: "... probabilidade é uma medida de dúvida sobre o resultado de um evento bem definido e aleatório, enquanto o conceito *fuzzy* trata a ambiguidade e dúvida na descrição do próprio evento".

As afirmações de ZADEH (1965) e PAN (2000) atraem, contundentemente, a aplicação da rede bayesiana descrita no item 3.2.1 para uma abordagem híbrida *fuzzy*-probabilística.

A inferência híbrida utilizada neste trabalho é realizada segundo a proposta de TIBIRIÇÁ (2005) que apresenta a equação (2) para o teorema de Bayes.

$$P(H_i|\tilde{e}_j) = \frac{P(\tilde{e}_j|H_i) P(H_i)}{P(\tilde{e}_j)} \quad (2)$$

onde:

$H_i$  – são as hipóteses a serem testadas;

$\tilde{e}_j$  – são as evidências imprecisas.

Para cada evidência  $\tilde{e}_j$  existe um conjunto de funções de pertinência<sup>10</sup> que descreve o modo como a ambiguidade e a dúvida na descrição dela é modelada. A condição de soma unitária da probabilidade das hipóteses dado um conjunto de evidências é apresentada na equação (3).

$$\sum_{j=1}^k P(H_i|\tilde{e}_j) = 1 \quad i = 1..n \quad (3)$$

Para cada evidência  $\tilde{e}_j$  tem-se a constante de normalização  $\tilde{\Delta}_j$ , equação (4):

$$\tilde{\Delta}_j = P(\tilde{e}_j|H_i) = \sum_{i=1}^n \left[ P(\tilde{e}_j|H_i) \mu_{ijm} + (1 - P(\tilde{e}_j|H_i)) \mu_{ijp} \right] P(H_i) \quad (4)$$

onde:

$\mu_{ijm}$  – maior grau de pertinência obtido para cada evidência;

$\mu_{ijp}$  – menor grau de pertinência obtido para cada evidência;

$P(\tilde{e}_j|H_i)$  – é a probabilidade condicional da evidência  $j$  relativa à hipótese  $i$ , obtida na tabela de probabilidades condicionais da rede bayesiana tradicional.

---

<sup>10</sup> O conjunto de funções de pertinência ligada à evidência cria os estados intermediários não existentes quando da abordagem dicotômica da probabilidade de um estado da rede bayesiana – ocorrência; não ocorrência.

Para cada conjunto de  $m$  evidências ( $k = 1, 2, \dots, m$ ) as probabilidades das hipóteses são obtidas através da equação (5):

$$P(H_i | \tilde{e}_1, \tilde{e}_2, \dots, \tilde{e}_k) = \frac{1}{\tilde{\Delta}_k} \sum_{i=1}^n [P(\tilde{e}_k | H_i) \mu_{ijm} + (1 - P(\tilde{e}_k | H_i)) \mu_{ijp}] P(H_i | \tilde{e}_1, \tilde{e}_2, \dots, \tilde{e}_{k-1}) \quad (5)$$

Observando a equação (5) nota-se que a rede híbrida funciona como uma espécie de ponderação entre as probabilidades e os graus de pertinência. No caso de ocorrência de um grau de pertinência  $\mu_{ijm} = 1$ , e consequentemente  $\mu_{ijp} = 0$ , tem-se a rede bayesiana tradicional.

As ferramentas da inteligência artificial apresentadas neste capítulo compõem a base de solução dos problemas de prognóstico e inferência das características de desempenho em ensaios de compressores analisados neste trabalho.

A utilização das redes *fuzzy*-bayesianas nesses ensaios é proposta neste trabalho no item 5.2.2 na tarefa de inferência da estabilidade. A adequabilidade do uso dessa ferramenta em ensaios de desempenho é corroborada pela publicação de um artigo em revista indexada (PENZ, 2011).

A utilização de redes neurais artificiais já apresenta evidências de sucesso nos trabalhos de HENKLEIN (2006), STEINBACH (2008) e LIMA (2010b). No desenvolvimento do presente trabalho tais ferramentas serão aprimoradas e será dada uma abordagem inédita à questão da confiabilidade. No próximo capítulo é apresentado o levantamento bibliográfico acerca da análise da confiabilidade na aplicação de redes neurais artificiais.





## 4 CONFIABILIDADE DE REDES NEURAS ARTIFICIAIS

Redes neurais artificiais têm sido muito exploradas como um paradigma alternativo às técnicas tradicionais de modelagem. Tal situação é reforçada quando estão envolvidos sistemas dinâmicos complexos com numerosas interações entre seus componentes (ERTUNC, 2008; NAVARRO-ESBRÍ, 2007).

As experiências acadêmicas e industriais têm demonstrado a aplicabilidade e, em alguns casos, a superioridade da abordagem neural na solução de problemas. No entanto, os aspectos metrológicos não têm sido tratados de maneira ampla o suficiente para a verificação da qualidade dos resultados obtidos por essas técnicas (ABLAMEYKO, 2003; MILANIC, 2004; KURD, 2007).

O objetivo deste capítulo é o levantamento bibliográfico acerca da avaliação da qualidade de resultados obtidos pelas redes neurais. Diversos artigos foram analisados com o intuito de verificar quais as formas de estabelecimento de intervalos de confiança têm sido utilizadas nas aplicações de redes neurais. Pode-se afirmar que o montante de referências analisadas é representativo no âmbito da literatura científica.

### 4.1 ASPECTOS GERAIS DA CONFIABILIDADE

A avaliação do funcionamento de uma rede neural é, normalmente, realizada sob o ponto de vista simplista do conceito de desvio padrão dos erros apresentados para um conjunto de treinamento, validação e teste (BARHEN, 2002; KHAWAJA, 2005). Na grande maioria das vezes esse conceito é apresentado como a “incerteza da rede neural”. Esse costume contrapõe-se aos conceitos metrológicos vigentes, o que necessariamente deve ser levado em consideração quando a rede neural é vista como integrante de um processo de medição.

A quantificação da incerteza dos resultados apresentados pelas redes neurais é foco de muitos trabalhos científicos, como será apresentado no item 4.2. Não existe uma teoria universal sobre o assunto. Dessa forma, a análise localizada na solução de problemas específicos tem sido a abordagem dominante.

Quando uma rede neural está diretamente envolvida em um processo de análise e tomada de decisão deve-se atentar para os seguintes pontos (HAYKIN, 1994; PAPADOPOULOS, 2001; ABLAMEYKO, 2003):

- não há segurança de que o algoritmo de treinamento encaminhou os pesos sinápticos a valores que correspondam a um mínimo global da função de erro;
- mesmo alcançado o mínimo global, a solução não será necessariamente ótima devido ao conjunto de treinamento finito, que não descreve o processo real por completo;
- as redes neurais se comportam de acordo com o que elas aprenderam na fase de treinamento, no entanto as informações sobre as incertezas dos padrões de treinamento não são usualmente empregadas nessa fase, o que contribui para um treinamento não otimizado;
- a maneira com que as incertezas dos valores de entrada se propagam através da rede até as saídas, isto é, como estimar a contribuição das incertezas das grandezas de entrada nas saídas.

## 4.2 ABORDAGENS APRESENTADAS NA LITERATURA

Os trabalhos de CHRYSSOLOURIS (1996), HWANG (1997) e VEAUX (1998) são até os dias atuais referências seguidamente citadas pelos mais diferentes autores. Esses estabeleceram abordagens para a estimativa de intervalos de confiança de redes neurais assumindo que os erros apresentados por elas são normalmente distribuídos e independentes. Os autores utilizaram técnicas de estimação de intervalos de confiança aplicadas em regressões não lineares e associaram a informação de que os modelos foram obtidos a partir de dados contaminados por incerteza de medição<sup>11</sup>. A equação (6) apresenta o intervalo de confiança do resultado da rede neural.

$$\hat{y}_0 \pm t_{n-p} \frac{\alpha}{2} [s_1^2 + (s_1^2 + \sigma_2^2) \mathbf{f}_0^T (\mathbf{F}^T \mathbf{F})^{-1} \mathbf{f}_0]^{1/2} \quad (6)$$

onde:

$\hat{y}_0$  – saída da rede para uma entrada inédita;

$t_{n-p} \alpha/2$  – fator *t-Student*;

$n$  – número de padrões utilizados no treinamento;

$p$  – número de parâmetros da rede neural (pesos e bias);

$s_1^2$  – estimador não tendencioso do erro referente ao modelo causado pelas variáveis não observáveis ou não controláveis;

---

<sup>11</sup> Os autores utilizam o termo ruído do dado (*data noise*), no entanto o autor deste traduz como incerteza de medição para adequar o texto aos termos metrológicos vigentes. Nas situações em que doravante, o autor do presente não achar adequada essa tradução, a literal será empregada.

- $\sigma_2^2$  – estimador dos erros de medição aleatórios presentes nas entradas da rede;
- $\mathbf{f}_0$  – vetor de derivadas da função aprendida pela rede em relação a cada parâmetro da rede para cada nova entrada;
- $\mathbf{F}$  – matriz jacobiana  $n \times p$  da função aprendida pela rede.

Uma característica do intervalo de confiança resultante da equação (6) é a forma com que relaciona o número de padrões utilizados no treinamento ( $n$ ) com o número de parâmetros da rede neural ( $p$ ). O fator *t-Student* é obtido para grau de liberdade  $n-p$  fazendo com que o intervalo de confiança cresça com a diminuição do número de padrões de treinamento. Deve-se atentar que a utilização dessa técnica pode dissimular o desempenho satisfatório de uma rede obtida com poucos padrões.

ABLAMEYKO (2003) estabelece que a incerteza dos resultados das redes neurais possui três origens e apresenta a forma como essas contribuições podem ser estimadas. São elas:

- a incerteza dos dados de entrada – baseado no procedimento apresentado no Guia para Expressão da Incerteza de Medição (BIPM, 2008a) o autor sugere a utilização do conceito de coeficiente de sensibilidade para avaliar a importância da incerteza de cada uma das entradas no cômputo do resultado da rede neural. Esses coeficientes podem ser obtidos numericamente para estimativa da incerteza combinada relativa aos dados de entrada, conforme a equação (7).

$$u^2(o_i) = \sum_{j=1}^n \left( \frac{\partial f_i}{\partial v_j} \right)^2 u(v_j)^2 + 2 \sum_{j=1}^{n-1} \sum_{k=j+1}^n \frac{\partial f}{\partial v_j} \frac{\partial f}{\partial v_k} u(v_j) u(v_k) \rho_{v_j v_k} \quad (7)$$

onde:

- $u(o_i)$  – incerteza padrão combinada da saída  $o_i$  da rede neural referente as entradas;
- $\partial f_i / \partial v_j$  – derivada da saída  $o_i$  da rede em relação às entradas  $v_j$ ;
- $u(v_*)$  – incerteza padrão de cada entrada da rede;
- $\rho_{v_j v_k}$  – coeficiente de correlação entre a  $j$ -ésima entrada e a  $k$ -ésima entrada da rede neural.

- a incerteza relativa ao modelo – baseado na constatação de que a rede neural não descreve a real relação entrada-saída, o autor sugere que, durante a fase de teste, a máxima diferença observada entre a saída da rede e o respectivo valor do padrão seja considerada como a contribuição do modelo à incerteza. A divisão do espaço de saída da rede pode ser considerada para a geração de contribuições particulares para a rede. O autor identifica essa contribuição por  $\delta_m$ ;
- a incerteza relativa a outras fontes – contribuições relacionadas com a existência de grandezas físicas, as quais afetam a grandeza de interesse, mas não são medidas ou controladas. O autor considera que essas influências devem ser conhecidas e quantificadas *a priori*. O autor identifica essa contribuição por  $\delta_{nm}$ .

Segundo ABLAMEYKO (2003) as contribuições referentes ao modelo e outras fontes,  $\delta_m$  e  $\delta_{nm}$  respectivamente, não são probabilísticas e a composição delas na forma de soma quadrática com  $u(o_i)$  resulta numa distribuição de média não nula de difícil interpretação em termos de probabilidade. Para o autor, a soma direta dessas contribuições, caracterizando uma situação de pior caso, torna-se uma medida mais conservadora da incerteza da rede.

PAPADOPOULOS (2001) estabelece que qualquer método para obtenção de intervalos de confiança para redes neurais deve informar as contribuições tanto da incerteza de medição relativa aos dados de entrada quanto à incerteza relativa ao modelo constituído após o treinamento. O artigo compara três métodos para obtenção desses intervalos de confiança na previsão de defeitos em papel. São eles:

- treinamento via máxima verossimilhança – estabelece a criação e treinamento de uma rede aumentada – com a mesma composição de neurônios das camadas intermediárias da rede original – para estimar a variância do resultado da rede  $\sigma_v^2(\mathbf{x};\mathbf{u})$  atribuída à incerteza de medição dos dados, conforme apresentado na figura 14; as duas redes são treinadas conjuntamente através de uma função de erro que engloba todos os seus parâmetros; a incerteza relativa ao modelo é obtida através de uma linearização que envolve o vetor de derivadas parciais da saída da rede em relação aos pesos sinápticos e à matriz de covariância desses pesos;

- treinamento bayesiano aproximado – utiliza a mesma rede aumentada apresentada na figura 14, mas realiza o treinamento das duas redes separadamente; a incerteza relativa ao modelo é obtida pelo mesmo método apresentado no item anterior;
- método *bootstrap* – parte da criação de um selecionado de  $n$  redes treinadas para  $n$  conjuntos de treinamento compostos por  $k$  padrões escolhidos aleatoriamente<sup>12</sup> da base de dados disponível; a incerteza referente aos dados é obtida pela variância dos resultados das  $n$  redes para os padrões não utilizados no treinamento; a variância dos resultados das  $n$  redes para toda a base de dados disponível é a incerteza relativa ao modelo.




Figura 14 – Rede aumentada, adaptada de PAPADOPOULOS (2001)

Os três métodos apresentados por PAPADOPOULOS (2001) assumem a composição das incertezas relativas aos dados e ao modelo como distribuição gaussiana de média igual ao valor apresentado pela rede neural – ou média de resultados no caso do método *bootstrap*. A área dessa distribuição que for coberta por uma distribuição predefinida como referência dos resultados esperados representa a medida da confiança dos resultados obtidos.

<sup>12</sup> *Bootstrap* é um método computacional para atribuir medidas de exatidão às estimativas obtidas estatisticamente. A amostra *bootstrap* é um conjunto de  $m$  elementos amostrados com reposição de uma população de  $m$  elementos (EFRON, 1993).

O método denominado *bootstrap* apresentado por PAPADOPOULOS (2001) exemplifica um artifício utilizado para melhorar a generalização de sistemas baseados em redes neurais. Esse artifício é a utilização de selecionados<sup>13</sup> de redes neurais para a obtenção de um único resultado.

A razão para utilização de selecionados de redes está calcada no desempenho que pode ser atingido comparado ao uso de apenas uma rede neural. Os erros dos componentes do selecionado se compensam parcialmente quando as saídas individuais são combinadas (TIBSHIRANI, 1994; EFRON, 1998).

Mesmo para redes obtidas com conjuntos de treinamento extraídos da mesma base de dados, os resultados podem ser suficientemente diferentes de modo que um processo simples de média seja favorável ao resultado final (HU, 2002; GRANITTO, 2005; ZIO, 2006; TRICHAKIS, 2011). Outros meios para combinar as saídas das redes podem ser aplicados visando desempenho superior como: regressão linear, análise de componentes principais, métodos não lineares, métodos bayesianos para fusão de informação (AHMAD, 2002; EDWARDS, 2002; HU, 2002; FORTUNA, 2007).

A seguir são destacados alguns aspectos evidenciados em artigos que tratam o uso de selecionados de redes como uma abordagem importante para a garantia da confiabilidade.

AHMAD (2002) apresenta o uso de selecionados na previsão em processos não lineares; propõe método de escolha de redes do selecionado para composição do resultado – isto é, nem sempre todas as redes são utilizadas para compor a resposta do selecionado; indica potenciais ganhos advindos da integração de resultados de redes escolhidas durante a aplicação.

EDWARDS (2002) relata a aplicação de selecionados de redes para previsão de aspectos da qualidade na indústria de papel; evidencia a possibilidade de definição de estratégias automáticas de criação e seleção de redes neurais para a composição de selecionados; relata como essas estratégias são importantes para a confiabilidade dos resultados dos selecionados; apresenta ganhos advindos do uso de abordagens modulares para composição de soluções mais abrangentes.

HU (2002) apresenta uma série de formas de concepção de soluções baseadas em múltiplas redes; relata a adequabilidade dessas soluções

---

<sup>13</sup> Na literatura científica esses conjuntos são comumente denominados de comitês (*committee machines*), empilhamento de redes neurais (*stacked neural networks*) ou, simplesmente, grupo de redes neurais (*neural networks ensemble*).

tanto para aplicações de regressão – onde os resultados são tipicamente agrupados através de operações de média – quanto para aplicações de classificação – onde as diferentes redes contribuem com saídas dicotômicas, isto é, como processos de votação; relata ainda a possibilidade de uso de conjuntos de redes criadas com funções diversas para modelar processos de maneira modular.

GRANITTO (2005) apresenta aspectos importantes para a escolha das redes neurais que compõe um selecionado; apresenta conceitos relacionados à necessidade de redes que tenham comportamentos diferentes para a composição de um selecionado mais robusto.

ZIO (2006) aplica conjuntos de redes neurais para previsão de grandezas presentes em plantas de energia nuclear; evidencia o desempenho do uso de múltiplas redes em lidar com aplicações com ampla faixa de valores de entrada; salienta a capacidade do método em apresentar boas respostas mesmo com entradas sujeitas a ruído.

FORTUNA (2007) avalia o uso de selecionados em processos de refino de combustíveis; compara métodos de integração de redes sob o ponto de vista de performance; evidencia ganhos significativos no uso de selecionados em comparação ao uso de redes neurais únicas; relata que o tempo demandado para criação dos selecionados é compensado pela simplicidade das análises dos resultados.

YU (2009) e WU (2010) apresentam a aplicação de selecionados para a substituição de cartas de controle em tarefas relacionadas ao controle estatístico de processos; apresentam formas de potencializar a criação de selecionados com redes que se complementem e resultem numa ferramenta com maior grau de generalização.

TRICHAKIS (2011) aplica selecionados de redes para previsão de recursos hidrológicos e meteorológicos; evidencia que a complexidade dos modelos matemáticos concernentes ao processo em questão necessita de redes neurais com tantos neurônios que impossibilitam a aplicação de estimativas a partir de mínimos quadrados para a caracterização de medidas de confiabilidade.

Como característica geral dos diversos artigos científicos analisados – no intuito de identificar potenciais métodos de análise e incremento da confiabilidade no uso de redes neurais – tem-se aspectos da aplicação norteando a implementação das ferramentas. Nota-se o tratamento localizado dos problemas para as aplicações como sistemas de manufatura (CHRYSSOLOURIS, 1996), previsão da qualidade de papel (PAPADOPOULOS, 2001; EDWARDS, 2002), monitoração de processos de refino de combustíveis (FORTUNA, 2007), aplicação em sistemas elétricos (MO-

RI, 1992; HWANG, 1997; MRUGALSKI, 2008), aplicações na área médica (DYBOWSKI, 2001; ABLAMEYKO, 2003), previsão em processos nucleares (ZIO, 2006), análise de comportamentos em ciências hidrológicas e meteorológicas (TRICHAKIS, 2011), desenvolvimento de sistemas para análise de imagens (ARSLAN, 2004). As informações apresentadas pelos artigos demonstraram a diversidade de abordagens para o estabelecimento de medidas de confiabilidade para redes neurais.



## 5 PROPOSTA DE MÉTODOS E PROCEDIMENTOS PARA GERAÇÃO DE INFERÊNCIAS E PROGNÓSTICOS MAIS CONFIÁVEIS

Este capítulo apresenta propostas de métodos e procedimentos visando resultados de ensaios confiáveis quando esses são obtidos com o uso de ferramentas da inteligência artificial.

Inicia com a descrição geral dos processos de inferência e prognóstico e a forma de inter-relação desses no acompanhamento dos ensaios de desempenho. Na sequência são detalhados métodos e procedimentos para a garantia da confiabilidade das tarefas de inferência do regime permanente quando usadas redes neurais artificiais. Para informação complementar do regime permanente é proposto o emprego de uma rede *fuzzy*-bayesiana que, adicionalmente às redes neurais artificiais, têm a função de prover resultados mais confiáveis para essa tarefa. O capítulo encerra com os métodos e procedimentos desenvolvidos para a tarefa de prognóstico do valor final.

O presente trabalho se ateve à análise das ferramentas montadas para a inferência do instante de entrada em regime permanente e prognóstico da capacidade de refrigeração.

### 5.1 PANORAMA

Os métodos e procedimentos desenvolvidos neste trabalho são aplicados às ferramentas baseadas em IA apresentadas por HENKLEIN (2006), STEINBACH (2008), CASELLA (2009) e LIMA (2010b). No tocante às redes neurais, cabe ressaltar que LIMA (2010b) utilizou o conhecimento gerado no desenvolvimento realizado por STEINBACH (2008), que por sua vez se baseou em HENKLEIN (2006). No tocante às redes *fuzzy*-bayesianas, CASELLA (2009) – em dissertação co-orientada pelo autor do presente trabalho – avaliou a viabilidade do uso dessas redes na inferência do regime permanente.

Tais trabalhos ocorreram no período de realização desta tese e, através da participação efetiva do seu autor, foram alinhados no intuito garantir avanço na qualidade dos resultados.

Os trabalhos relacionados à aplicação de redes neurais exploraram exaustivamente a escolha do tipo de rede neural, variáveis de entrada e formas de pré-processamento das mesmas, arquitetura (número de camadas e neurônios, funções de ativação e conectividade) e algoritmos de treinamento. Assim, ao final do trabalho de LIMA (2010b) obteve-se um

conjunto de ferramentas com desempenho satisfatório para a aplicação. Nessa condição, foge do escopo deste trabalho de doutorado executar novos processos de escolha das características das redes neurais, exceto na ocorrência de evidências que justifiquem tal ação.

O trabalho de LIMA (2010b) culminou com uma ferramenta composta por duas redes neurais para análise de cada uma das variáveis de interesse (capacidade de refrigeração, potência elétrica ativa consumida e coeficiente de performance), são elas: rede de inferência de regime; rede de prognóstico do valor final.

A ferramenta desenvolvida por LIMA (2010b) infere, primeiramente, o instante de entrada em regime permanente e, a partir desse resultado, realiza o prognóstico das variáveis de interesse. As redes neurais foram treinadas levando-se em consideração essa condição.

Vale ressaltar que LIMA (2010b) desenvolveu e implantou software na bancada de ensaios de desempenho para geração de resultados para avaliação da ferramenta. Desde então, foram realizados ensaios de maneira completa, como exige a norma e, para cada um, foi gerado um relatório que apresenta: identificação completa do compressor e condições de teste; valores finais das grandezas de interesse; tempos relativos às inferências de regime; prognósticos e respectivos erros para cada uma das grandezas.

No âmbito deste trabalho foi realizado e analisado um conjunto de 275 ensaios de avaliação de desempenho sendo esse conjunto dividido em dois grupos: 210 ensaios realizados sem aceleração de transitório; 65 ensaios realizados com aceleração de transitório – executados de acordo com o método apresentado no item 2.3. A análise revelou uma série de características de comportamento da ferramenta implantada por LIMA (2010b) e contribuiu para definição de métodos e procedimentos para melhoria e garantia da confiabilidade dos resultados, objetivo deste trabalho de doutorado.

É importante ressaltar que as medições das diversas grandezas pertinentes ao ensaio de desempenho estão com sua confiabilidade metrológica garantida. Tal condição é fruto dos diversos trabalhos já realizados pelo grupo de pesquisa do qual o autor deste é integrante. Essa condição é relatada na introdução deste documento e atribuída aos trabalhos de BARBOSA (2006), FLESCH (2006), POLETO (2006) e PETROVIC (2007). As estimativas de incertezas das grandezas foram realizadas nesses trabalhos e estão disponíveis. Essa situação é muito favorável para o processo de obtenção de inferências e prognósticos confiáveis.

Adicionalmente à confiabilidade metrológica das grandezas utilizadas, deve-se estabelecer a necessidade de ensaios com comportamen-

tos típicos para ocorrência de inferências e prognósticos seguros. Essa tipicidade é caracterizada por:

- uso de bancada de ensaio totalmente automatizada, isto é, sem influência do operador no decorrer do ensaio e com controles definidos e validados para todas as grandezas;
- ausência de causa crítica de instabilidade<sup>14</sup>;

Na sequência deste capítulo serão apresentados métodos e procedimentos capazes de integrar as informações de inferência e prognóstico e agregar confiabilidade às ferramentas para uso em ensaios.

## 5.2 INFERÊNCIA DO REGIME PERMANENTE DA VARIÁVEL DE INTERESSE

O período no qual a variável permanece dentro dos limites de tolerância e não mostra tendência a se mover fora desses limites é denominado regime permanente. Enquanto não se atingir esse período, diz-se que o ensaio se encontra no transitório (ISO, 1989).

Pelos requisitos da norma ISO 917 o regime permanente do ensaio só é alcançado quando todas as variáveis atingem os limites de variação relatados no item 2.2. Uma característica que deve ser levada em consideração é a de que os valores finais de ensaio não são previamente conhecidos assim como os valores de tolerância absolutos<sup>15</sup>. Só se saberá o valor final de ensaio de uma variável ao final do mesmo, dado que este é calculado pela média das medidas da última hora de ensaio (ISO, 1989). Assim, logicamente, chega-se à conclusão de que o instante de entrada (real) em regime só poderá ser levantado ao final do ensaio.

Para contornar essa situação – não conhecimento prévio dos valores finais das variáveis de interesse – e, conseqüentemente, as tolerâncias em valor absoluto para identificar a entrada em regime, deve-se recorrer às análises dos comportamentos das variáveis durante ensaios.

As ferramentas de identificação de entrada em regime devem ser capazes de diferenciar o período de regime transitório do período de regime permanente. A figura 15 (superior) mostra um exemplo de com-

---

<sup>14</sup> A causa crítica de instabilidade é definida – no âmbito deste trabalho – como a ocorrência de qualquer fato alheio à capacidade de ação dos controles ou erros grosseiros nas medições das diversas grandezas presentes no ensaio. As táticas para lidar com essas instabilidades e erros são mencionadas na sequência deste documento.

<sup>15</sup> A norma ISO 917 (1989) especifica a tolerância em percentual sobre o valor lido.

portamento da capacidade de refrigeração com o valor final e os limites de avaliação de estabilidade ( $\pm 2\%$ ) obtidos através dele. Nota-se que a partir dos 45 minutos de ensaio a capacidade permanece dentro dos limites que caracterizam a estabilidade. A figura 15 (inferior) mostra a saída ideal da ferramenta para identificação do regime: mudança de estado no exato momento de entrada em regime.

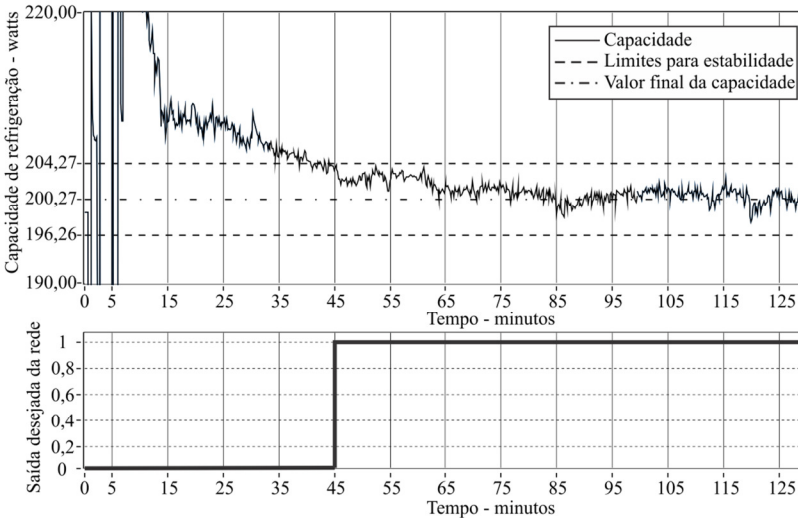


Figura 15 – Exemplo de comportamento da capacidade e saída ideal da ferramenta de inferência de regime

Para a inferência do instante de entrada no regime permanente da variável de interesse são propostas duas estratégias distintas:

- uma baseada nas ferramentas desenvolvidas por LIMA (2010b) com o uso de redes neurais artificiais, que neste trabalho são envolvidas por ações visando a garantia da confiabilidade;
- uma baseada em redes *fuzzy*-bayesianas – proposta neste trabalho e pré-avaliada por CASELLA (2009).

A integração dos resultados dessas estratégias implica considerável ganho na confiabilidade da inferência. Esse ganho será comprovado ao final desta seção.

### 5.2.1 Estratégia baseada em redes neurais

A elaboração da estratégia para garantia da confiabilidade das inferências de regime obtidas via redes neurais partiu de constatações advindas da análise dos resultados apresentados pela ferramenta implantada por LIMA (2010b) – nos 275 ensaios realizados no âmbito deste trabalho.

A primeira constatação refere-se à necessidade de ocorrência de inferência numa quantidade significativa de ensaios. Essa situação garante ganhos de tempo substanciais com a aplicação das técnicas de inteligência artificial nos ensaios de desempenho. No caso da capacidade de refrigeração, a inferência do regime permanente não ocorreu em 50 dos 275 ensaios analisados, aproximadamente 18%.

A segunda constatação refere-se à qualidade das inferências obtidas. Essa análise é realizada pela comparação da média das 15 medições da variável de interesse – precedentes ao instante de entrada em regime inferido – com o valor final do ensaio. Para a capacidade de refrigeração, a diferença absoluta média é de 2,2% com dois desvios padrão de 13,5%. Apesar de a diferença absoluta média estar muito próxima do objetivo – identificar o instante em que a capacidade adentra os limites de  $\pm 2\%$  – um total de 63 ensaios apresentaram inferências fora da região pretendida. Essa quantidade equivale a aproximadamente 28% dos ensaios que apresentaram inferência do regime.

Para melhorar os resultados obtidos e encaminhar confiabilidade é proposta neste trabalho uma estratégia baseada na utilização de diversas redes neurais para a realização da inferência do regime. Tais redes apresentam a mesma arquitetura, no entanto, são obtidas de diferentes conjuntos de treinamento e parâmetros iniciais (pesos e bias). Integradas à estratégia estão: um banco de dados de valores típicos de capacidade de refrigeração e temperatura do corpo; uma base de regras para integrar as repostas das diversas redes numa única indicação de estabilidade. A figura 16 apresenta o esquema geral da estratégia para a inferência de regime para a capacidade de refrigeração proposta no presente trabalho.

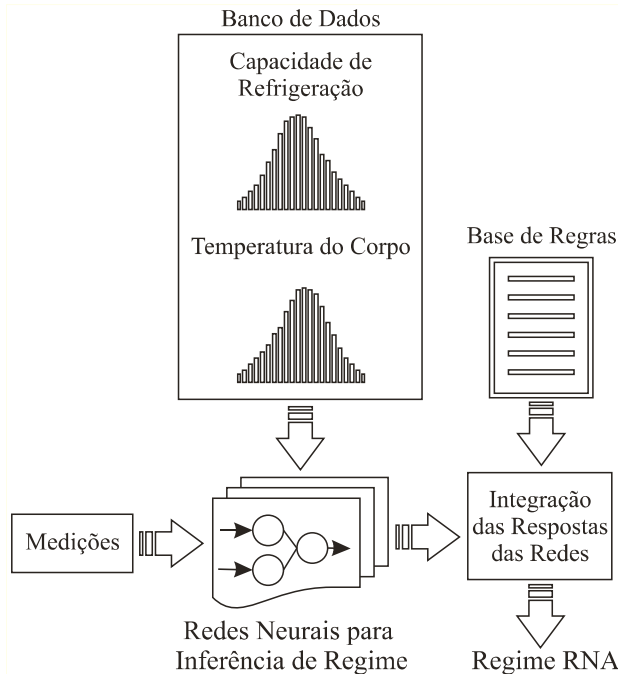


Figura 16 – Esquema geral da estratégia para a inferência de regime da capacidade de refrigeração

Nos próximos itens são apresentados e detalhados cada um dos aspectos relacionados à estratégia proposta. Apesar da proposta ser toda em relação à capacidade de refrigeração, essa poderá ser transferida para as outras variáveis de interesse num ensaio de desempenho: consumo de potência ativa e coeficiente de performance.

### 5.2.1.1 Caracterização das redes neurais

Este item apresenta as características das redes neurais utilizadas para inferência do regime permanente da capacidade de refrigeração: arquitetura e treinamento; variáveis de entrada e saída; conjuntos de treinamento.

#### a) Arquitetura e treinamento

A figura 17 descreve a arquitetura das redes neurais para a inferência de regime permanente da variável de interesse.

<i>Camada</i>	<i>Número de neurônios</i>	<i>Função de ativação</i>
Entrada	16	-
1ª escondida	15	Tangente hiperbólica
2ª escondida	10	Tangente hiperbólica
3ª escondida	10	Tangente hiperbólica
Saída	2	Logística

Figura 17 – Arquitetura das redes neurais para inferência de regime

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).

#### b) Variáveis de entrada

Para a inferência do regime permanente da capacidade de refrigeração, a rede é composta pelas entradas apresentadas na figura 18. Nota-se que para essa tarefa são utilizadas três variáveis: a própria capacidade de refrigeração; temperatura do corpo do compressor; pressão de sucção.

Uma contribuição deste trabalho foi a criação e utilização de um banco de dados de valores típicos para a capacidade de refrigeração e temperatura do corpo de compressores em ensaios de desempenho. Para o conjunto de ensaios disponíveis foram identificados os valores típicos segundo a seguinte classificação: modelo compressor; tensão de alimentação; frequência de alimentação; rotação (quando compressor de capacidade variável); condição termodinâmica de ensaio.

Assim, as entradas 2, 3 e 4 (figura 18) são normalizadas para o valor típico da capacidade de refrigeração, e as entradas 9 e 10 (figura 18) são normalizadas para o valor típico da temperatura do corpo.

Essa normalização tem como principal objetivo melhorar o conhecimento da rede neural no comportamento dinâmico característico dos ensaios de desempenho. A ferramenta implantada por LIMA (2010b) considerou apenas três valores para normalização das entradas referentes à capacidade de refrigeração – 50 W, 137,5 W e 220 W. Esses valores estão associados a uma classificação – definida pela fabricante de compressores – que considera o valor típico da capacidade de refrigeração:

- compressores grandes – 175 W a 265 W (valor médio = 220 W);
- compressores médios – 100 W a 175 W (valor médio = 137,5 W);
- compressores pequenos – até 100 W (valor médio = 50 W).

Para a normalização referente à temperatura do corpo os valores adotados por LIMA (2010b) foram 56 °C (compressores pequenos e médios) e 66 °C (compressores grandes).

Variável	Entradas
Capacidade de refrigeração	1 Desvio padrão de 15 amostras da variável precedentes ao instante atual (Std1).
	2 Média de 15 amostras da variável precedentes ao instante atual (M1).
	3 Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras (M2).
	4 Média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras (M3).
	5 Derivada entre 2 <sup>a</sup> e 3 <sup>a</sup> entrada (D1).
	6 Derivada entre 3 <sup>a</sup> e 4 <sup>a</sup> entrada (D2).
	7 Derivada entre 2 <sup>a</sup> e 4 <sup>a</sup> entrada (D3).
	8 Derivada entre 5 <sup>a</sup> e 6 <sup>a</sup> entrada (D4).
Temperatura do corpo	9 Média de 15 amostras da variável precedentes ao instante atual.
	10 Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras.
	11 Derivada entre 9 <sup>a</sup> e 10 <sup>a</sup> entrada.
	12 Derivada entre a 9 <sup>a</sup> entrada e a média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras.
Pressão de sucção	13 Média de 15 amostras da variável precedentes ao instante atual.
	14 Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras.
	15 Derivada entre 13 <sup>a</sup> e 14 <sup>a</sup> entrada.
	16 Derivada entre a 13 <sup>a</sup> entrada e a média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras.

Figura 18 – Entradas da rede de inferência de regime da capacidade



### c) Saída das redes

As redes foram providas de uma saída que deve excursionar entre os valores zero e um. O nível zero é atribuído para o período transitório, enquanto o nível um para o período de regime permanente.

### d) Intervalo de treinamento das redes

Nota-se na figura 15 (superior, página 68) que o início do ensaio (até 5 minutos) apresenta valores de capacidade com grandes oscilações resultantes da acomodação das diversas variáveis controladas. Nos ensaios utilizados para treinamento, esses períodos iniciais foram descartados. O instante final do intervalo corresponde ao tempo do ensaio de menor duração dentre todos os ensaios de treinamento. Assim, a amostra fornece dados representativos suficientes do regime permanente e do regime transitório.

## 5.2.1.2 Uso de múltiplas redes

Neste item é apresentada e justificada a aplicação de múltiplas redes neurais para a composição de uma ferramenta que consiga: inferir o instante de entrada em regime numa quantidade maior de ensaios; melhorar a qualidade das inferências, isto é, inferir instantes de entrada em regime mais próximos ao limite de estabilidade.

### a) Justificativa

O uso de múltiplas redes neurais é típico em diversas aplicações industriais e científicas. A combinação de um conjunto de redes pode ser entendida como uma forma de gerenciar as limitações individuais das redes. É sabido que as redes estão sujeitas a erros, mas elas podem ser combinadas de um modo que reduza os efeitos desses erros (KROGH, 1995; EFRON, 1998; SHARKEY, 1999; WINKLER, 2004; AHMAD, 2005; ZIO, 2006; PERETTI, 2010).

No âmbito deste trabalho foram treinadas diversas redes neurais para a tarefa de inferência do regime permanente. A figura 19 apresenta probabilidades de indicação de regime permanente para 30 redes obtidas para o conjunto de teste composto por 275 ensaios. A figura apresenta duas informações:

- ×  $p(\text{indicar}E|E)$  – probabilidade da rede de indicar estabilidade dado que o ensaio **está estável**;
- $p(\text{indicar}E|\sim E)$  – probabilidade da rede de indicar estabilidade dado que o ensaio **não está estável**.

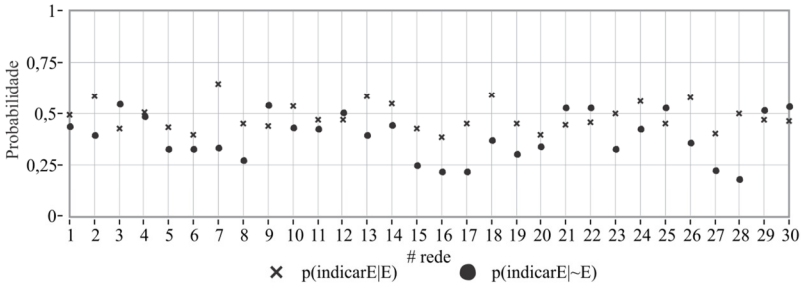


Figura 19 – Probabilidade de indicação de estabilidade pelas redes treinadas

Nota-se que as probabilidades estão dispostas entre 0,25 e 0,75 com maior concentração nas proximidades de 0,50. Aliada às probabilidades apresentadas na figura 19 existe a probabilidade das redes **não indicarem estabilidade**, como pode ser verificado na figura 20.




Figura 20 – Probabilidade de não indicação de estabilidade pelas redes treinadas

Essas informações corroboram as constatações advindas da análise da ferramenta implantada por LIMA (2010b) – apresentadas no início do item 5.2.1:

- $p(\text{indicar}E|\sim E)$  na faixa aproximada de 0,25 a 0,50 contribuem para a inferência do regime em momentos que implicam posicionamento da variável de interesse fora do limite definido para a estabilidade, por exemplo,  $\pm 2\%$  para a capacidade de refrigeração;

- probabilidades de não indicação do regime, na faixa aproximada de 0,20 a 0,40, comprometem o desempenho da ferramenta no quesito aumento de produtividade na execução de ensaios de compressores.

A identificação do instante de entrada em regime pode ser vista como uma aplicação industrial complexa já que, *a priori*, trata-se da inferência de um estado que somente será definido, segundo o método normatizado, ao final do ensaio de desempenho do compressor. Adicionalmente, as variáveis presentes nos ensaios podem assumir comportamentos bem distintos exigindo que a ferramenta de inferência seja robusta e garanta a qualidade do resultado.

O artigo de GEMAN (1992), intitulado “*Neural networks and the bias/variance dilemma*” trata do comportamento de ferramentas de inferência não paramétricas no que concerne aos erros relacionados aos resultados das mesmas. Como exemplo desse tipo de ferramenta de inferência tem-se as redes neurais artificiais tipo *perceptron* multicamadas treinadas com o método de retropropagação do erro – usada nas tarefas de inferência de regime e prognóstico neste trabalho.

GEMAN (1992) relata esses erros como sendo compostos por duas parcelas – bias e variância – e contrapõe as características de ferramentas não paramétricas (*model-free*) às características de reposta de soluções baseadas em modelos, para essas duas parcelas. Segundo o autor, as redes neurais podem apresentar significativa parcela de variância já que, tipicamente, possuem quantidades elevadas de parâmetros que devem ser ajustados no período de treinamento. Em contraponto, soluções baseadas em modelos são difíceis de serem implementadas para problemas complexos e, sendo incorretas, podem implicar elevados bias. Adicionalmente, destaca a ocorrência de elevados bias em redes neurais treinadas com baixas quantidades de exemplos ou quando o treinamento prossegue sem supervisão para um estado de *overfitting* (baixa generalização). Os conceitos e desenvolvimentos realizados por GEMAN (1992) têm suportado uma série de trabalhos no uso de múltiplas redes neurais para inferências em aplicações científicas e industriais complexas (AHMAD, 2002; EDWARDS, 2002; HU, 2002; GRANITTO, 2005; ZIO, 2006; FORTUNA, 2007; YU, 2009; WU, 2010; TRICHAKIS, 2011). Nesses trabalhos o uso de múltiplas redes destacou-se como ferramenta na busca de maior equilíbrio entre as parcelas de erro – bias e variância.

Esse levantamento bibliográfico aliado aos resultados apresentados nas figuras 19 e 20 endossam a necessidade de uso de múltiplas redes.

Um conjunto de redes neurais eficaz para a aplicação é formado por redes tão exatas e diversificadas quanto possível (SHARKEY, 1998; ZHANG, 1999; GRANITTO, 2005; YU, 2009; WU, 2010).

A exatidão das redes é obtida através do uso de conjuntos de treinamentos adequados quanto à abrangência dos exemplos em relação ao que a rede encontrará no uso. Adicionalmente, a supervisão do treinamento deve ser realizada de maneira a evitar, o quanto possível, o *overfitting* – baixa generalização (GRANITTO, 2005; YU, 2009; WU, 2010).

A garantia de diversidade<sup>16</sup> – num conjunto de redes neurais que será utilizado para uma determinada tarefa – está diretamente relacionada ao modo como o conjunto irá gerenciar a questão da variância (SHARKEY, 1996; ZIO, 2006; YU, 2009; WU, 2010). Uma característica importante para a garantia de um conjunto de redes diversas é quanto à simultaneidade de erros. Um conjunto de redes que apresenta baixas quantidades de erros simultâneos entre as redes tende a atender ao critério de diversidade (SHARKEY, 1999; BROWN, 2005; ROKACH, 2009).

Alguns meios para obtenção de redes potencialmente diversas são: uso de diferentes algoritmos de treinamento; uso de diferentes arquiteturas de redes (número de camadas e neurônios, conectividade entre camadas e neurônios, funções de ativação); uso de diferentes conjuntos de treinamento; uso de diferentes conjuntos de pesos iniciais para treinamento. Dentre esses meios, o uso de diferentes conjuntos de treinamento aliado aos diferentes conjuntos de pesos iniciais tem demonstrado maior potencial de geração de diversidade (SHARKEY, 1995; BROWN, 2005; ROKACH, 2009).

As trinta redes neurais para inferência de regime – cujas probabilidades de indicação de estabilidade são apresentadas nas figuras 19 e 20 – foram obtidas de conjuntos de treinamento distintos a partir de uma base de dados de 50 ensaios<sup>17</sup>. Essa base é assumida como representativa do comportamento típico em bancadas de avaliação de desempenho de compressores. Tal base é composta por ensaios de diversos modelos de compressores avaliados em diferentes condições termodinâmicas e sem nenhuma técnica de aceleração de transitório.

---

<sup>16</sup> O conceito de diversidade aplicado às redes neurais advém da área de engenharia de software onde, para aumentar a confiabilidade, diferentes versões de um mesmo software são realizadas (ERDOGMUS, 2009).

<sup>17</sup> O conjunto de cinquenta ensaios utilizado para obtenção das redes não faz parte dos 275 ensaios usados para avaliação dos métodos e procedimentos propostos neste trabalho. Tal conjunto é o mesmo utilizado para treinamento e teste das redes propostas por LIMA (2010b).

Para cada rede foram gerados: um conjunto composto por 40 ensaios para treinamento; um conjunto de ensaios para a validação *on-line*<sup>18</sup>. Os 40 ensaios do conjunto de treinamento foram selecionados aleatoriamente, com reposição, dos 50 disponíveis. Os conjuntos de validação *on-line* foram compostos pelos ensaios não selecionados para o conjunto de treinamento. A característica de reposição no processo de formação dos conjuntos de treinamento fez com que alguns apresentassem ensaios repetidos. Assim, os conjuntos de validação *on-line* variaram em número de ensaios.

Como meio de avaliar a diversidade e a adequabilidade do conjunto de trinta redes para inferência do regime são apresentados dois histogramas das correlações existentes entre as redes. A figura 21 apresenta as correlações existentes entre as redes para as respostas corretas de estabilidade, isto é, indicar estabilidade quando o ensaio está estável.




Figura 21 - Histograma das correlações das indicações corretas de estabilidade

<sup>18</sup> O processo de validação *on-line* (também conhecido por *early stopping*) refere-se a um 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. Assim, durante o treinamento, o erro médio quadrático para o conjunto de treinamento é comparado com o obtido para o conjunto de validação *on-line*. Se o último iniciar tendência a aumentar enquanto o primeiro diminui por um número arbitrado de iterações, significa que o treinamento tende à memorização e, então, o processo de ajuste dos parâmetros da rede deve ser finalizado. Assume-se, então, como a rede final, aquela imediatamente antes da contagem das iterações.

A figura 22 apresenta as correlações existentes entre as redes para as respostas incorretas de estabilidade, isto é, indicar estabilidade quando o ensaio não está estável.




Figura 22 - Histograma das correlações das indicações erradas de estabilidade

A análise das correlações apresentadas pelas redes revela que não existem redes iguais – ou que se comportam como tal – no conjunto de trinta redes. Os níveis de correlação apresentados, para a grande maioria das redes são de fracos a moderados, isto é, as redes compartilham erros e acertos em níveis próximos. Esse comportamento é compatível com o apresentado na figura 19. Esses resultados endossam o conjunto de redes obtido como um conjunto com diversidade aceitável.

Adicionalmente, uma análise da figura 20 (probabilidades de não indicar estabilidade) indicaria o descarte de redes com probabilidade mais elevada, pois poderiam não agregar ganhos ao processo de inferência. No entanto, o cruzamento com os dados apresentados na figura 19, revela que a maioria das redes com probabilidade acima de 0,20 de não indicar estabilidade têm as menores probabilidades de falso-positivo, isto é, indicar estabilidade dado que o ensaio não está estável. Essa é uma característica importante para a garantia da confiabilidade da inferência da estabilidade.

Quanto ao número de redes que devem compor a ferramenta de inferência, alguns dos artigos pesquisados indicam que o uso de 20 a 200 redes tem se mostrado suficiente para a grande maioria das aplicações – desde que apresentem comportamentos individuais adequados em termos de exatidão (EFRON, 1998; GRANITTO, 2005; ZIO, 2006; YU, 2009; WU, 2010).

Com o intuito de verificar a quantidade de redes necessária para o processo de inferência foi realizada uma análise com foco na diferença entre a capacidade de refrigeração no instante de indicação da estabilidade e o valor final de ensaio. Como foram levantados dois conjuntos de teste distintos – ensaios com e sem aceleração de transitório – tal análise considerou essa característica.

A figura 23 apresenta o erro médio absoluto percentual da capacidade de refrigeração no instante que determinadas quantidades de redes indicaram a estabilidade (ensaios sem aceleração de transitório). A linha cheia indica o erro médio absoluto percentual e as pontilhadas a adição e subtração de dois desvios padrões do erro. Por exemplo, na abscissa 15 – que significa que 15 redes indicaram estabilidade – o erro médio é de aproximadamente 2%. Nota-se que para indicação de estabilidade de mais de 27 redes o erro médio – incluindo os dois desvios padrões – está abaixo de 2%.

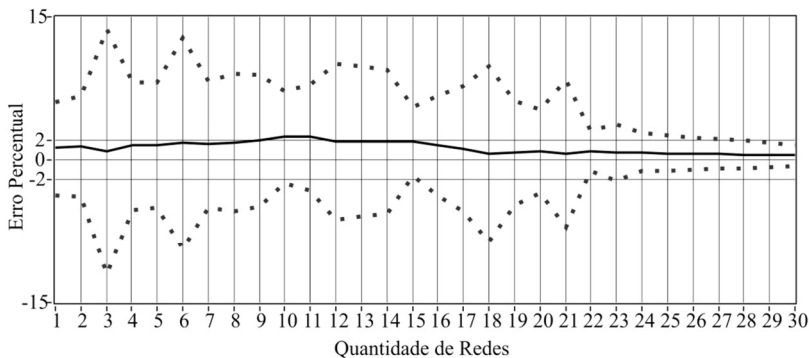


Figura 23 – Erro médio das 15 amostras precedentes à indicação de estabilidade (ensaios sem aceleração de transitório)

A figura 24 apresenta a mesma análise para ensaios com aceleração de transitório. Nesse caso, tem-se indicações de estabilidade com erros médios abaixo de 2% a partir de 16 redes, no entanto, há um pequeno acréscimo para 24 redes, mas volta à faixa de 2% a partir de 27 redes.

O comportamento oscilatório do erro absoluto médio deve-se ao fato da não indicação de estabilidade por parte de algumas redes. Isso faz com que a quantidade de ensaios usados para obtenção dos erros médios seja diferente para cada quantidade de redes.




Figura 24 – Erro médio das 15 amostras precedentes à indicação de estabilidade (ensaios com aceleração de transitório)

Essas análises corroboram a utilização múltiplas redes para a realização da inferência da estabilidade e indicaram que um conjunto formado por trinta mostrou-se adequado para a inferência do regime. No entanto, não se pode contar com a indicação da estabilidade de todas as redes – fato evidenciado pelas probabilidades de não indicação apresentadas na figura 20. Assim, o próximo item apresenta um meio para contornar essa situação.

#### b) Estratégia de integração das respostas das redes

Este item apresenta a definição de regras que relacionam as quantidades de redes e tempos de espera para caracterizar o instante de estabilidade obtido através das redes neurais.

O item anterior indicou que a estabilidade poderia ser aceita a partir da confirmação de, no mínimo, 27 redes. No entanto, como existe a probabilidade de redes não indicarem a estabilidade se faz necessária a definição de regras intermediárias de confirmação da estabilidade para quantidades mais baixas de redes. Assim, o processo de inferência fica mais robusto às peculiaridades de cada uma das redes em indicar, ou não, a estabilidade.

O objetivo é, então, definir tempos de espera para quantidades de redes inferiores a 27. Para isso tem-se 30 curvas do erro médio absoluto percentual da capacidade em função de tempos de espera após a indicação de estabilidade para cada quantidade de redes. As figuras 25 a 30 apresentam as curvas obtidas para 1, 5, 10, 15, 20 e 25 redes. O erro médio absoluto percentual está apresentado em linha cheia; em linhas pontilhadas tem-se dois desvios padrão somados e subtraídos do erro.






Figura 25 – Erro médio percentual versus tempo de espera para 1 rede




Figura 26 – Erro médio percentual versus tempo de espera para 5 redes




Figura 27 – Erro médio percentual versus tempo de espera para 10 redes




Figura 28 – Erro médio percentual versus tempo de espera para 15 redes




Figura 29 – Erro médio percentual versus tempo de espera para 20 redes




Figura 30 – Erro médio percentual versus tempo de espera para 25 redes

A observação das figuras 25 a 30 revela que quanto maior o número de redes indicando estabilidade, menor é o tempo de espera necessário para atingir erros inferiores ao nível estipulado de 2%. A análise dos gráficos resultou as regras apresentadas na figura 31, onde são indicadas as quantidades de redes e tempos de espera para a garantia de que a capacidade de refrigeração esteja na faixa de estabilidade.

Regra	Quantidade de redes	Tempo de espera
I	< 15	40 minutos
II	$\geq 15$ e < 20	30 minutos
III	$\geq 20$ e $\leq 27$	10 minutos
IV	> 27	0

Figura 31 – Relação entre quantidade de redes e tempo de espera

As figuras 32 e 33 mostram os histogramas da diferença percentual entre a capacidade de refrigeração no instante de entrada em regime – inferido segundo as regras definidas – e o valor final da capacidade. Nota-se que para a totalidade dos ensaios com aceleração de transitório a capacidade de refrigeração estava bem próxima da faixa de  $\pm 2\%$  do valor final. No caso sem aceleração existem mais ensaios fora da faixa de  $\pm 2\%$  do valor final.

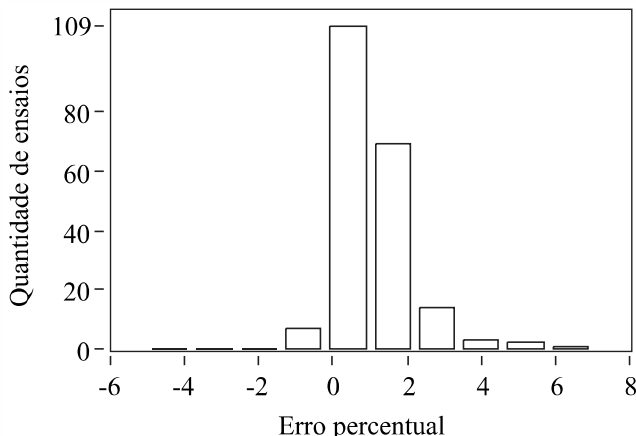


Figura 32 – Erro percentual da capacidade na inferência, sem aceleração




Figura 33 – Erro percentual da capacidade na inferência, com aceleração

A figura 34 apresenta as quantidades de ensaios para cada regra definida para inferência de regime utilizando redes neurais.

Regra	Quantidade de ensaios	
	Sem aceleração	Com aceleração
I	2	0
II	55	7
III	131	40
IV	22	18

Figura 34 – Quantidade de ensaios para cada regra adotada

Os resultados obtidos pela ferramenta proposta para inferência de regime utilizando redes neurais foram satisfatórios visto que os erros concentraram-se na faixa de  $\pm 2\%$ . Resultados fora dessa faixa foram obtidos, mas a estratégia apresentada no próximo item implicará ganhos que suportarão um melhor desempenho conjunto.

### 5.2.2 Estratégia baseada em rede *fuzzy*-bayesiana

A estratégia baseada na rede *fuzzy*-bayesiana (RFB) visa prover uma indicação adicional à inferência de regime realizada a partir das redes neurais. A modelagem realizada através de probabilidade e representação *fuzzy* permite uma visão distinta à neural para a identificação do regime permanente. Desta forma, pretende-se aumentar a confiabilidade da inferência a partir da integração das duas estratégias.

A idéia geral da modelagem da identificação do regime através da rede *fuzzy*-bayesiana é apresentada na figura 35.

O limite de estabilidade mostrado na figura 35 é de  $\pm 2\%$  do valor final do ensaio (o mesmo utilizado na solução usando redes neurais). O ensaio é analisado em períodos de tempo ( $t_p$ ) de 2,5 minutos. A capacidade de refrigeração é considerada estável se todos os valores medidos durante  $t_p$  estiverem dentro do referido limite.

As variáveis auxiliares são temperatura do corpo do compressor e o valor do controle da pressão de sucção.

O conhecimento da rede é estabelecido relacionando a estabilidade da capacidade de refrigeração com a estabilidade de cada uma das variáveis auxiliares para os diversos períodos  $t_p$  presentes nos ensaios da base de dados disponível. Dessa forma, pode-se obter informações do tipo: probabilidade da capacidade de refrigeração estar estável, dado que a temperatura do corpo do compressor está estável.




Figura 35 – Representação gráfica da identificação da estabilidade

### 5.2.2.1 Caracterização da rede proposta

A figura 36 apresenta um diagrama esquemático da estratégia *fuzzy*-bayesiana para a inferência do regime permanente da capacidade de refrigeração.

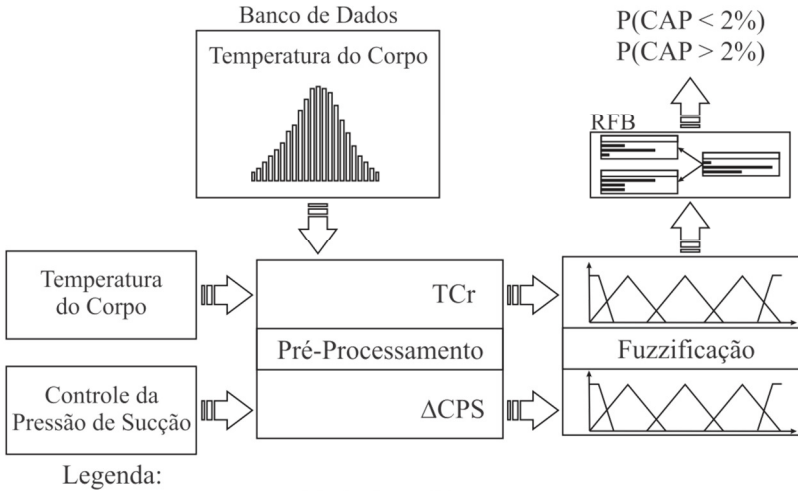


Figura 36 – Diagrama esquemático da rede *fuzzy*-bayesiana de inferência do regime

As variáveis escolhidas como auxiliares na identificação da estabilidade através da rede *fuzzy*-bayesiana têm significativa relação com a capacidade de refrigeração e com o tempo despendido nos ensaios de desempenho.

Para que o circuito de refrigeração empregado na bancada de ensaio entre em regime permanente, as diversas variáveis medidas devem apresentar valores de oscilação menores que os limites predefinidos. Esse objetivo é alcançado praticamente com a estabilização do fluxo de massa do circuito. O fluxo de massa constante de fluido refrigerante, por seu turno, é alcançado com a estabilização das condições de entrada e de saída do compressor, ou seja: pressão e temperatura na sucção e descarga – essas duas variáveis definem a densidade do gás – e a estabilização da temperatura do próprio compressor. A rigor, a condição de saída é

controlada somente a partir da pressão, porque a temperatura depende do processo de compressão e torna-se, então, uma variável isenta de controle.

A temperatura de sucção define parcialmente a densidade do gás, porque é controlada antes que o fluxo de fluido refrigerante em fase gasosa adentre o corpo do compressor. O que de fato define a densidade imediatamente antes da entrada do gás no cilindro do compressor é a temperatura do corpo e de partes adjacentes à tomada de sucção no cabeçote do compressor.

Assim, a estabilização do fluxo de massa depende da estabilização da pressão de sucção, da pressão de descarga e, sobretudo, da temperatura do corpo do compressor.

Uma análise dessas três variáveis foi realizada para identificação de quais apresentam comportamentos com maior potencial de modelagem *fuzzy*-bayesiana para realizar a inferência do regime da capacidade de refrigeração.

A escolha da temperatura do corpo é resultado da dinâmica bem característica de primeira ordem e da possibilidade de concepção de um banco de dados de valores típicos para diferenciação dos diversos compressores e condições de ensaio. Assim, poder-se-ia inserir no processo de inferência do regime, através da rede *fuzzy*-bayesiana, uma informação intimamente ligada ao comportamento do par compressor-condição de ensaio.

No caso da pressão de sucção, optou-se pela utilização da variação do sinal de controle da válvula de expansão. Tal sinal excursiona na faixa de 0 a 10 V, para abertura ou fechamento da válvula, no intuito de estabelecer as condições padronizadas de ensaio. Cabe ressaltar que o sinal é resultado da implementação de leis de controle que visam a manutenção da pressão de sucção o mais constante possível, porém sem perder em tempo de resposta, isto é, levá-la à condição padronizada de ensaio num tempo curto.

Inovação proposta e aplicada neste trabalho que levou à importante ganho advém da integração, mesmo de maneira indireta, de técnicas de modelagem de sistemas dinâmicos – típicos da engenharia de controle – com a rede *fuzzy*-bayesiana. Essas técnicas foram utilizadas para a determinação dos parâmetros do processo a controlar e fez uso de métodos experimentais; isto é, o comportamento da pressão de sucção foi observado na própria bancada que realiza os ensaios. A disponibilidade de modelos do processo permitiu o projeto de controladores que garantem a realização dos ensaios nas condições padronizadas.

a) Pré-processamento das variáveis auxiliares

As variáveis auxiliares – temperatura do corpo e controle da pressão de sucção – são observadas e tratadas de maneiras distintas. Como dito anteriormente, o período de análise de estabilidade é de 2,5 minutos – equivalente a 15 medições na bancada de ensaio de desempenho.

A temperatura do corpo do compressor é convertida para um valor relativo ao valor típico do modelo de compressor e à condição de ensaio. Esse valor típico é armazenado num banco de dados (o mesmo utilizado na inferência através de redes neurais). O valor médio desses valores relativos é obtido para as 15 medições do período em análise. A figura 37 apresenta alguns exemplos de comportamento desses valores médios de temperatura do corpo relativa (TCr) durante ensaios na bancada.




Figura 37 – Comportamentos típicos da temperatura do corpo relativa (TCr)

Para modelagem probabilística – relacionando a estabilidade da capacidade de refrigeração e a TCr – foram definidas as 6 faixas de avaliação identificadas de A a F.

- A:  $TCr \leq 0,50$ ;
- B:  $0,50 < TCr \leq 0,625$ ;
- C:  $0,625 < TCr \leq 0,75$ ;
- D:  $0,75 < TCr \leq 0,875$ ;
- E:  $0,875 < TCr \leq 1$ ;
- F:  $TCr > 1$ .



Para o controle da pressão de sucção o período de análise da estabilidade também é de 2,5 minutos e a entrada de rede é a diferença entre as médias no período atual e o anterior ( $\Delta\text{CPS}$ ). A figura 38 apresenta alguns exemplos de comportamento para a variação do controle da pressão de sucção.




Figura 38 – Comportamentos típicos da variação do controle da pressão ( $\Delta\text{CPS}$ )

Para modelagem probabilística – relacionando a estabilidade da capacidade de refrigeração e a  $\Delta\text{CPS}$  – foram definidas 9 faixas de avaliação identificadas de A a I.

- A:  $\Delta\text{CPS} \leq -0,03$ ;
- B:  $-0,03 < \Delta\text{CPS} \leq -0,02$ ;
- C:  $-0,02 < \Delta\text{CPS} \leq -0,01$ ;
- D:  $-0,01 < \Delta\text{CPS} \leq -0,005$ ;
- E:  $-0,005 < \Delta\text{CPS} \leq 0,005$ ;
- F:  $0,005 < \Delta\text{CPS} \leq 0,01$
- G:  $0,01 < \Delta\text{CPS} \leq 0,02$
- H:  $0,02 < \Delta\text{CPS} \leq 0,03$
- I:  $\Delta\text{CPS} > 0,03$ .

b) Definição das probabilidades condicionais

Essas faixas foram utilizadas para geração de probabilidades condicionais, como por exemplo,  $p(\text{TCr} \leq 0,50 \mid \text{erro capacidade} < 1\%)$  e  $p(-0,005 < \Delta\text{CPS} \leq 0,005 \mid \text{erro capacidade} > 2\%)$ .

As probabilidades condicionais que compõem a rede bayesiana foram obtidas dos 50 ensaios da base de dados de treinamento. As probabilidades foram obtidas considerando três condições para diferença da capacidade de refrigeração em relação ao valor final de ensaio: inferior a 1%; entre 1% e 2%; superior a 2%. As figuras 39 e 40 apresentam as probabilidades condicionais  $p(e|H)$ , onde  $e$  representa a evidência (gerada a partir das variáveis auxiliares) e  $H$  a hipótese (referente ao estado da capacidade de refrigeração).

Faixas - e	Diferença da capacidade de refrigeração - H		
	< 1 %	$\geq 1\% \text{ e } \leq 2\%$	> 2%
$\text{TCr} \leq 0,50$	0	0,013	0,067
$0,50 < \text{TCr} \leq 0,625$	0,006	0,034	0,138
$0,625 < \text{TCr} \leq 0,75$	0,018	0,081	0,190
$0,75 < \text{TCr} \leq 0,875$	0,040	0,235	0,257
$0,875 < \text{TCr} \leq 1$	0,214	0,205	0,201
$\text{TCr} > 1$	0,721	0,432	0,146

Figura 39 – Probabilidades condicionais da temperatura do corpo relativa

Faixas - e	Diferença da capacidade de refrigeração - H		
	< 1 %	$\geq 1\% \text{ e } \leq 2\%$	> 2%
$\Delta\text{CPS} \leq -0,03$	0	0,020	0,131
$-0,03 < \Delta\text{CPS} \leq -0,02$	0	0	0,052
$-0,02 < \Delta\text{CPS} \leq -0,01$	0,006	0,125	0,275
$-0,01 < \Delta\text{CPS} \leq -0,005$	0,092	0,263	0,144
$-0,005 < \Delta\text{CPS} \leq 0,005$	0,844	0,507	0,085
$0,005 < \Delta\text{CPS} \leq 0,01$	0,043	0,013	0,026
$0,01 < \Delta\text{CPS} \leq 0,02$	0,008	0,046	0,059
$0,02 < \Delta\text{CPS} \leq 0,03$	0,002	0,013	0,078
$\Delta\text{CPS} > 0,03$	0,006	0,013	0,150

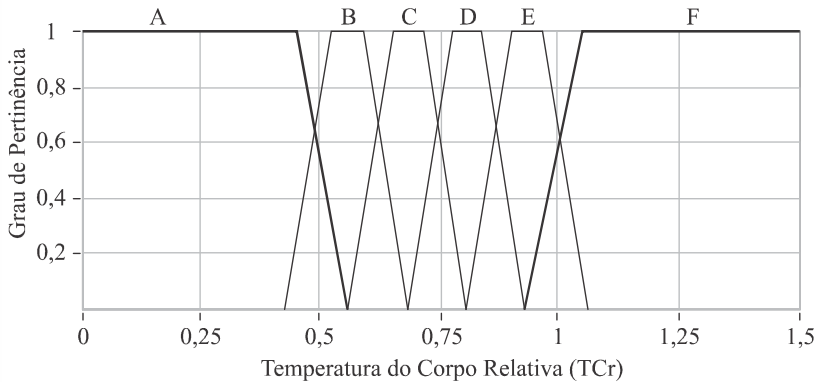
Figura 40 – Probabilidades condicionais do controle da pressão de sucção

### c) Definição das funções pertinência

A interpretação *fuzzy* das variáveis auxiliares foi realizada através da criação de dois conjuntos de funções de pertinência, um para cada variável auxiliar. Tais funções foram criadas segundo as faixas de avaliação definidas anteriormente.

As figuras 41 e 42 apresentam os conjuntos de funções pertinência para a descrição das variáveis temperatura do corpo relativa (TCr) e variação do controle da pressão de sucção ( $\Delta$ CPS), respectivamente.

A escolha das funções de pertinência – para as duas variáveis auxiliares – foi realizada através de avaliações das respostas obtidas. Tanto o tipo de função para as faixas quanto os valores de transição partiram de estabelecimentos prévios e iterativamente foram ajustados até a obtenção das melhores respostas.



Legenda:

**A:**  $TCr \leq 0,50$

**B:**  $0,50 < TCr \leq 0,625$

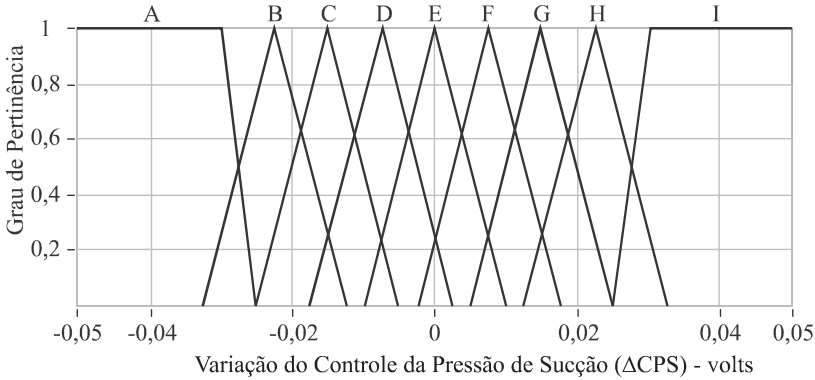
**C:**  $0,625 < TCr \leq 0,75$

**D:**  $0,75 < TCr \leq 0,875$

**E:**  $0,875 < TCr \leq 1$

**F:**  $TCr > 1$

Figura 41 – Funções de pertinência da temperatura do corpo relativa (TCr)



Legenda:

**A:**  $\Delta\text{CPS} \leq -0,03$       **B:**  $-0,03 < \Delta\text{CPS} \leq -0,02$       **C:**  $-0,02 < \Delta\text{CPS} \leq -0,01$   
**D:**  $-0,01 < \Delta\text{CPS} \leq -0,005$       **E:**  $-0,005 < \Delta\text{CPS} \leq 0,005$       **F:**  $0,005 < \Delta\text{CPS} \leq 0,01$   
**G:**  $0,01 < \Delta\text{CPS} \leq 0,02$       **H:**  $0,02 < \Delta\text{CPS} \leq 0,03$       **I:**  $\Delta\text{CPS} > 0,03$

Figura 42 – Funções de pertinência da variação do controle da pressão ( $\Delta\text{CPS}$ )

### 5.2.2.2 Integração *fuzzy*-bayesiana

A integração *fuzzy*-bayesiana segue os procedimentos apresentados no item 3.2 (página 51). Esses procedimentos indicam uma ponderação entre as probabilidades – que descrevem o modelo dicotômico de um evento pertencer ou não a uma determinada classificação – e os graus de pertinência – que modelam de forma contínua as classes relacionadas aos eventos.

As figuras 43 e 45 apresentam comportamentos da capacidade de refrigeração em ensaios distintos juntamente com os limites de estabilidade obtidos do valor final da referida grandeza. As figuras 44 e 46 mostram as respectivas respostas das redes híbridas para as diferentes classificações da capacidade de refrigeração.




Figura 43 – Capacidade de refrigeração para um ensaio de desempenho

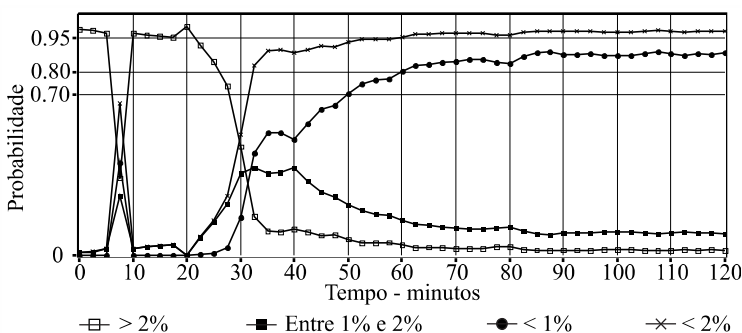


Figura 44 – Saída da rede híbrida para o ensaio da figura 43

Nota-se no primeiro ensaio (figuras 43 e 44) que a capacidade de refrigeração entra no limite de estabilização de  $\pm 2\%$  em aproximadamente 60 minutos e que a rede híbrida responde com a probabilidade ultrapassando o valor de 0,95 em tal instante – curva referente à probabilidade da capacidade de refrigeração estar a menos de 2% do valor final.

As figuras 45 e 46 mostram um ensaio em que a capacidade de refrigeração estava estabilizando e logo após o instante 20 minutos uma perturbação ocorreu. A resposta da rede híbrida acompanhou a instabilidade indicando alta probabilidade de o ensaio estar fora da faixa de 2%. Na sequência o ensaio retomou a tendência de estabilização e a resposta da rede acompanhou.




Figura 45 – Capacidade de refrigeração para um ensaio de desempenho




Figura 46 – Saída da rede híbrida para o ensaio da figura 45

Essas análises de indicação da estabilidade da rede híbrida foram realizadas assumindo uma probabilidade de 0,95 como patamar de decisão para a resposta. Obviamente, para a utilização da rede híbrida como parte do sistema de inferência da estabilidade, deve ser realizada uma análise mais criteriosa do patamar de decisão. Aliado ao patamar de decisão deve-se estabelecer um tempo de confirmação da resposta. Esse tempo é necessário, pois a rede poderá superar determinados patamares por um intervalo de análise  $t_p$  sem o ensaio estar efetivamente estabilizado. Ante essa necessidade foram definidos tempos de espera múltiplos inteiros (1, 2, 3, 4 e 5) do período de análise de estabilidade de 2,5 minutos.

As figuras 47 e 48 apresentam os erros absolutos médios da capacidade de refrigeração nos instantes de indicação de estabilidade para diferentes patamares de decisão – 0,5 a 0,95 – e tempos de espera – (2,5 a 12,5) minutos. Os gráficos apresentam ainda barras verticais indicando intervalos definidos por dois desvios padrões dos valores que compuseram as médias.




Figura 47 – Erro absoluto médio para rede híbrida - ensaios sem aceleração

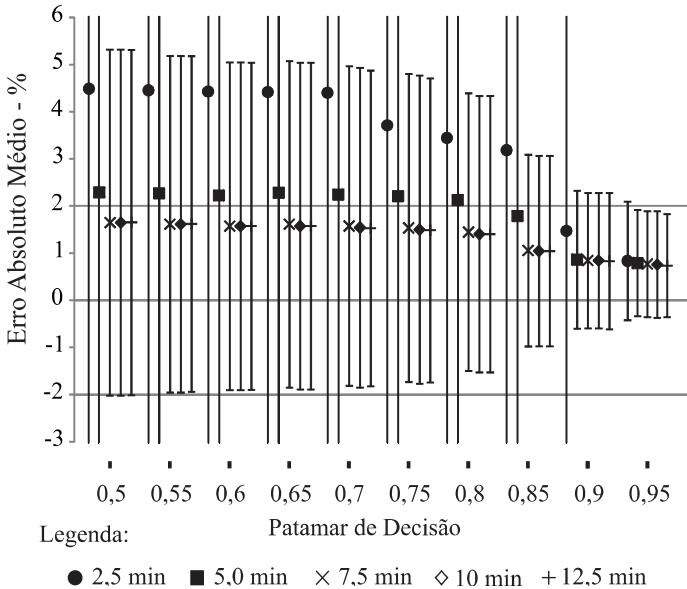


Figura 48 – Erro absoluto médio para rede híbrida - ensaios com aceleração

Para compor a análise de definição do patamar de decisão foram construídos, adicionalmente, os gráficos que relacionam a diferença temporal entre o instante de entrada em regime real e o indicado pela rede híbrida para os diferentes patamares de decisão e tempos de espera. As figuras 49 e 50 apresentam os erros para ensaios sem aceleração de transitório e ensaios acelerados, respectivamente. Vale salientar que valores negativos para as diferenças de tempo indicam que a indicação da rede ocorre após a estabilidade real dos ensaios.




Figura 49 – Erro médio no tempo de regime - ensaios sem aceleração

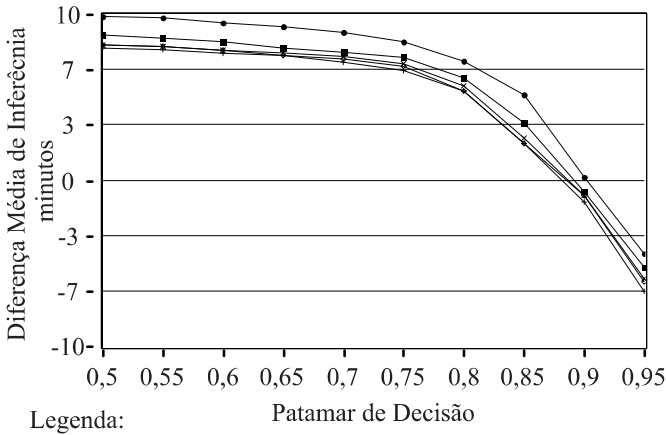


Figura 50 – Erro médio no tempo de regime - ensaios sem aceleração



A análise conjunta das figuras 47 a 50 aponta para adoção do patamar de decisão de 0,95 e tempo de espera de 7,5 minutos (3 períodos de análise de estabilidade) pelos seguintes motivos:

- valores médios do erro absoluto da capacidade de refrigeração, em relação ao valor final, mais baixos e com menor dispersão para os dois tipos de ensaio (sem e com aceleração de transitório);
- valores médios da diferença entre o tempo de regime real e indicado pela rede inferiores a zero para os dois tipos de ensaios (sem e com aceleração de transitório). Essa característica implica menores erros de falso-positivo para a indicação de estabilidade.

Esse item apresentou a proposta de rede *fuzzy*-bayesiana para a inferência do regime permanente. A integração dessa técnica com a ferramenta neural é abordada no próximo item.

### 5.2.3 Integração das ferramentas neural e *fuzzy*-bayesiana

O incremento na confiabilidade da inferência do regime permanente passa pela integração dos dois meios de identificação apresentados. As especificidades das modelagens utilizadas garantem um grau de heterogeneidade benéfica das ferramentas e que contribuirá para um melhor resultado global.

Partindo do pressuposto que as duas soluções têm a mesma importância, a integração é realizada com a confirmação de estabilidade de ambas. Assim, a inferência da estabilidade da capacidade de refrigeração será efetivada somente quando as ferramentas neural e *fuzzy*-bayesiana indicarem a estabilização.

Para avaliar o ganho obtido com a integração das duas técnicas são apresentados histogramas do erro percentual da capacidade no instante de identificação do regime em relação ao valor final de ensaio. Tais histogramas são para os dois subconjuntos da base de teste, ensaios sem aceleração (figura 51) e ensaios com aceleração de transitório (figura 52).




Figura 51 – Erro da capacidade, solução neural e integrada, sem aceleração

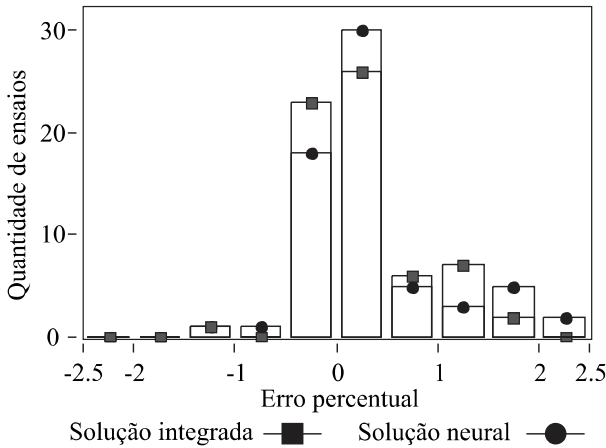


Figura 52 – Erro da capacidade, solução neural e integrada, com aceleração

No caso dos ensaios sem aceleração de transitório (figura 51) pode-se notar que houve acréscimo na quantidade de inferências na faixa de  $\pm 2\%$ . Para os ensaios com aceleração de transitório (figura 52) a integração das soluções fez com que, para todos os ensaios, a inferência ocorresse na faixa de  $\pm 2\%$ . Assim, conclui-se que a integração das técnicas foi benéfica para a tarefa de inferência do regime permanente.

A partir da inferência do regime permanente pode-se realizar o prognóstico da variável de interesse. O próximo item apresenta os de-

envolvimentos realizados para obtenção do prognóstico e garantia da sua confiabilidade.

### 5.3 PROGNÓSTICO DO VALOR FINAL DA VARIÁVEL DE INTERESSE

A estrutura da ferramenta para prognóstico do valor final da variável de interesse proposta neste trabalho é apresentada na figura 53. A partir da inferência do regime permanente, isto é, a resposta conjunta da ferramenta neural (RNA) e da *fuzzy*-bayesiana (RFB) para o regime, realiza-se o procedimento para prognóstico da variável de interesse. No caso específico, a variável de interesse é a capacidade de refrigeração (CAP).

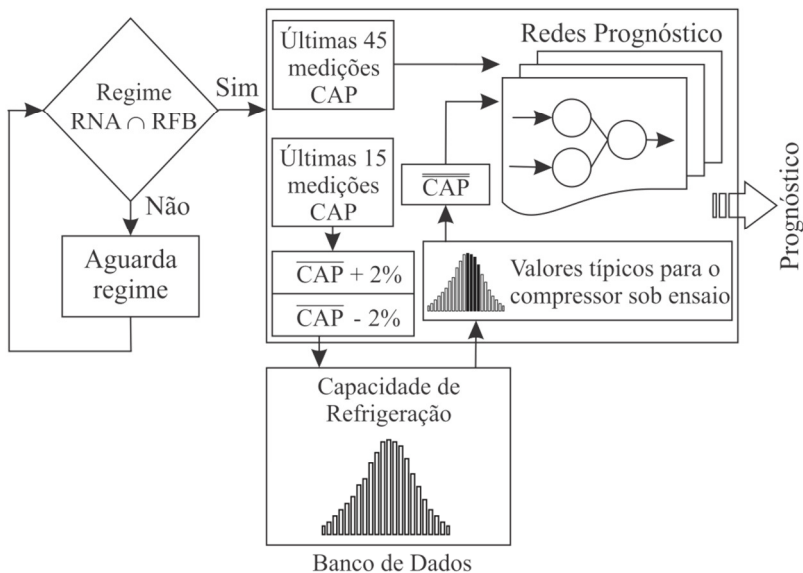


Figura 53 – Ferramenta para o prognóstico da capacidade de refrigeração

O prognóstico é realizado através de uso de redes neurais treinadas para estimar o valor final da capacidade de refrigeração a partir do instante de entrada em regime permanente. De maneira similar ao caso da inferência do regime através de redes neurais, o presente trabalho fez uso das redes definidas no trabalho de LIMA (2010b). Assim, tem-se as mesmas variáveis de entrada e saída, arquitetura e treinamento desenvolvidos por LIMA (2010b), descritos no item 5.3.1.

A ferramenta para o prognóstico faz uso de: 45 medições da capacidade de refrigeração (as mesmas responsáveis pela inferência do regime permanente); conjunto de redes neurais treinadas e escolhidas para o prognóstico; valor de capacidade de refrigeração típica específica.

O procedimento para o prognóstico é o seguinte:

- aguarda a inferência do regime permanente;
- com a inferência do regime, adquire as últimas 45 medições da capacidade de refrigeração;
- define valor de capacidade de refrigeração típica específica:
  - realiza média das últimas 15 medições ( $\overline{CAP}$ );
  - define faixa com  $\overline{CAP} \pm 2\%$ ;
  - busca no banco de dados os valores de capacidade que atendem a faixa definida;
  - realiza média dos valores resultantes do banco de dados ( $\overline{\overline{CAP}}$ ).
- executa cada uma das  $m$  redes neurais de prognóstico utilizando  $\overline{\overline{CAP}}$  como valor de capacidade de refrigeração típica específica;
- realiza a média das respostas das  $m$  redes neurais de prognóstico.

### 5.3.1 Caracterização da rede

Este item apresenta a descrição da rede neural utilizada para a tarefa de prognóstico da capacidade de refrigeração. São apresentados: arquitetura e treinamento; variáveis de entrada e saída; análise para escolha das redes treinadas.

#### 5.3.1.1 Arquitetura e treinamento

A figura 54 descreve a arquitetura da rede neural para o prognóstico da variável de interesse.

<i>Camada</i>	<i>Número de neurônios</i>	<i>Função de ativação</i>
Entrada	8	-
1ª escondida	20	Tangente hiperbólica
Saída	1	Linear

Figura 54 – Arquitetura da rede neural para prognóstico

Todos os treinamentos foram do tipo supervisionado e 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).

### 5.3.1.2 Variáveis de entrada e saída

Para o prognóstico da capacidade de refrigeração a rede é composta pelas entradas apresentadas na figura 55. Nota-se que para essa tarefa apenas a própria capacidade de refrigeração é utilizada e essa sofre pré-processamentos específicos para constituição das entradas. Os valores de capacidade de refrigeração são normalizados em função do valor típico de capacidade para o compressor e condição de ensaio. Assim, busca-se focar o conhecimento da rede no relacionamento entre o comportamento dinâmico dos instantes próximos à entrada em regime com o posicionamento do valor final de ensaio.

Variável	Entradas
Capacidade de refrigeração	1 Desvio padrão de 15 amostras da variável precedentes ao instante atual (Std1).
	2 Média de 15 amostras da variável precedentes ao instante atual (M1).
	3 Média de 15 amostras da variável precedentes ao instante atual deslocado de 15 amostras (M2).
	4 Média de 15 amostras da variável precedentes ao instante atual deslocado de 30 amostras (M3).
	5 Derivada entre 2 <sup>a</sup> e 3 <sup>a</sup> entrada (D1).
	6 Derivada entre 3 <sup>a</sup> e 4 <sup>a</sup> entrada (D2).
	7 Derivada entre 2 <sup>a</sup> e 4 <sup>a</sup> entrada (D3).
	8 Derivada entre 5 <sup>a</sup> e 6 <sup>a</sup> entrada (D4).

Figura 55 – Entradas da rede de prognóstico da capacidade

A saída de rede é um valor normalizado que deve ser convertido em watts através do valor típico de capacidade de refrigeração.

### 5.3.2 Uso de múltiplas redes

Assim como na inferência do regime permanente, a tarefa de prognosticar o valor final de ensaio para a capacidade de refrigeração

também fez uso de um conjunto de redes neurais. Esse artifício resulta, através da combinação das respostas das diversas redes neurais, numa ferramenta com maior grau de generalização em relação ao uso de uma única rede neural.

A partir dos 50 ensaios disponíveis foram gerados conjuntos para treinamento de 30 redes neurais. Cada um desses conjuntos foi composto por 40 ensaios para treinamento e um conjunto de ensaios para a validação *on-line*. Os 40 ensaios do conjunto de treinamento foram selecionados aleatoriamente, com reposição, dentre os 50 disponíveis. Os conjuntos de validação *on-line* foram compostos pelos ensaios não selecionados para o conjunto de treinamento. A característica de reposição no processo de formação dos conjuntos de treinamento fez com que alguns apresentassem ensaios repetidos. Assim, os conjuntos de validação *on-line* variaram em número de ensaios.

### 5.3.3 Resultados obtidos

Os resultados obtidos com o sistema completo (inferência de regime e prognóstico do valor final) são apresentados nas figuras 56 e 57.

A figura 56 apresenta um histograma dos erros de prognóstico obtidos para os ensaios sem aceleração de transitório.




Figura 56 – Histograma dos erros de prognóstico - sem aceleração

Nota-se que os erros obtidos para os prognósticos se concentraram na faixa de  $\pm 2\%$  dos valores finais de ensaio. O erro absoluto médio nesses resultados foi de 0,64%, sendo que apenas 9 ensaios apresentaram erro maior que 2%.

Considerando o erro médio dos prognósticos, isto é, levando em consideração o sinal do erro, obteve-se um valor de +0,34%. Essa tendência pode ser observada no histograma e é justificada pelo comportamento típico dos ensaios sem aceleração de transitório, nos quais a aproximação da capacidade de refrigeração para o valor final é, normalmente, pelo limite superior. A análise dos 9 ensaios que apresentaram erro de prognóstico superior a 2% revelou algumas informações importantes para o decorrer dos estudos e consequente melhoria dos resultados. Essa análise será retratada no item 5.4.

A figura 57 apresenta um histograma dos erros de prognóstico obtidos para os ensaios com aceleração de transitório.




Figura 57 – Histograma dos erros de prognóstico - com aceleração

Nota-se que a totalidade dos erros de prognóstico ficou dentro dos limites de  $\pm 1,5\%$  dos valores finais de ensaio. O erro absoluto médio foi de 0,48%.

Considerando o erro médio dos prognósticos, isto é, levando em consideração o sinal do erro, obteve-se um valor de -0,22%. Essa tendência pode ser observada no histograma e é justificada pelo comportamento típico dos ensaios com aceleração de transitório, nos quais o comportamento dinâmico da capacidade de refrigeração é significativamente mais rápido na aproximação para o valor final. Essa característica faz com que, no instante de regime inferido, a capacidade esteja bem próxima ao valor final e com baixas tendências de subida ou descida. Aliada a essa característica dos ensaios, o treinamento das redes neurais de prognóstico fez com que a saída da rede fosse, normalmente, abaixo dos valores de entrada, pois os ensaios utilizados para treinamento não

empregaram a técnica de aceleração de transitório, isto é, houve aproximação ao valor final pelo limite superior.

Essa constatação não invalida os resultados obtidos, mas abre oportunidade de melhorias, por exemplo: desenvolvimento de um sistema para prognósticos de ensaios com aceleração de transitório. Frente aos resultados obtidos até o momento, não há porque não se acreditar que se o treinamento for realizado a partir de ensaios com transitório acelerado, os resultados não tendam a ser melhores.

Dentre os 275 ensaios disponíveis, em apenas três casos o sistema não respondeu, isto é, não houve inferência do regime permanente e, conseqüentemente, não houve prognóstico da capacidade. Assim, nota-se um ganho significativo em relação ao sistema instalado atualmente no painel de desempenho que não apresentou resposta em 20% dos ensaios.

A figura 58 apresenta um resumo dos resultados obtidos com a ferramenta desenvolvida. São apresentadas as quantidades de ensaios (em valor percentual) que tiveram prognósticos dentro de determinadas faixas de erro.

	Tipo de ensaio	
	Sem aceleração	Com aceleração
Ensaio disponíveis	210	65
Sem inferência/prognóstico	3	0
Ensaio válidos	207	65
Erro máximo	Percentual de ensaios válidos	
± 0,75%	74,4%	83,1%
± 1,0%	83,1%	92,3%
± 1,5%	93,2%	100%
± 2,0%	95,6%	-
± 2,5%	97,1%	-
± 3,0%	97,6%	-
± 4,0%	98,5%	-

Figura 58 – Resumo dos resultados de prognóstico da solução proposta

Os prognósticos obtidos concordam de maneira significativa com os valores finais de ensaio relacionados ao método tradicional – média dos valores referentes a uma hora em regime permanente.

As normas concernentes à avaliação de desempenho de compressores impõem a utilização de dois métodos distintos para medição do fluxo de massa – utilizado para a estimativa da capacidade de refrigeração. Segundo essas normas, para que a avaliação de desempenho seja válida deve haver concordância entre os resultados obtidos pelos dois



métodos. Essa concordância é expressa por um índice máximo para a diferença entre os resultados, que é de: 4% para as normas ISO 917 (ISO, 1987) e DIN EN 13771-1 (DIN, 2008); 3% para a norma ANSI/ASHRAE 23 (ANSI/ASHRAE, 2005). Pode-se notar pela análise da figura 58, que os resultados obtidos pelas ferramentas de IA apresentaram ótima concordância com o método tradicional de ensaio. Essa comparação não tem o intuito de indicar as ferramentas de IA desenvolvidas como substitutas de um dos métodos exigidos pelas normas, mas evidenciar o desempenho das mesmas frente a índices de aceitação definidos pelas próprias normas.

A figura 59 expõe a contribuição das ferramentas desenvolvidas para o ganho de tempo na realização dos ensaios de desempenho sem aceleração de transitório. O ganho médio em tempo foi de aproximadamente 62%.




Figura 59 – Tempos de ensaios para casos sem aceleração de transitório

A figura 60 expõe a contribuição das ferramentas desenvolvidas para o ganho de tempo na realização dos ensaios de desempenho com aceleração de transitório. O ganho médio em tempo foi de aproximadamente 53%.

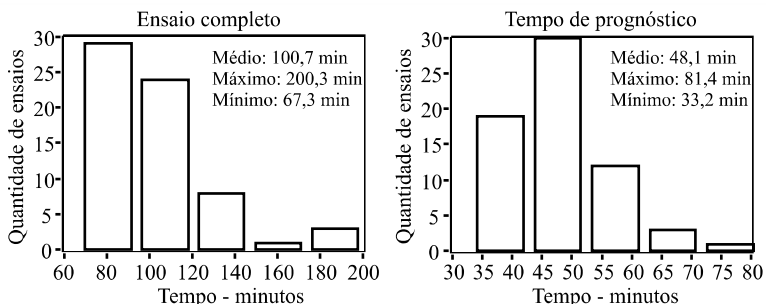


Figura 60 – Tempos de ensaios para casos com aceleração de transitório

Do ponto de vista de redução de tempo de ensaio há possibilidade de obtenção de maiores ganhos. As ferramentas desenvolvidas preveem que o tempo mínimo para realização do prognóstico é de 30 minutos. No entanto, em diversos ensaios foram observadas as inferências de regime, tanto com redes neurais quanto redes *fuzzy*-bayesianas, bem abaixo desse tempo e com ensaios se comportando adequadamente para o prognóstico.

#### 5.4 INFORMAÇÕES A *PRIORI* COMO FERRAMENTA DE INCREMENTO DA CONFIABILIDADE

Uma característica das ferramentas apresentadas para a geração de prognósticos dos valores finais é a influência da inferência do instante de regime permanente. Considerando que o prognóstico é realizado a partir do instante de regime inferido, este se torna o ponto chave na garantia da confiabilidade do processo como um todo. Como exemplo cabal dessa afirmação, toma-se o ensaio apresentado na figura 61.

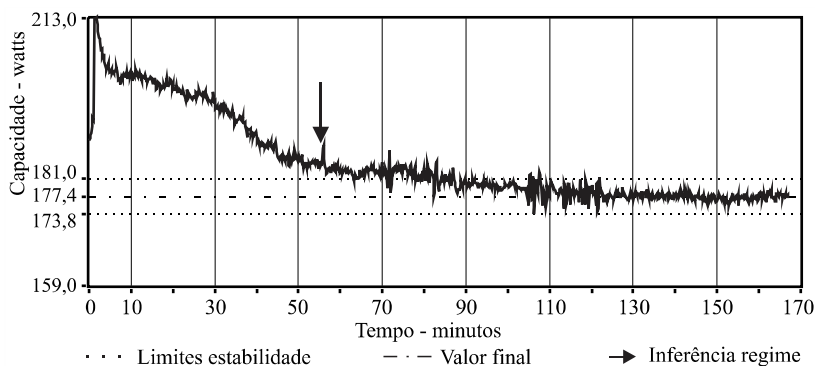


Figura 61 – Exemplo de ensaio com identificação do regime permanente

Nota-se que a inferência do regime permanente ocorreu no tempo aproximado de 55 minutos e que nessa região o ensaio apresentava uma tendência clara de estabilização. No entanto, no instante aproximado de 80 minutos uma nova derivada negativa ocorreu e fez com que a capacidade estabilizasse, ao final do ensaio, no valor médio de 177,4 W. O prognóstico realizado no instante inferido de 55 minutos apresentou um erro de 2,8%. O exemplo acima se caracteriza como um ensaio atípico para o sistema de inferência e prognóstico.

Como apresentado nos itens 5.2 e 5.3, é característica importante do conjunto de ferramentas proposto, a utilização de informações espe-

cíficas do modelo de compressor sob ensaio (valores típicos de capacidade de refrigeração e temperatura do corpo). Essas informações estão disponíveis antes da execução do ensaio em bancos de dados. Assim, diz-se que essas informações são “*a priori*”. Na sequência deste item são destacadas evidências de causas de prognósticos com erros fora da faixa de  $\pm 2\%$  e encaminhadas abordagens visando a redução desses erros.

Inicialmente, destaca-se que seis ensaios sem aceleração de transitório, dos nove com prognóstico fora da faixa de  $\pm 2\%$ , são do mesmo modelo de compressor e para o qual os valores típicos de capacidade de refrigeração têm maior dispersão. Tal dispersão é justificada pela existência de dois tipos de ensaio, definidos de acordo com a finalidade dos mesmos, são eles: ensaio de avaliação da produção; ensaios de pesquisa e desenvolvimento.

Ensaio de avaliação da produção tendem a apresentar resultados para características de desempenho com dispersão menor. Com o projeto do compressor definido, os resultados das amostras de controle da produção sujeitam-se apenas à variação do sistema produtivo.

Ensaio de pesquisa e desenvolvimento observam o aprimoramento dos compressores realizado a partir de mais variadas alterações no produto, como: alteração de motores; troca de materiais ou tratamento desses em diversas peças; testes com novos modelos de válvulas; redimensionamento de peças. Cada uma dessas alterações pode afetar o comportamento dos ensaios de desempenho e o valor das características de interesse de maneira distinta e, conseqüentemente, apresentar ao sistema de inferência e prognóstico, dinâmicas de ensaio diferentes daquelas já observadas e valores de desempenho distintos daqueles disponíveis nas bases de dados.

É típica de fabricantes de compressores a realização de ensaios de desempenho em amostras de compressores para os dois tipos de ensaio citados. O tamanho da amostra pode variar, mas é típico que no mínimo cinco peças sejam ensaiadas. Cada peça da amostra pode ser ensaiada uma ou mais vezes, dependendo da solicitação do cliente ou condição de sistema na qual o compressor será utilizado. Para minimizar a influência das especificidades das bancadas, atualmente busca-se a realização de tais ensaios em bancadas distintas. Esse tipo de procedimento visa assegurar estatisticamente a qualidade dos resultados para as variáveis de interesse e, conseqüentemente, evidenciar o andamento do processo produtivo e os ganhos auferidos em P&D.

Decorrente desse processo pode-se vislumbrar a definição de rotinas para comparar os resultados obtidos das ferramentas de inteli-

gência artificial. Adicionalmente à comparação a *posteriori* dos resultados, pode-se alinhar uma estratégia de uso de resultados (mesma peça ou amostra) em ensaios consecutivos. Assim, o conhecimento das variáveis de interesse – de uma determinada peça ou amostra – pode ser utilizado para aumentar a confiabilidade dos resultados em ensaios de desempenho subsequentes. Essas estratégias podem contribuir para o aumento da robustez das ferramentas de IA quanto à ocorrência de situações semelhantes à exemplificada na figura 61.

Esse capítulo apresentou um conjunto de recursos para concepção de ferramentas de inferência e prognóstico para aplicação em ensaios de desempenho de compressores. Os requisitos principais dos desenvolvimentos realizados foram confiabilidade dos resultados e economia significativa no tempo médio desses ensaios. O próximo capítulo apresenta propostas de análises no intuito de avaliar aspectos relacionados à confiabilidade e de como atuar para garantia dessa ao longo do tempo.

## 6 PROPOSTAS DE MÉTODOS E PROCEDIMENTOS PARA AVALIAÇÃO DA CONFIABILIDADE

Este capítulo apresenta análises gerais e específicas para descrição e incremento da confiabilidade dos resultados obtidos através das ferramentas de inteligência artificial. São apresentados aspectos normativos relacionados a ensaios e a forma como novos métodos devem ser avaliados para a garantia da confiabilidade dos resultados. É proposto um método para avaliação da influência da incerteza de medição na concepção e uso das ferramentas neurais e *fuzzy*-bayesiana apresentadas. Adicionalmente, é avaliada a relação entre os erros de prognóstico e os valores de capacidade dos compressores ensaiados.

### 6.1 FERRAMENTAS DA INTELIGÊNCIA ARTIFICIAL EM MÉTODOS DE ENSAIO

A norma ISO/IEC 17025 (ISO, 2005), intitulada “Requisitos gerais para a competência de laboratórios de ensaio e calibração” é referência internacional na definição de requisitos para a garantia da confiabilidade de ensaios realizados com métodos normatizados ou não. A aplicabilidade da norma é independente do escopo das atividades laboratoriais.

O item 5.4 da ISO/IEC 17025, intitulado “Métodos de ensaio e calibração e validação de métodos”, apresenta diretrizes e ações para especificação e garantia do desempenho de métodos de ensaios.

Para o caso de desenvolvimento de novos métodos a ISO/IEC 17025 estabelece que “esses devem ser submetidos a acordo com o cliente e devem incluir uma especificação clara dos requisitos do cliente e a finalidade do ensaio. O método desenvolvido deve ser devidamente validado de forma apropriada, antes de ser utilizado”.

É fato que a forma de obtenção de resultados de ensaios de desempenho de compressores de refrigeração, abordada neste trabalho, se refere a um método inovador e de grande impacto para os processos de pesquisa e desenvolvimento e controle da qualidade para as empresas fabricantes de compressores. Assim, a validação desse método deve ser realizada de maneira a garantir a empregabilidade do mesmo com segurança.

Nesse sentido a validação de métodos é tratada na ISO/IEC 17025 com o objetivo de confirmar que os mesmos sejam apropriados para o uso pretendido. Para atingir esse objetivo a técnica utilizada para

a determinação do desempenho de um método deve ser uma das seguintes ou uma combinação dessas:

- calibração com o uso de padrões de referência ou materiais de referência;
- comparações com resultados obtidos por outros métodos;
- comparações interlaboratoriais;
- avaliação sistemática dos fatores que influenciam o resultado;
- avaliação da incerteza dos resultados com base no conhecimento científico dos princípios teóricos do método e na experiência prática.

O método de ensaio de desempenho de compressores apresentado neste trabalho, pela inovação inerente, deve ser validado através da combinação de algumas das técnicas apresentadas anteriormente. Nesse intuito, serão destacadas as características de adequação ou não de cada uma delas.

Sobre a calibração com o uso de padrões de referência<sup>19</sup>, nesse caso não se tem ensaios com comportamentos que podem ser categorizados como padrões<sup>20</sup> no senso estrito definido pela metrologia. Existem ensaios que apresentam comportamentos julgados adequados para aplicação das ferramentas de inferência e prognóstico. No entanto, a calibração é fator importante no que concerne à garantia da confiabilidade metrológica de grandezas utilizadas pelo método. Para os casos de inferência e prognóstico da capacidade de refrigeração, as medições de pressão, temperatura e capacidade de refrigeração devem ser realizadas com confiabilidade metrológica garantida e níveis de incerteza adequados.

Sobre a comparação com resultados obtidos por outros métodos, nessa técnica tem-se a possibilidade de aplicação de esforços experimentais na realização de ensaios de desempenho de compressores segundo os procedimentos atualmente consolidados. Essa técnica foi bem explorada e os resultados apresentados nos itens 5.2 e 5.3. O conjunto de teste, composto por 275 ensaios, viabilizou a comparação dos resultados e indicou significativa confiabilidade aliada ao potencial ganho na redução do tempo de ensaio – figuras 59 e 60, página 105.

Sobre as comparações interlaboratoriais, essa técnica pode ser transformada numa rotina de comparações entre bancadas de ensaio de

---

<sup>19</sup> Padrão designado para a calibração de outros padrões de grandezas do mesmo tipo em uma dada organização ou local.

<sup>20</sup> Realização da definição de uma dada grandeza, com um valor determinado e uma incerteza de medição associada, utilizada como referência.

diversos laboratórios ou de um mesmo laboratório da empresa que vier a empregar os recursos de ensaio assistidos por IA, conforme apresentado no presente trabalho. É importante salientar que tais bancadas devem exibir características compatíveis entre si. Basicamente, essa compatibilidade pode ser garantida com o uso da mesma arquitetura da bancada utilizada para o desenvolvimento do método, onde se tem: incertezas de medição estabelecidas, adequadas e com confiabilidade garantida; automação completa da bancada sem permitir atuação do operador no controle das grandezas durante os ensaios; capacidade de processamento e armazenamento dos dados necessários para as tarefas de inferência e prognóstico.

Essas rotinas de comparação podem ser inseridas em processos de análise contínua. Uma proposta deste trabalho é a elaboração de mecanismos de avaliação e implementação de melhorias ao longo da utilização das ferramentas de IA, conforme a figura 62.




Figura 62 – Etapas de análise e melhoria contínua

Suponha-se uma determinada solução inicial (solução 0) concebida a partir de uma base de dados consistente. Essa solução 0 é utilizada no acompanhamento de diversos ensaios durante, por exemplo, 1 mês. Nesse período (etapa 0) pode-se coletar uma série de evidências sobre sua adequação aos processos de inferência e prognóstico. Essas

evidências podem ser utilizadas para a concepção da solução 1 – capaz de atingir menores incertezas e maior confiabilidade já que agrega as informações de treinamento e utilização da solução 0. Durante a etapa 1 a solução correspondente pode ser utilizada com suporte da solução 0. Desse modo estabelece-se num processo de validação e melhoria contínua das ferramentas de inferência e prognóstico.

Sobre a avaliação sistemática dos fatores que influenciam o resultado, essa técnica pode desdobrar-se em diversas análises envolvendo diferentes aspectos e partes do método apresentado neste trabalho, como por exemplo:

- análise detalhada dos comportamentos individuais das redes neurais e rede *fuzzy*-bayesiana frente a novos ensaios;
- análise das ferramentas para integração das diversas redes neurais e dessas com rede a *fuzzy*-bayesiana frente a novos ensaios;
- influência dos valores típicos de capacidade de refrigeração e temperatura do corpo tanto nas soluções neurais quanto na *fuzzy*-bayesiana;
- alterações de comportamento dinâmico das grandezas função de alterações nas bancadas de ensaio.

Sobre a avaliação de incertezas dos resultados com base em conhecimentos científicos e na experiência prática, basicamente essa técnica pode ser entendida como a regente no processo de validação do método. Esse fato é decorrente da necessidade de análises profundas do método no que diz respeito ao comportamento das redes neurais e *fuzzy*-bayesianas, as formas de integração, as influências dos dados de treinamento e uso. Deve-se salientar que a avaliação de incertezas, através do método tradicional do “Guia para Expressão da Incerteza de Medição” – GUM (BIPM, 2008a)<sup>21</sup>, para o conjunto de ferramentas proposto não é aplicável devido à impossibilidade de correção de todos os efeitos sistemáticos reconhecidos como significativos. A relação entre o resultado da inferência do instante de entrada em regime permanente e o resultado do prognóstico da variável de interesse não é internamente consistente<sup>22</sup>

---

<sup>21</sup> Incluem-se os documentos JCGM 101 que trata de métodos numéricos para a propagação de incertezas (BIPM, 2008b) e o JCGM 104 que apresenta os conceitos básicos relativos à avaliação de incertezas (BIPM, 2009).

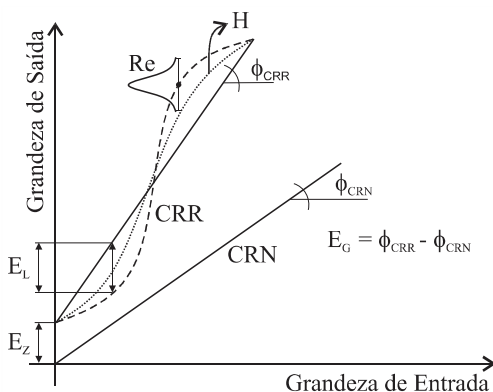
<sup>22</sup> Segundo o GUM, a grandeza observada é internamente consistente quando é diretamente derivável dos componentes que para ela contribuem, assim como ser independente de como esses componentes estejam agrupados, ou da decomposição de componentes em subcomponentes.



segundo os conceitos impostos pelo método de avaliação do GUM. Assim, o processo de avaliação de incertezas deve ser reconhecido, no caso do presente trabalho, como uma tarefa calcada em observação experimental e definição de condições de contorno próprias.

Nesse sentido propõem-se duas análises experimentais com foco na influência da incerteza de medição em dois momentos distintos: na concepção das ferramentas; e outra no uso das ferramentas propostas. Para tanto, a seguir são apresentadas descrições dos tipos básicos de fontes de incerteza de medição. Essas descrições servem para definir uma proposta de método para avaliação da influência da incerteza de medição em ferramentas baseadas em inteligência artificial – item 6.2.

A figura 63 representa o conjunto típico de fontes de erros de medição que deve ser analisado num processo de avaliação de incertezas de medição. A descrição das fontes parte da existência de duas curvas de resposta para um dado sistema de medição: a nominal (idealizada no projeto do mesmo); a real (fruto da interação de todas as não-idealidades presentes).



Legenda:

- |   |                               |
|---|-------------------------------|
| CRN – curva de resposta nominal;  | CRR – curva de resposta real; |
| $E_L$ – erro de linearidade;  | $E_Z$ – erro de zero;         |
| $E_G$ – erro de ganho;  | H – histerese;                |
| Re – repetitividade;  |                               |
| $\phi$ – parâmetros de caracterização do comportamento de ganho (sensibilidade <sup>23</sup> ). |                               |

Figura 63 – Fontes típicas de erros em sistemas de medição

<sup>23</sup> Segundo o Vocabulário Internacional de Metrologia (BIPM, 2008c), a sensibilidade de um sistema de medição é o quociente entre a variação da indicação do sistema de medição e a variação correspondente do valor da grandeza que está sendo medida.

A figura 63 mostra uma relação linear entre as grandezas de entrada e saída. No entanto essa relação pode ser qualquer e a análise será compatível. A seguir são apresentados conceitos e comentários a respeito da figura 63.

Erro de zero ( $E_Z$ ), conforme o VIM – Vocabulário Internacional de Metrologia (BIPM, 2008c), é o “erro no ponto de controle de um instrumento de medição para o valor zero do mensurando”. Em outras palavras, consiste numa indicação diferente de zero para um mensurando de valor zero. Esse erro é constante para toda a faixa de medição e, desta forma, considerado de característica sistemática.

Em muitos casos, na concepção de um sistema de medição, deseja-se que a relação entre a grandeza de entrada e a de saída seja estritamente linear. No entanto, muitos componentes utilizados nos sistemas têm algum tipo de característica ou não conformidade que contribui para que a relação desvie da linearidade. Desse comportamento surgem dois conceitos: erro de linearidade e erro de ganho.

A descrição completa do erro de linearidade necessitaria do levantamento completo da curva de resposta real (CRR, curva tracejada), isto é, identificar todos os pares entrada-saída compatíveis com a faixa de medição do sistema. Tal tarefa nem sempre é possível e a avaliação da não linearidade é realizada através do máximo desvio ( $E_L$ , erro de linearidade) encontrado, por exemplo, a partir de uma análise de mínimos quadrados (reta em linha cheia associada a CRR).

Quanto ao erro de ganho ( $E_G$ ), a inclinação da reta ajustada por mínimos quadrados para avaliação de  $E_L$  pode ser utilizada para a estimativa  $E_G$  em relação à inclinação ideal da curva de resposta nominal (CRN).

A repetitividade ( $Re$ ), de acordo com o VIM, é o “grau de concordância entre os resultados de medições sucessivas de um mesmo mensurando efetuadas sob as mesmas condições de medição”. O termo “as mesmas condições de medição” a que o VIM se refere significa realizar o mesmo procedimento de medição, com o mesmo observador, com o mesmo sistema de medição (utilizado nas mesmas condições), no mesmo local e dentro de um curto período de tempo. Um procedimento com alta repetitividade apresenta desvios muito pequenos em relação à média. Na figura 63 a repetitividade é apresentada sobre a curva de resposta real e para um determinado par entrada-saída. É desejável que o sistema de medição apresente comportamentos de repetitividade muito próximos para toda a faixa de medição.

A histerese ( $H$ ) está presente sempre que um instrumento apresentar respostas diferentes para entradas com valores crescentes e entra-

das com valores decrescentes. No caso de sistemas mecânicos esta característica é muito comum e é causada principalmente por folgas. Em sistemas eletroeletrônicos ela surge quando medidas são baseadas na ação de campos magnéticos em materiais ferromagnéticos, por exemplo. Na figura 63, a curva H (pontilhada) identifica uma nova curva de resposta que pode ser atribuída ao efeito da histerese.

Segundo o VIM, deriva é a “variação lenta de uma característica metrológica de um instrumento de medição”. As formas mais comuns de deriva são ao longo do tempo (também conhecida como estabilidade) e como função da variação de temperatura.

A deriva térmica ocorrerá sempre que o sistema estiver operando numa faixa de temperatura diferente daquela estipulada pelo fabricante. Geralmente, os fabricantes fornecem uma faixa de temperatura na qual o seu instrumento deve operar, onde as características metrológicas são garantidas.

A deriva temporal funciona semelhante à deriva térmica, porém, com relação ao tempo. Os fabricantes geralmente fornecem as características metrológicas válidas somente durante certo período de tempo, por exemplo, seis meses ou um ano. Extrapolando esse período, novos valores devem ser adotados, porém os fabricantes geralmente são omissoes com relação a esses valores. Os processos de verificação e calibração periódicas visam avaliar também esse tipo de deriva.

Os processos de avaliação de incertezas têm como objetivos a identificação e quantificação, quando possível, de cada uma dessas contribuições e, *a posteriori*, a geração de uma estimativa única e global para a incerteza.

Do ponto de vista das ferramentas de inteligência artificial definidas nos trabalhos realizados pode-se considerar a existência de três fontes: erro de ganho, erro de zero e linearidade. A repetitividade, histerese e derivas não se apresentam, pois se trata de uma implementação de software; para os mesmos valores de entrada têm-se os mesmos valores de saída.

Adicionalmente, na análise de processos de medição é típico considerar influências do procedimento, operador e condições ambientais. No caso presente considera-se:

- o procedimento definido e executado sempre da mesma maneira já que o software de automação da bancada já está validado;
- operador não tem influência no andamento do ensaio e a ele compete a tarefa de garantir a operacionalidade da

- bancada e identificar corretamente o compressor que será ensaiado;
- condições ambientais são mantidas dentro dos padrões estabelecidos por normas e pela empresa, assegurando as características metrológicas do hardware das bancadas de ensaio.

## 6.2 PROPOSTA DE MÉTODO PARA AVALIAÇÃO DA INFLUÊNCIA DA INCERTEZA DE MEDIÇÃO

Para investigar a influência da incerteza de medição nas redes apresentadas propõe-se um método baseado em delineamento de experimentos, contaminações controladas de incerteza nos dados, treinamento e uso das redes com dados contaminados, análise das respostas individuais das redes e das ferramentas propostas segundo os experimentos definidos.

A utilização de técnicas de delineamento de experimentos permite sistematizar a análise da influência das entradas das redes e identificar, através de análises estatísticas consolidadas, aquelas com maior poder de deslocar o resultado frente à grande média (TOUTENBURG, 2002; MASON, 2003).

Existem duas situações nas quais a avaliação da influência da incerteza dos dados é importante: na obtenção das redes, por exemplo, treinamento das redes neurais; no uso das redes na aplicação final.

Do ponto de vista da obtenção das redes, a execução de um experimento fatorial completo pode demandar demasiado tempo em função: do número de grandezas de entrada das redes; da quantidade de contaminações que se deseja avaliar; da quantidade de redes neurais utilizadas; do tempo médio de treinamento das redes.

Para redução do esforço no treinamento das redes propõe-se a utilização de arranjos ortogonais (TOUTENBURG, 2002; MASON, 2003) para a geração de uma quantidade menor de experimentos (combinações entre grandezas de entrada das redes e contaminações de incerteza de medição).

As técnicas de experimentação fatorial fracionada, baseadas em arranjos ortogonais, permitem a definição do número mínimo de experimentos e integram as ferramentas estatísticas necessárias para analisar os resultados e apontar os fatores de influência mais significativos (COX, 2000). No caso do presente trabalho são utilizadas ferramentas de análise segundo os métodos de Taguchi (COX, 2000).

O procedimento para avaliação da influência da incerteza de medição na obtenção das ferramentas é o seguinte:

- definir arranjo ortogonal de experimentos segundo Taguchi de acordo com o número de grandezas de entrada das redes e os diferentes níveis e formas de contaminação de incerteza;
- definir os conjuntos de treinamento e validação *on-line* para cada rede a treinar;
- treinar as redes definidas para a aplicação – de acordo com os critérios de aceitação julgados necessários quanto ao desempenho nos conjuntos de treinamento, validação *on-line* – com os dados sem contaminação de incerteza – salvar os parâmetros iniciais (pesos sinápticos e bias) a partir dos quais as redes foram treinadas;
- contaminar os conjuntos de treinamento e validação *on-line* para cada rede a treinar, segundo os experimentos definidos;
- treinar as redes a partir dos parâmetros iniciais salvos anteriormente – de acordo com os critérios de aceitação julgados necessários quanto ao desempenho nos conjuntos de treinamento, validação *on-line* – para cada experimento definido no arranjo ortogonal;
- aplicar as redes treinadas com contaminação dos dados num conjunto de teste sem contaminação;
- realizar a análise do arranjo ortogonal de experimentos segundo Taguchi (COX, 2000).

O procedimento para avaliação da influência da incerteza de medição no uso das soluções é o seguinte:

- definir arranjo ortogonal de experimentos segundo Taguchi de acordo com o número de grandezas de entrada das redes e os diferentes níveis e formas de contaminação de incerteza;
- contaminar o conjunto de teste disponível, segundo os experimentos definidos, isto é, criar um conjunto de teste para cada experimento;
- aplicar os dados conjunto de teste com contaminação nas redes disponíveis;
- realizar a análise do arranjo ortogonal de experimentos segundo Taguchi (COX, 2000).

### 6.2.1 Estudo de Caso 1: Treinamento das redes neurais de inferência

O procedimento proposto é aplicado na avaliação das redes de inferência de regime permanente da capacidade de refrigeração.

A forma de contaminação dos dados de treinamento parte da constatação de que o caráter sistemático das fontes de erros de medição é predominante em relação ao aleatório. Na aplicação em questão, o fato de utilização de médias de valores das grandezas usadas como entradas das redes neurais fortalece a predominância da influência de caráter sistemático.

Para as grandezas de entrada foram definidas formas e níveis de contaminação – descritas a seguir:

- contaminação de erro de zero e ganho positiva (ZG\_P) – todos os dados foram deslocados em +1%;
- contaminação de erro de zero e ganho negativa (ZG\_N) – todos os dados foram deslocados em -1%;
- contaminação de linearidade iniciando positiva e terminando negativa (LIN\_PN) – dados inferiores à média da grandeza no ensaio foram deslocados em +1% e os superiores deslocados em -1%;
- contaminação de linearidade iniciando negativa e terminando positiva (LIN\_NP) – dados superiores à média da grandeza no ensaio foram deslocados em -1% e os inferiores deslocados em +1%;
- dados utilizados na forma original, isto é, sem contaminação de incerteza (SI).

A figura 64 apresenta o esquema de contaminação adotado.

Contaminação	Variáveis de entrada		
	Capacidade de refrigeração	Temperatura do corpo	Pressão de sucção
ZG_P	+1%	+1%	+1%
ZG_N	-1%	-1%	-1%
LIN_PN	+1%:-1%	+1%:-1%	+1%:-1%
LIN_NP	-1%:+1%	-1%:+1%	-1%:+1%
SI	0	0	0

Figura 64 – Esquema de contaminação de incertezas para experimentos

Os níveis de incerteza adotados são maiores do que os praticados nas bancadas de ensaio de desempenho. A intenção é forçar uma contaminação maior para verificar situações de pior caso.

As formas de contaminação de linearidade LIN\_NP, LIN\_PN e SI são apresentadas de forma gráfica na figura 65. O valor ( $V_{\text{MÉDIO}}$ ) identifica o ponto no qual a contaminação muda de sinal e se refere à média dos valores da variável de interesse durante todo o ensaio.

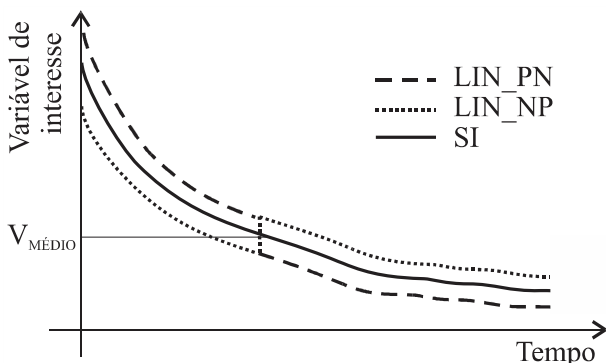


Figura 65 – Contaminação de linearidade para experimentos

O arranjo ortogonal definido para analisar a rede de inferência de regime é composto por 25 experimentos obtidos a partir da definição de 5 níveis de contaminação (ZG\_P, ZG\_N, LIN\_PN, LIN\_NP e SI) para cada uma das 3 grandezas de entrada (capacidade de refrigeração, temperatura do corpo e pressão de sucção), como mostrado na figura 66.

Como apresentado no item 5.2.1, a solução proposta para inferência do regime permanente prevê o uso de 30 redes neurais. Assim, para a análise da influência da incerteza no treinamento, foram gerados 25 conjuntos de 30 redes, totalizando 750 redes treinadas a partir dos pesos e bias iniciais das redes originais utilizadas para a geração dos resultados apresentados nos itens 5.2 e 5.3.

Experimento	Contaminação das grandezas de entrada		
	Capacidade de refrigeração	Temperatura do corpo	Pressão de sucção
1	ZG_P	ZG_P	ZG_P
2	ZG_P	ZG_N	ZG_N
3	ZG_P	LIN_PN	LIN_PN
4	ZG_P	LIN_NP	LIN_NP
5	ZG_P	SI	SI
6	ZG_N	ZG_P	ZG_N
7	ZG_N	ZG_N	LIN_PN
8	ZG_N	LIN_PN	LIN_NP
9	ZG_N	LIN_NP	SI
10	ZG_N	SI	ZG_P
11	LIN_PN	ZG_P	LIN_PN
12	LIN_PN	ZG_N	LIN_NP
13	LIN_PN	LIN_PN	SI
14	LIN_PN	LIN_NP	ZG_P
15	LIN_PN	SI	ZG_N
16	LIN_NP	ZG_P	LIN_NP
17	LIN_NP	ZG_N	SI
18	LIN_NP	LIN_PN	ZG_P
19	LIN_NP	LIN_NP	ZG_N
20	LIN_NP	SI	LIN_PN
21	SI	ZG_P	SI
22	SI	ZG_N	ZG_P
23	SI	LIN_PN	ZG_N
24	SI	LIN_NP	LIN_PN
25	SI	SI	LIN_NP

Figura 66 – Arranjo ortogonal de experimentos para treinamento das redes

Os 25 conjuntos de redes foram avaliados na base de teste disponível de 65 ensaios com aceleração de transitório. Na sequência são apresentadas análises através de gráficos de efeitos principais (*main effects*). Todos os resultados foram obtidos através do software de análise estatística *Minitab* (MINITAB, 2010).



O modelo estimado na análise dos experimentos revelou com  $(p=0,0$  e  $\alpha=0,05)$ <sup>24</sup> que a capacidade de refrigeração nas contribuições LIN\_PN e LIN\_NP se mostrou como a grandeza com maior influência (a resposta completa apresentada pelo *Minitab* – modelos gerados, análise de variância e análise de resíduos – pode ser vista no Apêndice A).

As figuras 67 a 69 apresentam os gráficos de efeitos principais<sup>25</sup> para cada uma das grandezas de entrada das redes de inferência considerando as respostas da ferramenta proposta – composta por 30 redes segundo os critérios apresentados da figura 31 (página 83) – para 65 ensaios. As linhas cheias próximas ao valor 0,44% representam a grande média para os 25 experimentos realizados.




Figura 67 – Efeitos principais da capacidade

Na figura 67 nota-se que as contribuições à incerteza da capacidade de refrigeração mais influentes são as referentes à linearidade, pois estão mais afastadas da grande média. Para as demais grandezas de entrada – temperatura do corpo (figura 68) e pressão de sucção (figura 69) – pode-se realizar a mesma análise. No entanto, observa-se que as influências são bem menores.

<sup>24</sup> Num teste de hipóteses,  $p$  representa a probabilidade de erroneamente rejeitar a hipótese nula quando a mesma é verdadeira. O valor obtido para  $p$  deve ser comparado com o  $\alpha$  definido *a priori*, onde  $\alpha$  é o risco máximo aceitável em rejeitar uma hipótese nula verdadeira.

<sup>25</sup> O erro percentual apresentado nos gráficos da análise se refere à diferença entre o valor da capacidade de refrigeração no instante de identificação do regime e a capacidade do final do ensaio realizado pelo método convencional (aguardando a estabilização de todas as variáveis por, pelo menos, 1 hora). A tarefa de inferência do regime permanente busca identificar o instante no qual a capacidade adentrou a faixa de  $\pm 2\%$  do valor final de ensaio.




Figura 68 – Efeitos principais da temperatura do corpo




Figura 69 – Efeitos principais da pressão de sucção

No ponto de vista da variabilidade das respostas frente às diferentes contribuições à incerteza pode-se apresentar as figuras 70 a 72. Além das informações de efeitos principais são apresentados intervalos definidos por dois desvios padrão para cada uma das contribuições. Nota-se que, visualmente, não há diferença significativa de comportamento, pois os intervalos são muito próximos entre si.




Figura 70 – Efeitos principais da capacidade, com 2 desvios padrão




Figura 71 – Efeitos principais da temperatura do corpo, com 2 desvios padrão




Figura 72 – Efeitos principais da pressão de sucção, com 2 desvios padrão

Para corroborar a análise realizada de maneira visual foram realizadas comparações estatísticas entre os resultados obtidos a partir das redes originais (figura 33, página 84) e os resultados dos experimentos com as seguintes contribuições: SI das variáveis capacidade de refrigeração, temperatura do corpo e pressão de sucção; LIN\_NP e LIN\_PN da capacidade de refrigeração. A comparação entre as redes originais e as respostas dos experimentos SI faz sentido na medida em que as redes resultantes dos experimentos SI são distintas das originais. Pela definição do arranjo ortogonal, nenhum experimento foi realizado com todas as variáveis sem contaminação, isto é, SI. Se esse fato tivesse ocorrido ter-se-ia um experimento com as redes originais.

Para realização dessa comparação os resultados foram avaliados para verificação do comportamento das distribuições e encaminhamento da escolha da abordagem a utilizar: paramétrica ou não paramétrica. As figuras 73 e 74 apresentam, respectivamente, um resumo da estatística descritiva e um gráfico tipo *boxplot* para a análise do comportamento das distribuições obtidas. A análise das informações apresentadas identifica comportamentos com desvio da distribuição normal como pode ser avaliado pelas estatísticas *skewness* e *kurtosis*, e, adicionalmente, pela observação da posição da mediana em relação ao primeiro e terceiro quartil nos gráficos *boxplot*. Assim, fica caracterizada uma aplicação típica de ferramentas não paramétricas para a análise comparativa dos resultados.

Contaminação	Média	Desvio Padrão	Mediana	Skewness	Kurtosis
	%				
Original	0,392	0,787	0,098	0,78	0,66
SI Capacidade	0,430	0,779	0,161	0,64	0,06
SI Temperatura	0,436	0,759	0,183	0,80	0,61
SI Pressão	0,438	0,787	0,169	0,80	0,39
LIN_PN Capacidade	0,368	0,649	0,153	0,36	0,44
LIN_NP Capacidade	0,491	0,872	0,176	0,97	0,46

Figura 73 – Estatística descritiva dos resultados das redes originais e experimentos selecionados

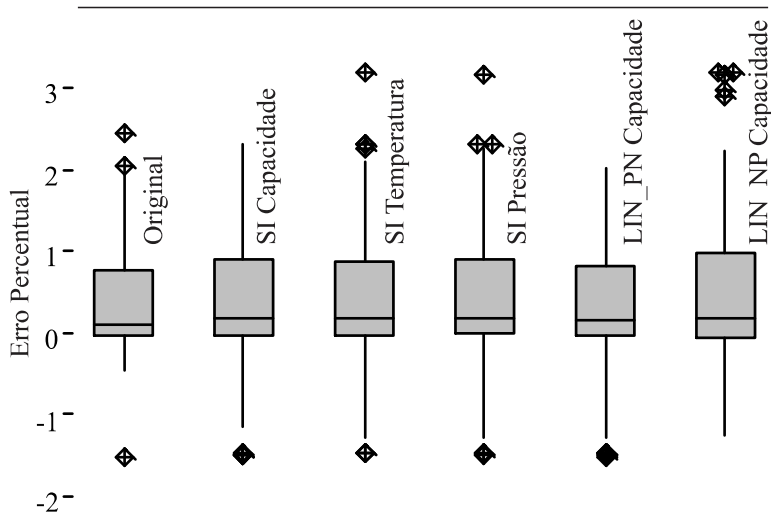


Figura 74 – Gráfico *boxplot* para redes originais e experimentos selecionados

Para a comparação dos resultados são utilizados dois testes de análise não paramétrica, são eles: *Mood Median* e *Kruskal-Wallis*. A utilização dos dois testes pretende assegurar uma melhor avaliação devido às características dos testes. O primeiro apresenta maior robustez em relação à presença de *outliers* (que podem ser vistos na figura 74). O segundo teste é mais adequado para avaliação de dados oriundos de diferentes distribuições – função dos diferentes níveis de *skewness* e *kurtosis* indicados na figura 73 (URDHWARESHE, 2010).

O teste de hipóteses realizado pelos dos métodos é:

$H_0$ : as medianas das populações são iguais


$H_1$ : as medianas das populações são diferentes

Nível de confiança considerado:  $\alpha = 0,05$

Os dois testes aceitaram a hipótese nula ( $H_0$ ), isto é, as medianas das populações são iguais e, portanto, pode-se considerar que não há diferença entre as respostas das redes originais e as respostas das redes referentes aos experimentos. Para o teste *Mood Median* as medianas são iguais com  $p = 0,938$  ( $\chi^2=1,27$ ;  $DF=5$ ); para o teste *Kruskal-Wallis* as medianas são iguais com  $p=0,965$  ( $H=0,97$ ;  $DF=5$ ). Os resultados completos apresentados pelo software de análise estatística *Minitab* podem ser apreciados no Apêndice A.

A partir das análises realizadas foram obtidas evidências de que a incerteza de medição, nos níveis e formas testadas, não influencia o treinamento das redes neurais de maneira a comprometer comportamento da solução proposta para a inferência do regime permanente da capacidade de refrigeração.

Do ponto de vista individual dos experimentos foi possível observar comportamentos que acompanharam as respostas obtidas com as redes originais, treinadas sem incerteza de medição. A figura 75 apresenta os resultados obtidos para o experimento 1 no qual há contaminação ZG\_P para as três grandezas de entrada da rede e a resposta da solução com as redes sem incerteza. As respostas dos demais experimentos podem ser observadas no Apêndice B (página 171).



Legenda:

Linha cheia – erro da solução de redes sem incerteza;

Pontos – erro da solução das redes do experimento;

Linha tracejada – erro médio da solução de redes sem incerteza;

Linha pontilhada – erro médio da solução de redes do experimento.

Figura 75 – Comportamento do experimento 1 para os 65 ensaios analisados

## 6.2.2 Estudo de Caso 2: Uso das redes neurais de inferência

A análise da influência da incerteza de medição no uso das redes é realizada seguindo o método proposto com as seguintes alterações:

- não há treinamento de redes específicas – a avaliação é realizada utilizando as redes originais (treinadas sem contaminação de incerteza);

- os dados que serão contaminados são os referentes ao conjunto de teste composto pelos 65 ensaios com aceleração do transitório.

A análise é baseada nos mesmos 25 experimentos definidos no estudo de caso anterior e apresentados nas figuras 64 a 66 (páginas 118 a 120).

O modelo estimado na análise dos experimentos revelou com ( $p < 0,05$ ) que todas as contribuições de incerteza têm relação significativa com os resultados (a resposta completa apresentada pelo *Minitab* – modelos gerados, análise de variância e análise de resíduos – pode ser apreciada no Apêndice A).

As figuras 76 a 78 apresentam os gráficos de efeitos principais<sup>26</sup> para cada uma das grandezas de entrada das redes de inferência considerando as respostas da solução proposta – composta por 30 redes segundo os critérios apresentados da figura 31 (página 83) – para 65 ensaios. As linhas cheias próximas ao valor 0,38% representam a grande média para os 25 experimentos realizados.




Figura 76 – Efeitos principais da capacidade

<sup>26</sup> O erro percentual apresentado nos gráficos da análise se refere à diferença entre o valor da capacidade de refrigeração no instante de identificação do regime e a capacidade do final do ensaio realizado pelo método convencional.

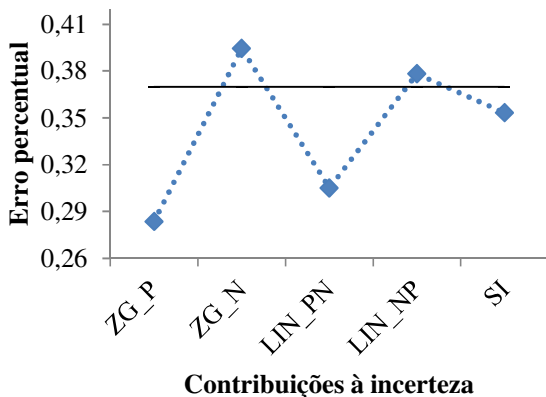


Figura 77 – Efeitos principais da temperatura do corpo





Figura 78 – Efeitos principais da pressão de sucção

Dentre as três variáveis de entrada das redes a temperatura do corpo apresentou maior influência ( $F=133,81$ ;  $p=0,0$ ) seguida pela capacidade de refrigeração ( $F=75,01$ ;  $p=0,0$ ) e pressão de sucção ( $F=5,04$ ;  $p=0,0$ ).


No ponto de vista da variabilidade das respostas frente às diferentes contribuições à incerteza pode-se apresentar as figuras 79 a 81. Além das informações de efeitos principais são indicados intervalos definidos por dois desvios padrão para cada uma das contribuições. Nota-se que visualmente não há diferença significativa de comportamento, pois os intervalos são muito próximos entre si.






**Contribuições à incerteza**

Figura 79 – Efeitos principais da capacidade, com 2 desvios padrão



**Contribuições à incerteza**

Figura 80 – Efeitos principais da temperatura do corpo, com 2 desvios padrão



**Contribuições à incerteza**

Figura 81 – Efeitos principais da pressão de sucção, com 2 desvios padrão

Para corroborar a análise realizada de maneira visual foram realizadas comparações estatísticas entre os resultados obtidos a partir das redes originais (figura 33, página 84) e os resultados dos experimentos das seguintes contribuições: ZG\_P, ZG\_N, LIN\_NP e LIN\_PN das variáveis capacidade de refrigeração e temperatura do corpo.

Para realização dessa comparação, os resultados foram avaliados para verificação do comportamento das distribuições e encaminhamento da escolha da abordagem a utilizar: paramétrica ou não paramétrica. As figuras 82 e 83 apresentam, respectivamente, um resumo da estatística descritiva e um gráfico tipo *boxplot* para a análise do comportamento das distribuições obtidas. A análise das informações apresentadas identifica comportamentos com desvio da distribuição normal, como pode ser avaliado pelas estatísticas *skewness* e *kurtosis*, e, adicionalmente, pela observação da posição da mediana em relação ao primeiro e terceiro quartil nos gráficos *boxplot*. Dessa forma, fica caracterizada a necessidade de ferramentas não paramétricas para a análise comparativa dos resultados.

Contaminação	Média	Desvio Padrão	Mediana	Skewness	Kurtosis
	%				
Original	0,392	0,787	0,098	0,78	0,66
ZG_P Capacidade	0,360	0,712	0,094	0,82	0,25
ZG_N Capacidade	0,320	0,649	0,098	0,69	0,28
LIN_PN Capacidade	0,368	0,711	0,090	0,82	0,22
LIN_NP Capacidade	0,323	0,651	0,096	0,70	0,26
ZG_P Temperatura	0,284	0,613	0,094	0,77	0,83
ZG_N Temperatura	0,394	0,736	0,098	0,72	-0,12
LIN_PN Temperatura	0,305	0,662	0,076	0,80	0,49
LIN_NP Temperatura	0,378	0,698	0,116	0,71	0,11

Figura 82 – Estatística descritiva dos resultados dos experimentos selecionados




Figura 83 – Gráfico *boxplot* dos resultados dos experimentos selecionados


Os mesmos testes não paramétricos utilizados na avaliação anterior são aplicados nessa análise (URDHWARESHE, 2010). Os dois testes aceitaram a hipótese nula ( $H_0$ ), isto é, as medianas das populações são iguais e, portanto, pode-se considerar que não há diferença entre as respostas das redes originais e as respostas das redes referentes aos experimentos. Para o teste *Mood Median* as medianas são iguais com  $p=0,963$  ( $\chi^2=2,48$ ;  $DF=8$ ); para o teste *Kruskal-Wallis* as medianas são iguais com  $p=0,883$  ( $H=3,71$ ;  $DF=8$ ). Os resultados completos apresentados pelo software de análise estatística *Minitab* podem ser apreciados no Apêndice A.

A partir das análises realizadas foram obtidas evidências de que a incerteza de medição, nos níveis e formas testadas, não influencia o uso das redes neurais de maneira a comprometer o comportamento da ferramenta proposta para a inferência do regime permanente da capacidade de refrigeração.

### 6.2.3 Estudo de Caso 3: Uso da rede *fuzzy*-bayesiana de inferência

A solução *fuzzy*-bayesiana, apresentada no item 5.2.2, apresenta duas grandezas de entrada: temperatura do corpo e variação do controle da pressão de sucção. A avaliação da influência da incerteza de medição é realizada somente a partir da contaminação da temperatura do corpo relativa (TCr). A entrada variação do controle da pressão de sucção ( $\Delta$ CPS) não será avaliada pois, além de não ser uma medição e sim a saída do sistema de controle, sua concepção de diferença entre médias de valores retiraria as contaminações de incerteza.

Os dados da temperatura do corpo foram contaminados da mesma forma dos estudos anteriores 6.2.1 e 6.2.2, como apresentado na figura 64 (página 118). A figura 84 apresenta os erros relativos da capacidade de refrigeração nos instantes de inferência sem contaminação e com as quatro contaminações na variável temperatura do corpo consideradas (ZG\_P, ZG\_N, LIN\_NP E LIN\_PN). Nota-se que os desvios máximos obtidos para as contaminações foram de aproximadamente 0,5% (para mais ou para menos) em quatro ensaios. Para os demais ensaios os erros para as contaminações acompanharam os erros sem contaminação.



Legenda:

Linha – erro da capacidade no instante da inferência sem contaminação de incerteza;

Traços – erros da capacidade nos instantes das inferências para os quatro modos de contaminação considerados.

Figura 84 – Erro percentual na identificação do regime

A análise de variância realizada para comparação dos erros apresentados revelou com  $p=1,0$  ( $F=0,0$ ;  $DF=4$ ) que as contaminações

não apresentaram influências estatisticamente diferentes. O resultado completo da análise de variância pode ser apreciado no Apêndice A. A figura 85 apresenta uma tabela dos erros médios e desvios padrão para os resultados. Os dados evidenciam a constatação da análise de variâncias.

Contaminação	Média	Desvio Padrão
	%	
Sem incerteza	0,483	0,731
ZG_P Temperatura	0,487	0,731
ZG_N Temperatura	0,472	0,730
LIN_PN Temperatura	0,479	0,732
LIN_NP Temperatura	0,475	0,732

Figura 85 – Influência da incerteza de medição na rede *fuzzy*-bayesiana

#### 6.2.4 Estudo de Caso 4: Uso das redes neurais de prognóstico

Esse estudo de caso apresenta a análise da influência da incerteza de medição na tarefa completa do prognóstico da capacidade de refrigeração utilizando a solução proposta composta por: inferência do regime usando redes neurais e rede *fuzzy*-bayesiana; prognóstico usando redes neurais. A análise da influência no prognóstico não pode ser realizada somente nas redes de prognóstico, mas na solução como um todo para a obtenção de resultados consistentes com o uso pretendido.

Para a análise foram utilizadas as redes originais – tanto na inferência de regime quanto no prognóstico da capacidade. Os dados dos ensaios com aceleração de transitório foram contaminados segundo os 25 experimentos definidos e aplicados à solução completa.

A figura 86 apresenta o gráfico de efeitos principais para as contribuições de incerteza da capacidade de refrigeração no prognóstico. O erro percentual é entre o prognóstico e o valor final do ensaio (segundo os dados contaminados).

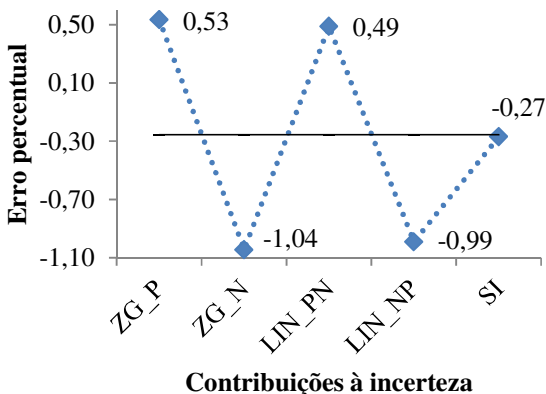



Figura 86 – Efeitos principais da capacidade

Do ponto de vista de efeitos principais pode-se notar que a tarefa de prognóstico, pelo motivo de ter somente a capacidade de refrigeração como entrada das redes neurais, apresenta desvios mais significativos para as contribuições à incerteza quando comparado com as análises da inferência de regime.

As redes de prognóstico têm como entradas desvio padrão, médias e diferenças entre médias – que inserem nas redes o comportamento dinâmico da capacidade de refrigeração. Após o treinamento, as redes relacionam o comportamento dinâmico da capacidade na região da inferência do regime com a posição futura da capacidade final do ensaio. Assim, supondo um comportamento de redução dos valores de capacidade no instante de inferência do regime as redes de prognóstico indicam valores mais baixos – na busca do valor final de ensaio. Na situação da capacidade estar crescente, as redes de prognóstico buscam um valor superior.


Na figura 86, a observação dos erros médios das contribuições ZG\_P, ZG\_N, LIN\_PN e LIN\_NP em relação ao caso sem incerteza de medição (SI), nota-se que as diferenças são muito próximas e na faixa entre 0,72% e 0,80%. Essa constatação e a observação da figura 87 – onde as dispersões para cada contribuição se apresentam praticamente iguais – indicam que não há diferença significativa entre as influências da capacidade em termos absolutos.



### Contribuições à incerteza

Figura 87 – Efeitos principais da capacidade com 2 desvios padrão

As figuras 88 a 91 apresentam os gráficos de efeitos principais para as variáveis temperatura do corpo e pressão de sucção. Nota-se que não há influência significativa em nenhuma das contribuições analisadas, mesmo essas tendo sido significativas nas análises da inferência do regime. A resposta completa apresentada pelo software *Minitab* pode ser apreciada no Apêndice A.



### Contribuições à incerteza

Figura 88 – Efeitos principais da temperatura do corpo




Figura 89 – Efeitos principais da pressão de sucção




Figura 90 – Efeitos principais da temperatura do corpo, com 2 desvios padrão




Figura 91 – Efeitos principais da pressão de sucção, com 2 desvios padrão



A figura 92 apresenta a comparação direta entre os resultados originais dos ensaios com aceleração de transitório e os máximos desvios devido às contaminações de incerteza. Os ensaios foram ordenados – pelo erro obtido com as redes originais – para facilitar a visualização do efeito gerado pela incerteza.




Figura 92 – Prognóstico original e os máximos desvios devido à incerteza

Os resultados originais para os ensaios com aceleração de transitório, já relatados, ficaram na faixa de  $\pm 1,5\%$  do valor final capacidade. Para os resultados dos experimentos com incerteza de medição de  $\pm 1,0\%$ , a faixa dos erros alargou-se para  $\pm 2,5\%$ , isto é, aumentou no valor da incerteza considerada. Essa constatação indica que os erros dos prognósticos são relacionados diretamente e proporcionalmente à incerteza da medição referente à capacidade de refrigeração.

### 6.3 RELAÇÃO ENTRE ERRO DE PROGNÓSTICO E CAPACIDADE DE REFRIGERAÇÃO

Esse item pretende investigar a relação existente entre os erros apresentados pela solução completa de prognóstico e os valores de capacidade de refrigeração dos ensaios obtidos pelo método tradicional. As análises são realizadas segundo método estabelecido na referência *Measurement System Analysis – MSA* (AIAG, 2010).

A figura 93 apresenta a relação entre os prognósticos e os valores finais da capacidade para os ensaios sem aceleração de transitório. Nota-

se que não há, através de inspeção visual, evidência da ocorrência de uma relação não linear entre os prognósticos e os valores finais.

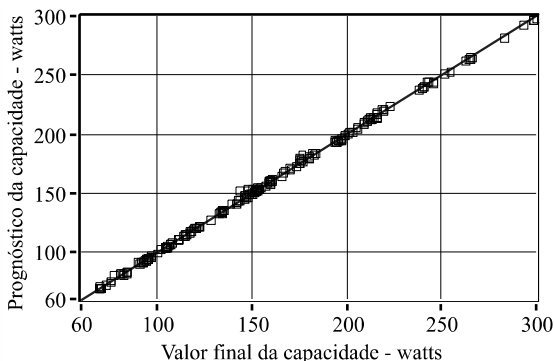


Figura 93 – Prognóstico versus valor final – sem aceleração

A figura 94 apresenta a relação entre os erros de prognóstico e os valores finais de capacidade obtidos pelo método tradicional. Para avaliar o comportamento dessa relação é realizada uma regressão linear no intuito de identificar possível relação significativa entre os dados apresentados.




Figura 94 – Erro do prognóstico versus valor final – sem aceleração

A análise realizada considera a relação entre o erro percentual e o logaritmo natural do valor final da capacidade para que a análise estatística seja mais eficaz.

A equação obtida foi  $Erro = 0,952 - 0,148 \cdot \ln(Capacidade)$ . No entanto os efeitos dos termos intercepto e inclinação não foram estatisti-

camente significativos com  $(T=1,35; p=0,177)$  e  $(T=-1,05; p=0,297)$ , respectivamente, para  $\alpha=0,05$ . Assim, a hipótese nula –  $H_0$ : não há relação significativa entre o erro e o valor da capacidade – não pode ser rejeitada. O resultado completo fornecido pelo software *Minitab* pode ser apreciado no Apêndice A.

A figura 95 apresenta a relação entre os prognósticos e os valores finais da capacidade para os ensaios com aceleração de transitório. Nota-se que não há, através de inspeção visual, evidência da ocorrência de uma relação não linear entre os prognósticos e os valores finais.




Figura 95 – Prognóstico versus valor final – com aceleração

A figura 96 apresenta a relação entre os erros de prognóstico e os valores finais de capacidade obtidos pelo método tradicional. No intuito de identificar possível relação significativa entre os dados apresentados é realizada uma regressão linear.

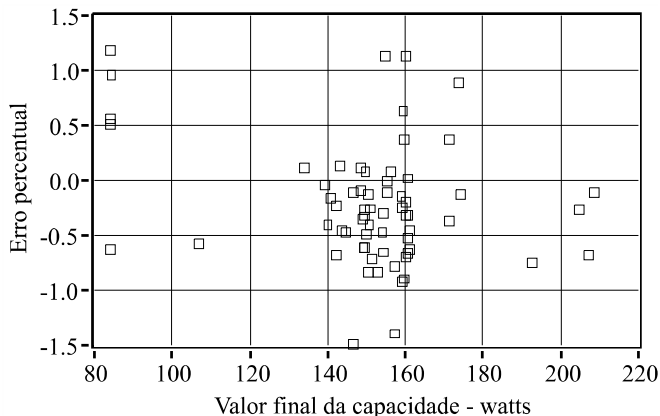


Figura 96 – Erro do prognóstico versus valor final – com aceleração

A análise realizada considera a relação entre o erro percentual e o logaritmo natural do valor final da capacidade para que a análise estatística seja mais eficaz.

A equação obtida foi  $Erro = 4,27 - 0,905 \cdot \ln(Capacidade)$ . Os efeitos dos termos intercepto e inclinação foram estatisticamente significativos com  $(T=2,26; p=0,027)$  e  $(T= -2,40; p=0,019)$ , respectivamente, para  $\alpha=0,05$ . Assim, a hipótese nula –  $H_0$ : não há relação significativa entre o erro e o valor da capacidade – deve ser rejeitada. No entanto, a estatística  $R^2$  resultou num valor de 8,4%, o que indica que muito pouco da variabilidade do erro do prognóstico pode ser atribuída à capacidade de refrigeração. A observação dos gráficos relacionados aos ensaios com aceleração de transitório evidencia: alta concentração de pontos na faixa de (140 a 160) W e entre erros de -1% e zero; poucos pontos abaixo de 100 W com erros na faixa (0,5 a 1,5) %. Essa concentração de dados em regiões específicas pode ter forçado artificialmente a ocorrência de relação significativa. Análises mais apuradas para avaliação da existência, ou não, de relação entre erro de prognóstico e capacidade de refrigeração em ensaios com aceleração de transitório devem ser realizadas quando houver disponibilidade de dados mais bem distribuídos em relação à capacidade. O resultado completo fornecido pelo software *Minitab* pode ser visto no Apêndice A.

Este capítulo apresentou propostas de métodos para avaliação da influência da incerteza de medição nas ferramentas de IA propostas para a inferência e prognóstico em ensaios de desempenho. As análises reali-

zadas contribuem para a confiabilidade dos resultados e fornecem evidências contundentes da segurança das ferramentas propostas.

Como as ferramentas de IA propostas neste trabalho se caracterizam como um meio original para a realização de ensaios, a norma ISO/IEC 17025 (ISO, 2005) foi avaliada nos aspectos concernentes à validação de métodos inovadores de ensaios. Resultaram dessa análise, diversos planos de ações para a garantia da confiabilidade dos resultados e acompanhamento dos mesmos visando à melhoria contínua.



## 7 CONSIDERAÇÕES FINAIS

O presente trabalho teve por objetivo estabelecer métodos e procedimentos para prover confiabilidade às inferências e prognósticos – obtidos via paradigmas da inteligência artificial (IA) – para caracterização do desempenho de compressores de refrigeração em regime a partir de dados obtidos do período transitório de ensaios de desempenho.

Não foi encontrada na bibliografia consultada referência a algum conjunto estruturado de recursos que fosse aplicado ao problema em questão. Decorreu um amplo trabalho de levantamento do estado-da-arte em ensaios de desempenho de compressores, redes neurais e bayesianas, sistemas *fuzzy* e confiabilidade metrológica. Fundamentado em tal estudo foi proposto um conjunto de ferramentas que permitiu alcançar plenamente o objetivo proposto.

### 7.1 CONCLUSÕES

#### 7.1.1 Quanto à revisão bibliográfica realizada

Redes neurais artificiais têm encontrado cada vez mais aplicações com o surgimento de processos e tarefas mais complexas. Para atender aos novos processos, que exigem ferramentas capazes de analisar e processar grandes quantidades de informação, os engenheiros e cientistas têm encontrado nas redes neurais uma ferramenta com alto poder de processamento.

A indústria é um setor que apresenta inúmeras situações nas quais tais tarefas altamente complexas devem ser realizadas com segurança e, muitas vezes, atendendo restrições e requisitos temporais de execução para garantir a eficácia dos processos internos. Nesse contexto, o uso de redes neurais tem contribuído de maneira significativa.

Como característica geral dos diversos artigos científicos analisados – no intuito de identificar potenciais métodos de análise e incremento da confiabilidade no uso de redes neurais – observa-se que aspectos da aplicação norteiam a implementação das ferramentas. Tal fato decorre da maneira como, tipicamente, o conhecimento a respeito da aplicação é inserido nas ferramentas de IA: uso de dados experimentais para modelagem das relações de causa e efeito através de processos de otimização numérica. Tais processos não garantem por si as soluções ideais e os dados experimentais usados não cobrem plenamente todas as possibilidades da aplicação. Nessas condições, as relações analíticas teóricas

concernentes à aplicação servem como balizadores na análise crítica dos resultados obtidos com ferramentas de IA.

Do ponto de vista metrológico, há um distanciamento significativo no uso dos conceitos e termos vigentes, implicando dificuldades na concepção, implantação e avaliação dessas ferramentas de IA. No entanto, normas como a ISO/IEC 17025 – referência na definição de requisitos para laboratórios de calibração e ensaio – preveem a aplicação de métodos que fazem uso dessas ferramentas, desde que validadas de modo consistente aos conhecimentos científicos.

As redes *fuzzy*-bayesianas ainda encontram dificuldades para sua inserção em ambientes industriais. Muitas das aplicações desse tipo de rede ainda estão relacionadas à área médica – originariamente o reduto das redes bayesianas – muito utilizadas em sistemas de diagnóstico. Espera-se, com a publicação deste trabalho e, adicionalmente, de artigos em revista, contribuir para a disseminação dessa ferramenta em aplicações industriais.

As ferramentas híbridas têm assumido papel destacado em aplicações científicas e industriais de IA. O uso concomitante de ferramentas como redes neurais, lógica *fuzzy*, sistemas especialistas baseados em regras e redes bayesianas – para citar alguns exemplos – tem contribuído significativamente para obtenção de resultados mais confiáveis e sistemas mais robustos. São claros os ganhos advindos do hibridismo, os quais se devem ao fato de que fundamentos e conceitos para descrição dos processos são distintos para cada ferramenta que, quando integradas, se complementam.

### 7.1.2 Quanto às inovações concretizadas neste trabalho

**A rede *fuzzy*-bayesiana para informação adicional do regime permanente** se mostra eficaz para a redução de falsas indicações de estabilidade (falso-positivo) e contribui para a confiabilidade no prognóstico do valor final das características de desempenho. Como um paradigma distinto às redes neurais artificiais, as redes *fuzzy*-bayesianas inferem segundo informações de probabilidade, que têm – atribuídas às variáveis associadas – a representação *fuzzy*. Essa distinção faz com que a rede *fuzzy*-bayesiana observe as variáveis do ensaio de modo a complementar a informação advinda das redes neurais. O uso desse tipo de rede é ainda incipiente em aplicações industriais – como o deste trabalho – mas o potencial dessa ferramenta é evidente. Recentemente, o autor deste publicou um artigo (PENZ, 2011), o qual, aparentemente, é o único relato de aplicação dessa ferramenta em ensaios de compressores.



**A análise probabilística para escolha de redes neurais treinadas com foco na aplicação** se mostrou eficaz quanto à aplicação de múltiplas redes neurais para inferência e prognóstico. O procedimento proposto para análise da necessidade de uso de múltiplas redes – através avaliações de probabilidade de indicação de regime associadas às informações de correlação nas respostas das redes – se mostrou adequado. Os meios para definição das regras de inferência – que relacionam quantidade de redes e tempos de espera – também se mostraram eficazes, tanto em relação à qualidade da inferência – identificação do regime na faixa de estabilidade – quanto na garantia de ganho significativo em tempo de ensaio.

**O método de avaliação da influência da incerteza de medição no treinamento e uso de redes neurais, redes *fuzzy*-bayesianas e soluções híbridas** conseguiu evidenciá-la em diferentes ferramentas e momentos relacionados à aplicação de IA nos ensaios de desempenho. Sua aplicação ao caso em questão mostrou que os resultados apresentaram influências que não comprometem os processos de inferência de regime, tanto no treinamento das redes quanto no uso. Em relação ao prognóstico, os erros dos resultados são direta e proporcionalmente relacionados à incerteza de medição da capacidade de refrigeração. O método proposto pode ser utilizado para estimar o comportamento das ferramentas de IA quando essas são aplicadas em painéis com especificações distintas de incerteza de medição.

**A integração de informações provenientes de sistemas de controle de processos e ferramentas de inteligência artificial com foco na confiabilidade** contribuiu para a redução de falso-positivo nas inferências de regime permanente dos ensaios. O uso desse tipo de informação é bastante favorável, pois a origem desses sinais é baseada em experimentação – na própria bancada de ensaio – para identificação de modelos de comportamento dinâmico. Esses modelos são usados, então, para o projeto dos controladores das variáveis. Assim, todo conhecimento – relacionado à engenharia de controle – usado nesse processo está associado ao sinal de controle. Dessa forma, a integração do sinal de controle à rede *fuzzy*-bayesiana implica adição de informações significativas para os processos de inferência e prognóstico.

**A integração de ferramentas de inteligência artificial e métodos de redução de transitório para diminuição drástica do tempo demandado por ensaios de desempenho** encaminhou tempo médio de ensaio inferior a 50 minutos com erros máximos inferiores a 1,5%. Cabe ressaltar que os treinamentos das redes neurais e da *fuzzy*-bayesiana ocorreram a partir de um conjunto de ensaios realizados sem

aceleração de transitório. Essa condição corrobora a robustez das ferramentas propostas.

### **7.1.3 Quanto à avaliação experimental das ferramentas propostas**

A avaliação das ferramentas propostas ocorreu numa quantidade expressiva de ensaios de desempenho realizados em condições de confiabilidade metrológica e operacional singulares. A bancada utilizada para realização dos ensaios representa o estado-da-arte em avaliação de desempenho de compressores de refrigeração.

Na área da inteligência artificial – principalmente em se tratando de redes neurais – os engenheiros de conhecimento dispõem, tipicamente, de base de dados muito restritas e, muitas vezes, essa deve ser utilizada tanto para o desenvolvimento das ferramentas quanto para a avaliação antes do uso efetivo. No caso do presente trabalho, um conjunto de 50 ensaios foi utilizado para o desenvolvimento das ferramentas e, um segundo conjunto composto de 275 ensaios foi utilizado para avaliar as propostas. Aliada à quantidade de ensaios para avaliação, o conjunto é dividido em dois grupos relacionados ao uso ou não de técnicas de aceleração de transitório. Essa característica atesta a robustez das ferramentas propostas à medida que ensaios de características dinâmicas fortemente distintas são utilizados na avaliação.

Vale ressaltar – como apresentado no item 5.4, página 106 – que dentre os nove ensaios sem aceleração que apresentaram erro de prognóstico superior a 2%, seis referem-se a um modelo específico de compressor. Tal modelo apresenta elevada dispersão nos valores típicos de capacidade de refrigeração. Essa dispersão está relacionada à presença tanto de ensaios de controle da qualidade da produção quanto dos processos de pesquisa e desenvolvimento.

Os primeiros apresentam, tipicamente, baixa dispersão dos valores de capacidade de refrigeração devido à estabilidade do processo produtivo. Já os ensaios de pesquisa e desenvolvimento representam compressores com alterações construtivas que visam à melhoria do desempenho. Assim, esses compressores apresentam valores, tipicamente, distintos de capacidade de refrigeração quando comparados às amostras da produção seriada. Essa dispersão é a provável causa para que os prognósticos aprestassem erros maiores do que o limite desejado de 2%.

Acredita-se que esses erros possam ser reduzidos com ações específicas, como o desenvolvimento de ferramentas que levem em consideração as particularidades desses dois tipos de ensaios. Adicionalmente, como os ensaios de desempenho são realizados sempre em amostras

– compostas tipicamente por 5 peças – a definição de estratégias de escalonamento e uso de resultados de ensaios subsequentes pode contribuir tanto para a confiabilidade quanto para a economia de tempo.

Quanto ao tempo demandado pelos ensaios, as ferramentas propostas neste trabalho contribuem significativamente para a eficiência dos processos de controle da qualidade e de P&D em compressores. Para ensaios sem aceleração de transitório, a economia média de tempo atinge índice superior a 60% em relação aos ensaios em bancadas 100% automatizadas. Para ensaios com aceleração de transitório, a economia média de tempo é superior a 50%. Cabe ressaltar que os resultados obtidos ainda podem ser melhorados, com ações de avaliação e de aprimoramento contínuo das ferramentas de inferência e prognóstico. Acredita-se também que o treinamento de redes neurais para análise específica dos ensaios com aceleração de transitório possa contribuir ainda mais para economia de tempo e redução de erros de prognóstico.

## 7.2 SUGESTÕES DE TRABALHOS FUTUROS

A literatura analisada durante o desenvolvimento deste trabalho evidenciou que a aplicação de técnicas de inteligência artificial terá destaque ainda maior nos meios científico e industrial nos próximos anos. Durante o desenvolvimento deste trabalho foram vislumbradas oportunidades de melhoria. As que não puderam ser satisfatoriamente exploradas são propostas na sequência como temas para futuros de trabalhos técnico-científicos.

- Para que todas as ferramentas propostas neste trabalho sejam utilizadas na rotina de empresa fabricante de compressores é necessário o estabelecimento de meios de geração e atualização de redes. Nessa condição é primordial: desenvolver meios para identificação de ensaios típicos – de maneira automática – para composição do conjunto de treinamento das redes; desenvolver software para treinamento e escolha automática de redes.
- Para garantir que os resultados estão saindo de acordo com os níveis de confiabilidade desejados e consolidar a melhoria contínua dos resultados faz-se necessário: conceber rotinas para acompanhamento do desempenho das ferramentas de inferência e prognóstico; definir as estratégias de comparação de soluções; definir formas de integração do conhecimento de soluções subsequentes para aumento da confiabilidade.

- Decorrente dos ótimos resultados obtidos para os ensaios com aceleração de transitório, e na busca por soluções cada vez melhores, sugere-se a concepção de uma ferramenta de inferência e prognóstico específica para esse tipo de ensaio.
- A inclusão de resultados de ensaios da linha de produção – através de redes neurais artificiais, redes *fuzzy*-bayesianas ou outra técnica a identificar – pode incrementar a confiabilidade de ensaios de desempenho em laboratório. Existe trabalho em andamento – no grupo de pesquisa do qual o autor deste é integrante – no sentido de correlacionar resultados de testes realizados na linha de produção com resultados de ensaios de desempenho realizados em laboratório. Tal trabalho pretende levar à linha informações de laboratório. A presente sugestão é realizar o caminho inverso: levar informações da linha para o laboratório, visando incremento da confiabilidade das inferências e prognósticos propostos.

## REFERÊNCIAS

ABLAMEYKO S.; GORAS L.; GORI M.; V. PIURI. **Neural Networks for Instrumentation, Measurement and Related Industrial Applications**. NATO Science Series: Computer & Systems Sciences. v. 185, 2003.

AHMAD, Z.; ZHANG, J. A comparison of different methods for combining multiple neural networks models. **Proceedings of the International Joint Conference on Neural Networks**, v. 1, May 2002.

AHMAD, Z.; ZHANG, J. Bayesian selective combination of multiple neural networks for improving long-range predictions in nonlinear process modeling. **Neural Computing & Applications**, v. 14, 2005.

AIAG Automotive Industry Action Group. **Measurement Systems Analysis – MSA: Reference manual**. 4<sup>th</sup> edition, 2010. 240 p.

ARSLAN, O.; MÜFTÜOĞLU, O. A practical method of confidence estimation for neural networks in image classification. **Proceedings of International Conference on Intelligent Knowledge Systems**, 16-20 Aug. 2004.

ASHRAE STANDARD. **ANSI/ASHRAE 23-2005**: Methods of testing for rating positive displacement refrigerant compressors and condensing units. Atlanta, EUA, 2005.

AYYUB, B.M.; KLIR, G. J. **Uncertainty modeling and analysis in engineering and the sciences**. Chapman & Hall/CRC, 2006.

BARBOSA, F. Q. **Redução das incertezas nas medições de grandezas elétricas em uma bancada de ensaios 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.

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 104:** Evaluation of measurement data – An introduction to the “Guide to the expression of uncertainty in measurement” and related documents. Jul. 2009. 28 p.

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

BORGES, M. R. **Desenvolvimento e aprimoramento de sistemas de medição para os laboratórios GTPP.** Apresentação interna Embraco, 2008.

BROWN, G.; WYATT, J.; HARRIS, R.; YAO, X. Diversity creation methods: a survey and categorization. **Journal of Information Fusion**, v. 6, 2005. 16 p.

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.

COX, D. R.; REID, N. **The theory of the design of experiments.** Monographs on statistics and applied probability, Chapman & Hall/CRC, 2000.

DAR – DEUTSCHER AKKREDITIERUNGS RAT. **Introducing the concept of uncertainty of measurement in testing in association with the application of the standard ISO/IEC 17025.** Berlin, 2002. 6 p.

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.

DOUMA, S. G.; VAN DEN HOF, P.M.J. An alternative paradigm for probabilistic uncertainty bounding in prediction error identification. **Proceedings 44<sup>th</sup> IEEE Conference on Decision and Control**, Spain, Dec. 2005. 6 p.

- DYBOWSKI, R.; ROBERTS, S. J. Confidence intervals and prediction intervals for feed-forward neural networks. **Clinical Applications of Artificial Neural Networks**, Cambridge, 2001, 28 p.
- 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.
- 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. Comparative analysis of an evaporative condenser using artificial neural network and adaptive neuro-fuzzy inference system. **International Journal of Refrigeration**, v. 31, 2008. 11 p.
- FLESCHE, C. A.; SCAVONE, R. Aplicación de sistemas expertos para determinar intervalos de calibración de instrumentos de medición en bancos de ensayo. **Revista Información Tecnológica**, ISSN 0716-8756. v. 9, n.2, 1998. 7 p.
- FLESCHE, R. C. C. **Desenvolvimento e Instalação de Recursos de Automação Aplicados a Ensaios de Compressores de Refrigeração da Embraco**. Florianópolis, 2006. Monografia (Curso de Engenharia de Controle e Automação Industrial), Universidade Federal de Santa Catarina,.
- 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**, vol. 18, p. 254-261, 2010.
- 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.
- GEMAN, S.; BIENENSTOCK, E.; DOURSAT, R. Neural networks and the bias/variance dilemma. **Neural Computation**, v. 4, 1992.
- 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.

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

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.

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.

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 10012**: Measurement management systems – Requirements for measurement processes and measuring equipment. 1st ed. Apr 2003.

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

ISO – INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 917**: Testing of refrigerant compressors. 2<sup>nd</sup> ed. Switzerland, 1989.

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.

KORB, K. B.; NICHOLSON, A. E. **Bayesian artificial intelligence**. Chapman & Hall/CRC, 2004.



- KOSKELA, T. **Neural Network Methods in Analysing and Modelling Time Varying Processes**. Dissertation for the degree of Doctor of Science in Technology. Helsinki University of Technology. 2003. 127 p.
- KROGH, A.; VEDELSBY, J. Neural networks ensembles, cross validation and active learning. **Advances in Neural Information Processing Systems**, vol. 7, MIT Press, 1995.
- KURD, Z.; KELLY, T.; AUSTIN, Jim. Developing artificial neural networks for safety critical systems. **Neural Computing & Applications**, v. 16, 2007. 9 p. doi 10.1007/s00521-006-0039-9.
- LECA, R.; GROZA, V. On the need to estimate the adequacy of measurement results. **International Workshop on Advanced Methods for Uncertainty Estimation in Measurement (AMUEM 2009)**, Bucharest, Romania, 6-7 July 2009.
- LEMMON, E.W., HUBER, M.L., McLINDEN, M.O. NIST Standard Reference Database 23: **Reference Fluid Thermodynamic and Transport Properties-REFPROP**, Version 8.0, National Institute of Standards and Technology, Standard Reference Data Program, Gaithersburg, 2007.
- LIMA, L. C. A. **Controle da alimentação elétrica para redução do tempo demandado por ensaios de desempenho de compressores e avaliação da influência da qualidade da energia elétrica nos resultados dos ensaios**. Florianópolis, 2010a. 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 validação de sistema neural para redução de tempo de ensaios de desempenho de compressores**. Florianópolis, 2010b. Dissertação (Mestrado em Metrologia Científica e Industrial) - Programa de Pós-graduação em Metrologia Científica e Industrial, Universidade Federal de Santa Catarina.
- MASON, R. L.; GUNST, R. F.; HESS, J. L. **Statistical design and analysis of experiments – with applications to engineering and science**. Wiley-Interscience, New Jersey, US, 2003.
- MATHWORKS. **Neural networks toolbox – user’s manual**. Versão 5, 2007.

MILANIC, S. et al. Incorporating prior knowledge into artificial neural networks – An industrial case study. **Neurocomputing**, v. 62, 2004. 21 p.

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

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

MORI, H.; ITOU, K.; UEMATSU, H.; TSUZUKI, S. An artificial neural-net based method for predicting power system voltage harmonics. **IEEE Transactions on Power Delivery**, v. 7, i. 1, Jan. 1992. 8 p.

MRUGALSKI, M.; WITCZAK, M.; KORBICZ, J. Confidence estimation of the multi-layer perceptron and its application in fault detection systems. **Engineering Applications of Artificial Intelligence**, v. 21, 2008.

NASSAR, S. M. **Tratamento de incerteza: sistemas especialistas probabilísticos**. Apostila da disciplina Sistemas Especialistas Probabilísticos do Programa de Pós-Graduação de Ciências da Computação, Universidade Federal de Santa Catarina, Junho de 2007.

NAVARRO-ESBRÍ, J. et al. A low data requirement models of a variable-speed vapour compression refrigeration system based on neural networks. **International Journal of Refrigeration**, v. 30, 2007. 8 p.

PAN, H.; LIU, L. Fuzzy Bayesian networks – a general formalism for representation, inference and learning with hybrid bayesian networks. **International Journal of Pattern Recognition and Artificial Intelligence**, v. 14, 2000. 23 p.

PAN, H.; McMICHAEL, D. Fuzzy causal probabilistic network – a new ideal and practical inference engine. **1<sup>st</sup> International Conference on Multisource-Multisensor Information Fusion**, Las Vegas, USA, 6-8 July 1998.

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.; FLESCH, C. A.; NASSAR, S. M.; FLESCH, R. C. C.; DE OLIVEIRA, M. A. Fuzzy-Bayesian network for refrigeration compressor performance prediction and test time reduction. **Expert Systems with Applications**. 2011. doi:10.1016/j.eswa.2011.09.107

PERETTI, C. de; SIANI, C.; CERRATO, M. A bootstrap neural network based heterogeneous panel unit root test: application to exchange rates. **Working Papers in Economics**, University of Glasgow, 2010.

PETROVIC, 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.

ROKACH, L. Taxonomy for characterizing ensemble methods in classification tasks: a review and annotated bibliography. **Computational Statistics & Data Analysis**, 2009.

RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. Second edition. Prentice Hall series in artificial intelligence, New Jersey, 2003. 1081 p.

SCUSSEL, J. N. **Propostas de ações para reduzir o tempo demandado por ensaio de desempenho de compressores herméticos**. 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.; SHARKEY, N. E. **How to Improve the Reliability of Artificial Neural Networks**. Technical Report CS-95-11, Department of Computer Science, University of Sheffield, UK, 1995.

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

SHARKEY, A.J.C.; SHARKEY, N.E.; CHANDROTH, G.O. Neural nets and diversity. **Neural Computing and Applications**, vol. 4, 1996. 10 p.

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.

STEINBACH, K. **Identificação do instante de entrada em condição 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.F.; SAIZ JABARDO J.M. **Refrigeração Industrial.** 2ª ed. Edgard Blücher Ltda, São Paulo, 2002. 371 p.

SYDENHAM, P. H. Relationship between measurement, knowledge and advancement. **Measurement**, v.34, 2003.

TIBIRIÇÁ, C. A. G. **Uma abordagem híbrida fuzzy-bayesiana para modelagem de incertezas.** Florianópolis, 2005. Dissertação (Mestrado em Ciência da Computação) - Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Santa Catarina.

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

TOUTENBURG, H. **Statistical analysis of designed experiments.** Springer Texts in Statistics, Second Edition, Springer-Verlag, New York, 2002.

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.

URDHWARESHE, H. **Six sigma for business excellence: Approach, tools and applications.** Pearson Education, 2010. 416 p.  
e-Book ISBN-10: 8131761657

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.

WINKLER, R. L.; CLEMEN, R. T. Multiple experts vs. multiple methods: Combining correlation assessments. **Decision Analysis**, vol. 1, no. 3, September 2004.

WINSTON, P. H. **Artificial intelligence.** 3<sup>rd</sup> edition. Addison-Wesley, 1992.

WU, B.; YU, J. A neural network ensemble model for on-line monitoring of process mean and variance shifts in correlated processes. **Expert Systems with Applications**. vol. 37, i. 6, p. 4058-4065, 2010.

YU, J. B.; XI, L. F. A. neural network ensemble-based model for on-line monitoring and diagnosis of out-of-control signals in multivariate manufacturing processes. **Expert Systems with Applications**. vol. 36, i. 1, p. 909-921, 2009.

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 8, 1965.

ZADEH, L. A. Probability measures of fuzzy events. **Journal of Mathematical Analysis and Applications**, v. 10, 1968.

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.



## APÊNDICE A – RESULTADOS DAS ANÁLISES ESTATÍSTICAS

Esse apêndice apresenta os resultados completos das análises estatísticas realizadas para avaliação das influências da incerteza de medição apresentadas nos estudos de caso do item 6.2: análise para modelo linear; análise de variâncias para médias; tabela de respostas para médias; gráficos para análise dos resíduos. Todas as análises foram realizadas com o software *Minitab* (MINITAB, 2010).

### *Estudo de Caso 1: Treinamento das redes neurais*

#### **Estimated Model Coefficients for Means**

Term	Coef	SE Coef	T	P
Constant	0,435287	0,002851	152,672	0,000
CAP ZG_P	0,005128	0,005702	0,899	0,386
CAP ZG_N	0,011460	0,005702	2,010	0,067
CAP LIN_PN	-0,067185	0,005702	-11,782	0,000
CAP LIN_NP	0,055847	0,005702	9,794	0,000
TC ZG_P	0,005477	0,005702	0,961	0,356
TC ZG_N	0,000027	0,005702	0,005	0,996
TC LIN_PN	0,005381	0,005702	0,944	0,364
TC LIN_NP	-0,012112	0,005702	-2,124	0,055
PSUC ZG_P	0,011247	0,005702	1,972	0,072
PSUC ZG_N	-0,003240	0,005702	-0,568	0,580
PSUC LIN_PN	-0,005631	0,005702	-0,988	0,343
PSUC LIN_NP	-0,004964	0,005702	-0,870	0,401

S = 0,01426    R-Sq = 94,4%    R-Sq(adj) = 88,8%

#### Analysis of Variance for Means

Source	DF	Seq SS	Adj SS	Adj MS	F	P
CAP	4	0,039089	0,039089	0,009772	48,09	0,000
TC	4	0,001036	0,001036	0,000259	1,27	0,333
PSUC	4	0,001000	0,001000	0,000250	1,23	0,349
Residual						
Error	12	0,002439	0,002439	0,000203		
Total	24	0,043564				

#### Unusual Observations for Means

Observation	Means	Fit	SE Fit	Residual	St Resid
19	0,501	0,476	0,010	0,026	2,59 R

R denotes an observation with a large standardized residual.

## Response Table for Means

Level	CAP	TC	PSUC
ZG_P	0,4404	0,4408	0,4465
ZG_N	0,4467	0,4353	0,4320
LIN_PN	0,3681	0,4407	0,4297
LIN_NP	0,4911	0,4232	0,4303
SI	0,4300	0,4365	0,4379
Delta	0,1230	0,0176	0,0169
Rank	1	2	3

Para avaliar a adequabilidade do modelo gerado são apresentados os gráficos das figuras 97 a 100. Pode-se notar que o comportamento dos resíduos indica uma boa aderência ao modelo gerado e que os dados utilizados para a geração do mesmo têm grau de normalidade adequado para aplicação das ferramentas de análise.




Figura 97 – Gráfico de probabilidade normal (influência no treinamento)




Figura 98 – Gráfico dos resíduos versus valores ajustados (influência no treinamento)






Figura 99 – Histograma dos resíduos (influência no treinamento)




Figura 100 – Gráfico dos resíduos versus a ordem de observação (influência no treinamento)

Testes não paramétricos para comparação dos resultados referentes às figuras 73 e 74.

#### Kruskal-Wallis Test

	N	Median	Ave Rank	Z
Original	50	0,09789	620,1	-0,58
SI Capacidade	250	0,16134	649,9	-0,03
SI Temperatura	250	0,18291	658,1	0,36
SI Pressão	250	0,16898	652,3	0,09
LIN_PN Capacidade	250	0,15284	636,9	-0,64
LIN_NP Capacidade	250	0,17594	661,3	0,51
Overall	1300		650,5	

H = 0,97 DF = 5 P = 0,965

H = 0,97 DF = 5 P = 0,965 (adjusted for ties)

**Mood median Test**

Chi-Square = 1,27

DF = 5

P = 0,938

C2	N<=	N>	Median	Q3-Q1	Individual 95,0% CIs
Original	27	23	0,098	0,799	(-----*-----+-----+-----)
SI Capacidade	127	123	0,161	0,941	(---*-----)
SI Temperatura	123	127	0,183	0,908	(---*-----)
SI Pressão	124	126	0,169	0,919	(---*-----)
LIN_PN Capacidade	131	119	0,153	0,857	(---*-----)
LIN_NP Capacidade	121	129	0,176	1,031	(---*-----)

Overall median = 0,163

## ***Estudo de Caso 2: Uso das redes neurais***

### Estimated Model Coefficients for Means

Term	Coef	SE Coef	T	P
Constant	0,342909	0,001830	187,360	0,000
CAP ZG_P	0,017251	0,003660	4,713	0,001
CAP ZG_N	-0,022273	0,003660	-6,085	0,000
CAP LIN_PN	0,025581	0,003660	6,988	0,000
CAP LIN_NP	-0,019473	0,003660	-5,320	0,000
TC ZG_P	-0,059324	0,003660	-16,207	0,000
TC ZG_N	0,051569	0,003660	14,088	0,000
TC LIN_PN	-0,037888	0,003660	-10,351	0,000
TC LIN_NP	0,035240	0,003660	9,627	0,000
PSUC ZG_P	0,029852	0,003660	8,155	0,000
PSUC ZG_N	-0,015275	0,003660	-4,173	0,001
PSUC LIN_PN	0,009811	0,003660	2,680	0,020
PSUC LIN_NP	-0,013645	0,003660	-3,728	0,003

S = 0,009151    R-Sq = 98,4%    R-Sq(adj) = 96,8%

### Analysis of Variance for Means

Source	DF	Seq SS	Adj SS	Adj MS	F	P
CAP	4	0,009142	0,009142	0,002286	27,29	0,000
TC	4	0,044822	0,044822	0,011205	133,81	0,000
PSUC	4	0,007612	0,007612	0,001903	22,72	0,000
Residual	12	0,001005	0,001005	0,000084		
Error						
Total		24	0,062581			

### Response Table for Means

Level	CAP	TC	PSUC
1	0,3602	0,2836	0,3728
2	0,3206	0,3945	0,3276
3	0,3685	0,3050	0,3527
4	0,3234	0,3781	0,3293
5	0,3418	0,3533	0,3322
Delta	0,0479	0,1109	0,0451
Rank	2	1	3

Para avaliar a adequabilidade do modelo gerado são apresentados os gráficos das figuras 101 a 104. Pode-se notar que o comporta-

mento dos resíduos indica uma boa aderência ao modelo gerado e que os dados utilizados para a geração do mesmo têm grau de normalidade adequado para aplicação das ferramentas de análise.




Figura 101 – Gráfico de probabilidade normal (influência no uso)




Figura 102 – Gráfico dos resíduos versus valores ajustados (influência no uso)




Figura 103 – Histograma dos resíduos (influência no uso)




Figura 104 – Gráfico dos resíduos versus a ordem de observação (influência no uso)

Testes não paramétricos para comparação dos resultados referentes às figuras 82 e 83.

Kruskal-Wallis Test

	N	Median	Ave Rank	Z
Original	50	0,09789	1052,2	0,32
ZG_P Capacidade	250	0,09374	1031,9	0,18
ZG_N Capacidade	250	0,09825	1016,4	-0,26
LIN_PN Capacidade	250	0,08974	1038,8	0,38
LIN_NP Capacidade	250	0,09654	1015,7	-0,28
ZG_P Temperatura	250	0,09374	989,1	-1,04
ZG_N Temperatura	250	0,09833	1061,8	1,04
LIN_PN Temperatura	250	0,07595	990,9	-0,99
LIN_NP Temperatura	250	0,11594	1054,0	0,81
Overall	2050		1025,5	

H = 3,71 DF = 8 P = 0,883

H = 3,71 DF = 8 P = 0,883 (adjusted for ties)



### Estudo de Caso 3: Uso da rede fuzzy-bayesiana

Abaixo é apresentada a análise de variância (ANOVA) para a comparação das diferenças entre a capacidade de refrigeração no instante de entrada em regime inferido pela rede *fuzzy-bayesiana* e o valor da capacidade final do ensaio.

Source	DF	SS	MS	F	P
Factor	4	0,010	0,002	0,00	1,000
Error	320	171,039	0,534		
Total	324	171,049			

S = 0,7311    R-Sq = 0,01%    R-Sq(adj) = 0,00%

Level	N	Mean	StDev
ZG_P	65	0,4868	0,7306
ZG_N	65	0,4716	0,7303
LIN_PN	65	0,4791	0,7321
LIN_NP	65	0,4750	0,7319
SI	65	0,4831	0,7305

Individual 95% CIs For Mean Based on Pooled StDev

Pooled StDev = 0,7311

### *Estudo de Caso 4: Uso das redes neurais de prognóstico*

#### *Estimated Model Coefficients for Means*

Term	Coef	SE Coef	T	P
Constant	-0,256752	0,000528	-486,237	0,000
CAP ZG_P	0,791008	0,001056	749,005	0,000
CAP ZG_N	-0,788232	0,001056	-746,376	0,000
CAP LIN_PN	0,744923	0,001056	705,367	0,000
CAP LIN_NP	-0,734712	0,001056	-695,698	0,000
TC ZG_P	0,000649	0,001056	0,614	0,551
TC ZG_N	-0,000414	0,001056	-0,392	0,702
TC LIN_PN	0,000649	0,001056	0,614	0,551
TC LIN_NP	-0,000414	0,001056	-0,392	0,702
PSUC ZG_P	-0,000321	0,001056	-0,304	0,766
PSUC ZG_N	-0,000569	0,001056	-0,539	0,600
PSUC LIN_PN	0,001822	0,001056	1,725	0,110
PSUC LIN_NP	-0,001550	0,001056	-1,468	0,168

S = 0,002640    R-Sq = 100,0%    R-Sq(adj) = 100,0%

#### *Analysis of Variance for Means*

Source	DF	Seq SS	Adj SS	Adj MS	F	P
CAP	4	11,7094	11,7094	2,92735	419954,73	0,000
TC	4	0,0000	0,0000	0,00000	0,25	0,903
PSUC	4	0,0000	0,0000	0,00001	1,17	0,372
Residual	12	0,0001	0,0001	0,00001		
Error						

Total    24    11,7095

#### *Response Table for Means*

Level	CAP	TC	PSUC
1	0,5343	-0,2561	-0,2571
2	-1,0450	-0,2572	-0,2573
3	0,4882	-0,2561	-0,2549
4	-0,9915	-0,2572	-0,2583
5	-0,2697	-0,2572	-0,2561
Delta	1,5792	0,0011	0,0034
Rank	1	3	2



## **RELAÇÃO ENTRE ERRO DE PROGNÓSTICO E CAPACIDADE DE REFRIGERAÇÃO**

Resultados da análise de regressão linear para os ensaios sem aceleração de transitório.

The regression equation is  
erro prog = 0,952 - 0,148 C13

202 cases used, 7 cases contain missing values

Termo	Coef	SE Coef	T	P
Constant	0,9517	0,7029	1,35	0,177
C13	-0,1476	0,1412	-1,05	0,297

S = 0,733070    R-Sq = 0,5%    R-Sq(adj) = 0,0%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	0,5872	0,5872	1,09	0,297
Residual Error	200	107,4782	0,5374		
Total	201	108,0655			

Resultados da análise de regressão linear para os ensaios com aceleração de transitório.

The regression equation is  
C9 = 4,27 - 0,905 C11

Predictor	Coef	SE Coef	T	P
Constant	4,266	1,887	2,26	0,027
C11	-0,9047	0,3772	-2,40	0,019

S = 0,579053    R-Sq = 8,4%    R-Sq(adj) = 6,9%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	1,9294	1,9294	5,75	0,019
Residual Error	63	21,1241	0,3353		
Total	64	23,0535			



## APÊNDICE B – RESULTADOS DOS EXPERIMENTOS TAGUCHI

A seguir são apresentados os resultados de cada experimento definido para avaliação da influência da incerteza de medição no treinamento das redes neurais para inferência do regime permanente da capacidade de refrigeração.

Legenda:

Linha cheia – erro da solução de redes sem incerteza;  
 Pontos – erro da solução das redes do experimento;  
 Linha tracejada – erro médio da solução de redes sem incerteza;  
 Linha pontilhada – erro médio da solução de redes do experimento.




Figura 105 – Resultado do experimento Taguchi 1

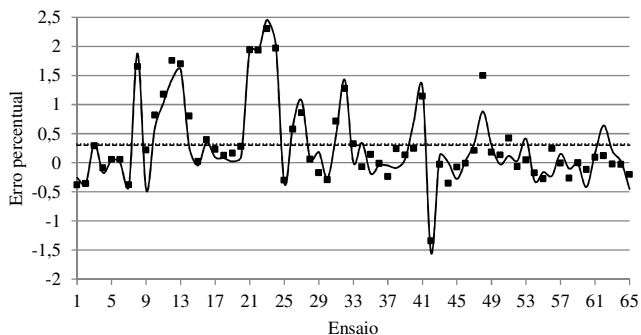


Figura 106 – Resultado do experimento Taguchi 2




Figura 107 – Resultado do experimento Taguchi 3




Figura 108 – Resultado do experimento Taguchi 4




Figura 109 – Resultado do experimento Taguchi 5




Figura 110 – Resultado do experimento Taguchi 6




Figura 111 – Resultado do experimento Taguchi 7




Figura 112 – Resultado do experimento Taguchi 8




Figura 113 – Resultado do experimento Taguchi 9

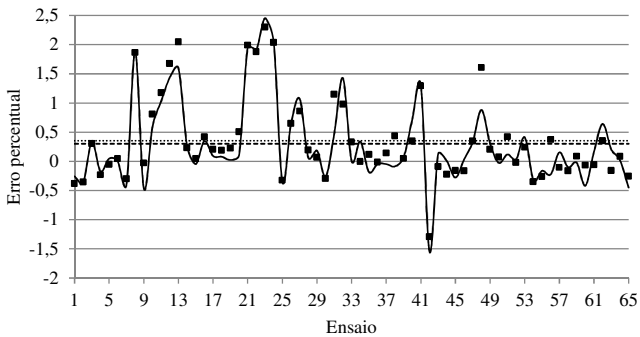


Figura 114 – Resultado do experimento Taguchi 10




Figura 115 – Resultado do experimento Taguchi 11




Figura 116 – Resultado do experimento Taguchi 12




Figura 117 – Resultado do experimento Taguchi 13




Figura 118 – Resultado do experimento Taguchi 14

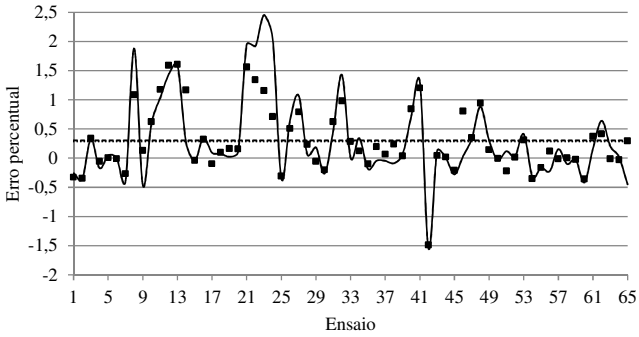


Figura 119 – Resultado do experimento Taguchi 15




Figura 120 – Resultado do experimento Taguchi 16




Figura 121 – Resultado do experimento Taguchi 17






Figura 122 – Resultado do experimento Taguchi 18




Figura 123 – Resultado do experimento Taguchi 19




Figura 124 – Resultado do experimento Taguchi 20




Figura 125 – Resultado do experimento Taguchi 21




Figura 126 – Resultado do experimento Taguchi 22




Figura 127 – Resultado do experimento Taguchi 23




Figura 128 – Resultado do experimento Taguchi 24




Figura 129 – Resultado do experimento Taguchi 25

