

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM METROLOGIA
CIENTÍFICA E INDUSTRIAL**

Vladimir Rodrigues de Lima

**DESENVOLVIMENTO E AVALIAÇÃO DE SISTEMA NEURAL
PARA REDUÇÃO DE TEMPO DE ENSAIO DE DESEMPENHO
DE COMPRESSORES**

Florianópolis

2010

Vladimir Rodrigues de Lima

**DESENVOLVIMENTO E AVALIAÇÃO DE SISTEMA NEURAL
PARA REDUÇÃO DE TEMPO DE ENSAIOS DE DESEMPENHO
DE COMPRESSORES**

Dissertação submetida ao Programa de Pós-Graduação em Metrologia Científica e Industrial da Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Metrologia
Orientador: Prof. Carlos Alberto Flesch, Dr. Eng.

Florianópolis

2010

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

L732d Lima, Vladimir Rodrigues de
Desenvolvimento e avaliação de sistema neural para redução
de tempo de ensaio de desempenho de compressores [dissertação]
/ Vladimir Rodrigues de Lima ; orientador, Carlos Alberto
Flesch. - Florianópolis, SC, 2010.
173 p.: il., grafs., tabs.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico. Programa de Pós-Graduação em
Metrologia Científica e Industrial.

Inclui referências

1. Metrologia científica. 2. Compressores. 3. Refrigeração.
4. Redes neurais (Computação). I. Flesch, Carlos Alberto. II.
Universidade Federal de Santa Catarina. Programa de Pós-
Graduação em Metrologia Científica e Industrial. III. Título.

CDU 537.7

Vladimir Rodrigues de Lima

**DESENVOLVIMENTO E AVALIAÇÃO DE SISTEMA NEURAL
PARA REDUÇÃO DE TEMPO DE ENSAIOS DE DESEMPENHO
DE COMPRESSORES**

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Metrologia” e aprovada em sua forma final pelo Programa de Pós-Graduação em Metrologia Científica e Industrial

Florianópolis, 16 de Setembro de 2010.

Prof. Carlos Alberto Flesch, Dr. Eng.
Orientador

Prof. Armando Albertazzi Gonçalves Junior, Dr. Eng.
Coordenador do Curso

Banca Examinadora:

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

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

Profª. Sílvia Modesto Nassar, Dra.
Universidade Federal de Santa Catarina

Eng. Marco Aurélio de Oliveira, M. Sc.
Whirlpool S.A. / Embraco

Aos meus pais, Carlos e Fátima,
à minha irmã Jeane
e à minha esposa Lúnia,
com carinho.

AGRADECIMENTOS

A Deus pelo poder da criação e à lei do amor.

Aos meus pais, Carlos e Fátima, pela educação que me deram e pelo amor incondicional.

À minha irmã, Jeane, sempre presente em todas minhas realizações, pelo amor e carinho de sempre.

À minha esposa, Lúnia, minha amada, minha companheira de todas as batalhas, pelo amor, carinho, compreensão e apoio.

Ao professor Carlos Alberto Flesch, pela orientação neste trabalho, pela presteza, pela dedicação, pela presença e profissionalismo exemplar.

Aos professores do Programa de Pós-Graduação em Metrologia Científica e Industrial, Albertazzi, Cavaco, Donatelli, Flesch e Schneider, pela dedicação e conhecimento compartilhado.

Aos professores de outros departamentos, Mauro Roisenberg, Saulo Güths e Arnaldo Perin, pela dedicação e conhecimento compartilhado.

Aos membros da banca, Arcanjo, Cavaco, Sílvia e Marco Aurélio, pela disponibilidade e dedicação em avaliar e contribuir no fechamento deste trabalho.

Aos amigos do mestrado pelos bons momentos compartilhados, pelas discussões técnicas, pelas madrugadas a fora nos trabalhos do professor Schneider, pelas piadas, churrascos, viagens, alegria e companheirismo de sempre.

Especialmente ao amigo Kleber Steinbach, pela orientação de sempre, pela paciência, pelos devaneios e por todo o apoio técnico essencial no desenvolvimento deste trabalho.

À Rosana, pelo apoio, profissionalismo, presteza e alegria de sempre.

Aos funcionários da Embraco, Marco Aurélio, Maikon, João Rosseto e Idalécio, pela oportunidade e todo apoio prestado durante a realização deste trabalho.

À UFSC e ao Labmetro pela oportunidade de realização do mestrado.

À Fundação Certi e seus colaboradores, pela oportunidade e apoio prestado.

Por fim, a todos que direta ou indiretamente contribuíram na realização deste trabalho.

“O Amor é o meio, a verdade é o fim.
Se usarmos o meio, cedo ou tarde chegaremos ao
fim, à verdade, a Deus.”

(Mahatma Gandhi)

“Quem sabe concentrar-se numa coisa e insistir
nela como único objetivo, obtém, ao cabo, a capa-
cidade de fazer qualquer coisa.”

(Mahatma Gandhi)

“Guardai-vos de fazer vossas boas obras diante
dos homens, para serdes vistos por eles. Do con-
trário, não tereis recompensa junto de vosso Pai
que está no céu.”

(Mateus, 6:1)

"Espero que eles estejam conscientes que ciência
sem consciência é a ruína da alma. Não vamos
pensar que ciência é uma beleza, ela sozinha".
"A ciência deve ser universal, sem dúvida. Porém,
nós não devemos acreditar incondicionalmente
nisto."

(César Lattes)

SUMÁRIO

LISTA DE FIGURAS	8
LISTA DE TABELAS	14
LISTA DE ABREVIATURAS E SIGLAS	16
RESUMO	18
ABSTRACT	20
1. INTRODUÇÃO	22
1.1. CONTEXTUALIZAÇÃO	22
1.2. OBJETIVOS DA DISSERTAÇÃO	23
1.3. ESTRUTURA DA DISSERTAÇÃO	23
2. ENSAIO DE DESEMPENHO DE COMPRESSORES HERMÉTICOS	26
2.1. GRANDEZAS TERMODINÂMICAS	27
2.2. CONCEITOS DE REFRIGERAÇÃO	28
2.3. ENSAIO DE COMPRESSORES	32
2.3.1. Definições das grandezas do ensaio	33
2.3.2. Procedimentos gerais	34
2.3.2.1. Método C – Calorímetro a seco	34
2.3.2.2. Método F – medidor de fluxo de massa na fase líquida	37
2.3.3. Requisitos gerais da Norma ISO 917	38
2.4. BANCADA PARA ENSAIO DE DESEMPENHO DE COMPRESSORES HERMÉTICOS	41
3. REDES NEURAIS ARTIFICIAIS	46
3.1. CARACTERIZAÇÃO	47
3.1.1. Visão geral	47
3.1.2. Fundamentos	48
3.1.3. Treinamento	53
3.1.4. Formas de implementação	55
3.2. APLICAÇÕES DE REDES NEURAIS A ENSAIOS DE DESEMPENHO	56
4. ESTRUTURAÇÃO DO SISTEMA NEURAL PARA INFERÊNCIA DE VALOR FINAL DE ENSAIO E ENTRADA EM REGIME	58
4.1. CONCEPÇÃO GERAL DO SISTEMA	58
4.2. DEFINIÇÃO DAS VARIÁVEIS DE ENTRADA E SAÍDA DAS REDES NEURAIS	66
4.2.1. Aspectos gerais	66
4.2.2. Pré-processamento das variáveis de entrada	67

4.2.2.1.	<i>Eliminação de variações abruptas indesejáveis.....</i>	68
4.2.2.2.	<i>Equalização das variáveis de entrada</i>	68
4.2.2.3.	<i>Inserção de atrasos e derivadas dos valores de atrasos</i>	70
4.2.2.4.	<i>Limitação do intervalo de ensaio</i>	70
4.2.2.5.	<i>Normalização dos dados de entrada da rede neural....</i>	73
4.2.3.	<i>Rede neural para detecção do instante de entrada em regime permanente.....</i>	76
4.2.3.1.	<i>Variáveis de entrada.....</i>	76
4.2.3.2.	<i>Variáveis de saída.....</i>	80
4.2.4.	<i>Rede neural para inferência do valor final de ensaio ...</i>	82
4.2.4.1.	<i>Variáveis de entrada.....</i>	82
4.2.4.2.	<i>Variáveis de saída.....</i>	84
4.3.	ARQUITETURA DAS REDES NEURAIS.....	86
4.4.	PARÂMETROS DAS REDES.....	88
4.5.	FORMAÇÃO DO UNIVERSO DE DADOS PARA TREINAMENTO DAS REDES	94
4.6.	CONJUNTO DE TREINAMENTO E VALIDAÇÃO DAS REDES NEURAIS	95
5.	DESENVOLVIMENTO DO SISTEMA NEURAL.....	100
5.1.	DESENVOLVIMENTO DAS REDES NEURAIS NO MATLAB.....	100
5.2.	PROGRAMAÇÃO DO SISTEMA NEURAL EM LABVIEW.....	113
6.	ANÁLISE DOS RESULTADOS	118
6.1.	RESULTADOS DO MÓDULO NEURAL CAPACIDADE	119
6.2.	RESULTADOS DO MÓDULO NEURAL CONSUMO	124
6.3.	RESULTADOS DO MÓDULO NEURAL COP	127
6.4.	COP OBTIDO A PARTIR DOS MÓDULOS NEURAIS DE CAPACIDADE E CONSUMO .	131
6.5.	RESULTADOS DO MÓDULO NEURAL DA TEMPERATURA DO CORPO	136
6.6.	MEDIÇÕES NA ENTRADA EM REGIME DA TEMPERATURA DO CORPO	138
6.7.	MEDIÇÕES NA ENTRADA EM REGIME DA TEMPERATURA DO CORPO + 10 MIN.	144
6.8.	DESEMPENHO OPERACIONAL DA REDE.....	150
7.	CONCLUSÕES E PROPOSIÇÕES PARA TRABALHOS FUTUROS.....	154
7.1.	CONCLUSÕES	154
7.2.	OPORTUNIDADES FUTURAS	157
	REFERÊNCIAS.....	160

LISTA DE FIGURAS

Figura 1 – Proposta da técnica neural.	23
Figura 2 – Ciclo de refrigeração por compressão de vapor.....	29
Figura 3 – Compressor recíproco. (a) Curso de admissão. (b) Curso de descarga (Welch, 2000).....	31
Figura 4 – Compressor: diagrama P x V (Welch, 2000).	31
Figura 5 – Compressor hermético de deslocamento positivo (HENKLEIN, 2006).	32
Figura 6 – Diagrama do circuito (Método C) (ISO 917, 1989).	35
Figura 7 – Diagrama do circuito (Método F) (ISO 917, 1989)	37
Figura 8 – Instante de entrada em regime conforme norma ISO917.....	40
Figura 9 – Bancada de ensaio de desempenho de compressores (esquema geral)	42
Figura 10 – Arquitetura do sistema de automação da bancada de desempenho de compressores (PETROVCIC, 2007).....	43
Figura 11 – Atividades em IA	46
Figura 12 – Modelo geral de neurônio (HAYKIN, 2001).	49
Figura 13 – Diferentes tipos de função de ativação.	50
Figura 14 – Rede <i>feedforward</i> de camada única.	51
Figura 15 – Rede <i>feedforward</i> multicamada.	52
Figura 16 – Rede recorrente com neurônios escondidos.....	53
Figura 17 – Sistema neural e seus subsistemas	59
Figura 18 – Resultados gerados pelo sistema neural.....	61
Figura 19 – Determinação do valor medido e corrigido (VMC) e da faixa de comparação da inferência do valor final de ensaio.....	63

Figura 20 – Etapas de pré-processamento das variáveis de entrada.....	67
Figura 21 – Variação indesejável da variável capacidade durante ensaio de desempenho de compressor modelo EGU80CLC.....	68
Figura 22 – Comparativo de normalização com e sem equalização.	69
Figura 23 – Definição do intervalo de ensaio da rede de regime.	72
Figura 24 – Definição do intervalo de ensaio da rede de inferência.	73
Figura 25 – Valores discrepantes nos primeiros minutos de ensaio.....	75
Figura 26 – Dados normalizados com e sem saturação da primeira entrada da rede de regime CAP para um ensaio.....	76
Figura 27 – Tratamento das variáveis de entrada da rede de regime de capacidade.....	78
Figura 28 – Registro da temperatura do corpo do compressor durante ensaio de desempenho.....	79
Figura 29 – (a) Passagem do regime transitório para o regime permanente. (b) Saída desejada da rede de regime.	81
Figura 30 – (a) Detecção da entrada em regime do consumo pela rede neural. (b) Detecção da entrada em regime da capacidade pela rede neural.	91
Figura 31 – Curvas de aprendizado: (a) Regime CAP; (b) Regime CONS; (c) Regime COP; (d) Regime Tcorpo; (e) Inferência CAP; (f) Inferência CONS; (g) Inferência COP.....	93
Figura 32 – Comportamento anômalo: (a) Pressão de sucção. (b) Capacidade. (c) Consumo. (d) COP.....	96
Figura 33 – Comportamento padrão: (a) Pressão de sucção. (b) Capacidade. (c) Consumo. (d) COP.....	98
Figura 34 – Estrutura de <i>cell array</i> utilizada para formação dos vetores de entrada e saída das redes (STEINBACH, 2008).	101

Figura 35 – Erro médio de FP e FN em função do patamar decisão: (a) Rede regime CAP; (b) Rede regime CONS; (c) Rede regime COP. (d) Rede regime Tcorpo.....	104
Figura 36 – Saída rede de regime: (a) CAP. (b) CONS. (c) COP. (d) Tcorpo.	106
Figura 37 – Oscilação na saída da rede de regime do COP.....	107
Figura 38 – Histograma do erro VMC (%) na detecção do regime: (a) CAP. (b) CONS. (c) COP.....	109
Figura 39 – Erro percentual da inferência da CAP: (a) Início da janela de simulação. (b) Fim da janela de simulação.....	110
Figura 40 – Erro percentual da inferência do CONS: (a) Início da janela de simulação. (b) Fim da janela de simulação.....	111
Figura 41 – Erro percentual da inferência do COP: (a) Início da janela de simulação. (b) Fim da janela de simulação.....	112
Figura 42 – Blocodiagrama do sistema neural programado.	113
Figura 43 – Rede Neural Calorímetro.vi.....	115
Figura 44 – Rede Capacidade.vi.....	115
Figura 45 – Rede Consumo.vi.....	115
Figura 46 – Rede COP.vi.....	116
Figura 47 – Rede Temperatura.vi.....	116
Figura 48 – Gera Relatorio.vi.....	116
Figura 49 – Erro percentual inferência CAP: (a) Histograma de erro. (b) Erro de Inferência % x ensaio.	120
Figura 50 – Erro percentual VMC CAP: (a) Histograma de erro. (b) Erro do VMC % x ensaio.	121
Figura 51 – Detecção prematura de entrada em regime da capacidade	122

Figura 52 – Ganho percentual de tempo para a inferência e VCM da CAP: (a) Histograma. (b) Ganho de tempo % x ensaio.	123
Figura 53 – Erro percentual inferência CONS: (a) Histograma de erro. (b) Erro de inferência % x ensaio.....	125
Figura 54 – Erro percentual do VMC do CONS: (a) Histograma de erro. (b) Erro do VCM % x ensaio.	126
Figura 55 – Ganho percentual de tempo para a inferência e VCM do CONS: (a) Histograma. (b) Ganho de tempo % x ensaio.	127
Figura 56 – Erro percentual inferência COP: (a) Histograma de erro. (b) Erro do VCM % x ensaio.....	128
Figura 57 – Erro percentual do VMC do COP: (a) Histograma de erro. (b) Erro do VCM % x ensaio.	129
Figura 58 – Registro da variável COP para o ensaio 6.	130
Figura 59 – Ganho percentual de tempo para a inferência e VCM do COP: (a) Histograma. (b) Ganho de tempo % x ensaio.	131
Figura 60 – Erro percentual do COP obtido a partir das inferências da CAP e do CONS: (a) Histograma de erro. (b) Erro do COP % x ensaio.	132
Figura 61 – Erro percentual do COP obtido a partir do VMC da CAP e do CONS: (a) Histograma de erro. (b) Erro do COP % x ensaio.....	134
Figura 62 – Ganho percentual de tempo para o COP obtido a partir da inferência ou do VMC da capacidade e do consumo: (a) Histograma do ganho de tempo. (b) Ganho de tempo % x Ensaio.....	135
Figura 63 – Erro da rede de regime da temperatura do corpo: (a) Histograma de erros. (b) Erro da rede x Ensaio.	137
Figura 64 – Diagrama de caixa dos erros de regime da rede de temperatura do corpo.	138

Figura 65 – Erro percentual da média de 5 min da CAP no regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.	139
Figura 66 – Desvio-padrão percentual da CAP em 5 min no regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.	140
Figura 67 – Erro percentual da média de 5 min do CONS no regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.	141
Figura 68 – Desvio-padrão percentual do CONS em 5 min no regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.	142
Figura 69 – Erro percentual da média de 5 min do COP no regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.	143
Figura 70 – Desvio-padrão percentual do COP em 5 min no regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.	144
Figura 71 – Erro percentual da média de 10 min da CAP após regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.	145
Figura 72 – Desvio-padrão percentual da CAP em 10 min após regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.	146
Figura 73 – Erro percentual da média de 10 min do CONS após regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.	147
Figura 74 – Desvio-padrão percentual do CONS em 10 min após regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.	148
Figura 75 – Erro percentual da média de 10 min do COP após regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.	149
Figura 76 – Desvio-padrão percentual do COP em 10 min após regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.	150

LISTA DE TABELAS

Tabela 1 – Entradas e saídas do sistema neural.....	65
Tabela 2 – Entradas da rede de regime da capacidade.	77
Tabela 3 – Entradas da rede de regime da temperatura do corpo.....	79
Tabela 4 – Entradas das redes de inferência do valor final.	83
Tabela 5 – Valores de saída para treinamento das redes de inferência do valor final.	85
Tabela 6 – Estrutura final das redes neurais.....	87
Tabela 7 – Parâmetros de treinamento das redes.....	88
Tabela 8 – Condições de contorno dos ensaios para treinamento das redes	94
Tabela 9 – Distribuição dos ensaios nos conjuntos de treinamento, validação e teste.	97
Tabela 10 – Influência dos erros de inferência da CAP e CONS no erro do COP.....	133
Tabela 11 – Influência dos erros do VMC da CAP e CONS no erro do COP.....	134
Tabela 12 – Resultados dos módulos neurais.....	152
Tabela 13 – Resultados das medições no regime da Tcorpo.....	153

LISTA DE ABREVIATURAS E SIGLAS

RNA	Redes Neurais Artificiais
IA	Inteligência Artificial
Tcorpo	Temperatura do corpo do compressor
Psuc	Pressão de sucção do compressor
MLP	Perceptron Multicamadas (<i>Multi Layer Perceptron</i>)
COP	<i>Coefficient of Performance</i>
CAP	Capacidade de refrigeração
CONS	Consumo do compressor
VMC	Valor medido e corrigido
FP	Falso positivo
FN	Falso negativo
Tesp	Tempo de espera mínimo para confirmar saída da rede de regime
PC	<i>Personal Computer</i>
PXI	<i>PCI Extension for Instrumentation</i>
SCXI	<i>Signal Conditioning Extension for Instrumentation</i>
VI	<i>Virtual Instrument</i>
IHM	Interface Homem-Máquina

RESUMO

Ensaio de compressores constitui uma ferramenta essencial no desenvolvimento de sistemas de refrigeração mais eficientes. Um dos ensaios mais representativos é o de desempenho. Tais ensaios são geralmente realizados em bancadas que apresentam incertezas de medição muito altas quando comparadas aos ganhos incrementais que devem ser analisados. Isso implica uso de técnicas estatísticas e faz com que ensaios tenham que ser replicados. Associando-se a esse fato há um longo tempo demandado por cada ensaio, o que torna evidente a dificuldade e o alto custo associado a tal análise.

A demora do ensaio é devida principalmente ao longo tempo que o compressor e a bancada levam para entrar em condições de regime permanente – condição nominal de ensaio. Trabalhos recentes mostraram que é viável reduzir o tempo de ensaio empregando redes neurais artificiais (RNA) para analisar o compressor ainda em condições transitórias.

Esta dissertação visa contribuir com a validação da técnica de redução de tempos demandados por ensaios de desempenho de compressores de refrigeração através do uso de redes neurais artificiais (RNA). Nesse contexto, foi avaliada a aplicação da técnica em diferentes compressores sob diferentes condições operacionais. A técnica neural avaliada analisa a evolução dos valores das variáveis de ensaio durante o período transitório e tira conclusões quanto ao instante de entrada em regime de cada uma das variáveis de interesse: consumo; capacidade; COP. Além disso, a técnica neural realiza a inferência do valor final de ensaio das variáveis de interesse logo após a entrada em regime permanente dessas. Um sistema desenvolvido usando tal técnica foi implantado em bancada de ensaios de uma empresa.

Os resultados obtidos mostram que a aplicação de RNA pode reduzir drasticamente o tempo demandado por tais ensaios.

ABSTRACT

The experimental test methods of refrigerant compressors are an essential tool, given the importance of such compressors in the development of more efficient systems. Generally, these methods can be applied in quality control tests, in research and development tests, or in tests to collect data for datasheets. The refrigerant compressor performance test is one of the most representatives. Such tests are made in benches that present very high measurement uncertainties when compared to the incremental gains to be analyzed. It makes tests to be replicated. In addition each test takes a long time to be realized, which makes clear the difficulty and high cost associated with such analysis.

This long time is due to difficulties of control and the delay of the compressor and the bench to get into steady state conditions – nominal test conditions. Recent works developed in Labmetro (Laboratório de Metrologia e Automação da UFSC) have showed that it is possible to reduce the testing time using artificial neural networks which analyzes the compressor during the transient period.

This dissertation aims to contribute to the validation of the technique of reduction of time demanded by performance testing of refrigerant compressors through the use of artificial neural networks. This technique was applied for different compressors and different operating conditions. The developed system using this technique was implanted in a test bench of a company.

The neural technique to be validated analyzes the evolution of the test variables during the transient period and draws conclusions about the moment in which the main variables (input power; refrigerating capacity; coefficient of performance) reach the steady state condition. Furthermore, the neural technique makes the inference of the test final value of the main variables immediately after these variables have reached the steady state condition.

The results confirm the applicability of artificial neural networks in refrigerant compressor performance test benches.

1. INTRODUÇÃO

1.1. Contextualização

A evolução tecnológica, a globalização e movimentos ecológicos têm imposto crescentes exigências aos compressores herméticos. Como o mercado fica mais competitivo, prospera quem possui a solução que melhor atende ao consumidor. Para se chegar a uma posição de liderança no mercado é preciso inovar e evoluir, e ainda fazê-lo mais rápido que os concorrentes.

Grande parte do desenvolvimento de compressores de refrigeração faz uso de ensaios de desempenho para analisar e comprovar ganhos incrementais. Também o controle de qualidade e o levantamento de curvas para catálogos exigem tais ensaios. No caso da empresa que serviu de estudo de caso neste trabalho – líder no mercado mundial –, aproximadamente 70% dos ensaios realizados dizem respeito ao desenvolvimento. Acontece que tais ensaios são realizados em bancadas que apresentam incertezas de medição muito altas quando comparadas aos ganhos incrementais que devem ser analisados. Isso faz com que ensaios tenham que ser replicados. Associando-se a esse fato há um longo tempo demandado por cada ensaio – atualmente em média 4 horas e meia – o que torna evidente a dificuldade e o alto custo associado a tal análise.

A demora do ensaio é devida a dificuldades de controle e ao longo tempo que o compressor e a bancada levam para entrar em condições de regime permanente – condição nominal de ensaio. Trabalhos recentes desenvolvidos no Labmetro (HENKLEIN, 2006; STEINBACH, 2008) mostraram que é viável reduzir o tempo de ensaio empregando redes neurais para analisar o compressor em condições transitórias, portanto sem esperar que o mesmo entre em regime permanente. Nesse contexto, o sistema neural torna-se fundamental para redução significativa do tempo demandado por ensaios, possibilitando redução direta de custos, além de viabilizar que se realmente mais rapidamente os setores de produção e de desenvolvimento da empresa. No entanto havia ainda necessidade de validar os resultados alcançados para diferentes compressores e para diferentes condições operacionais. Além disso, faltava desenvolver um sistema neural que fosse incorporado aos painéis de ensaio e que pudesse ser usado tanto para o sistema neural aprender com ensaios corriqueiros que ali fossem realizados, como para realização de ensaios usando as redes neurais.

1.2. Objetivos da dissertação

Os objetivos desta dissertação de mestrado são: contribuir com a validação da técnica de redução de tempos demandados por ensaios de desempenho de compressores de refrigeração através do uso de RNA; desenvolver um sistema, usando tal técnica, a ser implantado em bancada de ensaios de uma empresa.

A técnica neural a ser validada analisa a evolução dos valores das variáveis de ensaio durante o período transitório e tira conclusões quanto ao instante de entrada em regime permanente de cada uma das variáveis de interesse (Consumo; Capacidade; COP). Além disso, a técnica neural realiza a inferência do valor final de ensaio das variáveis de interesse logo após a entrada em regime permanente destas. A proposta da técnica neural é ilustrada na figura 1.

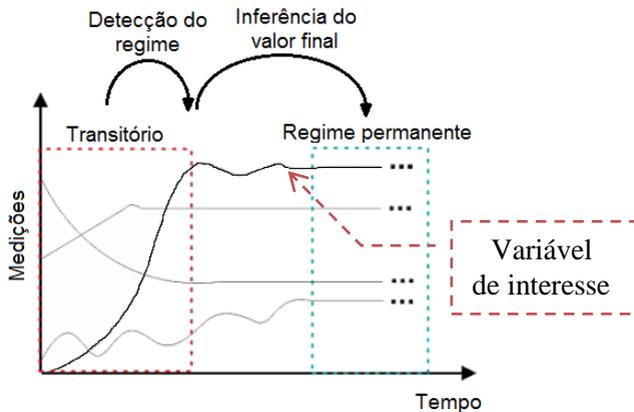


Figura 1 – Proposta da técnica neural.¹

1.3. Estrutura da dissertação

A dissertação foi estruturada em sete capítulos, de forma a manter uma seqüência lógica e clara dos assuntos abordados neste trabalho.

O capítulo 2 trata do ensaio de desempenho de compressores herméticos, abordando os métodos de ensaio aplicados, conceitos de refrigeração, as grandezas termodinâmicas envolvidas, as exigências normativas e a bancada de ensaios.

O capítulo 3 traz uma breve revisão sobre as redes neurais artificiais e sua aplicabilidade em ensaios de desempenho de compressores.

¹ Adaptado de HENKLEIN (2006).

O capítulo 4 apresenta a concepção geral do sistema neural e a estratégia adotada para as redes neurais de inferência do valor final de ensaio e de detecção de entrada em regime.

O capítulo 5 descreve o desenvolvimento do sistema neural, apresentando as etapas da elaboração das redes neurais em Matlab bem como da programação do sistema neural em Labview.

O capítulo 6 faz uma análise do desempenho operacional do sistema neural implantado em bancada de desempenho de compressores em uma empresa.

O capítulo 7 estabelece as conclusões desta dissertação e propostas de trabalhos futuros.

2. ENSAIO DE DESEMPENHO DE COMPRESSORES HERMÉTICOS

A refrigeração possui uma natureza diversificada e é amplamente utilizada numa variedade de aplicações na engenharia, abrangendo desde resfriamento de dispositivos eletrônicos a resfriamento de alimentos, e possui um aspecto multidisciplinar, envolvendo uma combinação de variadas disciplinas como engenharia mecânica, engenharia química, química, engenharia de alimentos e engenharia civil (DINCER, 2003).

Essa rápida expansão pode ser explicada por diversos fatores, entre eles, o desenvolvimento da engenharia de precisão e processos de fabricação sofisticados e o surgimento de compressores com motores elétricos de baixa potência; o que possibilitou o desenvolvimento dos refrigeradores e condicionadores de ar domésticos de pequeno porte (DOSSAT, 2004).

Embora não seja percebido pelas últimas gerações, os sistemas de refrigeração e condicionamento de ar são avanços tecnológicos recentes, que proporcionaram uma evolução silenciosa no modo de vida da sociedade moderna. Historicamente, o desenvolvimento de sistemas de refrigeração e condicionamento de ar teve forte influência na evolução da indústria de geração e distribuição de energia elétrica. O alto custo da energia elétrica foi fator que também desencadeou uma série de desafios aos engenheiros. Desafios esses que visam aumentar a eficiência dos equipamentos e reduzir o consumo de energia elétrica (LEANDRO, 2006).

Aproximadamente 10,2% do consumo de energia elétrica total do Brasil se deve a aplicações de climatização de ambientes e refrigeração, nas quais o componente mais importante, do ponto de vista da conversão de energia em um ciclo de refrigeração, é o compressor. O mercado desse componente no Brasil movimenta US\$1,5 bilhões por ano, com crescimento de 3% ao ano, onde os compressores herméticos² representam 37% desse montante (LEANDRO, 2006).

Os métodos de ensaio experimental de compressores de refrigeração constituem uma ferramenta essencial, dada a importância de tais compressores no desenvolvimento de sistemas mais eficientes. De um modo geral, tais métodos podem ser aplicados em ensaios de controle de qualidade, em ensaios de pesquisa e desenvolvimento, ou em ensaios para levantamento de dados para catálogo (HENKLEIN, 2006). Um dos ensaios mais representativos é o de desempenho de compressores de

² O conceito de compressor hermético é explicado no item 2.2.

refrigeração, cujas normas mais frequentemente utilizadas e aceitas pela indústria são a “ISO 917 - *Testing of refrigerant compressors*”(ISO 917, 1989) e a “ANSI/ASHRAE 23: *Methods of Testing for Rating Positive Displacement Refrigerant compressors and Condensing Units*” (ANSI/ASHARE 23, 1993).

2.1. Grandezas termodinâmicas

Neste item são apresentadas, resumidamente, as descrições das grandezas termodinâmicas necessárias à compreensão do texto ao longo da dissertação, com base em DINCER (2003).

Energia [J] – é a capacidade de gerar trabalho. Pode assumir diferentes formas durante sua transferência, tais como térmica, mecânica, elétrica e energia química.

Energia interna [J] – é a energia associada ao estado da substância, principalmente em função de sua temperatura. Todo corpo tem certa quantidade de energia interna que está relacionada ao movimento contínuo de seus átomos ou moléculas e às forças interativas entre essas partículas.

Calor [J] – energia térmica cuja transferência ocorre quando uma diferença de temperatura existe em um meio ou entre meios diferentes. A energia flui do meio de maior temperatura para o de menor.

Entalpia [J] – é uma combinação de propriedades termodinâmicas empregadas com frequência cujo objetivo é simplificar a análise de problemas termodinâmicos. Seu valor é dado pela soma da energia interna com o produto da pressão pelo volume (energia total).

Entalpia específica [J/kg] – é a medida da energia de aquecimento (energia total) por unidade de massa de uma substância.

Entropia [J/K] – é uma medida do grau de desordem molecular de uma substância num dado estado; também expressa o grau de irreversibilidade de um processo.

Massa específica [kg/m³] – razão entre a massa e o volume de uma substância.

Pressão [kPa] – por definição é a razão entre a componente normal da força que age sobre uma área por unidade de área.

Temperatura [K] – define o grau de agitação molecular e por consequência a energia disponível num corpo.

Trabalho [J] – é uma medida da energia transferida por uma diferença de pressão ou força. Normalmente convencionam-se que o trabalho realizado por um sistema é positivo e o trabalho realizado sobre o sistema é negativo. Alguns sistemas podem adotar convenção contrária.

Volume específico [m^3/kg] – razão entre volume e massa de uma substância; o inverso da massa específica.

2.2. Conceitos de refrigeração

Refrigeração é definida como o processo de extrair calor de uma fonte de calor, substância ou meio a baixa temperatura e transferi-lo a um ambiente de temperatura superior (WANG, 2000).

A refrigeração opera de maneira contrária ao comportamento natural da transferência de calor e, para isso, necessita de uma fonte externa de energia para realizar a troca de calor.

Um sistema de refrigeração é uma combinação de componentes e equipamentos conectados de forma seqüencial a fim de produzir o efeito de refrigeração.

No ciclo de refrigeração por compressão de vapor, um fluido refrigerante é submetido a um processo seqüencial de evaporação, compressão, condensação e expansão, absorvendo calor de um ambiente a baixa temperatura e o rejeitando num ambiente a uma temperatura superior. A figura 2 ilustra um ciclo de refrigeração.

Onde:

Q_a – calor absorvido;

Q_r – calor rejeitado;

W – potência elétrica de entrada do compressor;

1 – vapor superaquecido a baixa pressão;

2 – vapor superaquecido a alta pressão;

3 – líquido sub-resfriado a alta pressão;

4 – mistura líquido-vapor a baixa pressão.

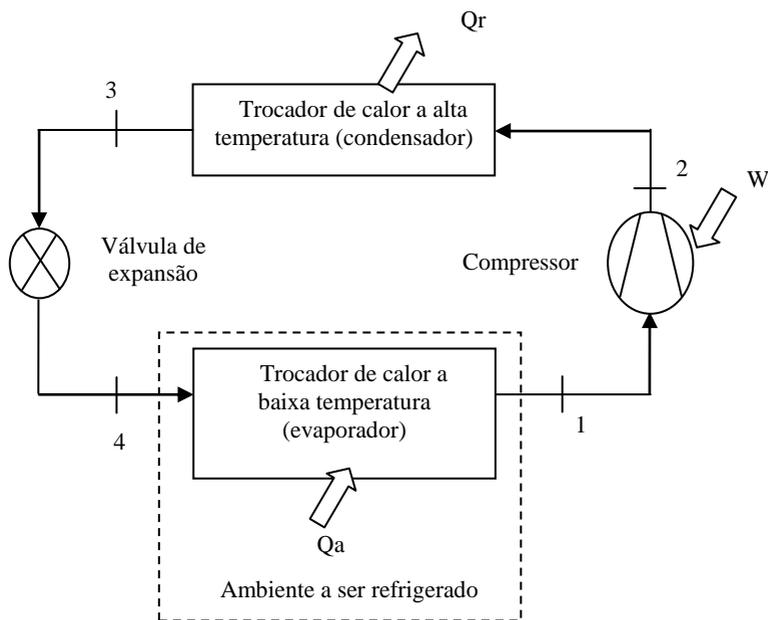


Figura 2 - Ciclo de refrigeração por compressão de vapor

O processo de refrigeração envolve a mudança de estado do refrigerante, o qual assume novas propriedades termodinâmicas, e a transferência de energia entre o refrigerante e o meio ao redor. As seguintes etapas ocorrem durante a operação de um sistema de refrigeração a compressão de vapor (WANG, 2000):

Evaporação (estado 4 ao 1) – nesta etapa, o fluido refrigerante em fase líquida evapora completamente numa temperatura constante e inferior à do meio ao seu redor, absorvendo calor equivalente à diferença de entalpia entre fase líquida e gasosa (Q_a), produzindo o efeito de refrigeração.

Superaquecimento (estado 1) – O vapor de refrigerante saturado oriundo do evaporador é usualmente superaquecido de forma a assegurar que o refrigerante líquido não flua no interior do compressor, evitando danos ao mesmo. O grau de superaquecimento depende principal-

mente do tipo de refrigerante e compressor bem como da construção do evaporador.

Compressão (estado 1 ao 2) – O refrigerante é comprimido isentropicamente³ (entropia constante), elevando sua pressão e temperatura para a condensação.

Condensação (estado 2 ao 3) – O vapor de refrigerante passa por uma redução de sua temperatura, seguida de condensação até líquido saturado e finalmente sub-resfriado, transferindo calor equivalente à diferença de entalpia entre fase gasosa e líquida (Q_r) ao meio a seu redor. Todo esse processo ocorre a pressão constante. O objetivo do sub-resfriamento é aumentar o efeito da refrigeração. O grau de sub-resfriamento depende principalmente da temperatura do ambiente ao redor durante condensação e da construção e capacidade do condensador.

Expansão (estado 3 ao 4) – O refrigerante líquido a alta pressão flui através de uma válvula de expansão, reduzindo sua pressão isentalpicamente para a pressão de evaporação. Parte mínima do líquido vira vapor e entra no evaporador no ponto 4. A porção de líquido remanescente evapora à temperatura de evaporação, completando o ciclo.

O compressor é um dos principais dispositivos empregados em sistemas de refrigeração, sendo o responsável pela injeção de energia no fluido necessária para que a troca de calor seja realizada.

Em um ciclo de refrigeração, o compressor tem a função de bombear o vapor de refrigerante proveniente do evaporador de tal forma a manter os valores desejados de temperatura e pressão neste último. No processo de compressão, a pressão e a temperatura do vapor de refrigerante se elevam por restrição.

Compressores podem ser do tipo deslocamento positivo ou do tipo dinâmico, sendo que ambos podem ser do tipo hermético, semi-hermético ou aberto. Uma forma bastante conhecida do compressor a deslocamento positivo é a do tipo pistão (recíproco alternativo). A figura 3 apresenta um esquema do compressor recíproco, o qual trabalha com ciclo de dois cursos: curso de admissão; curso de descarga.

³ No processo de compressão real a entropia não permanece constante. A utilidade de se considerar a entropia constante é que quando se conhece as condições do fluido no ponto 1 (pressão e temperatura) e a pressão de saída no ponto 2, pode-se determinar as entalpias nos pontos 1 e 2 e o trabalho de compressão como $\dot{m} \times (h_1 - h_2)$, sendo \dot{m} a vazão mássica e h_1 e h_2 as entalpias nos pontos 1 e 2 respectivamente (Stoecker e Jones, 1982).

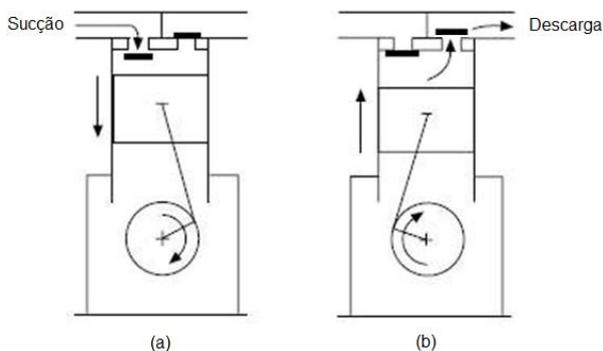


Figura 3 - Compressor recíproco. (a) Curso de admissão.
(b) Curso de descarga (Welch, 2000).

À medida que o pistão desce durante o curso de sucção, a pressão interna reduz até que seja inferior à pressão na tubulação de sucção, e a válvula de sucção abre para admitir vapor de refrigerante proveniente do evaporador. Na parte inferior do curso, esta válvula fecha novamente e o curso de compressão se inicia. Quando a pressão no cilindro é superior à pressão na tubulação de descarga, a válvula de descarga abre e o vapor de refrigerante comprimido é encaminhado ao condensador. O vapor de refrigerante presente no volume nocivo na parte superior do curso é re-expandido antes que uma nova carga possa entrar no cilindro, configurando uma das perdas do compressor (ver figura 4).

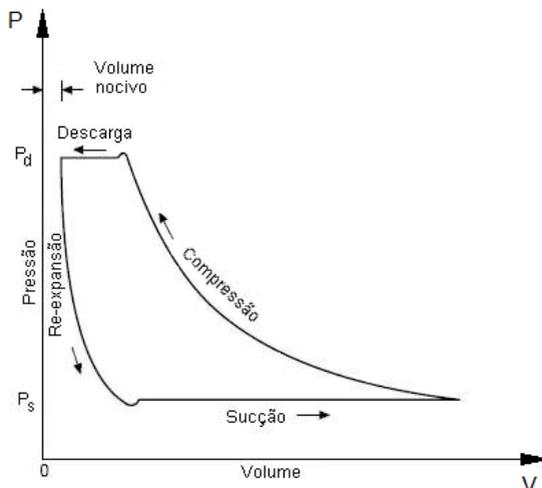


Figura 4 – Compressor: diagrama P x V (Welch, 2000).

Os compressores herméticos, disponíveis para pequenas capacidades e geralmente usados em sistemas de pequeno porte (refrigeradores domésticos, freezers e condicionadores de ar), possuem o motor e demais partes constituintes hermeticamente seladas numa carcaça soldada, e desta forma não sendo acessíveis para manutenções. O refrigerante e o óleo de lubrificação ocupam o mesmo invólucro.

Os compressores objetos de estudo deste trabalho são herméticos de estágio simples (possuem apenas um pistão e um cilindro) do tipo deslocamento positivo. Na figura 5 tem-se uma imagem em corte deste compressor.

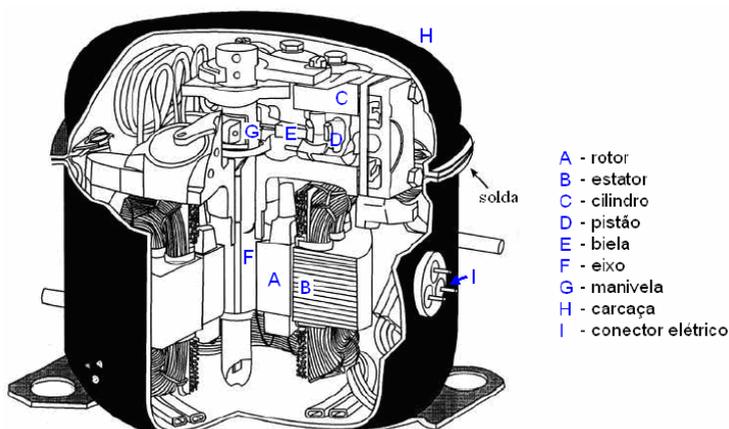


Figura 5 - Compressor hermético de deslocamento positivo (HENKLEIN, 2006).

2.3. Ensaio de Compressores

As características de compressores de refrigeração podem ser determinadas por meio de diferentes ensaios. Alguns desses ensaios são os de partida e tombamento, de desgaste, de vida e de desempenho. Esses ensaios são regulados por normas internacionais ou padrões de operação que definem características tanto do processo de medição quanto do sistema de refrigeração empregado. Devido à necessidade de medição, controle e monitoramento de diversas variáveis, tais ensaios são, tipicamente, realizados em bancadas especiais automatizadas.

Neste trabalho são abordados os ensaios de desempenho baseados na norma “ISO 917 - *Testing of refrigerant compressors*” (ISO 917, 1989). Nessa norma, alguns métodos de teste são descritos para a medi-

ção da capacidade de refrigeração, da potência absorvida, da eficiência isentrópica e do coeficiente de desempenho do compressor.

Além de permitir a correta aplicação do compressor no sistema de refrigeração, podem ser citadas outras razões para a realização do ensaio de desempenho (HENKLEIN, 2006):

- Identificação e quantificação de melhorias construtivas no compressor;
- Fornecimento de dados para projeto dos elementos de um sistema de refrigeração;
- Detectar tendências durante o processo de fabricação;
- Comparar dados entre fabricantes.

2.3.1. Definições das grandezas do ensaio

A capacidade de refrigeração de um compressor (Φ_0), dada em watt, é definida como o produto da vazão mássica de refrigerante através do compressor pela diferença entre a entalpia específica do refrigerante na entrada do compressor e a entalpia específica de líquido saturado na temperatura correspondente à pressão de descarga na saída do compressor (ISO 917, 1989).

A eficiência volumétrica (η_v) é a razão da vazão volumétrica medida na sucção pelo deslocamento do compressor (ISO 917, 1989).

Potência de entrada (P), dada em watt, é a potência medida nos terminais do motor do compressor hermético somada com a potência absorvida por elementos auxiliares necessários à operação do compressor (ISO 917, 1989).

A eficiência isentrópica (η_i) é a razão do produto da vazão mássica e a diferença na entalpia isentrópica através do compressor pela potência de entrada (ISO 917, 1989). A eficiência isentrópica de um compressor é definida como o trabalho necessário para comprimir o fluido refrigerante num processo isentrópico dividido pelo atual trabalho usado na compressão do refrigerante. A eficiência de um compressor é comumente dada como a eficiência isentrópica (HANLON, 2001).

O coeficiente de desempenho (ϵ), também conhecido como COP (*coefficient of performance*), é definido como a razão da capacidade de refrigeração (calor útil trocado no evaporador) pela potência de entrada do compressor (energia gasta no compressor). O COP pode assumir valores maiores que a unidade.

A eficiência isentrópica e o coeficiente de desempenho são adimensionais (ISO 917, 1989).

2.3.2. Procedimentos gerais

As prescrições da norma ISO 917 se aplicam apenas a compressores de simples estágio e deslocamento positivo⁴. Os procedimentos de teste estabelecidos pela mesma são gerais para todas as condições de operação, sendo que essas últimas devem especificar: as pressões absolutas de sucção e descarga, a temperatura na sucção e a frequência rotacional do compressor (ISO 917, 1989).

A determinação da capacidade de refrigeração do compressor compreende (ISO 917, 1989):

- A determinação da vazão mássica do refrigerante, obtida para cada método de ensaio usado, por meio de um aparato inserido externamente ao circuito de teste, entre a saída e a entrada do compressor.
- A determinação, a partir de tabelas conhecidas, das propriedades termodinâmicas do refrigerante: entalpia específica do refrigerante no estado de líquido saturado na temperatura correspondente à pressão de descarga do compressor; entalpia específica do refrigerante na temperatura e pressão de sucção do compressor.

A norma sugere nove métodos de ensaio, sendo que dois devem ser executados simultaneamente. Cada método possui diferentes montagens de circuito e sistemas de medição (ISO 917, 1989).

A norma exige que a diferença dos resultados de capacidade de refrigeração, obtidos a partir dos dois métodos escolhidos, relativa à média dos mesmos não deve exceder a 4%. A capacidade de refrigeração deve ser tomada como a média dos dois resultados (ISO 917, 1989).

Na bancada de ensaios utilizada neste trabalho, foram aplicados os métodos C e F. Esses métodos serão detalhados nos itens 2.3.2.1 e 2.3.2.2.

2.3.2.1. Método C – Calorímetro a seco

Este sistema de calorímetro⁵ a seco, representado na figura 6, consiste de uma serpentina por onde passa o fluido refrigerante envolto por um elemento fornecedor de calor, a fim de promover a evaporação do refrigerante. Esse elemento pode ser uma resistência elétrica envolvendo o evaporador ou um invólucro por onde circula um líquido de

⁴ O conceito de compressor de simples estágio e deslocamento positivo já foi abordado no item 2.2.

⁵ Equipamento usado na calorimetria, entendida como a ciência de se medir calor (Webster, 2000).

trabalho, como água, por exemplo. A vazão mássica é obtida pelo balanço de energia através do calor fornecido ao calorímetro, das perdas para o ambiente e das entalpias de entrada e saída do calorímetro (ISO 917, 1989).

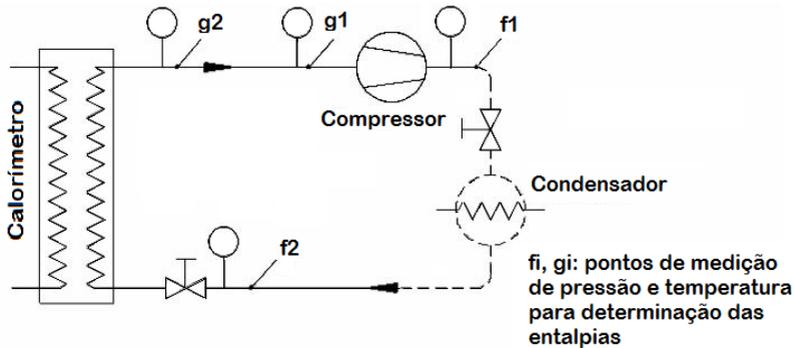


Figura 6 - Diagrama do circuito (Método C) (ISO 917, 1989).

Para a determinação da capacidade de refrigeração, a potência dissipada nas resistências de aquecimento, para controlar a temperatura de saída do evaporador, deve ser mantida constante com variação máxima de $\pm 1\%$ (ISO 917, 1989).

A vazão mássica de refrigerante é dada pela equação [1] (ISO 917, 1989).

$$q_{mf} = \frac{\phi_h + F_l(t_a - t_c)}{h_{g2} - h_{f2}} \quad [1]$$

Onde:

q_{mf} – vazão mássica de refrigerante [kg/s];

ϕ_h – potência elétrica do aquecedor [W];

F_l – fator de perda do calorímetro [W/K];

t_a – temperatura ambiente média [K];

t_c – temperatura média da superfície do calorímetro [K];

h_{g2} – entalpia específica do refrigerante evaporado deixando o calorímetro (h_{g2} é função da temperatura e pressão no ponto g_2 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [J/kg];

h_{f2} – entalpia específica do refrigerante líquido entrando na válvula de expansão (h_{f2} é função da temperatura e pressão no ponto f_2 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [J/kg].

A capacidade de refrigeração, ajustada às condições de teste básicas especificadas, é dada pela equação [2] (ISO 917, 1989).

$$\phi_0 = q_{mf} \frac{V_{ga}}{V_{gl}} (h_{g1} - h_{f1}) \quad [2]$$

Onde:

ϕ_0 – capacidade de refrigeração do compressor [W];

q_{mf} – vazão mássica de refrigerante obtida da equação [1] [kg/s];

V_{ga} – volume específico do vapor de refrigerante entrando no compressor durante o ensaio [m^3/kg];

V_{gl} – volume específico do vapor de refrigerante na sucção correspondente às condições de teste básicas especificadas [m^3/kg];

h_{g1} – entalpia específica do refrigerante entrando no compressor nas condições de teste básicas especificadas (h_{g1} é função da temperatura e pressão no ponto g_1 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [J/kg];

h_{f1} – entalpia específica do refrigerante líquido na temperatura de saturação correspondente à pressão de descarga do

compressor especificada nas condições de teste básicas (h_{f2} é função da temperatura e pressão no ponto f_2 e das propriedades termodinâmicas tabeladas do refrigerante utilizado) [J/kg].

2.3.2.2. Método F – medidor de fluxo de massa na fase líquida

No método F (ISO 917, 1989) um medidor de vazão mássica é conectado na linha de líquido entre o reservatório de líquido e a válvula de expansão (ver figura 7). Neste método devem ser realizadas as medições de pressão e temperatura do refrigerante na entrada e na saída do compressor, bem como a leitura do fluxo de massa.

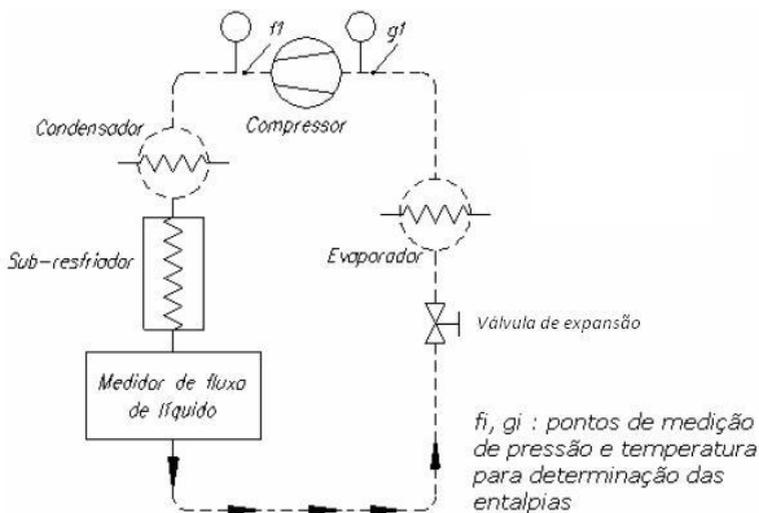


Figura 7 - Diagrama do circuito (Método F) (ISO 917, 1989)

Para que o medidor de vazão funcione corretamente, é adicionado um sub-resfriador logo após o condensador para evitar a passagem de bolhas no medidor que induzem a erro e provocam pulsação de fluxo mássico (ISO 917, 1989).

Neste método devem ser realizadas as medições de pressão e temperatura do refrigerante na entrada e na saída do compressor (Figura 7, pontos de medição g_1 e f_1 respectivamente), bem como a leitura do fluxo de massa no medidor (ISO 917, 1989).

Como o sistema utilizado possui um separador de óleo logo após a descarga do compressor, a norma indica que o cálculo da capacidade deve ser feito utilizando a equação [2], sendo que o valor do fluxo de massa (q_{mf}) é obtido pela leitura no medidor de vazão mássica.

Para ambos os métodos de ensaio (Método C e Método F), além das medições necessárias para o cálculo da capacidade de refrigeração, outras medições, que não são controladas⁶, precisam ser realizadas para a completa caracterização dos parâmetros do compressor (HENKLEIN, 2006):

- temperatura de descarga do compressor;
- potência elétrica ativa consumida pelo compressor;
- corrente elétrica que circula pelo compressor;
- potência dissipada nos resistores localizados no evaporador;
- temperatura da carcaça do compressor;
- resistência de enrolamento (final do ensaio);
- frequência rotacional (final do ensaio).

2.3.3. Requisitos gerais da Norma ISO 917

A norma define níveis de incerteza máximos para as medições realizadas durante os ensaios, bem como limites de variação dinâmica das variáveis.

Os limites de incerteza aceitáveis, de acordo com a norma, podem ser resumidos conforme segue (ISO 917, 1989):

- Temperatura (termômetros de mercúrio, termopares e termorresistores):
 - Água no calorímetro ou condensador: $\sigma = \pm 0,06 \text{ }^\circ\text{C}$;
 - Outras medições de temperatura: $\sigma = \pm 0,3 \text{ }^\circ\text{C}$;
- Pressão (coluna de mercúrio, tubo de bourdon e manômetros de diafragma ou fole):
 - pressão de sucção (absoluta): $\sigma = \pm 1\%$ do valor medido;
 - outras medições de pressão: $\sigma = \pm 2\%$ do valor medido;

⁶ No ensaio de compressores existem variáveis que são controladas e outras que são somente lidas, conforme será explicado no item 2.4.

- Grandezas elétricas:
 - todas as medições (potência, corrente, tensão e resistência): $\sigma = \pm 1\%$ do valor medido;
- Fluxo mássico (medidor de fluxo de massa líquido ou vapor e rotâmetros que medem simultaneamente massa ou volume):
 - medições na fase líquida: $\sigma = \pm 1\%$ do valor medido;
 - medições na fase gasosa: $\sigma = \pm 2\%$ do valor medido;
- Freqüência rotacional (contador de revolução, tacômetro, estroboscópio e oscilógrafo): $\sigma = \pm 0,75\%$ do valor medido;
- Tempo: $\sigma = \pm 0,1\%$ do valor medido;
- Massa: $\sigma = \pm 0,2\%$ do valor medido.

Conforme visto acima, a norma ISO 917 apresenta os limites de incerteza das medições como sendo o próprio valor de desvio padrão, mesmo não sendo a forma indicada pelo Guia para a Expressão da Incerteza de Medição da ISO (INMETRO, 2003).

Durante o ensaio, o compressor deve operar continuamente até se atingir um período no qual flutuações em todas as variáveis, podendo afetar os resultados do teste, fiquem dentro dos limites estabelecidos e não mostrem tendência definitiva a se mover fora desses limites (ISO 917, 1989). Esse período é denominado de regime permanente (ISO 917, 1989). Enquanto não se atingir esse período, diz-se que o ensaio se encontra no regime transitório (ver figura 8).

Uma vez a condição de regime permanente tendo sido alcançada, as medições devem ser realizadas em intervalos de tempo iguais, não excedendo 20 min, durante um período de pelo menos 1 h (ISO 917, 1989). O valor de medição para cada variável será a média aritmética dessas sucessivas leituras (ver figura 8)⁷ (ISO 917, 1989).

⁷ A norma ISO 917 estabelece o tempo de uma hora (1 h) para o cálculo da média. Porém algumas empresas adotam tempo de 45 minutos para ensaios que não exigem a adoção da ISO 917.

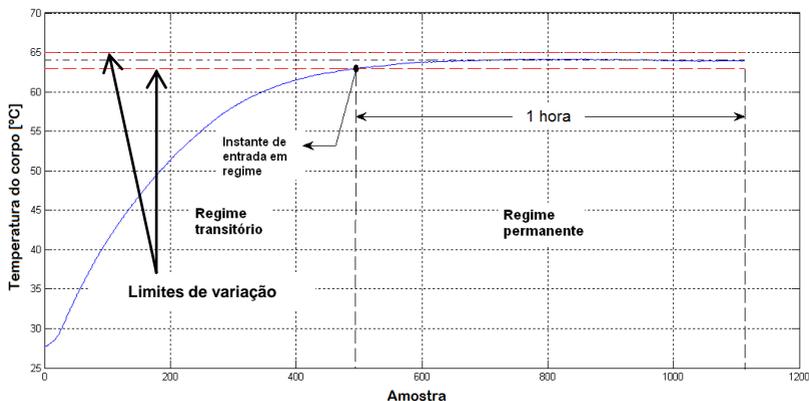


Figura 8 - Instante de entrada em regime conforme norma ISO917

Os limites de variação impostos pela norma ISO 917 para caracterizar o regime permanente numa dada condição de teste são (ISO 917, 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 que $\pm 3\text{ K}$ 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 desempenho são calculados tomando como base a média aritmética dos valores medidos consecutivamente na última hora de ensaio operando em regime permanente (ISO 917, 1989).

Os limites de variação da capacidade de refrigeração, da potência ativa consumida pelo compressor e da temperatura do corpo do com-

pressor não são especificados em norma. Porém esses limites são definidos pela empresa parceira deste trabalho da seguinte forma:

- Capacidade: $\pm 2\%$ do valor final de ensaio.
- Consumo: $\pm 2\%$ do valor final de ensaio.
- Temperatura carcaça: $\pm 1\text{ }^{\circ}\text{C}$ do valor final de ensaio⁸.

2.4. Bancada para Ensaio de Desempenho de Compressores Herméticos

Uma bancada típica de ensaio de desempenho de compressores herméticos é constituída por um circuito de refrigeração básico contendo elementos que permitam atender a exigências normativas e exigências de clientes internos e externos à empresa. Assim, um compressor é colocado em teste sob condições controladas de operação (condições definidas por: pressões absolutas de sucção e descarga; temperatura na sucção; frequência rotacional do compressor). Isso permite a correta comparação entre os resultados de diversos compressores e fornece importantes informações, principalmente para garantia da qualidade, pesquisa e desenvolvimento.

Existem vários métodos para realizar os ensaios (conforme item 2.3.2) e cada um estabelece diferentes medições em diferentes pontos do circuito, porém a estrutura física que realiza o controle das variáveis é basicamente a mesma. A figura 9 apresenta o diagrama simplificado da bancada utilizada neste trabalho. Vários equipamentos como separador de óleo, transdutores de pressão, transdutores de temperatura e filtros foram omitidos nesta representação, porém os principais elementos para a compreensão funcional da mesma estão representados.

⁸ A temperatura da carcaça é uma variável medida. Não confundir este limite de tolerância com o limite de 3 K de tolerância definido pela norma ISO 917 para as temperaturas controladas, as quais são necessárias na definição da condição de teste.

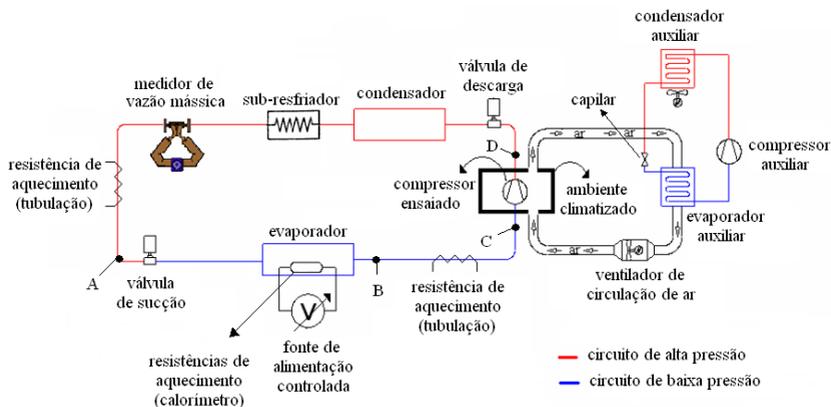


Figura 9 - Bancada de ensaio de desempenho de compressores (esquema geral)

Na figura 9 pode-se ver que existem dois circuitos de refrigeração envolvidos, um para o compressor ensaiado (circuito primário) e outro para climatizar o ambiente do compressor sob ensaio (circuito secundário).

O compressor ensaiado tem a sua pressão de sucção e de descarga impostas pelas válvulas de sucção e de descarga respectivamente. Essas válvulas, juntamente com as resistências de aquecimento, servem para impor a condição de operação na qual é observado o desempenho do compressor⁹. A quantificação da vazão de refrigerante é definida pelas trocas de calor no evaporador e pela medição direta no medidor de vazão mássica. O sub-resfriador serve para prevenir a vaporização de refrigerante no medidor de vazão mássica. São medidas as pressões e temperaturas nos pontos A, B, C e D; dessa forma são conhecidas, a partir de uma tabela de propriedades termodinâmicas de refrigerante, as entalpias em A, B, C e D. A partir da potência entregue pela fonte de alimentação controlada e das entalpias em A e B é possível definir o fluxo de massa de fluido refrigerante conforme equação [1]. Conhecendo o fluxo de massa e as entalpias em C e D é possível definir a capacidade de refrigeração do compressor a partir da equação [2].

Os elementos do circuito secundário são respectivamente: compressor auxiliar, condensador auxiliar, elemento de expansão (capilar), evaporador auxiliar, ventilador de circulação de ar e envoltório (box)

⁹ Dependendo do ponto de operação, o compressor possui um comportamento diferente, podendo ter capacidade de refrigeração e consumo maiores ou menores (HENKLEIN, 2006; HECKMANN, 1999).

para troca de calor entre compressor sob ensaio e ar de arrefecimento. O último item tem por função manter a temperatura e movimentação de ar em torno do compressor sob ensaio.

A bancada foi desenvolvida com requisitos de *hardware* e *software* de forma a reduzir ao máximo as fontes de incertezas nas medições, possibilitar a utilização de técnicas de controle em computador e reduzir ao máximo o tempo de ensaio. Por meio da aplicação de instrumentos de medição com baixa incerteza e de técnicas de controle adequadas, consegue-se atuar mais rapidamente nas variáveis proporcionando-lhes um comportamento estável com variações bem menores do que as permitidas na norma (ISO 917, 1989) (POLETTO, 2006).

A figura 10 apresenta a arquitetura do sistema de automação da bancada de desempenho bem como a interação entre os diversos módulos do sistema.

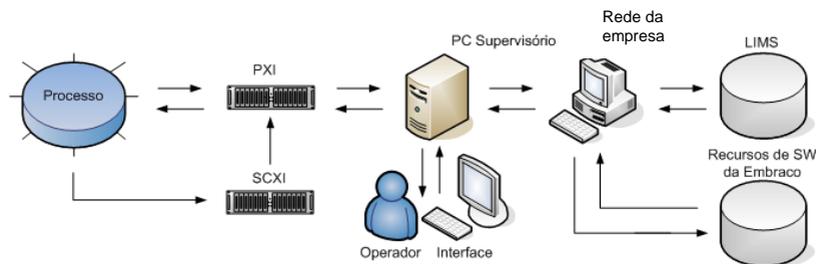


Figura 10 - Arquitetura do sistema de automação da bancada de desempenho de compressores (PETROVIC, 2007)

A interação do usuário se dá apenas com o PC supervisório e a interação com o painel é realizada apenas pelo PXI/SCXI¹⁰.

Basicamente, as funções desempenhadas pelo conjunto PXI/SCXI são a aquisição de sinais (grandezas elétricas, temperatura, pressão, fluxo de massa, fluxo de água), controle (PID, Fuzzy, etc), comandos (abertura e fechamento de válvulas e chaves), segurança (monitoramento e proteção), cálculo de propriedades termodinâmicas, comunicação e rotinas de manutenção e calibração.

O PC supervisório roda um VI (*Virtual Instrument*) do Labview e comunica-se com o VI residente no PXI via ethernet.

¹⁰ PXI é uma especificação administrada pela PXI Systems Alliance que define uma plataforma aberta baseada em PC otimizado para teste, medição e controle. O SCXI, fabricado pela National InstrumentsTM, é uma plataforma de chaveamento e condicionamento de sinais de alta performance, para medições e sistemas de automação.

O LIMS é um banco de dados da empresa parceira que armazena várias informações pertinentes às condições e resultados de ensaio. O VI do Labview rodando no PC supervisor acessa o LIMS para *download* e *upload* de informações.

Após o término de cada ensaio, é feito o download dos dados gerados pelo PXI/SCXI para futuras utilizações (ex.: redes neurais; Monte Carlo).

A arquitetura proposta é modular e flexível nas suas interfaces de comunicação, permitindo fácil expansão e integração com outros instrumentos. Também é não proprietária, com grande disponibilidade de fabricantes e produtos no mercado. A comunicação via rede com outros computadores é suportada, facilitando a troca de informações com outros sistemas corporativos, bem como a inserção manual de dados no sistema.

Depois da partida do compressor, a bancada de ensaios inicia o processo de controle para que as variáveis atinjam os valores da condição de operação em que o compressor está sendo testado. Enquanto esses valores não estiverem continuamente dentro dos limites de variação em torno do valor de referência, o ensaio estará no transitório. As variáveis medidas e controladas são (SCUSSEL, 2006):

- pressão de descarga;
- pressão de sucção;
- temperatura da sucção;
- tensão e corrente elétrica da alimentação do compressor;
- temperatura e velocidade do fluxo de ar em torno do compressor;
- temperatura interna ao trocador de calor (evaporador);
- temperatura externa ao trocador de calor (evaporador);
- vazão e temperatura da água de condensação;
- subresfriamento do fluido refrigerante na entrada do trocador.

As variáveis somente medidas são (SCUSSEL, 2006):

- temperatura de descarga do compressor;
- temperatura do corpo do compressor;
- potência elétrica entregue no evaporador;
- potência elétrica entregue ao compressor;
- resistência do enrolamento do compressor;
- medidas diversas, de acordo com o tipo de ensaio que está sendo utilizado e interesse do fabricante.

O nível de automação da bancada visa minimizar a influência do operador sobre os ensaios, diminuir o período de transitório e permitir

que as variáveis controladas apresentassem padrões semelhantes em ensaios diferentes. Tais características são importantes não somente para a geração de dados confiáveis para o treinamento das redes neurais artificiais, mas também para a própria implantação das mesmas na bancada. A bancada atual permite que sejam realizados ensaios com duração média de 2,25 h, o que já é um grande avanço se compararmos aos tempos obtidos em painéis anteriores, nos quais os ensaios duravam cerca de 4,5 h (PETROVIC, 2007). Apesar disso, é desejável reduzir ainda mais o tempo de ensaio, a fim de aumentar o número de ensaios realizados, de melhorar a análise estatística para controle de qualidade e diminuir o tempo de identificação de melhorias em atividades de pesquisa e desenvolvimento. Uma das técnicas para almejar tal objetivo é justamente a utilização de redes neurais artificiais para detecção do instante de entrada em regime e inferência do valor final de ensaio.

3. REDES NEURAIS ARTIFICIAIS

Segundo BITTENCOURT (2006), Inteligência Artificial - IA é o conjunto de técnicas para resolver problemas complexos, isto é, problemas que, apesar de não terem solução algorítmica (modelo matemático), são solucionados por seres humanos.

O objetivo central da IA é a criação de modelos para a capacidade cognitiva e a construção de sistemas computacionais baseados nesses modelos. A figura 11 apresenta os tipos de atividades desenvolvidas em IA e seus agentes (BITTENCOURT, 2006): (1) desenvolvimento de modelos cognitivos; (2) construção de ferramentas para exploração e experimentação de técnicas computacionais que permitam que os modelos desenvolvidos em (1) sejam utilizados em (3); (3) implementação de aplicações.

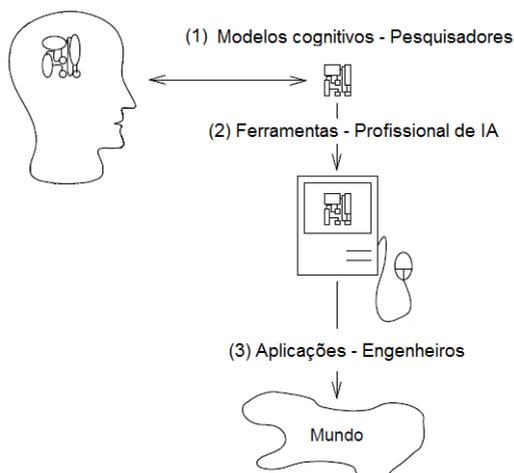


Figura 11 – Atividades em IA¹¹

Existem duas linhas principais de pesquisa para a construção de sistemas inteligentes (BITTENCOURT, 2006): conexionista; simbólica.

A linha simbólica segue a tradição lógica, na qual o comportamento inteligente global é simulado, sem considerar os mecanismos responsáveis por este comportamento (BARRETO, 1997).

A linha conexionista visa à modelagem da inteligência humana através da simulação dos componentes do cérebro, isto é, de seus neurô-

¹¹ Adaptado de BITTENCOURT (2006).

nios e de suas interligações. O modelo conexionista deu origem à área de redes neurais artificiais – RNA.

Nesse caso, em lugar de tentar programar um computador digital de modo a fazê-lo emular um comportamento inteligente (saber jogar xadrez, compreender e manter um diálogo, traduzir línguas estrangeiras, resolver problemas de matemática tais como se encontram nos primeiros anos dos cursos de engenharia etc.) procura-se elaborar um sistema que tenha circuitos modelando os circuitos cerebrais. Espera-se daí ver um comportamento inteligente emergindo, aprendendo novas tarefas, errando, fazendo generalizações e descobertas, e frequentemente ultrapassando seu professor (BARRETO, 1997).

As características, em muitos aspectos complementares às associadas à abordagem simbólica, que tornam a aplicação de redes neurais artificiais interessante do ponto de vista da solução de problemas, são as seguintes (BITTENCOURT, 2006):

- capacidade de “aprender” através de exemplos e de generalizar este aprendizado de maneira a reconhecer instâncias similares que nunca haviam sido apresentadas como exemplo;
- bom desempenho em tarefas mal definidas, onde falta o conhecimento explícito sobre como encontrar uma solução;
- não requer conhecimento a respeito de eventuais modelos matemáticos dos domínios de aplicação;
- elevada imunidade ao ruído, isto é, o desempenho de uma rede neural artificial não entra em colapso em presença de informações falsas ou ausentes, como é o caso nos programas convencionais, mas piora de maneira gradativa;
- possibilidade de simulação de raciocínio “a priori” e impreciso.

3.1. Caracterização

3.1.1. Visão geral

Segundo HAYKIN (2001), rede neural artificial é um processador paralelamente distribuído constituído de unidades de processamento simples (neurônios), que têm propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ele se assemelha ao cérebro em dois aspectos:

- a) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;

- b) forças de conexão entre neurônios, conhecidas como pesos sinápticos (parâmetros livres), são utilizadas para armazenar o conhecimento adquirido.

Uma tarefa importante para uma rede neural é aprender um modelo do mundo (ambiente) no qual ela está inserida e manter o modelo suficientemente consistente com o mundo real de maneira a atingir os objetivos especificados da aplicação de interesse. O projeto de uma rede neural artificial é baseado diretamente nos dados do mundo real, permitindo-se que o conjunto de dados fale por si mesmo.

Uma rede neural artificial extrai seu poder computacional através, primeiro, de sua estrutura paralelamente distribuída e segundo de sua habilidade de aprender e, portanto, de generalizar. Por causa desse paralelismo, a falha de alguns neurônios não causa efeitos significativos para o desempenho de todo o sistema, o que é chamado de tolerância a falhas. As RNA são capazes de mapear relações desconhecidas entre dados de entrada e saída sem conhecimento prévio do processo investigado. Esse mapeamento é alcançado através do ajuste dos parâmetros internos (pesos sinápticos) e bias¹² da rede. Esse processo é denominado aprendizagem ou treinamento. A generalização se refere ao fato de a rede neural artificial produzir saídas adequadas para entradas que não estavam presentes durante o treinamento. Assim, a aplicação das RNA em processos e relações complexas as fazem bastante úteis em diferentes tipos de problemas modernos (TALEB, MEROUFEL e WIRA, 2009).

Aplicações de redes neurais são inúmeras, tais como: aproximação de funções, reconhecimento de padrões, prognóstico médico, prognóstico de mercados financeiros, controle de processos industriais, aplicações climáticas, robótica, análise e processamento de sinais, dentre outras.

3.1.2. Fundamentos

A construção de redes neurais artificiais (RNA) tem inspiração nos neurônios biológicos e nos sistemas nervosos. O modelo geral de neurônio é mostrado na figura 12, sendo uma generalização do modelo de McCulloch e Pitts (HAYKIN, 2001).

¹² O bias é caracterizado no item 3.1.2.

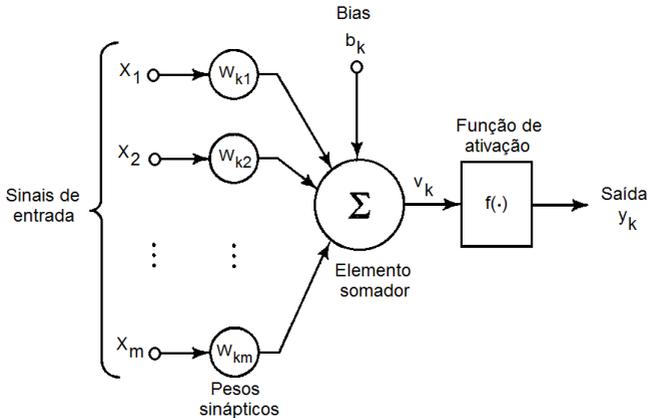


Figura 12 – Modelo geral de neurônio artificial (HAYKIN, 2001).

Em termos matemáticos, o processamento de informação de um neurônio k pode ser descrito pelas equações [3] e [4].

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad [3]$$

e

$$y_k = f(u_k + b_k) \quad [4]$$

onde:

- x_1, x_2, \dots, x_m são os sinais de entrada;
- $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ;
- u_k é a saída do combinador linear para os sinais de entrada;
- b_k é o bias;
- v_k é a saída do combinador linear para os sinais de entrada somada ao bias b_k ;
- $f(\cdot)$ é a *função de ativação*;
- y_k é o sinal de saída do neurônio.

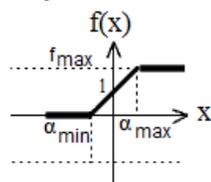
O uso do bias b_k tem o efeito de aplicar uma polarização à saída u_k do combinador linear (equação 5).

$$v_k = u_k + b_k \quad [5]$$

de modo que a atividade de um neurônio passa a ser calculada por [4]. Se a soma ponderada das entradas do neurônio excede certo nível, o neurônio produzirá um sinal de saída.

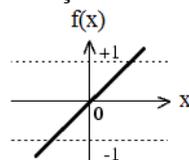
As funções de ativação mais utilizadas, além da função degrau, são apresentadas na figura 13. As funções de ativação utilizadas no âmbito deste trabalho, bem como o motivo de sua aplicação, são apresentadas no item 4.3.

Função semi-linear:



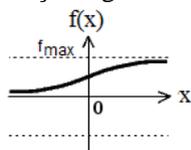
$$f(x) = \begin{cases} 0 & \text{se } x < \alpha_{min} \\ mx + l & \text{se } \alpha_{min} \leq x \leq \alpha_{max} \\ f_{max} & \text{se } x > \alpha_{max} \end{cases}$$

Função linear:



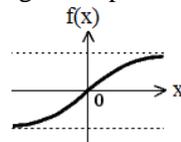
$$f(x) = mx + l$$

Função sigmoidal:



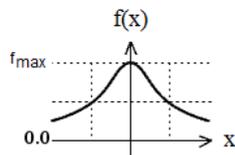
$$f(x) = \frac{f_{max}}{1 + e^{-\frac{x}{s}}}$$

Tangente hiperbólica:



$$f(x) = f_{max} \frac{e^{2sx} - 1}{e^{2sx} + 1}$$

Função gaussiana:



$$f(x) = f_{max} e^{-\frac{x^2}{2s^2}}$$

Figura 13 – Diferentes tipos de função de ativação.

A força (peso) sináptica é uma representação do conhecimento armazenado, ou seja, a memória para conhecimentos prévios. A cada sinal de entrada é atribuído um determinado peso de acordo com a experiência passada (conhecimento) armazenada na sinapse (GUPTA, JIN e HOMMA, 2003).

Na maioria dos modelos, a função u_k é, da mesma maneira que no modelo de McCulloch e Pitts, simplesmente a soma ponderada, embora existam modelos onde é utilizado o produto, o mínimo ou o máximo (BITTENCOURT, 2006).

Do ponto de vista da topologia da interligação entre neurônios, uma rede pode ser de alimentação para frente (*feedforward*) ou recorrente. Nas redes de alimentação para frente, os neurônios são organizados em camadas e a informação se desloca em um único sentido, entre camadas adjacentes. Nas redes recorrentes, não existe direção privilegiada para a propagação da informação, podendo haver retroalimentação.

De um modo geral, existem três classes fundamentais de arquiteturas de rede (HAYKIN, 2001):

- Redes *feedforward* de camada única: forma mais simples de uma rede em camadas, na qual se tem uma camada de nós de entrada conectada a uma camada de neurônios de saída (nós computacionais). Essa rede é estritamente do tipo *feedforward* ou acíclica. A figura 14 ilustra uma rede *feedforward* de camada única contendo quatro nós em ambas as camadas de entrada e saída.

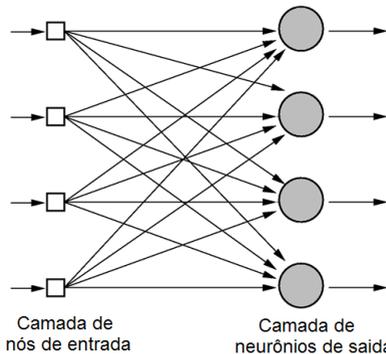


Figura 14 – Rede *feedforward* de camada única.

- Redes *feedforward* multicamadas: também chamada de perceptron multicamadas (*multilayer perceptron* – MLP) é uma rede alimentada para frente (rede direta) apresentando uma ou mais

camadas escondidas (intermediárias). Quando se tem uma ou mais camadas escondidas, a rede é capaz de extrair informações de maior complexidade. Os neurônios de cada camada intermediária têm como entrada os sinais de saída da camada anterior somente. A figura 15 ilustra o layout de uma rede neural *feedforward* multicamadas para o caso de uma única camada escondida.

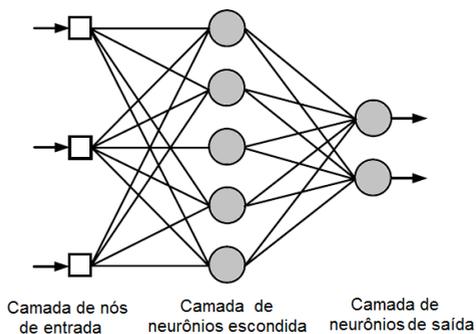


Figura 15 – Rede *feedforward* multicamada.

- Redes recorrentes: esta rede se distingue da rede alimentada para frente pelo fato de possuir, pelo menos, uma malha de realimentação. A presença de realimentação resulta num comportamento dinâmico não-linear. A figura 16 ilustra uma rede recorrente na qual as realimentações são provenientes tanto de neurônios escondidos, quanto dos neurônios de saída.

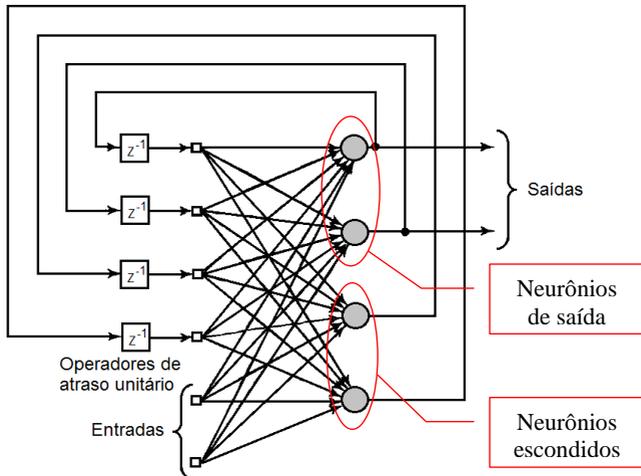


Figura 16 – Rede recorrente com neurônios escondidos.

A arquitetura de rede utilizada neste trabalho foi a perceptron multicamadas (MLP) direta com o algoritmo de treinamento da retro-propagação, utilizando linha de atrasos na camada de entrada (para inserir dinamismo à rede). Trabalhos anteriores (HENKLEIN, 2006 e STEINBACH, 2008) obtiveram bons resultados utilizando tal estrutura. São justificativas para sua aplicação:

- maior popularização e simplicidade do algoritmo de treinamento (em relação às redes recorrentes) das redes neurais diretas;
- as redes MLP são capazes de ignorar entradas irrelevantes;
- a rede MLP direta, com inserção de dinamismo, é bastante indicada em fenômenos essencialmente dinâmicos, não-lineares e de inferência;
- as ferramentas do *toolbox* do software Matlab (DEMUTH, BEALE e HAGAN, 2009) simplificam a programação e treinamento dessas redes.

3.1.3. Treinamento

Uma rede neural artificial adquire conhecimento através de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de bias. Segundo HAYKIN (2001), o aprendizado é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação do ambiente no qual a rede está inserida. O

tipo de aprendizado é determinado pela maneira com a qual as mudanças nos parâmetros ocorrem.

Um conjunto de regras bem definidas para a solução de um problema de aprendizagem é denominado algoritmo de aprendizado ou algoritmo de treinamento. Existem alguns algoritmos de treinamento que, além do ajuste de pesos, provocam também mudanças na própria arquitetura da rede, como a criação ou eliminação de neurônios (BITTENCOURT, 2006).

O treinamento pode ser de dois tipos: supervisionado ou não supervisionado. O treinamento supervisionado exige a disponibilidade de um conjunto de treinamento formado por pares de vetores de entrada e de saída, chamados pares de treinamento. Já no treinamento não supervisionado, o conjunto de treinamento consiste somente de vetores de entrada.

A maioria dos algoritmos de treinamento de redes neurais é inspirada, direta ou indiretamente, na lei de Hebb (BITTENCOURT, 2006): A intensidade de uma ligação sináptica entre dois neurônios aumenta se ambos são excitados simultaneamente. Essa lei pode ser formalizada da seguinte maneira:

$$\Delta\omega_{ij} = \eta x_i x_j \quad [6]$$

Onde:

- $\Delta\omega_{ij}$ é o acréscimo da intensidade da conexão entre os neurônios i e j ;
- η é o parâmetro definindo a intensidade da correção chamado *taxa de aprendizado*;
- x_i e x_j são os estados de ativação dos neurônios.

A regra delta (WIDROW e HOFF, 1960; WIDROW, 1962), é uma variação da lei de Hebb para levar em conta o valor desejado do estado de ativação do neurônio (d_i):

$$\Delta\omega_{ij} = \eta (d_i - x_i) x_j \quad [7]$$

Algoritmos usuais de treinamento de redes neurais são (BITTENCOURT, 2006):

- retropropagação;
- contrapropagação (do inglês, *counterpropagation*);
- aprendizado competitivo, utilizado nas redes de Kohonen;

- algoritmos genéticos.

No âmbito do presente trabalho foi utilizado o algoritmo de retropropagação (*backpropagation*). Tal algoritmo pode ser considerado como uma generalização da regra delta para redes diretas (alimentadas para frente) com mais de duas camadas (BARRETO, 1997).

A retropropagação é um algoritmo de treinamento supervisionado. Sem entrar em detalhes, os quais podem ser encontrados em (RUMELHART, HINTON e WILLIAMS, 1986), seu funcionamento pode ser descrito pelas seguintes etapas:

- apresenta-se à rede um exemplo e verifica-se a saída da rede, a qual é comparada à saída esperada, dando um erro;
- calcula-se o gradiente desse erro com relação aos valores sinápticos da camada de saída, os quais são atualizados por um passo escolhido;
- calcula-se o erro da saída da penúltima camada, e assim por diante propagando para trás o erro (origem do nome *backpropagation*) por todas as camadas de conexões;
- a seguir apresenta-se mais um exemplo (pode ser o mesmo repetido) e continua-se o processo até que o erro seja menor que uma tolerância desejada.

Como o algoritmo de retropropagação requer o cálculo do gradiente do vetor de erro, é interessante que a função de ativação seja derivável em todos os pontos. Isso explica o sucesso da função sigmoideal (figura 13) como função de ativação, pois ela apresenta essa propriedade.

3.1.4. Formas de implementação

Existem basicamente dois métodos de implementação de redes neurais: *software* e *hardware* (MOLZ, ENGEL e MORAES, 1999). As redes neurais também podem ser implementadas por meio do desenvolvimento conjunto de *hardware* e *software* (*codesign*), como proposto nos trabalhos de (MOLZ, ENGEL e MORAES, 1999) e (TORRES-HUITZILL, GIRAU e GAUFFRIAU, 2007).

A implementação por *hardware*, comparada com a implementação via *software*, geralmente recai num processo mais demorado e mais difícil de ser implementado (MOLZ, ENGEL e MORAES, 1999). A implementação de redes neurais em *hardware* pode ser feita em circuitos integrados (CI) digitais ou analógicos. Neurônios implementados com circuitos analógicos são rápidos e possuem reduzida complexidade, entretanto possuem algumas desvantagens, tais como (SORAES, 2006):

baixa imunidade a ruídos elétricos; necessidade do uso de resistores de alta precisão para representação dos pesos sinápticos. Implementações digitais, comparadas com as analógicas, são menos sensíveis a ruídos, possuem maior exatidão na implementação dos pesos sinápticos e apresentam facilidade no projeto e modificação do circuito (CHAMON, 1993). Com o avanço das tecnologias de dispositivos lógicos programáveis, os FPGA (*Field Programmable Gate Arrays*) ganharam bastante importância no desenvolvimento de sistemas digitais. Os FPGA oferecem a flexibilidade do software (para a configuração do dispositivo) junto com a velocidade e o paralelismo do hardware (BRAGA, 2005).

As redes neurais também podem ser implementadas via *software*, usando plataformas computacionais e ferramentas como MATLAB, Labview, Java, VBA, linguagem C, dentre outros. A implementação de redes neurais por *software* possui a vantagem de ser rápida e facilmente implementável (MOLZ, ENGEL e MORAES, 1999).

Neste trabalho optou-se pela implementação do sistema neural via software, mais precisamente, via ferramenta Labview, uma vez que a bancada de ensaio de desempenho na qual o sistema neural foi implantado tinha seu programa principal rodando em Labview.

3.2. Aplicações de redes neurais a ensaios de desempenho

Este trabalho, juntamente com trabalhos anteriores realizados no Labmetro (Laboratório de Metrologia e Automação da UFSC) (HENKLEIN, 2006; STEINBACH, 2008), faz parte de uma vertente inovadora, que é a utilização de IA em metrologia, mais especificamente o uso de RNA em bancada de ensaios de desempenho de compressores.

Trabalhos como o de HENKLEIN (2006) e STEINBACH (2008) envolveram sistemas de IA aplicados a ensaios de desempenho. O primeiro tinha o objetivo de verificar a viabilidade da aplicação de técnicas de IA à inferência de características de regime permanente durante o transitório em ensaios de desempenho de compressores herméticos de refrigeração. O segundo visava identificar o instante em que as variáveis de ensaio (capacidade, consumo e COP) entram em condição de regime permanente através do uso de RNA.

A proposta do trabalho atual é validar a técnica de IA à realidade de uma empresa fabricante de compressores e implantar um sistema, usando tal técnica, em bancada de ensaios de desempenho de compressores de refrigeração.

Devido à complexidade da análise dos dados de comportamento das variáveis em ensaios de desempenho e à ausência de regras explícitas para tal tarefa, as RNA se tornam bastante aplicáveis devido à sua

capacidade intrínseca em mapear relações desconhecidas entre dados de entrada e saída sem conhecimento prévio do processo investigado.

Para garantir a aplicabilidade dos recursos de IA, as soluções que vierem a ser propostas devem reduzir o tempo de ensaio sem comprometer a confiabilidade dos resultados.

Apesar de não poder ser aplicado para ensaios que devem seguir a exigências normativas bem estabelecidas, o que corresponde a um pequeno percentual dos ensaios, o sistema de RNA é bastante interessante, uma vez que possibilita a redução do tempo de execução de todos os demais ensaios.

4. ESTRUTURAÇÃO DO SISTEMA NEURAL PARA INFERÊNCIA DE VALOR FINAL DE ENSAIO E ENTRADA EM REGIME

Entende-se aqui por estruturação, o projeto das redes neurais propriamente dito, que envolve a definição da arquitetura, do algoritmo de aprendizagem (método de ajuste dos pesos) e seus parâmetros, das funções de ativação, a escolha do conjunto de entrada e saída, o tratamento das variáveis de entrada, bem como a interação entre as redes que compõem o sistema neural e definição das saídas geradas por esse sistema.

A definição dessa estrutura está fundamentada em trabalhos realizados anteriormente (Henklein, 2006 e Steinbach, 2008), no estudo do processo (comportamento das variáveis envolvidas), nas reuniões realizadas com a empresa envolvida no estudo de caso, no próprio processo de treinamento das redes e no estado-da-arte de redes neurais artificiais.

4.1. Concepção geral do sistema

Este trabalho consiste no desenvolvimento de um sistema neural desenvolvido em plataforma Labview de tal sorte a ser integrado a uma bancada de ensaios de desempenho de compressores herméticos.

A finalidade do sistema neural é a detecção, em tempo real, do instante de entrada em regime de variáveis de interesse do ensaio (COP, capacidade e consumo) bem como a inferência, nesse instante, do valor final de ensaio dessas variáveis. Para tanto, o sistema é subdividido em subsistemas (módulos neurais) conforme ilustrado na figura 17.

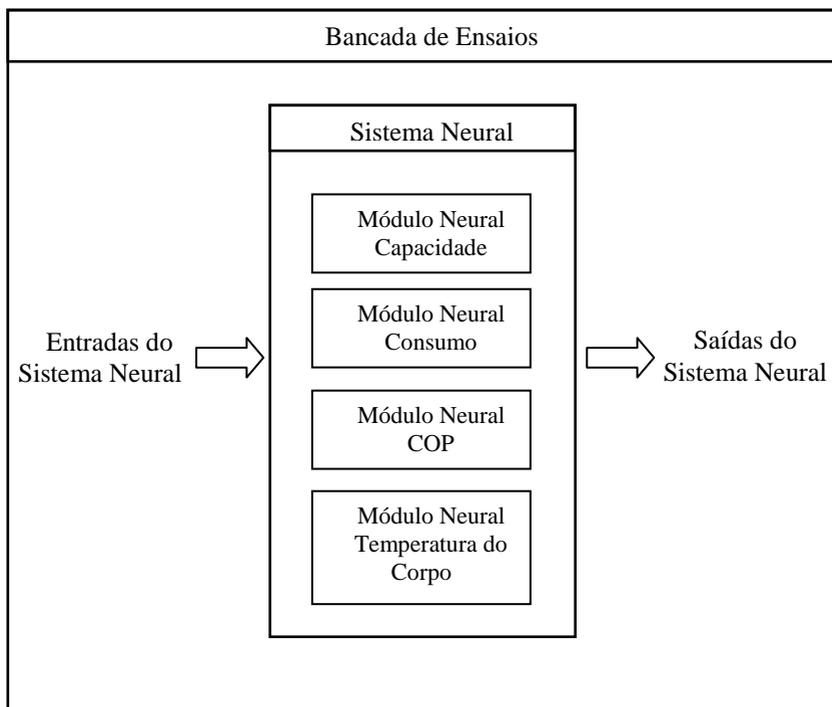


Figura 17 - Sistema neural e seus subsistemas

O “Módulo Neural Capacidade” é composto por uma rede de inferência do valor final de ensaio e outra rede de detecção do instante de entrada em regime da variável capacidade. Essa mesma estrutura é aplicada ao “Módulo Neural Consumo” e ao “Módulo Neural COP”, salvo as variáveis de interesse, no caso consumo e COP respectivamente. Nem a norma ISO 917 nem a empresa envolvida no estudo de caso especificam o cálculo do COP a cada instante, sendo o mesmo determinado na última 1 h¹³ de ensaio operando em regime permanente, conforme item 2.3.3. Mesmo assim, foi decidido criar um módulo neural para o COP, a fim de comparar os resultados de regime e inferência gerados pelo mesmo com os gerados pelo COP obtido a partir dos módulos neurais de capacidade e consumo. O “Módulo Neural Temperatura do Corpo” é

¹³ A norma ISO 917 estabelece o tempo de uma hora (1 h) para o cálculo da média. Porém, é usual, para ensaios que não exigem a adoção da ISO 917, tempo de 45 minutos.

composto por uma rede de detecção do instante de entrada em regime da variável temperatura do corpo.

A figura 18 apresenta o gráfico de capacidade por tempo de um determinado compressor. Nessa figura, estão indicados dois instantes de tempo relativos à geração de dados pelo sistema neural. A explicação que segue vale também para as demais variáveis de interesse, no caso, consumo e COP. O instante de tempo “ t_1 ” representa a detecção da entrada em regime permanente da variável de interesse pela rede de regime desta variável. Nesse instante é apresentado o resultado da inferência do valor final da variável de interesse dado pela rede de inferência. O instante de tempo “ t_2 ” representa a detecção da entrada em regime permanente da variável temperatura do corpo pela rede de regime da temperatura do corpo. Nesse instante são apresentados a média e o desvio padrão da variável de interesse, correspondentes a 5 minutos de amostragem anteriores a esse momento. Após 10 minutos de amostragem, contados a partir desse instante, são apresentados a média e o desvio padrão da variável de interesse, correspondentes a esse período de amostragem. A temperatura do corpo é a última variável do ensaio a estabilizar. Portanto, é esperado que as demais variáveis apresentem uma variação dinâmica bem próxima de zero e apresentem valores bem próximos do valor final de ensaio. Os resultados de média apresentados após a detecção de entrada em regime permanente da temperatura do corpo mostrarão o quão próximo as variáveis de interesse estarão do valor final de ensaio. Já os resultados de desvio-padrão dos valores efetivamente medidos referentes a esses períodos são apresentados para dar uma indicação quantitativa da variabilidade das grandezas de interesse.

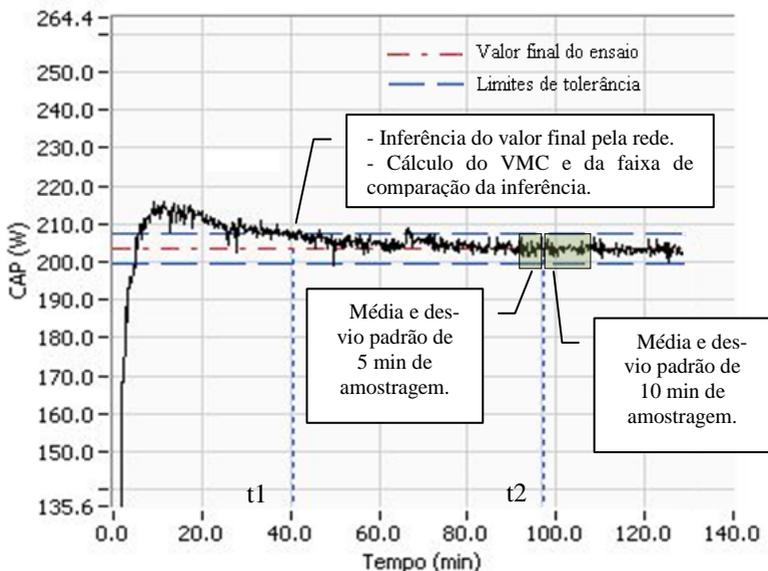


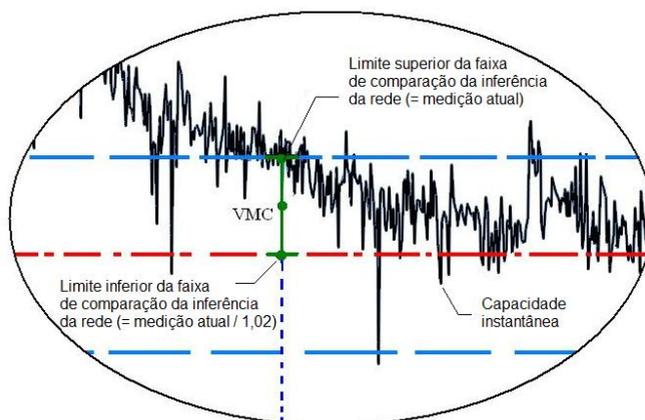
Figura 18- Resultados gerados pelo sistema neural

Além da inferência do valor final de ensaio dado pelas redes de inferência, tem-se como saída do sistema neural, também no instante de tempo “ t_1 ”, o que se denominou “Valor Medido e Corrigido” (VMC)¹⁴. Esse valor é uma tentativa de inferir o valor final da variável de interesse sem o uso de redes neurais de inferência do valor final. O cálculo do VMC é baseado na premissa de que, uma vez detectado o instante de entrada em regime permanente pela rede neural de regime, e considerando a inexistência de falso positivo¹⁵, pode-se afirmar que o valor final de ensaio estará compreendido num intervalo entre a atual leitura da variável e um rebatimento, a partir desse valor, para cima ou para baixo, de um percentual igual à própria tolerância de variação da variável de interesse no regime permanente (2% para Capacidade e Consumo

¹⁴ Na definição do VMC, o termo “Corrigido” não tem nada a ver com a definição de correção estabelecida no Vocabulário Internacional de Termos Fundamentais e Gerais de Metrologia – VIM (INMETRO, 2007). Segundo o VIM, correção é o valor adicionado algebricamente ao resultado não corrigido de uma medição para compensar um erro sistemático.

¹⁵ Tempo de falso positivo é definido como o tempo durante o qual a rede neural afirma que a variável já se encontra em regime permanente quando na realidade ainda não está. Para a recíproca também existe outra definição, denominada tempo de falso negativo, que é o tempo no qual a rede neural afirma que a variável ainda não se encontra em regime permanente quando na realidade já está.

e 1% para COP¹⁶). O sentido do rebatimento depende do sinal da derivada nesse instante, o qual pode ser positivo, negativo ou nulo. Um sinal positivo significa que a variável entra na região de regime permanente pelo limite inferior da tolerância e então, tem-se um rebatimento para cima. Já um sinal negativo denota que a variável entra pelo limite superior da tolerância, fazendo com que o sentido do rebatimento seja para baixo. Quando se tem um valor de derivada muito baixo ou nulo, é bem provável que a variável já tenha atingido um valor muito próximo do valor final do ensaio, uma vez que a mesma não mais apresenta variação dinâmica dentro da região de regime permanente. Nesse caso, pode-se estabelecer o intervalo no qual se espera que o valor final de ensaio esteja compreendido, da seguinte forma: limite superior igual à leitura atual somada da metade da tolerância de variação da variável no regime permanente (1% para Capacidade e Consumo e 0,5% para COP) e o limite inferior igual à leitura atual subtraída da mesma quantia. O valor do VMC propriamente dito está situado na metade deste intervalo. O objetivo principal do cálculo do VMC é criar uma faixa de comparação da inferência do valor final de ensaio pela rede neural. Na figura 19 foi feito um *zoom* na região de entrada em regime permanente (instante t1) da variável capacidade da figura 18, a qual entra na região de regime permanente pelo limite superior da tolerância. A figura 19 ilustra a determinação do VMC e da faixa de comparação da inferência do valor final de ensaio.



¹⁶ Os limites de tolerância da capacidade de refrigeração e do consumo já foram especificados no item 2.3.3. A tolerância de variação do COP no regime permanente não é especificada em norma e nem pela empresa parceira. A justificativa do valor de tolerância em 1% é dada no item 4.2.3.2.

Figura 19 - Determinação do valor medido e corrigido (VMC) e da faixa de comparação da inferência do valor final de ensaio.

Nem sempre o resultado de inferência do valor final e VMC são fornecidos ao mesmo tempo pelos módulos neurais de capacidade e de consumo, até porque as variáveis em questão possuem comportamentos distintos. Esse tempo depende, obviamente, da detecção de entrada em regime da variável (capacidade ou consumo) dado pelas respectivas redes de regime. A título de análises futuras, torna-se interessante saber qual seria o resultado de inferência e VMC da variável que entra em regime primeiro (capacidade ou consumo), no instante de entrada em regime da outra variável. Desta forma, o módulo neural que fornece o resultado primeiro também fornece um segundo resultado no momento em que o outro módulo fornecer o seu.

Os módulos neurais de capacidade e consumo também fornecem o resultado de inferência do valor final e VMC no momento em que o módulo neural do COP apresenta seu resultado (correspondente ao instante de detecção de entrada em regime do COP pela rede de regime desta variável).

Outra saída fornecida pelo sistema neural é o que foi denominado COP calculado. Nessa saída são fornecidos os resultados de inferência do valor final e VMC, ambos calculados a partir das primeiras saídas dos módulos neurais de capacidade e consumo, conforme equações [8] e [9]. O instante no qual o resultado do COP calculado é apresentado corresponde ao maior tempo entre os tempos nos quais são apresentados os primeiros resultados dos módulos neurais de capacidade e consumo.

$$\text{Inf}_{\text{COP}} = \text{Inf}_{\text{CAP}}(1^{\circ} \text{ resultado}) / \text{Inf}_{\text{CONS}}(1^{\circ} \text{ resultado}) \quad [8]$$

$$\text{VMC}_{\text{COP}} = \text{VMC}_{\text{CAP}}(1^{\circ} \text{ resultado}) / \text{VMC}_{\text{CONS}}(1^{\circ} \text{ resultado}) \quad [9]$$

Onde:

Inf_{COP} – inferência do COP calculada a partir dos primeiros resultados de inferência da CAP e do CONS.

Inf_{CAP} – primeiro resultado de inferência da CAP.

Inf_{CONS} – primeiro resultado de inferência do CONS.

VMC_{COP} – VMC do COP calculado a partir dos primeiros resultados de VMC da CAP e do CONS.

VMC_{CAP} – primeiro resultado de VMC da CAP.

VMC_{CONS} – primeiro resultado de VMC do CONS.

A detecção do instante de entrada em regime dada pelos módulos neurais de capacidade e consumo pelas respectivas redes de regime, podem eventualmente apresentar erro de falso positivo, ou seja, afirmar que a variável já se encontra em regime quando na realidade não está. Essa detecção prematura de entrada em regime faz com que a variável se encontre numa região na qual a rede de inferência não está pronta para apresentar um resultado confiável (ver mais detalhes no item 4.2.3). Pensando nisso, e baseado no tempo médio de entrada em regime real dos ensaios utilizados nos treinamentos das redes, decidiu-se acrescentar mais uma saída ao sistema neural. A mesma consiste em apresentar o resultado de inferência do valor final e VMC em 30 min de ensaio. O objetivo desta saída é analisar a qualidade desses resultados em meia hora de ensaio e, com isso, analisar a possibilidade de estabelecer um tempo mínimo de ensaio para apresentar os resultados das redes dos módulos neurais de capacidade, consumo e COP. Isto, em princípio, daria maior robustez ao sistema neural, uma vez que reduziria a ocorrência de erros de falso positivo das redes de regime, e a variável estaria numa região mais propícia para a inferência do valor final de ensaio.

No intuito de sintetizar tudo o que foi explanado nesta seção, é apresentada a tabela 1 contendo as variáveis de entrada e saída do sistema neural. O critério de escolha das variáveis de entrada apresentadas na tabela 1 é descrito no item 4.2.

É importante alertar que o sistema neural proposto aqui é a primeira versão implantada e, portanto, não representa, necessariamente, a configuração do sistema definitivo a ser utilizado. Todas as saídas geradas pelo mesmo, ao longo de certo tempo de utilização, serão compiladas, formando uma espécie de relatório gerencial, do qual serão extraídas informações estatísticas de avaliação desse sistema. Assim será possível escolher a melhor estratégia na direção do melhor desempenho do sistema neural.

A composição do sistema neural, considerando a elaboração dos módulos neurais, a interação entre os mesmos, a interação do sistema neural com a bancada de desempenho e a forma como os resultados são apresentados e armazenados geram requisitos de software, os quais serão apresentados em detalhes no item 5.

Tabela 1- Entradas e saídas do sistema neural

Sistema Neural	
Entradas	Vazão mássica medida pelo medidor de vazão mássica [kg/s]
	Potencia de entrada [W]
	Temperatura do corpo [°C]
	Pressão de sucção [bar]
	Inicia/Finaliza Ensaio [informação booleana]
	Compressor médio/grande [informação booleana]
	Delta H padrão [J/kg]
Entradas para Relatório de Ensaio	Capacidade final do ensaio calculado pela bancada [W]
	Consumo final do ensaio calculado pela bancada [W]
	COP final do ensaio calculado pela bancada [W]
	Modelo do compressor
	Nº cadastro LIMS
	Nº condição
	Nº amostra
	Nº repetição
	Rotação nominal do inversor [rpm]
	Data
	Tensão de alimentação [V]
	Frequência da rede de alimentação [Hz]
	Temperatura de evaporação [°C]
	Temperatura de condensação [°C]
Fluido refrigerante	
Saídas	1ª Saída Módulo Neural CAP (Inferência, VMC, instante apresentação saída)
	2ª Saída Módulo Neural CAP (Inferência, VMC, instante apresentação saída)
	Saída Módulo Neural CAP no instante de regime do COP (Inferência, VMC, instante apresentação saída)
	Saída Módulo Neural CAP em 30 min (Inferência, VMC, instante apresentação saída)
	1ª Saída Módulo Neural CONS (Inferência, VMC, instante apresentação saída)
	2ª Saída Módulo Neural CONS (Inferência, VMC, instante apresentação saída)
	Saída Módulo Neural CONS no instante de regime do COP (Inferência, VMC, instante apresentação saída)
	Saída Módulo Neural CONS em 30 min (Inferência, VMC, instante apresentação saída)
	Saída Módulo Neural COP (Inferência, VMC, instante apresentação saída)
	Saída Módulo Neural COP em 30 min (Inferência, VMC, instante apresentação saída)
	Média e desvio-padrão do COP, CAP e CONS nos 5 min precedentes ao regime da Tcorpo
Média e desvio-padrão do COP, CAP e CONS nos 10 min posteriores ao regime da Tcorpo	

4.2. Definição das variáveis de entrada e saída das redes neurais

4.2.1. Aspectos gerais

As RNA (redes neurais artificiais) podem extrair relacionamentos funcionais entre as entradas e as saídas através da modelagem dos dados, sem necessitar da consideração explícita das equações que geraram o processo. Entretanto, a fim de se conseguir uma representação adequada deste relacionamento, uma RNA necessita conter todas as informações relevantes para o problema (Valença e Ludermir, 2007). Conseqüentemente, a seleção correta das entradas é uma das tarefas mais importantes enfrentadas quando do projeto de uma rede neural. Porém, as contribuições das variáveis de entrada em prever o valor da saída são difíceis de ser compreendidos através dos pesos da rede (Valença e Ludermir, 2007).

Essa característica de modelo “caixa-preta” das RNA dificulta a explicitação de relações causa-efeito. Em geral, as variáveis selecionadas como preditoras de um modelo são baseadas na experiência do projetista (Infantosi, Almeida, *et al.*, 2002).

Quando a dimensão do conjunto de variáveis é elevada, torna-se necessário selecionar um subconjunto das potenciais variáveis de entrada medidas para reduzir o número de parâmetros livres no modelo de rede, a fim de se obter boa generalização com dados limitados de entrada. A seleção deste subconjunto é uma tarefa vital no projeto de uma rede neural. A correta escolha das entradas é também importante no aumento da eficiência computacional. Contudo, esta escolha não é simples de ser feita. Sistemas reais são geralmente complexos e em sua maioria associados a processos não-lineares. Conseqüentemente, as dependências entre variáveis de saída e entrada, bem como dependências condicionais entre variáveis, são difíceis de medir (Fernando, Maier, *et al.*, 2005).

Segundo (HAYKIN, 2001), a existência de colinearidade entre variáveis de entrada de uma RNA implica aumento desnecessário da complexidade e pouco acréscimo de informação. A diminuição da correlação das variáveis de entrada possibilita melhoria na convergência, com ganho de simplicidade para o modelo.

Alguns métodos podem ser citados para determinar a influência total de cada variável de entrada e fazer a seleção das mesmas, como por exemplo, o algoritmo de Garson (Garson, 1991), mais tarde modificado por Goh (Goh, 1995), o algoritmo MI (*Mutual Information*) (Rossi, Lendasse, *et al.*, 2006), o algoritmo PMI (*Partial Mutual Information*)

(Maya, Maier, *et al.*, 2008) e a ACP (Análise de Componentes Principais) (Infantosi, Almeida, *et al.*, 2002), porém tais métodos não foram utilizados neste trabalho.

A escolha das variáveis de entrada foi feita empiricamente baseada em trabalhos anteriores (STEINBACH, 2008; Henklein, 2006) e na análise do processo, de modo a reduzir ao máximo a dimensão do modelo, sem perda na quantidade de informação disponível, e acelerar o treinamento.

4.2.2. Pré-processamento das variáveis de entrada

Uma vez selecionado o subconjunto das potenciais variáveis de entrada, é necessário fazer um pré-processamento dessas variáveis para uso nas redes neurais. Tal pré-processamento consistiu de cinco etapas representadas no bloco-diagrama da figura 20 e explicadas em detalhes nos itens subsequentes.

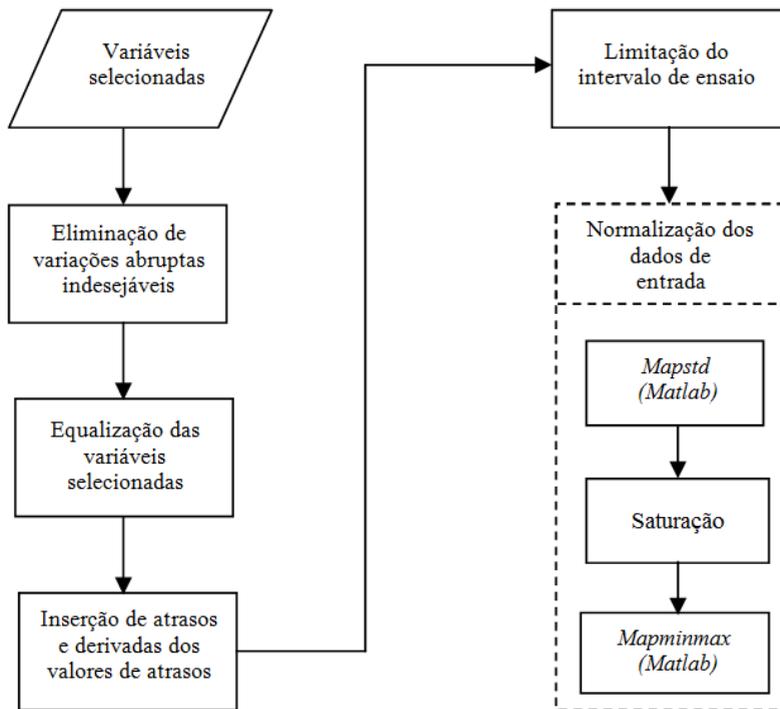


Figura 20 – Etapas de pré-processamento das variáveis de entrada.

4.2.2.1. Eliminação de variações abruptas indesejáveis

Conforme STEINBACH (2008), para que uma rede não sofra influência de dados que não representam os padrões de treinamento é necessário preparar esses dados para uso no treinamento das redes neurais. Os sinais medidos das variáveis selecionadas para treinamento das redes neurais podem sofrer variações abruptas indesejáveis oriundas de problemas na medição ou devido a perturbações provenientes do próprio sistema ensaiado. Tais variações não representam a real variação dinâmica que deve ser interpretada pela rede neural e, portanto, devem ser ignorados pela mesma¹⁷. A figura 21 mostra um exemplo de variação fora de padrão para a variável capacidade extraída de um ensaio de desempenho de um compressor modelo EGU80CLC da EMBRACO e utilizada no treinamento das redes neurais.

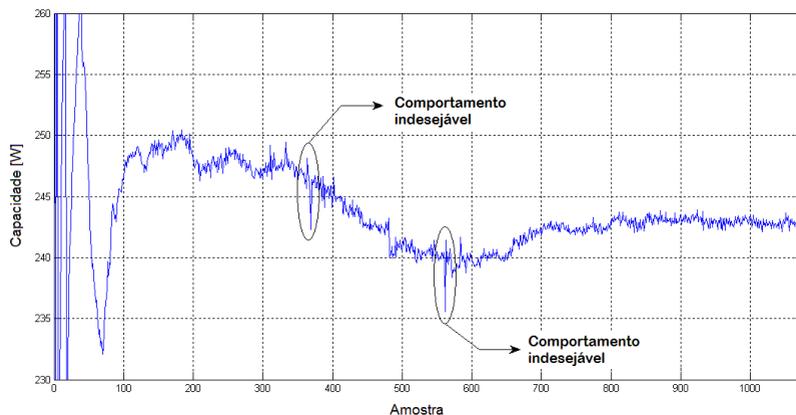


Figura 21 - Variação indesejável da variável capacidade durante ensaio de desempenho de compressor modelo EGU80CLC.

As variações pontuais fora de padrão apresentadas na figura 21 foram eliminadas fazendo-se a média entre a medição anterior e a medição posterior ao ponto de variação.

4.2.2.2. Equalização das variáveis de entrada

Os compressores receberam uma classificação conforme o nível de capacidade da seguinte maneira¹⁸:

¹⁷ Neste trabalho não houve a preocupação em detectar a origem exata de tais variações, mas sim em eliminá-las de forma a apresentar à rede neural o comportamento padrão desejável.

¹⁸ Esta classificação foi fornecida pela empresa parceira deste projeto.

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)

Os ensaios utilizados para treinamento das redes constituíram-se de ensaios de compressores grandes e médios. Para evitar que a rede neural de regime da capacidade fique sensível à classificação do ensaio de acordo com seu nível de capacidade final, os valores amostrados de capacidade de cada ensaio foram convertidos em valores percentuais em relação ao valor médio da respectiva classe daquele compressor. Pretende-se, com isso, fazer com que a rede compreenda o comportamento dinâmico de cada ensaio sem levar em conta o valor final de capacidade. Na figura 22, foram plotados os valores normalizados para a segunda entrada da rede de regime de capacidade, no tempo de amostra 400, para todos os ensaios de treinamento.

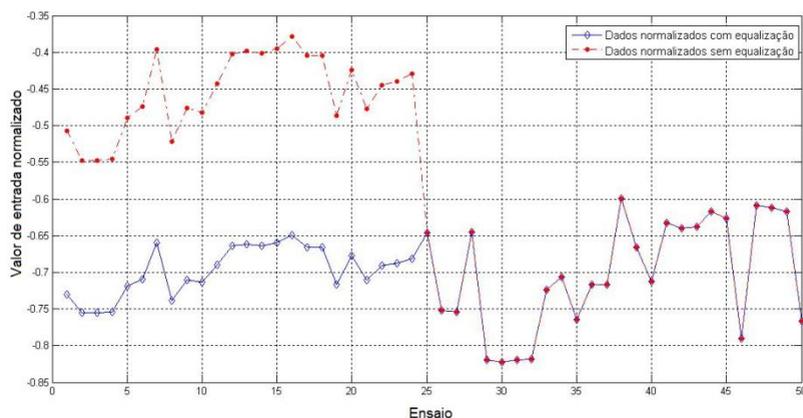


Figura 22 - Comparativo de normalização com e sem equalização.

Como pode ser visto na figura 22, os dados normalizados sem equalização apresentaram uma separação nos valores normalizados entre ensaios com compressores grandes (ensaio 1 ao 24) e ensaios com compressores médios (ensaio 25 ao 50). Os grandes ficaram distribuídos em torno de -0,45, enquanto os médios ficaram em torno de -0,7. Já os dados normalizados com a equalização não apresentaram esta divisão.

Os valores amostrados de temperatura do corpo de cada ensaio também foram convertidos em percentual em relação aos valores médios finais de temperatura do corpo, os quais foram de 56 °C e 66 °C para os compressores médios e grandes respectivamente.

4.2.2.3. Inserção de atrasos e derivadas dos valores de atrasos

O sistema modelado neste trabalho apresenta características tipicamente dinâmicas, ou seja, a saída depende dos valores instantâneos e da seqüência histórica das variáveis envolvidas, diferentemente de um modelo estático o qual só depende dos valores instantâneos das variáveis envolvidas.

A estrutura de rede utilizada neste trabalho é uma rede direta (*Feedforward*). Tais redes são estáticas, não possuem ciclos e são capazes de modelar apenas sistemas estáticos.

Problemas dinâmicos só podem ser “bem resolvidos” se forem utilizadas redes neurais artificiais com características dinâmicas. Para incluir dinamismo a uma solução conexionista, pode-se aplicar uma das seguintes técnicas (FRANCESCHI, BARRETO e ROISENBERG, 2000):

- inserir linhas de atrasos após a camada de entrada em redes neurais diretas;
- utilizar redes com ciclos e neurônios dinâmicos: redes recorrentes ou redes de Hopfield.

Desta forma, o tratamento das variáveis de entrada envolveu a inserção de atrasos e derivadas dos valores de atraso tanto na variável de interesse quanto nas demais variáveis de entrada (os detalhes são apresentados nos itens 4.2.3 e 0). A aplicação de atrasos e derivadas nas variáveis de entrada foi utilizada por STEINBACH (2008) obtendo bons resultados.

Esta abordagem para construir um sistema dinâmico não-linear fornece uma clara separação de responsabilidades: a rede estática é responsável pela não-linearidade, e a memória é responsável pelo tempo.

É válido observar que a maioria dos trabalhos encontrados na literatura utiliza somente valores absolutos das variáveis, porém, os valores das derivadas auxiliam no processo de estacionaridade, já que possibilitam a identificação de uma tendência linear (BET, 2005).

4.2.2.4. Limitação do intervalo de ensaio

Um intervalo de tempo de ensaio foi definido para formação do conjunto de entrada das redes neurais. Este intervalo não é o mesmo para as redes de inferência do valor final de ensaio e para as redes de detecção de entrada em regime.

Nos primeiros instantes do ensaio, os sinais medidos de algumas variáveis possuem elevadas variações de amplitude em curto espaço de tempo. Esse período turbulento se explica pelo fato de que, nos momentos iniciais, tanto o sistema de ensaio quanto o compressor apresentam

instabilidades típicas. Adicionalmente, os baixos valores de vazão mássica e pressão fazem com que os respectivos transdutores forneçam medições não muito confiáveis. Portanto, é razoável desconsiderar esses primeiros instantes na definição do intervalo de ensaio. O período turbulento pode variar de ensaio para ensaio, mas foi estabelecido um intervalo médio de descarte baseado na análise de todos os ensaios. Para as redes de regime de capacidade e COP foram descartadas as primeiras 20 amostras (correspondente a 3,3 minutos considerando tempo de amostragem de 10 segundos). Já para a rede de regime de consumo foram descartadas as primeiras 15 amostras (2,5 minutos). Assim, o início do intervalo de ensaio corresponde ao tempo descartado.

O instante final do intervalo de ensaio para as redes de regime corresponde ao menor tempo de ensaio dentre todos os ensaios de treinamento. Assim, a amostra fornece dados representativos suficientes do regime permanente e do regime transitório. A definição do intervalo de ensaio para as redes de regime é apresentada na figura 23, extraída do registro da variável capacidade de um ensaio de desempenho de um compressor modelo EGU80CLC da EMBRACO. Este ensaio teve duração de 1076 amostras (2h59min) e atingiu pico de 1773 W no valor de capacidade durante os instantes iniciais de ensaio. Porém, os valores máximos dos eixos y e x no gráfico foram limitados em 400 W e 665 amostras¹⁹, respectivamente. A área selecionada corresponde ao intervalo desprezado (primeiras 20 amostras). Todo o intervalo restante, ou seja, da amostra 20 a 665, será o intervalo de ensaio utilizado para treinamento da rede de regime.

¹⁹ Número de amostras correspondente ao menor tempo de ensaio dentre todos os ensaios de treinamento.

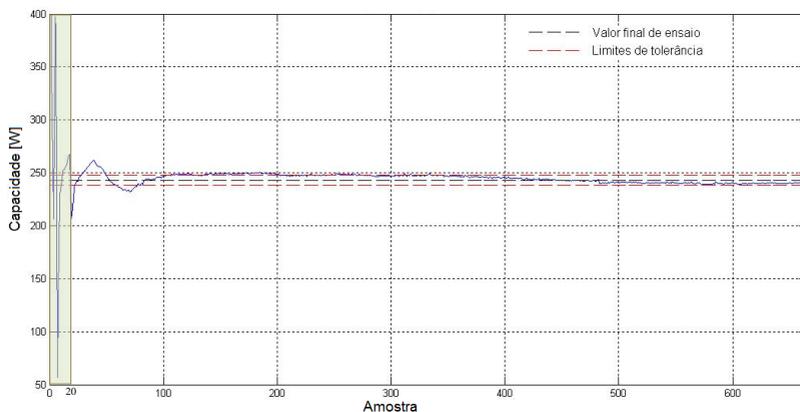


Figura 23 - Definição do intervalo de ensaio da rede de regime.

Já para as redes de inferência do valor final de ensaio, o instante de início do intervalo corresponde ao instante real de entrada em regime da variável de interesse. O período do intervalo corresponde ao maior tempo de falso negativo obtido após passagem de todos os ensaios (ensaios de treinamento e validação) pela rede de regime já treinada. O objetivo aqui é treinar as redes de inferência a partir da entrada em regime da variável de interesse. O intervalo de treinamento definido anteriormente garante a aplicação da rede de inferência mesmo na presença de erros de falso negativo na utilização da rede de regime. A figura 24 ilustra a definição do intervalo de ensaio para as redes de inferência do valor final (região selecionada). Trata-se do mesmo ensaio da figura 23, porém com a escala do eixo y mais limitada e a escala do eixo x contemplando todo o tempo de ensaio (1076 amostras). O início do intervalo em 276 amostras corresponde ao instante real de entrada em regime. O final do intervalo está na amostra 316 e corresponde ao instante inicial somado do tempo de falso negativo, que neste caso é de 40 amostras.

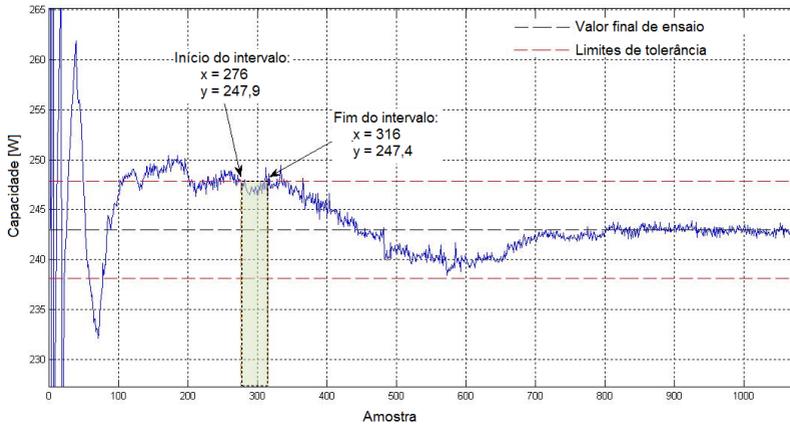


Figura 24 - Definição do intervalo de ensaio da rede de inferência.

4.2.2.5. Normalização dos dados de entrada da rede neural

O projeto das redes neurais também consistiu em uma etapa de normalização, que tem como finalidade adaptar os dados de entrada à faixa dinâmica das funções de ativação da rede neural, neste caso, tangente hiperbólica²⁰ (na 1ª camada intermediária). Valores muito altos podem saturar a função de ativação, prejudicando a convergência da rede neural. Assim, todos os dados foram normalizados, ou seja, enquadrados no intervalo $[-1 +1]$. Para tanto, utilizou-se a função *mapminmax* do software Matlab definida conforme equação [10].

$$y = (y_{\max} - y_{\min}) * (x - x_{\min}) / (x_{\max} - x_{\min}) + y_{\min} \quad [10]$$

Onde:

- x: matriz ou vetor de matrizes (*cell array*) de entrada;
- y: matriz ou vetor de matrizes (*cell array*) de entrada normalizado;
- y_{max}: máximo valor de cada linha de y;
- y_{min}: mínimo valor de cada linha de y;
- x_{max}: máximo valor de cada linha de x;
- x_{min}: mínimo valor de cada linha de x.

Assume-se que x somente possui valores reais finitos, e que os elementos de cada linha são distintos.

²⁰ A escolha das funções de transferência é tratada no item 4.3.

Segundo (LeCun, 1998), a convergência será mais rápida se o valor médio de cada entrada da rede, calculado sobre todo o conjunto de treinamento, for próximo de zero. De uma forma geral, qualquer desvio do valor médio da entrada da rede em relação ao zero irá desviar o ajuste de pesos numa direção particular e assim retardar o treinamento. Para a rede neural, a informação útil da série de dados está contida em pequenas variações e não no valor médio da entrada da rede. Assim, a normalização passou por uma etapa de remoção da média de cada variável de entrada. Assim, a função *mapstd* do software Matlab foi utilizada. Esta função normaliza as entradas e as saídas de modo que elas tenham média zero e desvio padrão unitário, conforme equação [11].

$$y = (x-xmean)*(ystd/xstd) + ymean \quad [11]$$

Onde:

- x: matriz ou vetor de matrizes (*cell array*) de entrada;
- y: matriz ou vetor de matrizes (*cell array*) de entrada normalizado;
- xmean: valor médio de cada linha de x;
- xstd: desvio padrão de cada linha de x;
- ymean: valor médio de cada linha de y;
- ystd: desvio padrão de cada linha de y (igual a 1).

Assume-se que x somente possui valores reais finitos, e que os elementos de cada linha são distintos.

Em princípio, passado o período turbulento descrito no item 4.2.2.4, as medições começam a fornecer valores confiáveis. Porém pode ocorrer que tais medições possuam valores ainda bem distantes dos valores finais de ensaio, o que se explica pelo fato da variável se encontrar no início do período transitório, além do que o tempo de descarte pode não ter sido suficiente. A figura 25, extraída do registro da variável capacidade de um ensaio de desempenho de um compressor modelo VEMY9C (4500 rpm) da EMBRACO, ilustra bem esta situação. Este ensaio possui duração de 887 amostras (147,83 min), porém o eixo x está limitado em 179 amostras (29,83 min). Pode-se perceber que, mesmo descartando os dados até a amostra 20, nos instantes seguintes ainda se tem valores bem distantes dos valores de regime da variável capacidade, com amostras atingindo inclusive valor nulo.

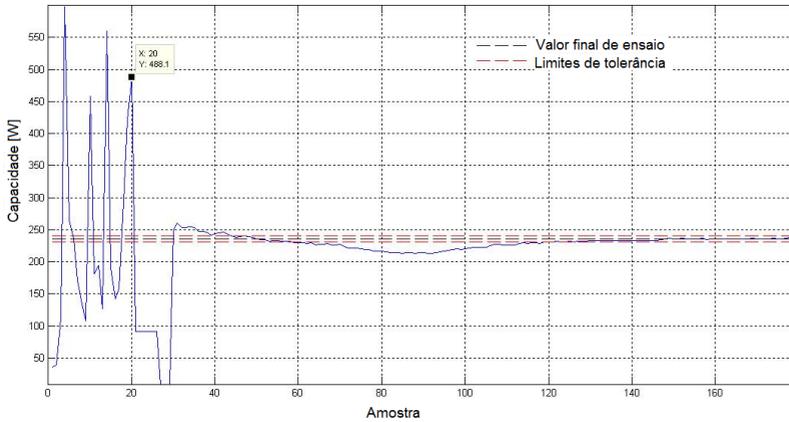


Figura 25- Valores discrepantes nos primeiros minutos de ensaio.

Torna-se necessário diminuir a influência causada por valores que se destacam excessivamente em relação aos demais, ou seja, diminuir a distância entre os valores de variáveis muito espaçadas. Isso melhora a sensibilidade dos neurônios de entrada em relação à variabilidade dos dados, principalmente para dados localizados na região de entrada em regime. Assim, o processo de normalização dos vetores de entrada das redes neurais passou por um procedimento de limitação da amplitude das variáveis de entrada. Essa etapa foi realizada após a aplicação da função *mapstd* e antes da aplicação da função *mapminmax* e consistiu em saturar os valores de entrada da rede em 5, ou seja, 5 vezes o desvio padrão unitário. A variabilidade dos dados de entrada sem e com a aplicação da saturação pode ser vista na figura 26. Nessa figura é apresentada a normalização dos dados de um ensaio referentes à primeira entrada da rede de regime de capacidade. Visualmente pode-se notar que a variabilidade dos dados normalizados com a saturação aumentou em relação à normalização sem a saturação.

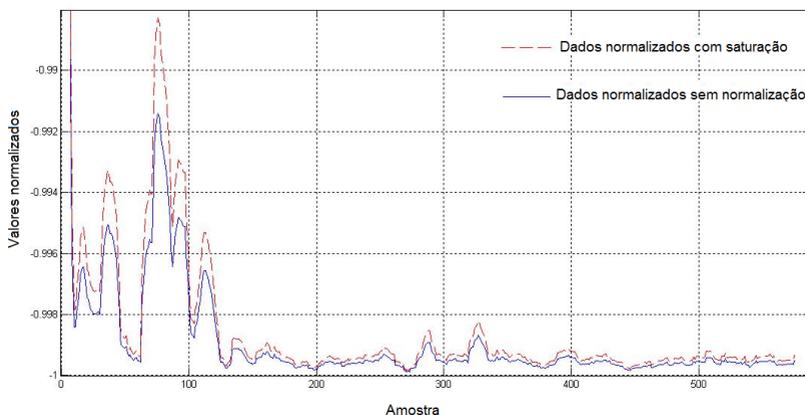


Figura 26 - Dados normalizados com e sem saturação da primeira entrada da rede de regime CAP para um ensaio

4.2.3. Rede neural para detecção do instante de entrada em regime permanente

Neste item são descritas as variáveis de ensaio selecionadas, bem como o tratamento recebido pelas mesmas, para comporem as entradas e saídas das redes neurais de detecção do instante de entrada em regime permanente.

4.2.3.1. Variáveis de entrada

As variáveis selecionadas para a composição das entradas da rede de regime de capacidade foram: a própria capacidade (que é a variável de interesse), a pressão de sucção (P_{suc}) e a temperatura do corpo (T_{corpo}). A pressão de sucção, apesar de ser uma variável controlada, tem influência na estabilização da capacidade, já que variações na mesma provocam variações na vazão mássica, a qual está diretamente relacionada com a capacidade. A temperatura do corpo, conforme já mencionado por STEINBACH (2008), possui comportamento dinâmico com maior inércia (é a última variável a se estabilizar) e auxilia na identificação do comportamento dinâmico do ensaio. Portanto, é de se esperar que a estabilização das três variáveis (CAP, P_{suc} e T_{corpo}) assegure que o período de regime permanente foi realmente alcançado.

Após as etapas de eliminação das variações abruptadas indesejáveis e de equalização²¹ das variáveis de entrada (ver itens 4.2.2.1 e 4.2.2.2), as três variáveis foram tratadas para comporem as 16 entradas da rede de regime de capacidade, conforme tabela 2 e figura 27.

Tabela 2 - Entradas da rede de regime da capacidade.

Variável relacionada	Entrada na rede	Descrição
Capacidade	1	Desvio padrão de 15 amostras da variável “capacidade” precedentes ao instante atual (Std1).
	2	Média de 15 amostras da variável “capacidade” precedentes ao instante atual (M1).
	3	Média de 15 amostras da variável “capacidade” precedentes ao instante atual deslocado de 15 amostras (M2).
	4	Média de 15 amostras da variável “capacidade” precedentes ao instante atual deslocado de 30 amostras (M3).
	5	Derivada entre 2ª e 3ª entrada (D1).
	6	Derivada entre 3ª e 4ª entrada (D2).
	7	Derivada entre 2ª e 4ª entrada (D3).
	8	Derivada entre 5ª e 6ª entrada (D4).
Temperatura do corpo	9	Média de 15 amostras da variável “temperatura do corpo” precedentes ao instante atual.
	10	Média de 15 amostras da variável “temperatura do corpo” precedentes ao instante atual deslocado de 15 amostras.
	11	Derivada entre 9ª e 10ª entrada.
	12	Derivada entre a 9ª entrada e a média de 15 amostras da variável “temperatura do corpo” precedentes ao instante atual deslocado de 30 amostras.
Pressão de sucção	13	Média de 15 amostras da variável “pressão de sucção” precedentes ao instante atual.
	14	Média de 15 amostras da variável “pressão de sucção” precedentes ao instante atual deslocado de 15 amostras.
	15	Derivada entre 9ª e 10ª entrada.
	16	Derivada entre a 9ª entrada e a média de 15 amostras da variável “pressão de sucção” precedentes ao instante atual deslocado de 30 amostras.

A figura 27, extraída de um ensaio de um compressor modelo EGX80CLC da EMBRACO, apresenta o registro da variável capacidade

²¹ A variável *pressão de sucção* não é submetida à etapa de equalização, uma vez que se trata de uma variável controlada cujo valor é imposto de acordo com as condições de ensaio pré-estabelecidas.

e os tratamentos realizados nesta variável, no instante de tempo atual (neste caso, na amostra 170), que comporão as entradas de número um a oito da rede de regime de capacidade. As áreas selecionadas representam atrasos de 15 amostras. Os tratamentos realizados nas variáveis “temperatura do corpo” e “pressão de sucção” (médias deslocadas no tempo e derivadas) para comporem as entradas de número 9 a 16 seguem o mesmo princípio.

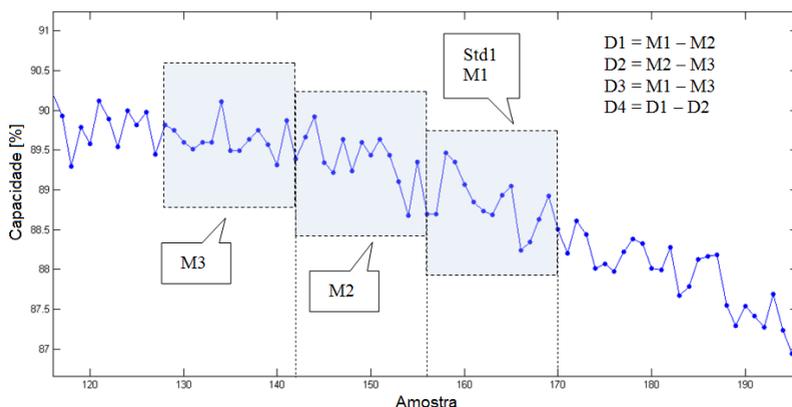


Figura 27 - Tratamento das variáveis de entrada da rede de regime de capacidade²².

O padrão de entrada aplicado à rede de regime de capacidade, detalhado na tabela 2, foi aplicado às redes de regime do consumo e do COP, com a diferença de que as entradas de número um a oito se referem à variável consumo e COP respectivamente. Este padrão é aplicado a todos os ensaios de treinamento e em todos os instantes de tempo compreendidos no intervalo de ensaio definido em 4.2.2.4, formando assim o conjunto de entrada para treinamento das redes de regime.

Como pode ser observado na figura 28, a variação dinâmica da temperatura do corpo durante o ensaio de desempenho do compressor é bem comportada e se aproxima muito à de um sistema de 2ª ordem.

²² A descrição das siglas está apresentada na Tabela 2.

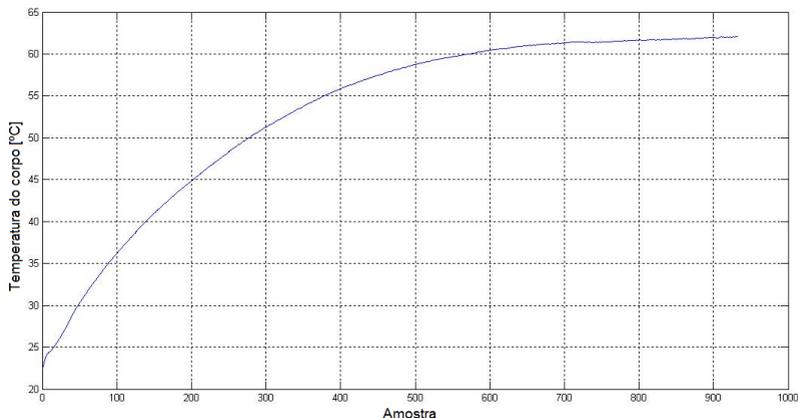


Figura 28 - Registro da temperatura do corpo do compressor durante ensaio de desempenho.

Assim, a variável selecionada para compor a entrada da rede de regime da temperatura do corpo foi a própria variável de interesse, que após passar pela etapa de equalização, foi tratada para formar as oito entradas da rede de regime de temperatura do corpo, conforme apresentado na tabela 3. Para o entendimento dos cálculos de médias e derivadas apresentados na tabela 3, pode-se utilizar a figura 27.

Tabela 3 - Entradas da rede de regime da temperatura do corpo

Entrada na rede	Descrição
1	Média de 15 amostras da variável “temperatura do corpo” precedentes ao instante atual.
2	Média de 15 amostras da variável “temperatura do corpo” precedentes ao instante atual deslocado de 15 amostras.
3	Média de 15 amostras da variável “temperatura do corpo” precedentes ao instante atual deslocado de 30 amostras.
4	Derivada entre 1ª e 2ª entrada.
5	Derivada entre 2ª e 3ª entrada.
6	Derivada entre 1ª e 3ª entrada.
7	Derivada entre 4ª e 5ª entrada.
8	Variável “temperatura do corpo” pura no instante atual.

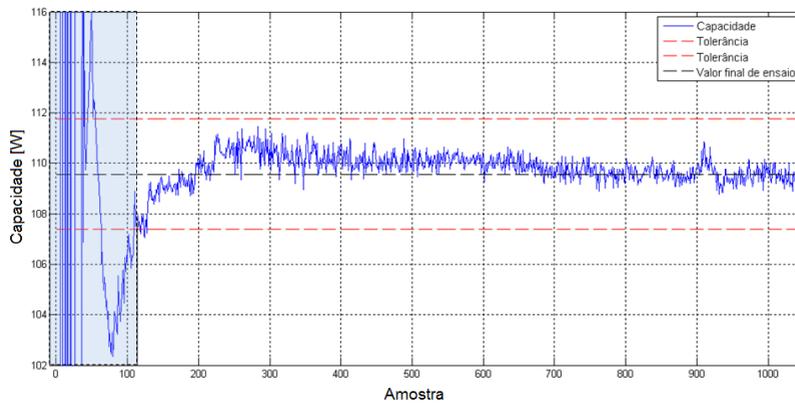
4.2.3.2. Variáveis de saída

Conforme descrito no item 2.3.3, 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.

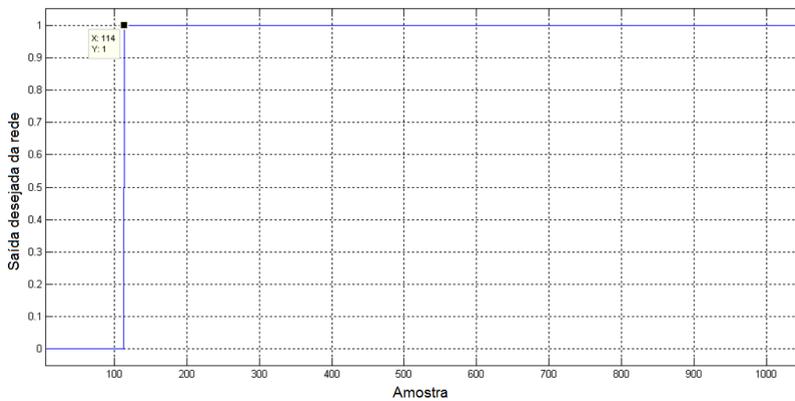
As redes de identificação de entrada em regime devem ser capazes de diferenciar o período de regime transitório do período de regime permanente. Para tanto, as mesmas foram providas de uma saída que deve excursionar entre o valor zero e um. O nível zero é atribuído para o período transitório, enquanto o nível um para o período de regime permanente. A figura 29 ilustra como os dados de saída das redes de regime foram gerados. Na figura 29a tem-se o registro da variável capacidade, extraído do ensaio de desempenho de um compressor modelo VEGZ11C (3500 rpm) da EMBRACO. A área selecionada representa o período de regime transitório, já o restante do tempo é o período de regime permanente. Na figura 29b, percebe-se que a saída desejada da rede excursionsa do nível zero para o nível um no momento em que a variável capacidade entra nos limites de tolerâncias, ou seja, na região de regime permanente.

O padrão de saída desejada da rede descrito acima é reproduzido para todas as variáveis de interesse (CAP, CONS, COP e Tcorpo), para todos os ensaios de treinamento e em todos os instantes de tempo compreendidos no intervalo de ensaio definido em 4.2.2.4, formando assim o conjunto de saída para treinamento das redes de regime.

Os limites de tolerância (ver figura 29a) da capacidade de refrigeração, da potência ativa consumida pelo compressor (consumo) e da temperatura do corpo do compressor já foram especificados no item 2.3.3. Já para o limite de tolerância do COP, não é definido nenhum valor, seja por norma, seja pela empresa envolvida no estudo de caso. Porém foi estabelecido um valor de tolerância de $\pm 1\%$ do valor final de ensaio, visto que para os ensaios disponíveis para treinamento, valores de tolerância acima de $\pm 1\%$ não proporcionaram dados de entrada confiáveis para diferenciação entre transitório e regime permanente por parte da rede neural.



(a)



(b)

Figura 29 - (a) Passagem do regime transitório para o regime permanente. (b) Saída desejada da rede de regime.

4.2.4. Rede neural para inferência do valor final de ensaio

Neste item são descritas as variáveis de ensaio selecionadas, bem como o tratamento recebido pelas mesmas, para comporem as entradas e saídas das redes neurais de inferência do valor final de ensaio.

4.2.4.1. Variáveis de entrada

As variáveis utilizadas na formação das entradas das redes de inferência do valor final de capacidade, consumo e COP foram, respectivamente para cada rede: capacidade (CAP); consumo (CONS); COP.

As variáveis selecionadas também passaram pela etapa de eliminação das variações abruptas indesejáveis. Já a etapa de equalização foi realizada somente na variável capacidade²³. Em seguida, as variáveis foram tratadas para comporem as entradas das redes de inferência do valor final, conforme tabela 4. A idéia é fazer com que, nos instantes iniciais após a detecção de entrada em regime pela rede de regime, a rede de inferência deduza o valor final de ensaio. A inferência será realizada na região de regime permanente e se baseia no comportamento dinâmico da variável de interesse. A região utilizada no treinamento da rede de inferência já foi descrita no item 4.2.2.4. A utilização da rede fora desta região de treinamento pode provocar erros maiores na inferência do valor final.

²³ Para o consumo e o COP não existem faixas definidas, assim como existem para a capacidade (diferenciando compressores de capacidade média e grande). Assim, a etapa de equalização não é aplicável ao consumo e ao COP.

Tabela 4 - Entradas das redes de inferência do valor final.

Rede de Inferência	Entrada na rede	Descrição
Capacidade	1	Desvio padrão de 15 amostras da variável “capacidade” precedentes ao instante atual (Std1).
	2	Média de 15 amostras da variável “capacidade” precedentes ao instante atual (M1).
	3	Média de 15 amostras da variável “capacidade” precedentes ao instante atual deslocado de 15 amostras (M2).
	4	Média de 15 amostras da variável “capacidade” precedentes ao instante atual deslocado de 30 amostras (M3).
	5	Derivada entre 2ª e 3ª entrada (D1).
	6	Derivada entre 3ª e 4ª entrada (D2).
	7	Derivada entre 2ª e 4ª entrada (D3).
	8	Derivada entre 5ª e 6ª entrada (D4).
Consumo	1	Desvio padrão de 15 amostras da variável “capacidade” precedentes ao instante atual (Std1).
	2	Média de 15 amostras da variável “consumo” precedentes ao instante atual (M1).
	3	Média de 15 amostras da variável “consumo” precedentes ao instante atual deslocado de 15 amostras (M2).
	4	Média de 15 amostras da variável “consumo” precedentes ao instante atual deslocado de 30 amostras (M3).
	5	Derivada entre 2ª e 3ª entrada (D1).
	6	Derivada entre 3ª e 4ª entrada (D2).
	7	Derivada entre 2ª e 4ª entrada (D3).
	8	Derivada entre 5ª e 6ª entrada (D4).
COP	1	Desvio padrão de 15 amostras da variável “COP” precedentes ao instante atual (Std1).
	2	Média de 15 amostras da variável “COP” precedentes ao instante atual (M1).
	3	Média de 15 amostras da variável “COP” precedentes ao instante atual deslocado de 15 amostras (M2).
	4	Média de 15 amostras da variável “COP” precedentes ao instante atual deslocado de 30 amostras (M3).
	5	Derivada entre 2ª e 3ª entrada (D1).
	6	Derivada entre 3ª e 4ª entrada (D2).
	7	Derivada entre 2ª e 4ª entrada (D3).
	8	Derivada entre 5ª e 6ª entrada (D4).

4.2.4.2. Variáveis de saída

A saída das redes de inferência será o próprio valor final de ensaio, obtido pela média da variável de interesse nos últimos 45 minutos de ensaio²⁴. Tais valores são apresentados na tabela 5 para cada rede de inferência. É importante salientar que, para um mesmo número de ensaio, não significa que o mesmo foi utilizado para as três redes de inferência, ou seja, a escolha dos ensaios para treinamento é independente para as três redes.

Como pode ser visto na tabela 5, o valor de saída da rede de inferência de capacidade está expresso em percentual, uma vez que a variável capacidade passou por uma equalização, conforme descrito no item 4.2.2.2.

²⁴ A norma ISO 917 estabelece o tempo de uma hora (1 h) para o cálculo da média. Porém, algumas empresas adotam tempo de 45 minutos para ensaios que não exigem a adoção da ISO 917.

Tabela 5 - Valores de saída para treinamento das redes de inferência do valor final.

Ensaio	Rede inferência capacidade [%]	Rede inferência consumo [W]	Rede inferência COP
1	98,01	95,58	1,841
2	123,72	98,05	1,655
3	123,64	99,71	1,544
4	87,57	108,27	1,895
5	87,19	105,31	1,603
6	126,37	105,79	1,734
7	121,88	85,05	1,813
8	107,07	144,74	1,722
9	96,32	131,80	1,602
10	111,27	150,54	1,779
11	91,16	116,44	1,949
12	112,06	155,78	1,627
13	83,48	67,60	1,789
14	116,26	85,65	1,624
15	116,63	86,48	1,608
16	97,94	120,31	1,818
17	114,28	86,42	1,626
18	87,63	69,33	1,620
19	88,19	69,92	1,265
20	84,78	60,36	1,593
21	70,24	75,44	1,698
22	98,58	122,04	1,819
23	103,62	150,27	1,609
24	110,43	150,53	1,660
25	109,64	149,47	1,410
26	97,31	69,09	1,517
27	112,04	130,07	1,614
28	109,75	150,10	1,614
29	95,98	127,19	1,587
30	104,67	142,13	1,846
31	105,83	143,35	1,867
32	70,46	53,44	1,855
33	114,41	86,47	1,738
34	69,42	75,45	1,734
35	-	-	1,735
36	-	-	1,280

4.3. Arquitetura das redes neurais

A disposição dos neurônios em camadas, a forma de conexão entre camadas e na própria camada são denominadas arquitetura de rede (Fausett, 1994). A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede (HAYKIN, 2001).

Conforme já adiantado no item 4.2.2.3, a arquitetura de rede utilizada neste trabalho foi uma rede direta, mais precisamente, um perceptron de múltiplas camadas (MLP) com inserção de atrasos na camada de entrada. Essa estrutura foi escolhida por se estar lidando com um problema dinâmico não-linear e que requer o processamento de padrões que evoluem no tempo. As redes MLP são as mais amplamente utilizadas e foram aplicadas com sucesso no trabalho anterior (STEINBACH, 2008).

Para treinamento das redes foi utilizado o algoritmo de retropropagação (*backpropagation*), o qual fornece um método computacional eficiente para o treinamento de perceptrons de múltiplas camadas (HAYKIN, 2001).

Redes alimentadas diretamente com múltiplas camadas apresentam uma ou mais camadas ocultas. Essas camadas permitem que seus elementos se organizem de tal forma que cada elemento aprenda a reconhecer características diferentes do espaço de entrada, assim, o algoritmo de treinamento deve decidir que características devem ser extraídas do conjunto de treinamento. A desvantagem em utilizar camada escondida é que o aprendizado se torna muito mais difícil (VIEIRA e ROISENBERG, 2002).

O número de camadas intermediárias e de neurônios geralmente é obtido por tentativa e erro, sendo a experiência a principal heurística do projetista da RNA. Todavia, deve-se levar em consideração que com um número muito pequeno de neurônios a rede pode não ter recursos suficientes para aprender. Além disso, a utilização de um número muito grande de neurônios e conexões pode fazer a rede perder sua capacidade de interpolação (ou generalização), pois ela decora os exemplos (VIEIRA e ROISENBERG, 2002).

Apesar de não existir uma regra para obter o número correto de neurônios e camadas ocultas, alguns pesquisadores sugerem critérios para essa escolha. De acordo com HECHT-NIELSEN (1989), com o uso de apenas uma camada oculta com aproximadamente $2i+1$ neurônios, onde i é o número de variáveis de entrada, já é possível calcular uma função arbitrária qualquer.

A escolha do número de camadas e neurônios foi baseada nesse último critério e na estrutura utilizada no trabalho anterior (STEINBACH, 2008). Basicamente calculou-se o número de unidades na camada oculta como sendo $2i+1$ e o resultado foi distribuído em mais de uma camada. Observou-se que quanto menor o número de camadas ocultas, mais lento ficava o treinamento das redes.

A estrutura final das redes neurais, contendo o número de camadas e o número de neurônios por camada, é apresentada na tabela 6. Pode-se notar que as redes de detecção do instante de entrada em regime permanente possuem dois neurônios de saída. Além do neurônio de saída já citado no item 4.2.3.2, foi acrescentado um segundo neurônio, com informação antagônica à do primeiro, para reforçar a informação de saída da rede.

Tabela 6 - Estrutura final das redes neurais artificiais.

Rede Neural	Número de neurônios (função de transferência) ²⁵				
	Camada de entrada	1ª Camada oculta	2ª Camada oculta	3ª Camada oculta	Camada de saída
Regime capacidade	16	15 (<i>tansig</i>)	10 (<i>tansig</i>)	10 (<i>tansig</i>)	2 (<i>logsig</i>)
Regime consumo	16	15 (<i>tansig</i>)	10 (<i>tansig</i>)	10 (<i>tansig</i>)	2 (<i>logsig</i>)
Regime COP	16	15 (<i>tansig</i>)	10 (<i>tansig</i>)	10 (<i>tansig</i>)	2 (<i>logsig</i>)
Regime Tcorpo	8	20 (<i>tansig</i>)	10 (<i>purelin</i>)	-	2 (<i>logsig</i>)
Inferência capacidade	8	20 (<i>tansig</i>)	-	-	1 (<i>purelin</i>)
Inferência consumo	8	20 (<i>tansig</i>)	-	-	1 (<i>purelin</i>)
Inferência COP	8	20 (<i>tansig</i>)	-	-	1 (<i>purelin</i>)

Apesar de não fazerem parte do escopo de definição da estrutura da rede neural propriamente dita, as funções de transferência utilizadas em cada camada de neurônios também foram apresentadas na tabela 6. Essas funções são definidas independentemente da arquitetura de rede

²⁵ As funções de transferência são apresentadas na sintaxe do toolbox de redes neurais do Matlab. Os termos *logsig*, *tansig* e *purelin* representam, respectivamente, as funções de transferência: logística, tangente hiperbólica e linear.

utilizada. Uma rede MLP treinada com algoritmo de retropropagação pode, em geral, convergir mais rapidamente quando as funções de ativação utilizadas no modelo neural forem anti-simétricas (funções ímpar) (HAYKIN, 2001). Isso explica a escolha das funções *tangente hiperbólica* e *linear* utilizadas nas camadas ocultas. A função de transferência utilizada nos neurônios da camada de saída das redes de regime foi a função *logística*, uma vez que a saída dessas redes assume valores no intervalo [0,1]. Já na camada de saída das redes de inferência, foi usada a função linear, visto que essa saída pode assumir valores maiores que 1. Todas essas funções foram apresentadas no item 3.1.2.

4.4. Parâmetros das redes

Além da definição dos vetores de entrada e saída das redes e da arquitetura, outros parâmetros devem ser definidos para a finalização do projeto e treinamento das redes. Tais parâmetros são apresentados na tabela 7.

Tabela 7 - Parâmetros de treinamento das redes

Rede neural	Algoritmo de treinamento de retropropagação	Número máximo de épocas de treinamento (<i>epochs</i>)	Máxima falha de validação (<i>max_fail</i>)	Erro médio quadrático almejado (<i>goal</i>)	Mínimo gradiente (<i>min_grad</i>)
Regime CAP	<i>trainlm</i>	1500	-	0.0011	0.001
Regime CONS	<i>trainlm</i>	1500	-	0.0011	0.001
Regime COP	<i>trainlm</i>	1500	-	0.0011	0.001
Regime Teorpo	<i>trainlm</i>	1500	70	0.00	10 ⁻⁸
Inferência CAP	<i>trainlm</i>	1000	30	0.1	10 ⁻⁶
Inferência CONS	<i>trainlm</i>	500	70	0.1	10 ⁻⁶
Inferência COP	<i>trainlm</i>	1000	20	0.002	10 ⁻⁶

Como pode ser visto na tabela 7, o algoritmo de treinamento de retropropagação utilizado em todas as redes foi o Levenberg-Marquardt (*trainlm*). Este algoritmo de otimização é o mais amplamente utilizado (Ranganathan, 2004) e aparece como o método mais rápido para treina-

mento de redes neurais diretas de tamanho moderado (até algumas centenas de pesos) (Demuth, Beale e Hagan, 2009).

O algoritmo Levenberg-Marquardt pode ser pensado como uma combinação dos métodos de gradiente descendente e de Gauss-Newton. Quando a solução atual está distante da correta, o algoritmo se comporta como um método de gradiente descendente: lento, mas com convergência garantida. Quando a solução atual está próxima da correta, ele torna-se um método de Gauss-Newton (Lourakis, 2005).

Outros algoritmos de retropropagação como o *Gradient descent backpropagation (traingd)*, *Gradient descent with momentum backpropagation (traingdm)*, *Gradient descent with adaptive learning rate (traingda)* e o *Resilient backpropagation (trainrp)* foram testados, mas o algoritmo Levenberg-Marquardt foi o que apresentou o melhor compromisso “tempo de treinamento x generalização da rede”. Tal algoritmo foi utilizado também com bons resultados no trabalho anterior (STEINBACH, 2008).

O algoritmo de retropropagação escolhido utiliza o modo de treinamento por lote, ou seja, o ajuste dos pesos é realizado após a apresentação de todos os exemplos de treinamento que constituem uma época. Esse modo de treinamento tem como características fornecer uma estimativa do vetor gradiente e a não obrigatoriedade de apresentação aleatória dos padrões.

O parâmetro *mem_reudc* (não citado na tabela 7), inerente à função de treinamento empregada, foi usado para controlar a quantidade de memória consumida pelo algoritmo. Isso foi necessário para evitar que o treinamento travasse por falta de memória. Quanto maior o valor ajustado nesse parâmetro, menor a quantidade de memória necessária e maior o tempo de treinamento.

Os demais parâmetros da tabela 7 se referem aos critérios de parada de treinamento utilizados. Dessa forma o treinamento foi encerrado quando um dos seguintes critérios foi satisfeito: o número máximo de épocas for atingido; o desempenho de generalização for adequado (máxima falha de validação); o erro médio quadrático atingir um valor suficientemente pequeno (atingir o valor almejado); o vetor gradiente da superfície de erro em relação ao vetor de peso for suficientemente pequeno (mínimo gradiente).

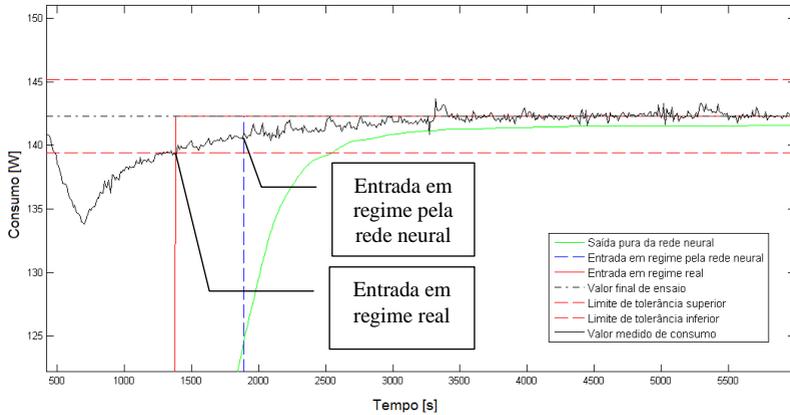
Algumas redes convergiam rapidamente, atingindo gradientes bem pequenos. Tais redes tiveram seus parâmetros de mínimo gradiente definidos com valores muito baixos (10^{-6} e 10^{-8}) em relação às demais. Isso foi uma tentativa de fazer com que o treinamento não parasse pre-

maturamente, assim evoluindo mais na superfície de erro em busca do mínimo global.

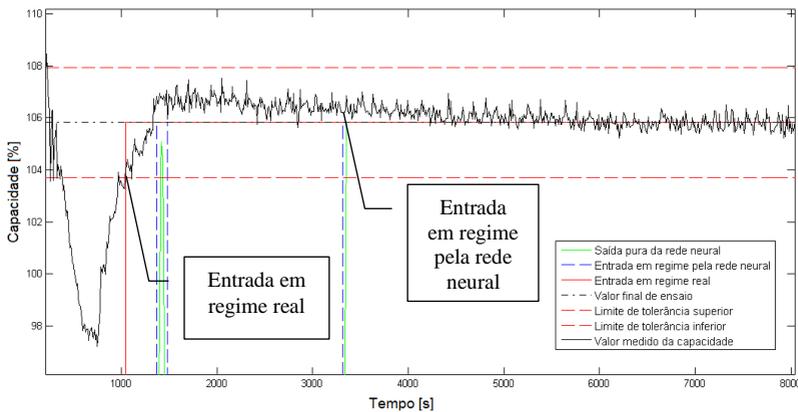
No critério de parada pela máxima falha de validação, após cada iteração (época) de aprendizagem, a rede é testada pelo seu desempenho de generalização. Vetores de validação são utilizados para encerrar o processo de aprendizagem se o erro médio quadrático calculado com o conjunto de validação aumentar ou permanecer o mesmo durante *max_fail* épocas. Os vetores de validação são usados para uma verificação ulterior de que a rede neural está generalizando bem, mas tais vetores não produzem nenhum efeito na aprendizagem.

Nas redes de regime de capacidade, consumo e COP, o critério de parada pela máxima falha de validação não foi aplicado, visto que o mesmo poderia interromper o treinamento de forma prematura, ocasionando um *underfitting*, em outras palavras, uma falta de generalização. A razão é a seguinte: nessas redes, mais importante do que detectar o momento exato de entrada em regime, é garantir que a variável realmente se encontre na região de regime permanente e não apresente tendência a sair dos limites de tolerância. É interessante que, na região de entrada em regime, a variável apresente um comportamento padrão, caracterizado por uma variação suave e por uma tendência a se acomodar no valor final de ensaio sem apresentar sobre-sinal em relação a esse. Com essa última condição garantida, a rede de inferência entra em ação aplicando uma correção que dependerá do comportamento da variável na região de regime.

Para esclarecer melhor, a figura 30 apresenta, respectivamente, o registro das variáveis consumo e capacidade extraídos de dois ensaios de desempenho de um compressor modelo VEMY9C (4500 rpm) da EMBRACO.



(a)



(b)

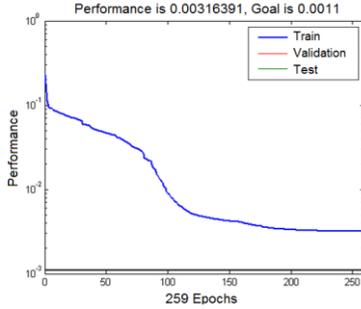
Figura 30 - (a) Detecção da entrada em regime do consumo pela rede neural. (b) Detecção da entrada em regime da capacidade pela rede neural.

Na figura 30a, a variável entra na região de regime de forma suave (baixas derivadas) e assim continua até se acomodar no valor final de ensaio. Percebe-se que, apesar da rede de entrada em regime ter apresentado um erro de falso negativo, a variável se encontra numa região está-

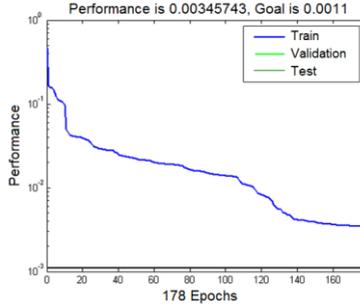
vel²⁶ e, portanto, propícia para inferência do valor final. Na figura 30b, a variável entra na região de regime apresentando uma derivada acentuada, demonstrando uma forte tendência a ultrapassar os limites de tolerância, tendência essa reforçada pela ocorrência de sobre-sinal em relação ao valor final. A indicação definitiva do instante de entrada em regime pela rede de regime ocorre numa região na qual a variável apresenta variação dinâmica suave até sua acomodação no valor final de ensaio.

Uma vez definidos os parâmetros das redes, procede-se o treinamento das mesmas. A cada mudança de parâmetro das redes foram realizados, no mínimo, dois treinamentos, a fim de evitar resultados insatisfatórios devido ao vetor de pesos inicial. As curvas de erro referentes ao último treinamento das redes neurais são apresentadas na figura 31.

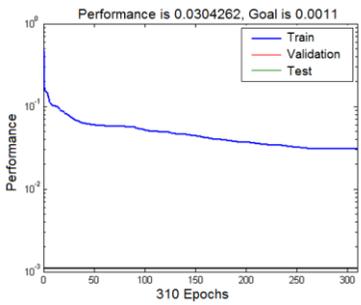
²⁶ O conceito de estabilidade aqui se refere ao fato da variável se encontrar entre os limites de tolerância e não apresentar tendência a sair destes, mesmo que a variável apresente variações dinâmicas na região de regime.



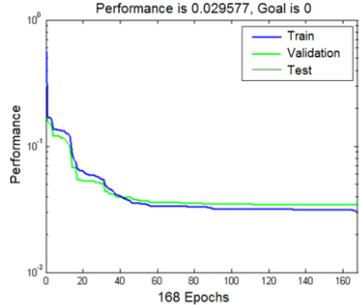
(a)



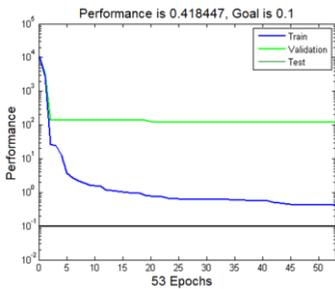
(b)



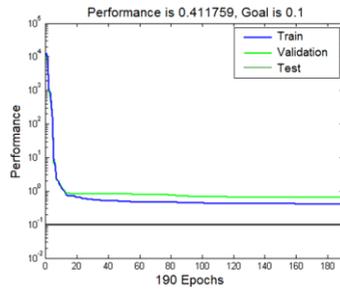
(c)



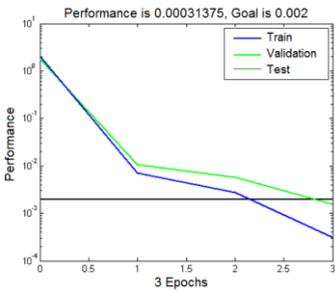
(d)



(e)



(f)



(g)

Figura 31 - Curvas de aprendizado:
 (a) Regime CAP; (b) Regime CONS;
 (c) Regime COP; (d) Regime Tcorpo;
 (e) Inferência CAP; (f) Inferência CONS;
 (g) Inferência COP.

4.5. Formação do universo de dados para treinamento das redes

A primeira etapa no desenvolvimento das redes neurais, antes mesmo das etapas descritas nos itens 4.2 ao 4.4, consistiu na seleção do conjunto de ensaios de desempenho de compressores para formar o universo de dados para o treinamento das redes neurais. A questão mais importante nessa etapa é a seleção de ensaios fidedignos à realidade, ou seja, ensaios que forneçam uma amostra representativa dos dados contendo as características distintas do problema que as redes neurais artificiais irão se deparar na aplicação final.

Tornou-se, então, necessária a definição das seguintes condições de contorno para obtenção dos ensaios que comporão o universo de treinamento das redes neurais: classificação do compressor (pequeno, médio ou grande²⁷), fluido refrigerante utilizado (R600a ou R134a), condição de ensaio (temperaturas de condensação e evaporação), métodos de ensaio aplicados (segundo a ISO 917) e a bancada de ensaios utilizada (bancada no Labmetro ou na empresa que serviu de estudo de caso). A idéia é que, para uma mesma bancada de ensaios, para um mesmo fluido refrigerante, para uma mesma condição de ensaio e mesmos métodos de ensaio, a rede seja capaz de interpolar para ensaios ainda não vistos desde que os mesmos estejam compreendidos na faixa de classificação utilizada no treinamento.

A tabela 8 apresenta o escopo definido para os ensaios que comporão o universo de treinamento.

Tabela 8 - Condições de contorno dos ensaios para treinamento das redes

Condição de contorno	Definição
Classificação do compressor	Médios e grandes
Fluido refrigerante	R600a
Condição de ensaio	Temperatura de condensação: + 54.4 °C Temperatura de evaporação: - 23.3 °C
Métodos de ensaio	Métodos C e F
Bancada de ensaios	Última versão da bancada automatizada na empresa

Ao total, foram recebidos 61 ensaios da empresa, distribuídos da seguinte forma: 28 ensaios de compressores grandes e 33 ensaios de compressores médios. Numa decisão conjunta com a empresa, os compressores pequenos não fizeram parte desse conjunto, visto que a banca-

²⁷ A classificação dos compressores em pequeno, médio ou grande, com os respectivos valores de capacidade já foi apresentada no item 4.2.2.2.

da se comporta diferentemente quando tais compressores são ensaiados em relação aos compressores médios e grandes.

4.6. Conjunto de treinamento e validação das redes neurais

Com base nas condições de contorno estabelecidas no item 4.5, foram realizados 61 ensaios para o treinamento das redes, os quais foram distribuídos nos conjuntos de treinamento, validação e teste. O ideal é fazer essa distribuição de maneira aleatória, porém um cuidado especial foi tomado durante a seleção dos ensaios para o conjunto de treinamento. Os ensaios foram realizados num período no qual a bancada de ensaios se encontrava em testes, período este caracterizado por constantes ajustes de controle. Dessa forma, alguns ensaios chegaram a apresentar saltos anormais na pressão de sucção, fazendo com que as outras variáveis, como a capacidade, o consumo e o COP também sentissem tais variações. Tal comportamento não representa a realidade de uso das redes no futuro. Portanto, procurou-se selecionar os melhores ensaios, ou seja, aqueles que representassem um comportamento padrão (não-anômalo), para formarem o conjunto de treinamento.

A figura 32 apresenta as curvas de pressão de sucção, capacidade, consumo e COP registradas durante ensaio de compressor modelo VEMY9C (2000 rpm) da EMBRACO. Na figura 32(a), na altura da amostra de número 500, nota-se um salto anormal na pressão de sucção. É interessante ressaltar que essa variação anômala ocorreu numa região na qual a variável pressão de sucção se encontrava, teoricamente, controlada e mantida num valor fixo de referencia. Tal salto é refletido nas demais variáveis, como pode ser observado nas figura 32(b), (c) e (d).

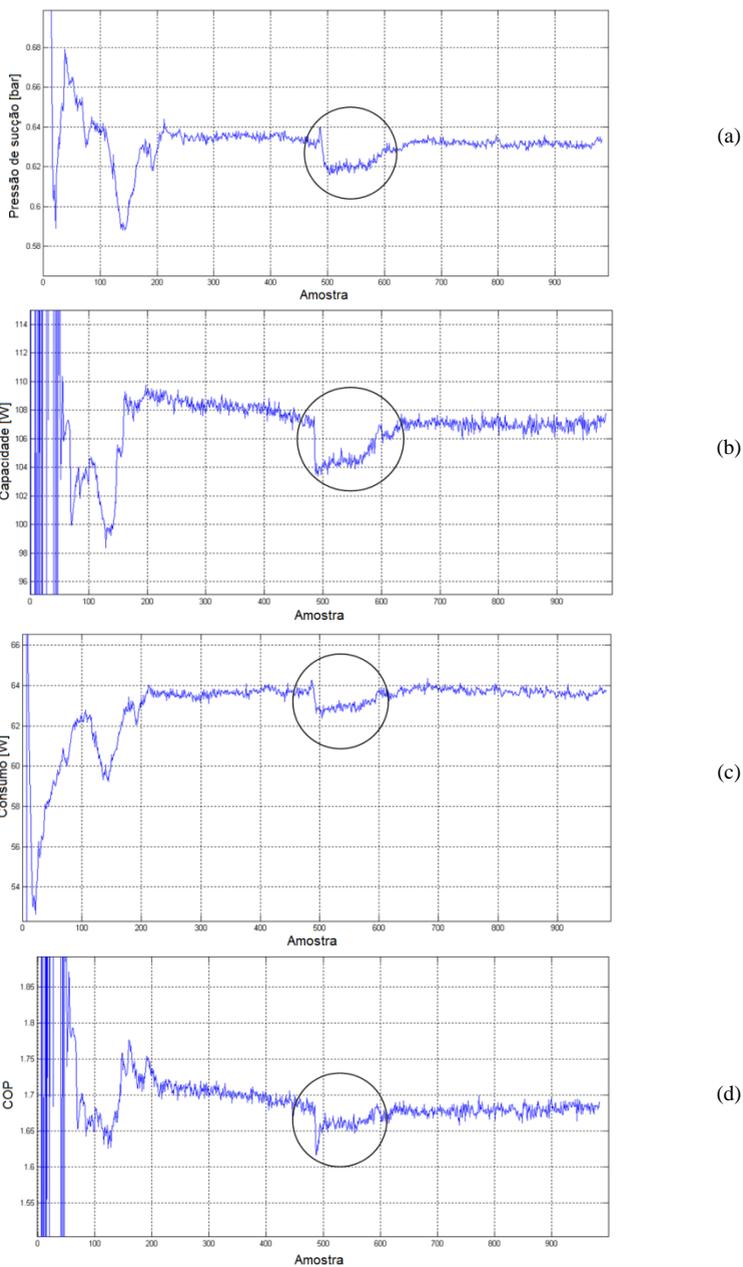


Figura 32 – Comportamento anômalo: (a) Pressão de sucção. (b) Capacidade. (c) Consumo. (d) COP.

A figura 33 apresenta curvas de comportamento considerado típico para as variáveis pressão de sucção, capacidade, consumo e COP, extraídas de um ensaio de desempenho de compressor modelo VEMY9C (4500 rpm) da EMBRACO.

Para compor o conjunto de validação, é razoável reservar de 10 a 25% do total dos casos (NIEVOLA, 2007). A distribuição dos ensaios em seus respectivos conjuntos também levou em conta que um conjunto de treinamento grande reduz o risco de sub-amostragem da função não-linear (aumenta a chance de boa generalização), porém aumenta o tempo de treinamento (GOH, 1995). A tabela 9 apresenta a distribuição dos ensaios nos conjuntos de treinamento, validação e teste para todas as redes. O ideal é utilizar apenas ensaios não vistos pelas RNA no conjunto de teste, porém, por limitação do número de ensaios, o conjunto de teste foi composto pelo total de ensaios disponíveis, os quais incluem o próprio conjunto de treinamento. Como explicado em 4.4, o conjunto de validação não gera efeito de aprendizagem, mas é utilizado para verificar se a rede neural artificial esta generalizando bem durante seu treinamento. Portanto, o conjunto de validação se adéqua perfeitamente à proposta do conjunto de teste que é a de apresentar às RNA ensaios ainda não vistos pela mesma.

Tabela 9 - Distribuição dos ensaios nos conjuntos de treinamento, validação e teste.

Rede Neural	Número de ensaios		
	Conjunto Treinamento	Conjunto Validação	Conjunto Teste
Regime CAP	38	12	61
Regime CONS	38	12	61
Regime COP	35	15	61
Regime Tcorpo	38	12	61
Inferência CAP	34	16	61
Inferência CONS	34	16	61
Inferência COP	36	14	61

5. DESENVOLVIMENTO DO SISTEMA NEURAL

O desenvolvimento do sistema neural foi subdividido em duas etapas: projeto e treinamento das redes neurais em Matlab; programação do sistema neural final em Labview.

As redes neurais foram desenvolvidas em Matlab aproveitando o potencial do *Neural Network Toolbox* (DEMUTH, BEALE e HAGAN, 2009) o qual provê ferramentas para concepção, execução, visualização e simulação de redes neurais.

O sistema neural final foi desenvolvido em Labview de forma a permitir fácil integração no programa principal da bancada de ensaios de desempenho de compressores herméticos da empresa parceira.

Os próximos itens apresentam maiores detalhes a respeito da programação das redes neurais e do sistema neural proposto neste trabalho.

5.1. Desenvolvimento das redes neurais no Matlab

Na elaboração deste trabalho foram desenvolvidos programas distintos em Matlab para treinamento e avaliação das seguintes redes:

- rede de regime da CAP;
- rede de regime do CONS;
- rede de regime do COP;
- rede de regime da Tcorpo;
- rede de inferência da CAP;
- rede de inferência do CONS;
- rede de inferência do COP.

A partir dos arquivos em *txt* contendo as medições de ensaios fornecidos pela empresa parceira, as redes foram treinadas. Ao final do treinamento, cada programa fornece os parâmetros da rede treinada, incluindo os pesos das conexões, as funções de transferência, o número de camadas, o número de neurônios por camada, o vetor de bias e parâmetros de normalização. Tais dados foram utilizados na programação do sistema neural em Labview.

Cada programa de treinamento das redes neurais é subdividido em quatro etapas descritas do item 5.1.1 ao 5.1.4.

5.1.1. Importação dos dados de ensaios

Nesta etapa, os arquivos contendo as medições dos ensaios que serão utilizados para o treinamento das redes são carregados e as variá-

veis de ensaio necessárias para a composição da entrada das redes são definidas.

Após carregamento, os ensaios são separados nos conjuntos de treinamento, validação e teste.

5.1.2. Manipulação dos dados

Nesta etapa são montados os vetores de entrada e saída dos conjuntos de treinamento, validação e teste. Para construção dos vetores, o recurso *cell array* do Matlab foi utilizado. Os vetores foram criados de forma que cada elemento do vetor represente um instante de tempo formado por uma matriz de dados como é mostrado na figura 34. A janela de tempo foi definida conforme descrito em 4.2.2.4.

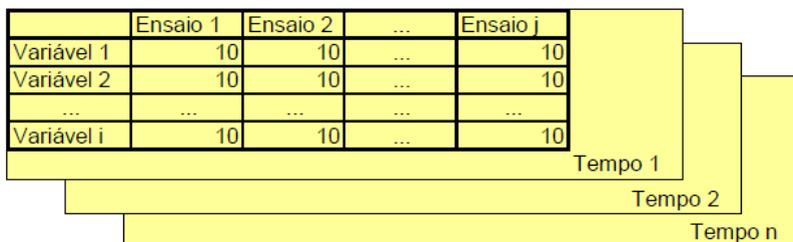


Figura 34 – Estrutura de *cell array* utilizada para formação dos vetores de entrada e saída das redes (STEINBACH, 2008).

Na figura 34, dentro de cada tempo, as linhas correspondem às variáveis de entrada no caso dos vetores de entrada ou às variáveis de saída no caso dos vetores de saída. As variáveis de entrada e saída das redes neurais foram definidas conforme descrito em 4.2. Ainda na figura 34, as colunas correspondem aos ensaios escolhidos, sejam eles para treinamento, validação ou teste.

Nesta etapa também são realizadas a equalização das variáveis de entrada e a limitação do intervalo de ensaio para treinamento, conforme descrito nos itens 4.2.2.2 e 4.2.2.4, respectivamente.

5.1.3. Normalização dos dados de entrada, projeto e treinamento da rede neural

Nesta etapa é realizada a normalização dos vetores de entrada das redes de acordo com o que foi descrito em 4.2.2.5. Os parâmetros da normalização são então gravados para posterior uso na programação das redes em Labview.

A estrutura da rede e seus parâmetros são definidos, estabelecendo-se as seguintes características: arquitetura da rede; número de camadas; número de neurônios por camada; algoritmo de treinamento; funções de transferência; critérios de parada de treinamento (número máximo de épocas; máxima falha de validação; erro médio quadrático almejado; mínimo gradiente). As estruturas de rede utilizadas assim como seus parâmetros foram descritos nos itens 4.3 e 4.4, respectivamente.

Após a normalização dos vetores de entrada e definição da arquitetura e parâmetros da rede, a mesma é treinada e gravada. O arquivo da rede treinada contém as informações da rede treinada (arquitetura; parâmetros; pesos; bias). Tais informações também serão utilizadas na programação das redes em Labview.

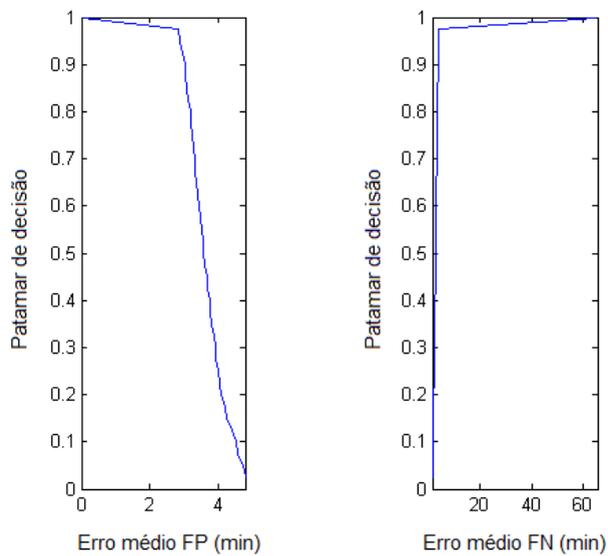
5.1.4. Análise gráfica para avaliação da rede treinada

Após treinamento da rede, esta deve ser simulada para o conjunto de teste. Alguns gráficos são gerados para auxiliar na avaliação de desempenho das redes. Essas análises apresentam algumas especificidades para as redes de inferência e de regime, as quais são explicadas na seqüência.

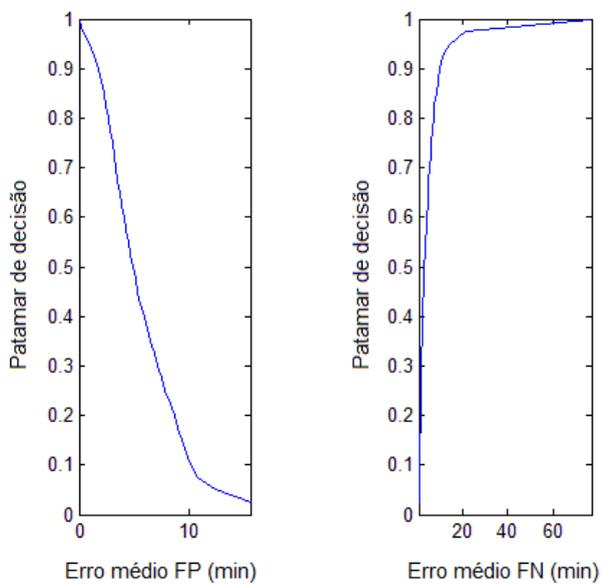
5.1.4.1. Rede de regime

A saída da rede de regime simulada para o conjunto de teste pode assumir valores compreendidos no intervalo entre 0 e 1. Dessa forma, um patamar de decisão deve ser considerado para que a saída da rede seja aceita ou não como pertencente ao regime permanente. A escolha do patamar de decisão tem influência direta no resultado da rede. Para auxiliar tal escolha, dois tipos de gráfico foram gerados: um gráfico que relaciona os patamares de decisão com os erros médios de FN e FP; um gráfico que compara o instante de entrada em regime real e a saída da rede.

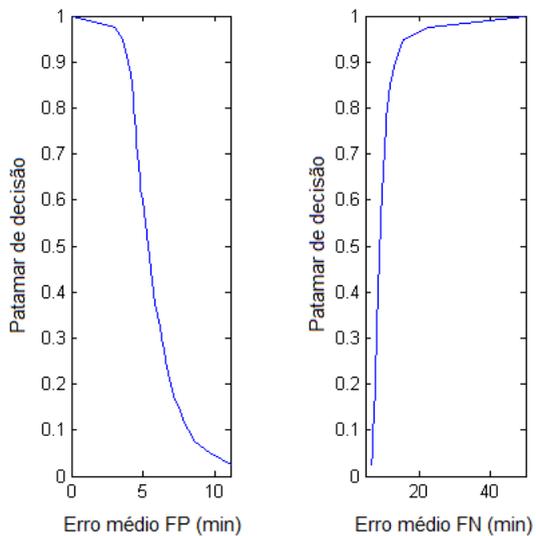
A figura 35 apresenta o erro médio de FP e FN, para os 61 ensaios do conjunto de teste, em função do patamar de decisão, para as redes de CAP, CONS, COP e Tcorpo, respectivamente.



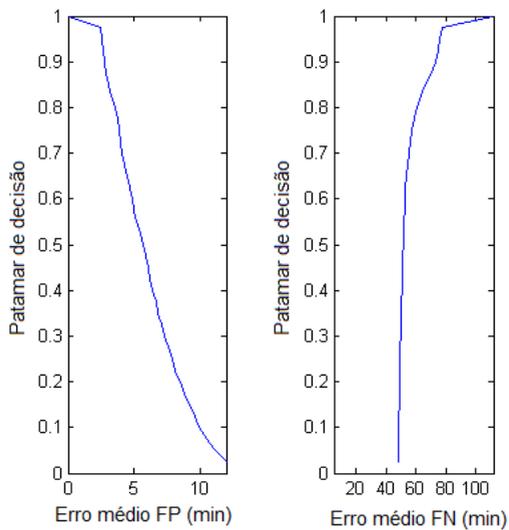
(a)



(b)



(c)

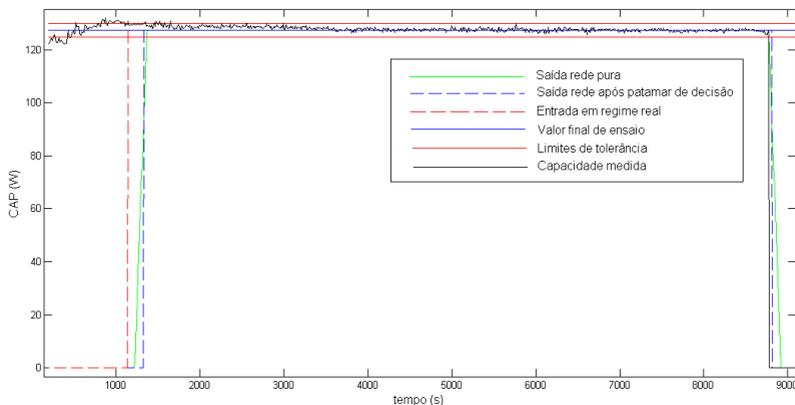


(d)

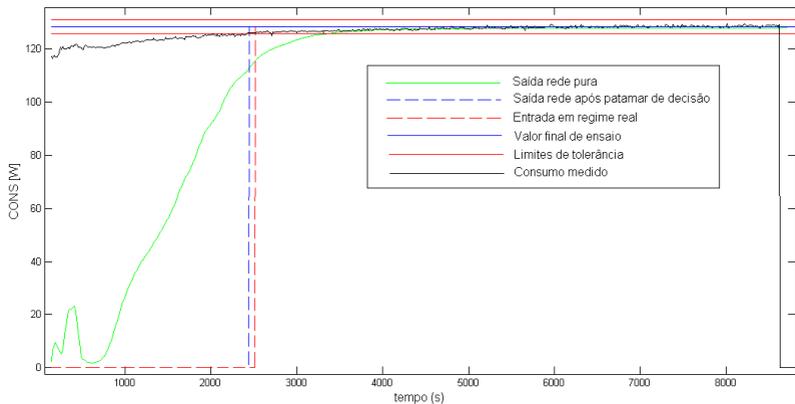
Figura 35 – Erro médio de FP e FN em função do patamar decisão:
 (a) Rede regime CAP; (b) Rede regime CONS; (c) Rede regime COP. (d) Rede regime Tcorpo

Como pode ser visto na figura 35, quanto maior o patamar de decisão, menor é o erro de FP, maior o erro de FN e maior a sensibilidade a possíveis oscilações na saída da rede. Os patamares de decisão foram escolhidos de forma a garantir um erro médio de FP de, no máximo, 5 min. Os valores escolhidos para os patamares de decisão foram os seguintes: 0,70 para a rede de regime da CAP; 0,88 para a rede de regime do CONS; 0,7 para a rede de regime do COP; 0,6 para a rede de regime da Tcorpo.

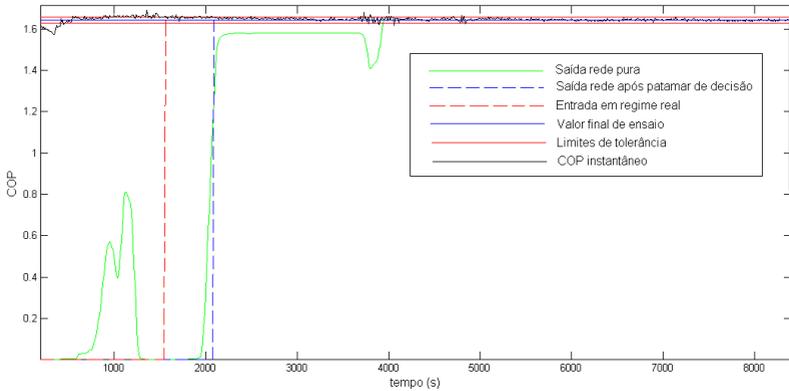
A figura 36 apresenta a saída da rede de regime para ensaios não utilizados no treinamento, referente às redes de CAP, CONS, COP e Tcorpo, respectivamente. Nesses gráficos pode-se comparar o instante de entrada em regime real com a saída da rede.



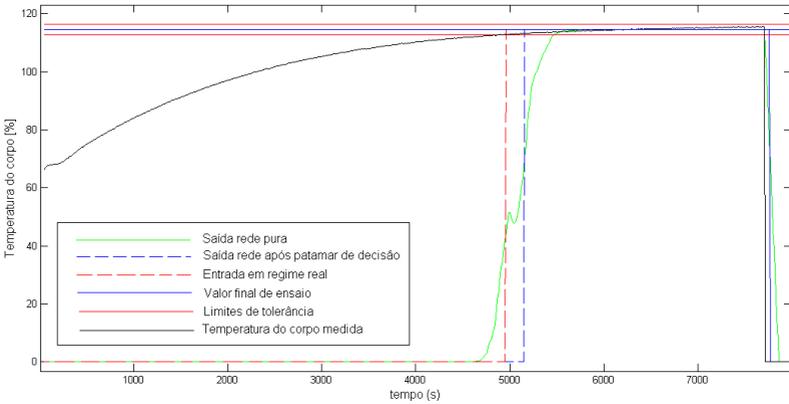
(a)



(b)



(c)



(d)

Figura 36 – Saída rede de regime: (a) CAP. (b) CONS. (c) COP. (d) Tcorpo.

Mesmo após a definição do patamar de decisão, a saída definitiva da rede²⁸ pode apresentar oscilações em função de variações na saída pura da rede que podem vir a acontecer. Para ilustrar tal situação, a figura 37 apresenta a saída da rede de COP para um determinado ensaio. Pode-se notar uma oscilação de aproximadamente 90 segundos na saída definitiva da rede. Torna-se necessário definir um tempo de espera mínimo (T_{esp}) para a confirmação da saída da rede. Esse tempo funciona como um filtro para oscilações na saída da rede. A detecção de regime pela rede só será confirmada se a saída definitiva da rede permanecer em nível alto durante, pelo menos, um tempo igual ao tempo de espera. A

²⁸ Saída da rede após passar pelo patamar de decisão.

escolha do tempo de espera foi feita após a análise de todos os gráficos de saída da rede para o conjunto de teste. Tomou-se como tempo de espera o maior tempo encontrado de oscilação na saída definitiva da rede. Os valores escolhidos para os tempos de espera foram os seguintes: 400 segundos para a rede de regime da CAP; 300 segundos para a rede de regime do CONS; 560 segundos para a rede de regime do COP; 440 segundos para a rede de regime da Tcorpo.

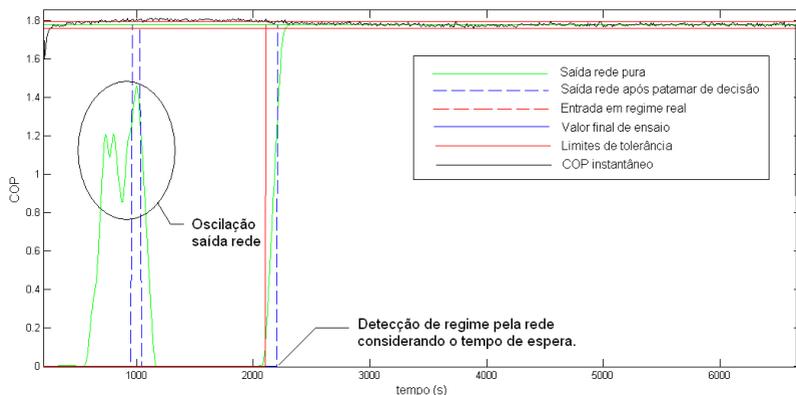


Figura 37 – Oscilação na saída da rede de regime do COP.

Os tempos de entrada em regime pela rede, considerando o tempo de espera, são comparados aos tempos de entrada em regime real para todos os ensaios de teste. O maior tempo de falso positivo encontrado (Tfp), após essa comparação, é definido como o tempo de espera definitivo para confirmação da rede de regime. Esse tempo deve ser, no mínimo, igual ao tempo de espera ($T_{fp} \geq T_{esp}$) e tem a função de evitar a ocorrência de FP, bem como de filtrar oscilações na saída da rede. Os valores escolhidos para o Tfp foram os seguintes: 400 segundos para a rede de regime da CAP; 440 segundos para a rede de regime do CONS; 720 segundos para a rede de regime do COP; 480 segundos para a rede de regime da Tcorpo.

Após as definições do patamar de decisão, do Tesp e do Tfp, procede-se à análise do resultado da rede propriamente dito. Tal análise, no caso das redes de regime da CAP, COP e CONS, é feita observando os resultados de erro percentual do VMC²⁹, em relação ao valor final de

²⁹ Conforme dito em 4.4, as redes de regime devem garantir que a variável realmente se encontre na região de regime permanente e não apresente tendência a sair dos limites de tolerân-

ensaio, nos instantes de detecção de entrada em regime pela rede neural³⁰ para o conjunto de teste. Para tanto, é gerado um histograma desses erros percentuais. A rede é treinada e os demais parâmetros ajustados (patamar de decisão; Tesp; Tfp) de forma a se almejar um histograma do erro percentual do VMC o menos disperso possível e compreendido nos limites de $\pm 2\%$. A figura 38 apresenta os histogramas de erros percentuais referentes ao último treinamento realizado para as redes de CAP, CONS e COP, respectivamente.

cia. Essa região deve ser a mais propícia para realizar a inferência. Por isso a análise é feita no VMC encontrado nesse ponto.

³⁰ Entrada em regime considerando aplicação do Tesp e do Tfp.

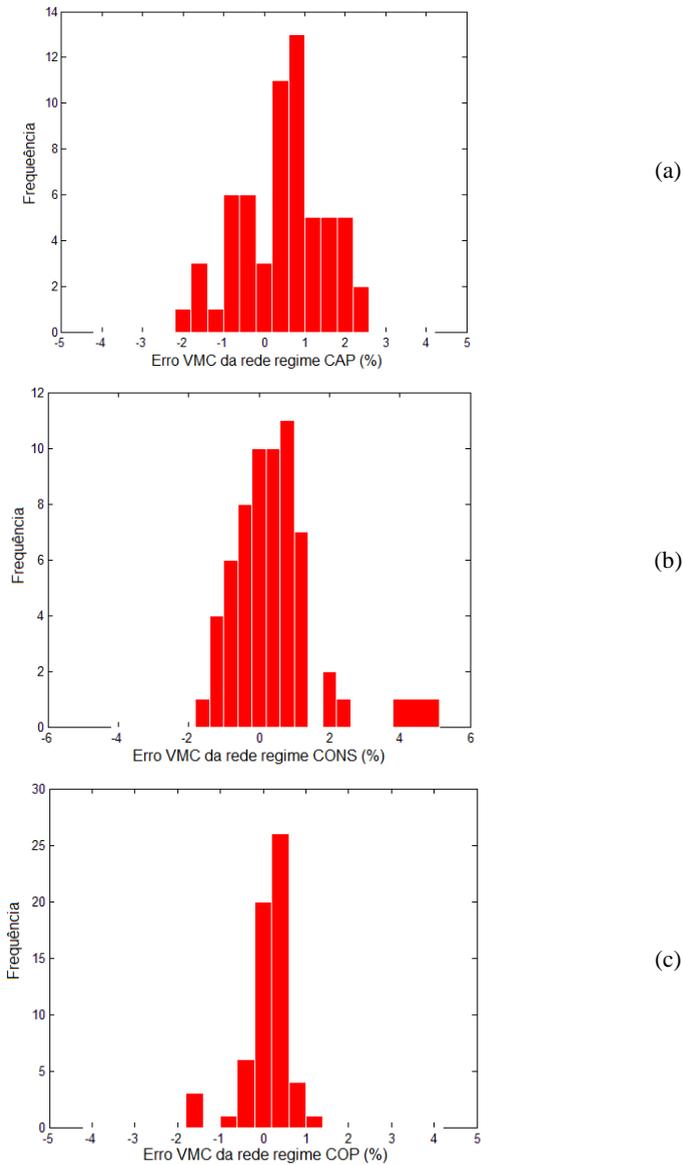


Figura 38 – Histograma do erro VMC (%) na detecção do regime: (a) CAP. (b) CONS. (c) COP.

5.1.4.2. Rede de inferência

Após treinamento, as redes de inferência são simuladas para o conjunto de teste. A janela utilizada para a simulação não é a mesma utilizada durante o treinamento. Enquanto esta tem seu início nos tempos de entrada real em regime, aquela tem seu início nos tempos de entrada em regime pela rede de regime somado ao Tfp. O fim da janela corresponde ao maior tempo de falso negativo encontrado (Tfn) após comparação dos tempos de entrada em regime pela rede de regime aos tempos de entrada em regime real para os ensaios de teste. Durante o período da janela de simulação é realizada uma inferência a cada instante de amostragem, sendo que o tempo entre amostras é de 10 segundos.

A figura 39 apresenta as curvas de erro percentual da inferência da capacidade em relação ao valor final de ensaio, referente ao instante inicial e final da janela de simulação.

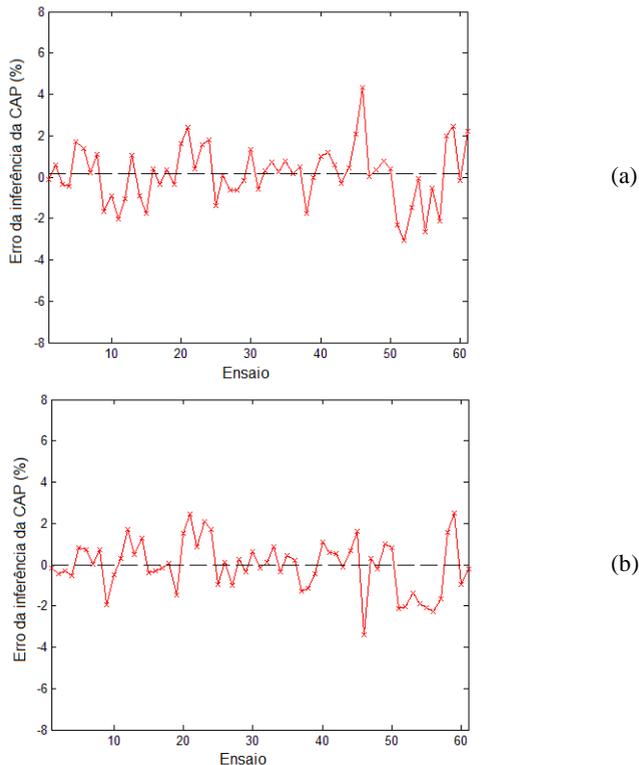
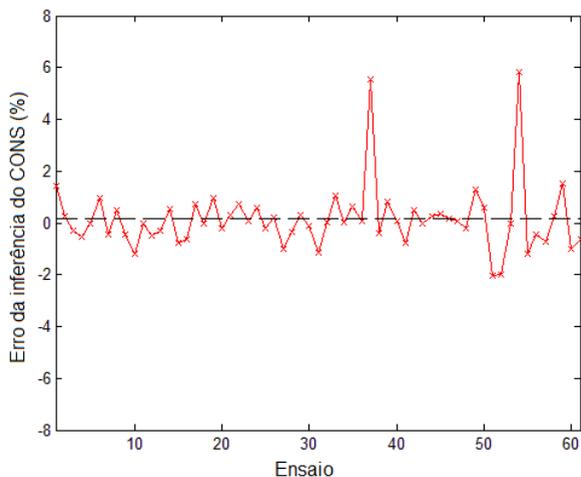
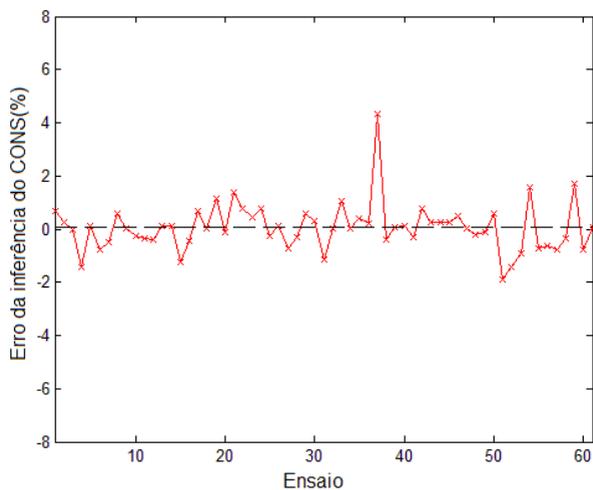


Figura 39 – Erro percentual da inferência da CAP:
(a) Início da janela de simulação. (b) Fim da janela de simulação.

A figura 40 apresenta as curvas de erro percentual da inferência do consumo em relação ao valor final de ensaio, referente ao instante inicial e final da janela de simulação.



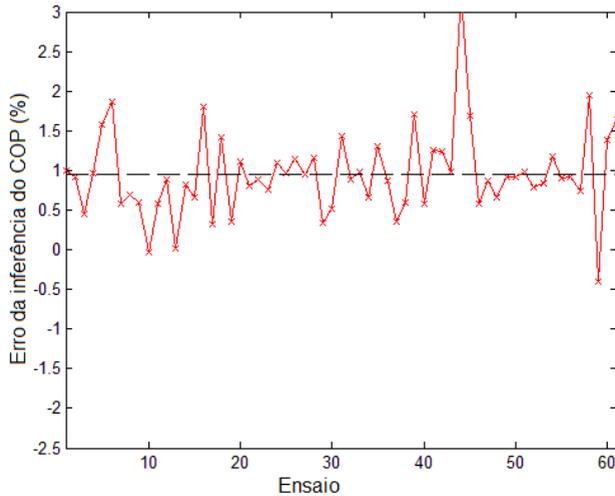
(a)



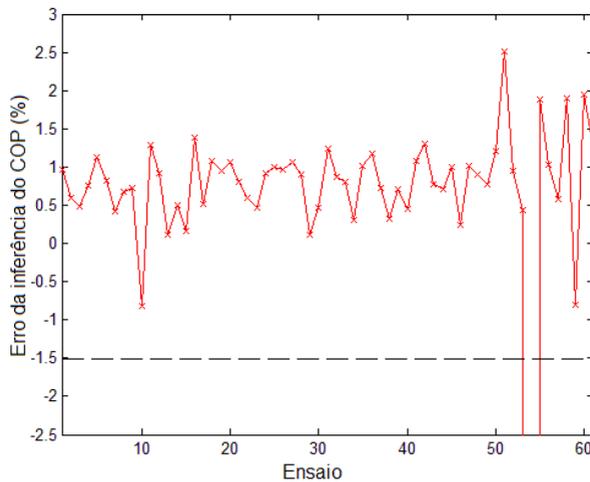
(b)

Figura 40 - Erro percentual da inferência do CONS:
(a) Início da janela de simulação. (b) Fim da janela de simulação.

A figura 41 apresenta as curvas de erro percentual da inferência do COP em relação ao valor final de ensaio, referente ao instante inicial e final da janela de simulação.



(a)



(b)

Figura 41 - Erro percentual da inferência do COP:
(a) Início da janela de simulação. (b) Fim da janela de simulação.

5.2. Programação do sistema neural em Labview

Os módulos neurais, com suas respectivas redes treinadas, foram implementados em Labview para compor o sistema neural a ser implantado em bancada de ensaios na empresa parceira. A figura 42 apresenta o blocodiagrama do sistema neural programado em Labview, contendo o fluxo de informações trocado entre os módulos.

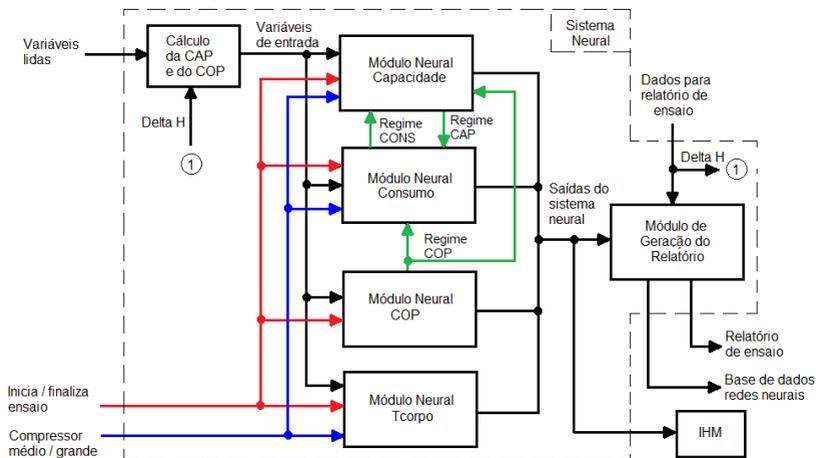


Figura 42 – Blocodiagrama do sistema neural programado.

Abaixo seguem as descrições dos sinais apresentados na figura 42:

- Variáveis lidas – são as variáveis lidas do processo pelo PXI e enviadas ao sistema neural via PC supervisor. São elas: potência elétrica consumida; pressão de sucção; vazão mássica; temperatura da carcaça.
- Variáveis de entrada – A partir das variáveis lidas e da variação de entalpia (Delta H), a CAP e o COP são obtidos. Tais variáveis, juntamente com a potência elétrica consumida (CONS), a pressão de sucção e a temperatura da carcaça, formam as variáveis de entrada dos módulos neurais.
- Inicia / finaliza ensaio – Informação *booleana*, proveniente do PC supervisor, que excursiona de 0 para 1 no início do ensaio, e de 1 para 0 no final do ensaio. Tal informação é essencial para a zeragem dos *buffers* dos módulos neurais e estabelecimento dos tempos de início e fim de ensaio.

- Compressor médio / grande – Informação *booleana*, proveniente do PC supervisor, que apresenta nível 0 quando se ensaia compressor grande e nível 1 quando se ensaia compressor médio. Essa informação é útil no processo de equalização das variáveis de entrada, conforme já explicado no item 4.2.2.2.
- Dados para relatório de ensaio – Informações provenientes do PC supervisor e utilizadas na geração do relatório de ensaio, bem como no cálculo da CAP e do COP instantâneos. Tais informações contemplam: CAP final; CONS final; COP final; modelo compressor; nº lims; nº condição; nº amostra; nº repetição; rotação nominal do inversor; data; tensão; frequência; temperatura de evaporação; temperatura de condensação; tipo de fluido; delta H.
- Regime CONS – Informação *booleana* enviada do Módulo Neural Consumo para o Módulo Neural Capacidade, que vai do nível 0 para 1 quando o regime do CONS é detectado pela rede neural.
- Regime CAP – Informação *booleana* enviada do Módulo Neural Capacidade para o Módulo Neural Consumo, que vai do nível 0 para 1 quando o regime da CAP é detectado pela rede neural.
- Regime COP – Informação *booleana* enviada do Módulo Neural COP para o Módulo Neural Capacidade e Módulo Neural Consumo, que vai do nível 0 para 1 quando o regime do COP é detectado pela rede neural.
- Saídas do sistema neural – Contém as informações enviadas à subVI de geração do relatório e à IHM para visualização do operador. Tais informações contemplam as inferências das redes, os instantes de detecção em regime pelas redes e os gráficos de ensaio.
- Relatório de ensaio – Relatório gerado em Excel contendo as informações do ensaio (provenientes dos “Dados para relatório de ensaio”), os resultados das redes (inferências; erros de inferência; tempos de regime; medições no regime da Tcorpo; medições em 30 min) e os gráficos em função do tempo da CAP, do CONS, do COP e da Tcorpo. Tais gráficos auxiliam na análise de desempenho das redes, pois contemplam não somente o registro instantâneo de cada variável, mas

também os limites de tolerância, o valor final de ensaio e a detecção de entrada em regime pela rede.

- **Base de dados redes neurais** – Base de dados dos ensaios, gerada em formato *txt*, contendo todas as informações de cada relatório de ensaio gerado.

O objetivo dos relatórios de ensaio e da base de dados das redes neurais é formar um histórico para futuras análises e conclusões a respeito do desempenho das técnicas neurais utilizadas.

Os Módulos Neurais da figura 42, juntamente com o Módulo de Geração do Relatório, constituem as subVIs do sistema neural, assim descritas: Rede Capacidade.vi; Rede Consumo.vi; Rede COP.vi; Rede Temperatura.vi; Gera Relatório.vi. A VI do sistema neural “Rede Neural Calorímetro.vi” implantada na VI principal da bancada de ensaio, com suas entradas e saídas, é apresentada na figura 43.

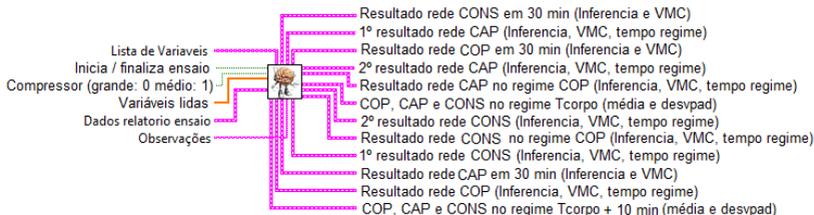


Figura 43 – Rede Neural Calorímetro.vi

A figura 44 apresenta a subVI do Módulo Neural Capacidade “Rede Capacidade.vi” com suas entradas e saídas.

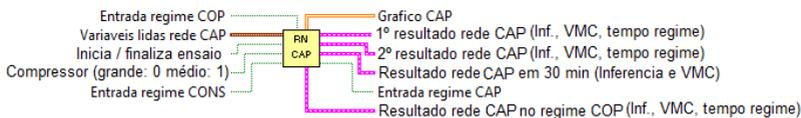


Figura 44 – Rede Capacidade.vi

A figura 45 apresenta a subVI do Módulo Neural Consumo “Rede Consumo.vi” com suas entradas e saídas.

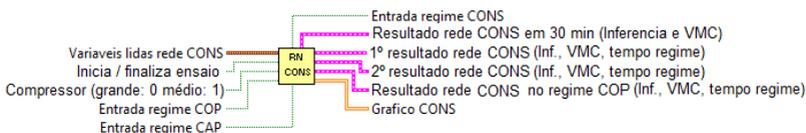


Figura 45 – Rede Consumo.vi

A figura 46 apresenta a subVI do Módulo Neural COP “Rede COP.vi” com suas entradas e saídas.

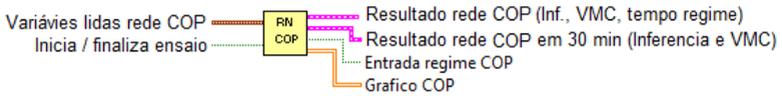


Figura 46 – Rede COP.vi

A figura 47 apresenta a subVI do Módulo Neural Tcorpo “Rede Temperatura.vi” com suas entradas e saídas.

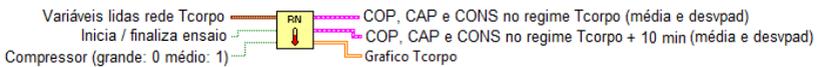


Figura 47 – Rede Temperatura.vi

A figura 48 apresenta a subVI do Módulo de Geração do Relatório “Gera Relatorio.vi” com suas entradas e saídas.

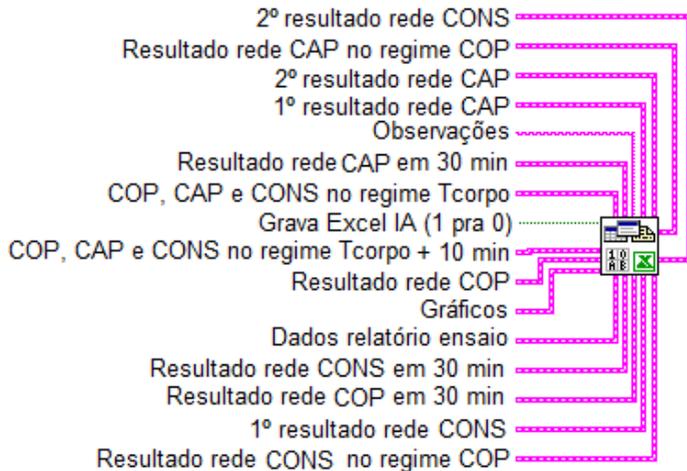


Figura 48 – Gera Relatorio.vi

Neste capítulo foram apresentadas as etapas de programação do sistema neural nos *softwares* Matlab e Labview. Os resultados alcançados são apresentados e analisados no capítulo seguinte.

6. ANÁLISE DOS RESULTADOS

Após o treinamento das redes neurais, o sistema neural foi implementado em Labview e, em seguida, implantado na bancada de ensaio de desempenho da empresa parceira. O objetivo nesta etapa foi levantar o desempenho operacional do sistema neural frente a ensaios rotineiros na empresa, no que tange aos tempos de resposta das redes e ao erro de inferência das redes em relação ao valor final de ensaio. Em outras palavras, deseja-se saber se há um ganho de tempo efetivo e se a resposta da rede é confiável.

Para o ganho de tempo das redes não há um valor de referência a ser atingido. Na realidade, é interessante que esse ganho de tempo seja o maior possível. Já para o erro de inferência das redes em relação ao valor final de ensaio, deseja-se que os mesmos estejam compreendidos nos seguintes limites definidos como metas para o presente trabalho: 2 % para CAP, 2% para CONS e 3 % para COP.

O sistema neural foi submetido a 30 ensaios conforme os requisitos estabelecidos na tabela 8 do item 4.5. A única diferença em relação a tais requisitos foi relativa a um dos métodos de ensaio utilizados. Apesar das redes terem sido treinadas com dados de ensaios que utilizaram os métodos C e F (ISO 917, 1989), o sistema neural foi testado em bancada de desempenho utilizando os métodos A e F (ISO 917, 1989).

O método A é semelhante ao método C (já descrito no item 2.3.2.1), possuindo a mesma formulação matemática, mas com a diferença que o calor é cedido ao fluido refrigerante por meio de uma fonte de calor imersa num fluido secundário no interior de um vaso de pressão. A evaporação do refrigerante ocorre dentro de uma serpentina ou câmara que separa o refrigerante do fluido secundário. A escolha do método A no lugar do método C foi uma decisão da empresa parceira. O método usual na empresa - e também em nível mundial - é o método A como alternativa ao método F. Acontece que, de forma concomitante a este trabalho, foi avaliada a adequação de utilização do método C na bancada de ensaios. Tal avaliação coincidiu com a etapa de levantamento de dados para treinamento das redes.

A análise dos resultados foi subdividida em sete tópicos:

- resultados do Módulo Neural Capacidade;
- resultados do Módulo Neural Consumo;
- resultados do Módulo Neural COP;
- COP obtido a partir dos módulos neurais de capacidade e consumo;
- resultados do módulo neural da temperatura do corpo;

- medições na entrada em regime da temperatura do corpo;
- medições na entrada em regime da temperatura do corpo + 10 min.

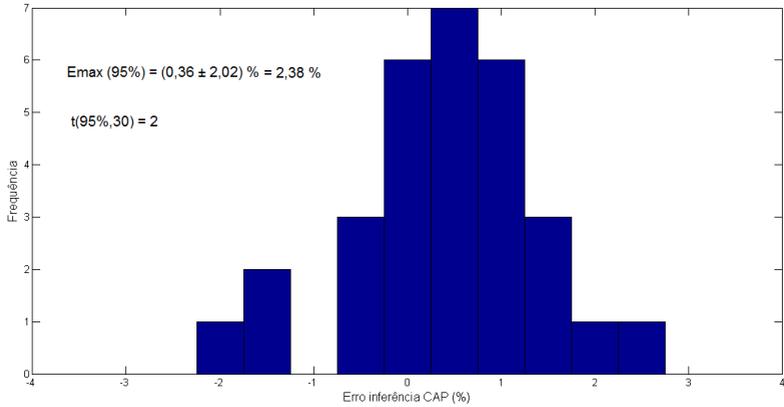
6.1. Resultados do módulo neural capacidade

Conforme já descrito no item 4.1, o Modulo Neural Capacidade fornece os resultados de inferência e VMC desta variável em três instantes: no instante da detecção de entrada em regime pela rede de capacidade; no instante da detecção de entrada em regime pela rede de consumo (somente se a detecção de entrada em regime da rede de capacidade entrar antes da detecção de entrada em regime da rede de consumo³¹); no instante da detecção de entrada em regime pela rede do COP.

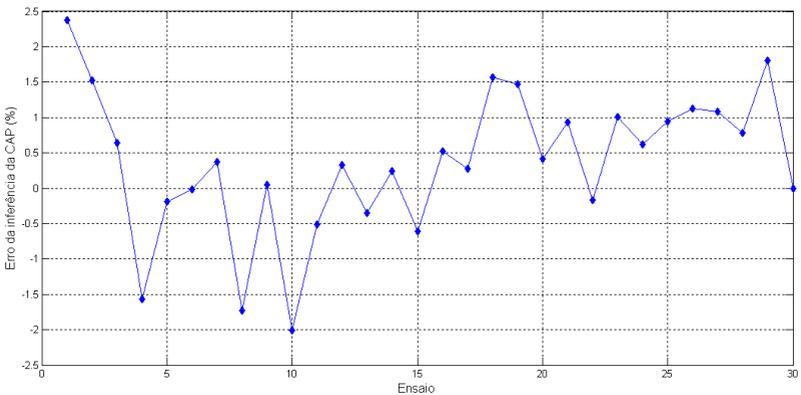
Para a análise dos erros percentuais da capacidade em relação ao valor final de ensaio foram levantados dois histogramas: erro percentual da inferência da capacidade no instante de detecção de entrada em regime pela rede neural de capacidade e erro percentual do VMC da capacidade no instante de detecção de entrada em regime pela rede neural de capacidade. Também foi levantado o histograma do ganho de tempo em relação ao tempo final de ensaio para os dois casos descritos acima.

A figura 49 apresenta o histograma do erro percentual em relação ao valor final de ensaio para a inferência da capacidade no instante de detecção de entrada em regime pela rede neural de capacidade, bem como o gráfico desse erro percentual em função de cada ensaio.

³¹ Referir-se ao item 4.1 para maiores detalhes.



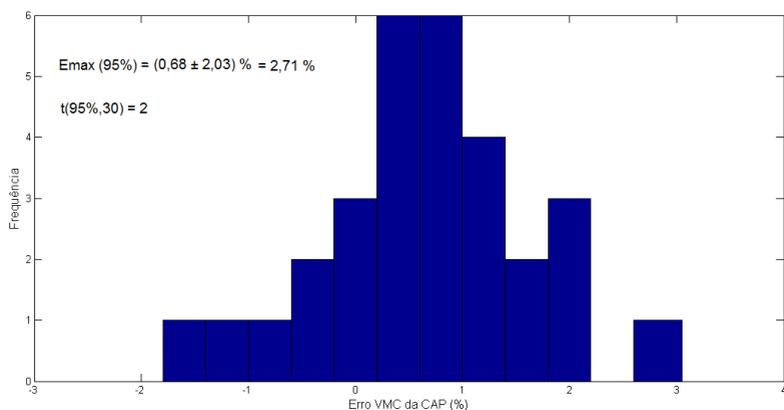
(a)



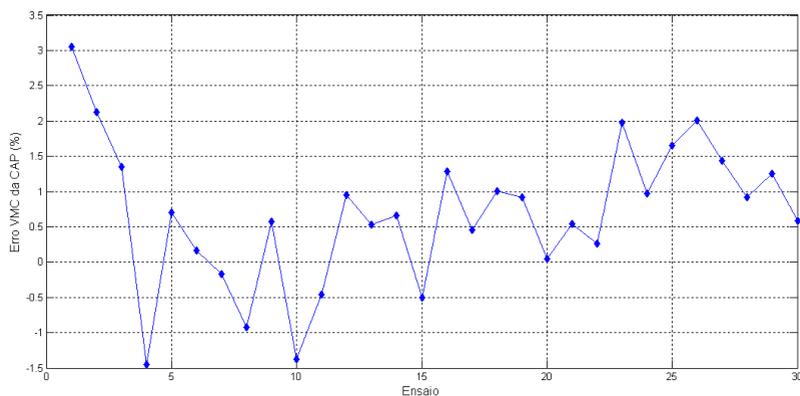
(b)

Figura 49 – Erro percentual inferência CAP: (a) Histograma de erro.
(b) Erro de Inferência % x ensaio.

A figura 50 apresenta o histograma do erro percentual em relação ao valor final de ensaio para o VMC da capacidade no instante de detecção de entrada em regime pela rede neural de capacidade, bem como o gráfico deste erro percentual em função de cada ensaio.



(a)



(b)

Figura 50 - Erro percentual VMC CAP: (a) Histograma de erro.
(b) Erro do VMC % x ensaio.

Como pode ser visto na figura 49 e figura 50, os erros percentuais da inferência e do VMC da capacidade no instante de detecção de entrada em regime pela rede neural de capacidade ficaram concentrados na faixa de $\pm 2\%$, o que é bastante positivo uma vez que essa faixa corresponde aos limites de erro de inferência definidos pela empresa parceira. Uma quantidade expressiva dos ensaios apresentou erro percentual da inferência (20 ensaios) e do VMC (19 ensaios) entre $\pm 1\%$.

Ainda na figura 49 e figura 50, percebe-se que o 1º ensaio apresentou erros de inferência e VMC da capacidade bem acima de 2%. A figura 51 apresenta o registro da variável capacidade desse ensaio con-

templando o instante de detecção de entrada em regime pela rede neural de capacidade. Analisando a figura 51 percebe-se que houve uma detecção prematura do instante de entrada em regime da capacidade e que a variável capacidade apresenta uma derivada elevada com uma tendência a sair do limite superior de tolerância. Conforme já explicado no item 4.4, essa condição de variação dinâmica elevada não é propícia para a inferência do valor final de ensaio. Isso justifica um erro de inferência e de VMC acima dos 2%.

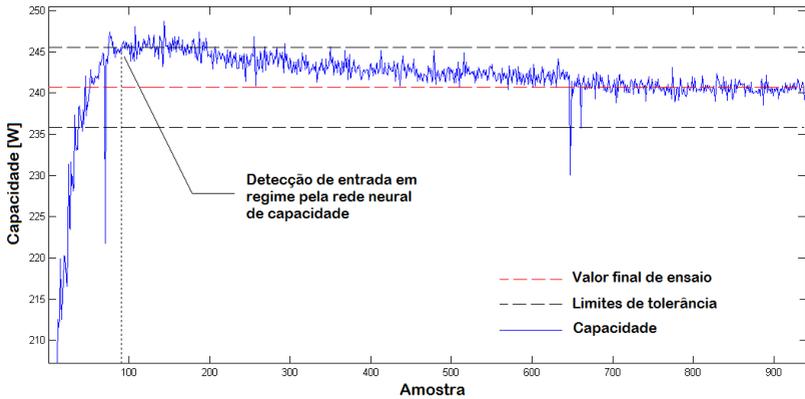


Figura 51 - Detecção prematura de entrada em regime da capacidade

A figura 52 apresenta o histograma do ganho de tempo percentual em relação ao tempo final de ensaio para a inferência e o VMC da capacidade no instante de detecção de entrada em regime pela rede neural de capacidade, bem como o gráfico deste ganho de tempo percentual em função de cada ensaio.

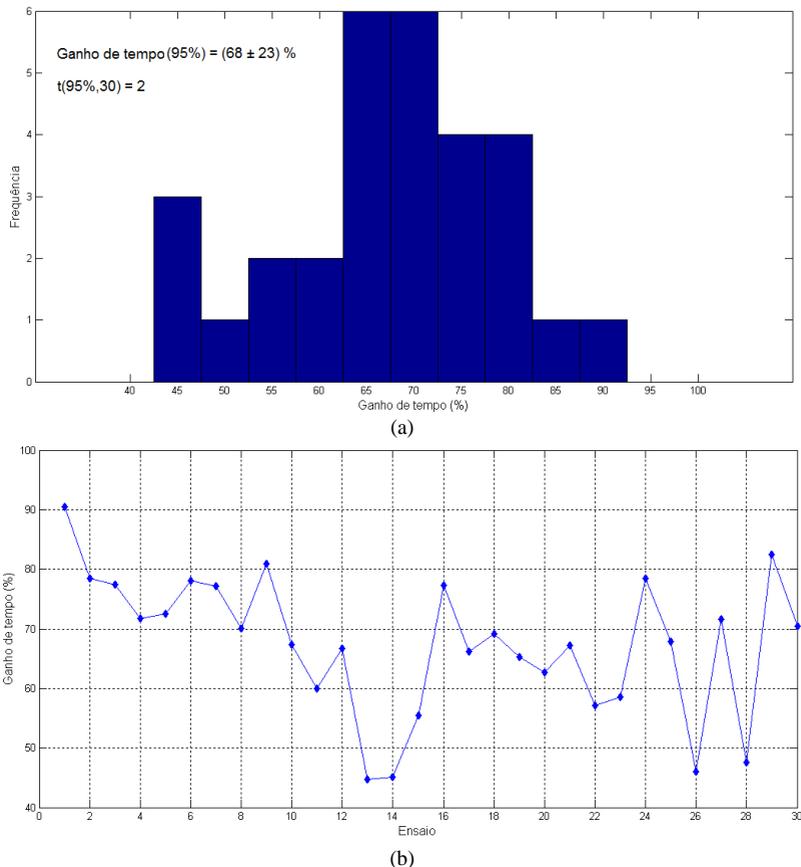


Figura 52 – Ganho percentual de tempo para a inferência e VCM da CAP:
 (a) Histograma. (b) Ganho de tempo % x ensaio.

Como pode ser visto na figura 52, os ganhos de tempo percentuais em relação ao tempo de ensaio para a inferência e o VCM no instante de detecção da entrada em regime pela rede de capacidade são expressivos, com sua grande maioria concentrada entre 60 % e 80 %. O ganho de tempo de 90 % referente ao 1º ensaio não pode ser tão comemorado, uma vez que esse ensaio apresentou uma detecção prematura de entrada em regime da capacidade e erros percentuais de inferência e de VCM acima de 2 %. Um ganho de tempo só se torna efetivo se a ele está associado a um aceitável erro percentual de inferência e de VCM da capacidade.

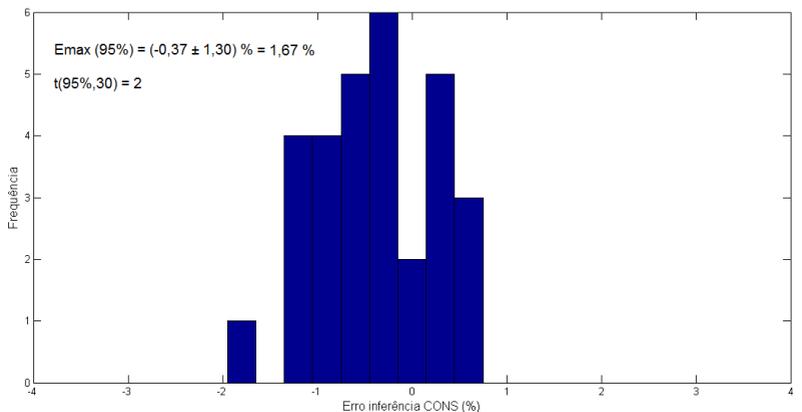
6.2. Resultados do módulo neural consumo

Conforme já descrito no item 4.1, o Módulo Neural Consumo fornece os resultados de inferência e VMC dessa variável em três instantes: no instante da detecção de entrada em regime pela rede de consumo; no instante da detecção de entrada em regime pela rede de capacidade (somente se a detecção de entrada em regime da rede de consumo entrar antes da detecção de entrada em regime da rede de capacidade³²); no instante da detecção de entrada em regime da rede do COP.

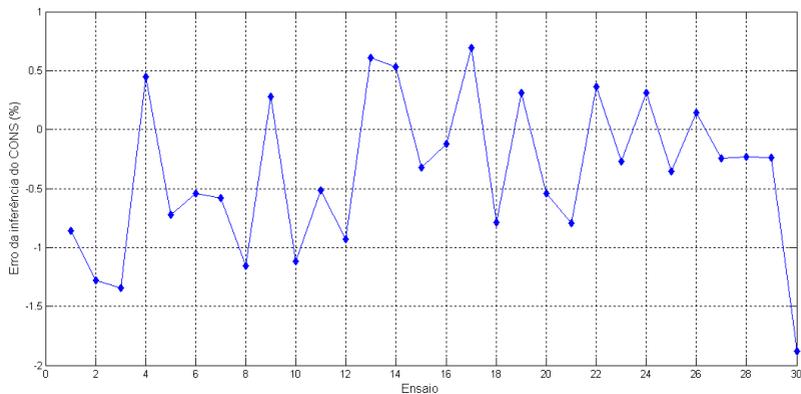
Para análise dos erros percentuais do consumo em relação ao valor final de ensaio foram levantados dois histogramas: erro percentual da inferência do consumo no instante de detecção de entrada em regime pela rede neural do consumo; erro percentual do VMC do consumo no instante de detecção de entrada em regime pela rede neural do consumo. Também foi levantado o histograma do ganho de tempo em relação ao tempo final de ensaio para os dois casos descritos acima.

A figura 53 apresenta o histograma do erro percentual em relação ao valor final de ensaio para a inferência do consumo no instante de detecção de entrada em regime pela rede neural do consumo, bem como o gráfico deste erro percentual em função de cada ensaio.

³² Referir-se ao item 4.1 para maiores detalhes.



(a)

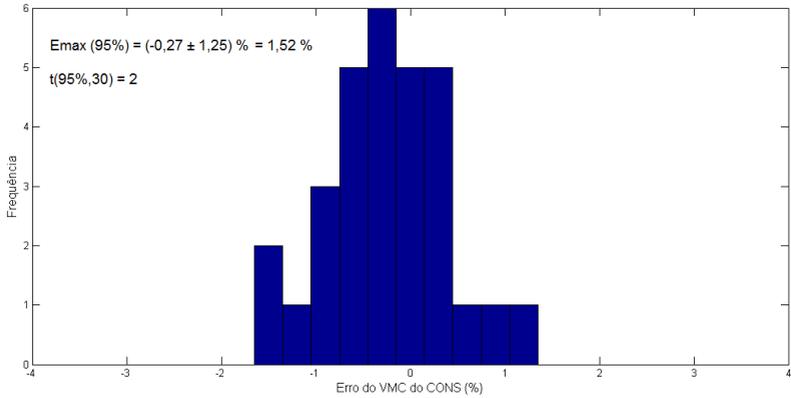


(b)

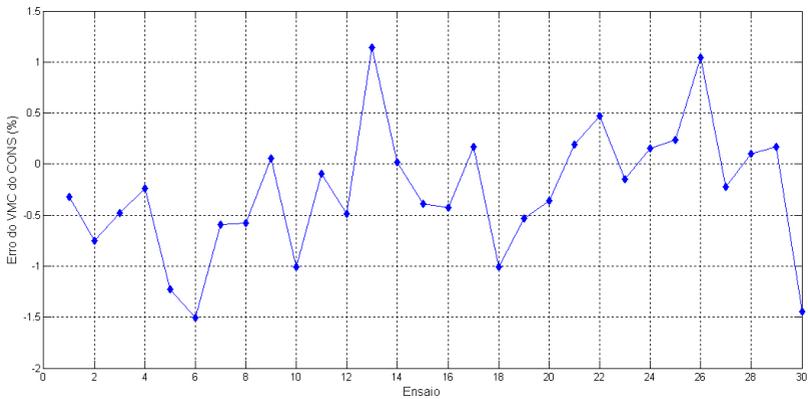
Figura 53 - Erro percentual inferência CONS: (a) Histograma de erro.

(b) Erro de inferência % x ensaio.

A figura 54 apresenta o histograma do erro percentual em relação ao valor final de ensaio para o VMC do consumo no instante de detecção de entrada em regime pela rede neural do consumo, bem como o gráfico deste erro percentual em função de cada ensaio.



(a)

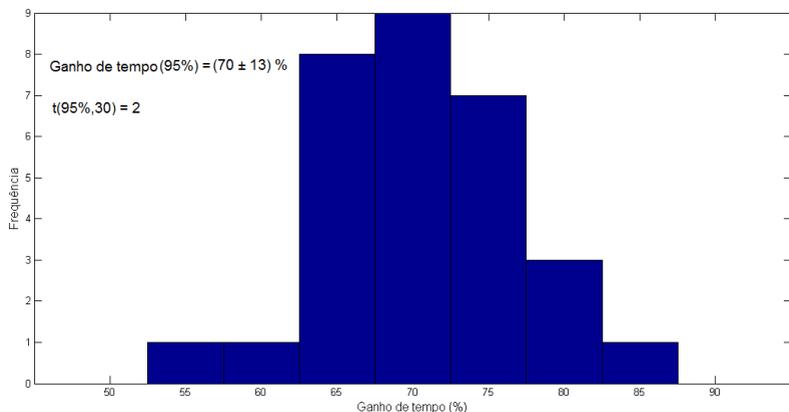


(b)

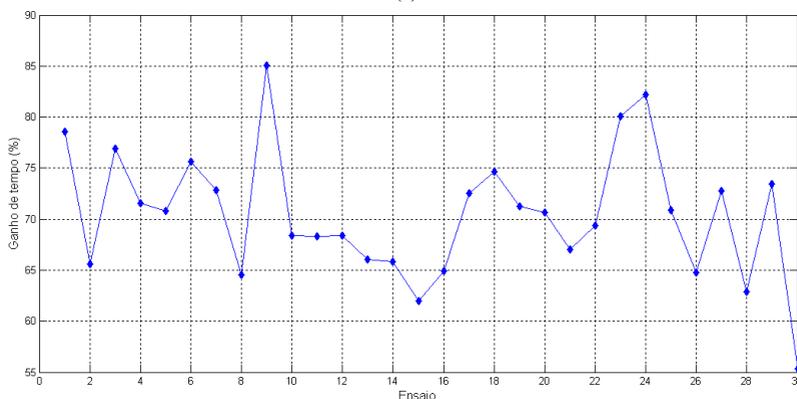
Figura 54 - Erro percentual do VCM do CONS: (a) Histograma de erro.
 (b) Erro do VCM % x ensaio.

Como pode ser visto na figura 53 e figura 54, os erros percentuais da inferência e do VCM do consumo no instante de detecção de entrada em regime pela rede neural de consumo não ultrapassaram os limites de $\pm 2 \%$, sendo que a grande maioria dos ensaios apresentou erro percentual da inferência (25 ensaios) e do VCM (25 ensaios) entre $\pm 1 \%$.

A figura 55 apresenta o histograma do ganho de tempo percentual em relação ao tempo final de ensaio para a inferência e o VCM do consumo no instante de detecção de entrada em regime pela rede neural do consumo, bem como o gráfico deste ganho de tempo percentual em função de cada ensaio.



(a)



(b)

Figura 55 - Ganho percentual de tempo para a inferência e VCM do CONS:
 (a) Histograma. (b) Ganho de tempo % x ensaio.

Como pode ser visto na figura 55, os ganhos de tempo percentuais em relação ao tempo de ensaio para a inferência e o VMC no instante de detecção da entrada em regime pela rede de consumo são expressivos, com sua grande maioria concentrada entre 65 % e 80 %.

6.3. Resultados do módulo neural COP

Conforme já descrito no item 4.1, o Módulo Neural COP fornece os resultados de inferência e VMC desta variável no instante da detecção de entrada em regime da rede do COP.

Para a análise dos erros percentuais do COP em relação ao valor final de ensaio foram levantados dois histogramas: erro percentual da

inferência do COP no instante de detecção de entrada em regime pela rede neural do COP e erro percentual do VCM do COP no instante de detecção de entrada em regime pela rede neural do COP. Também foi levantado o histograma do ganho de tempo em relação ao tempo final de ensaio para os dois casos citados acima.

A figura 56 apresenta o histograma do erro percentual em relação ao valor final de ensaio para a inferência do COP no instante de detecção de entrada em regime pela rede neural do COP, bem como o gráfico deste erro percentual em função de cada ensaio.

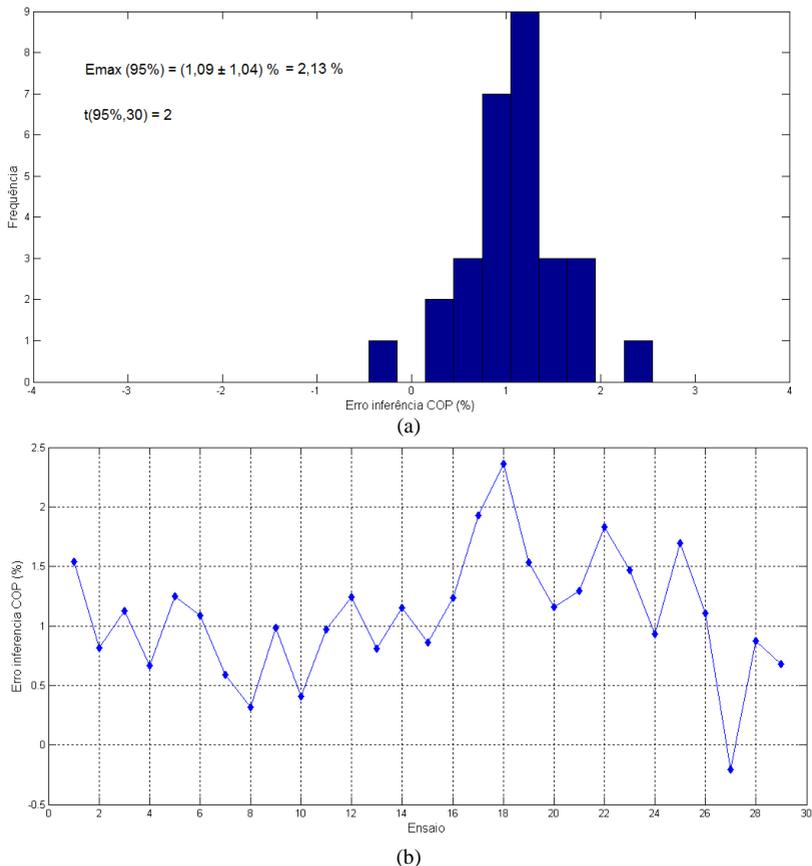


Figura 56 - Erro percentual inferência COP: (a) Histograma de erro.
(b) Erro do VCM % x ensaio.

A figura 57 apresenta o histograma do erro percentual em relação ao valor final de ensaio para o VMC do COP no instante de detecção de entrada em regime pela rede neural do COP, bem como o gráfico deste erro percentual em função de cada ensaio.

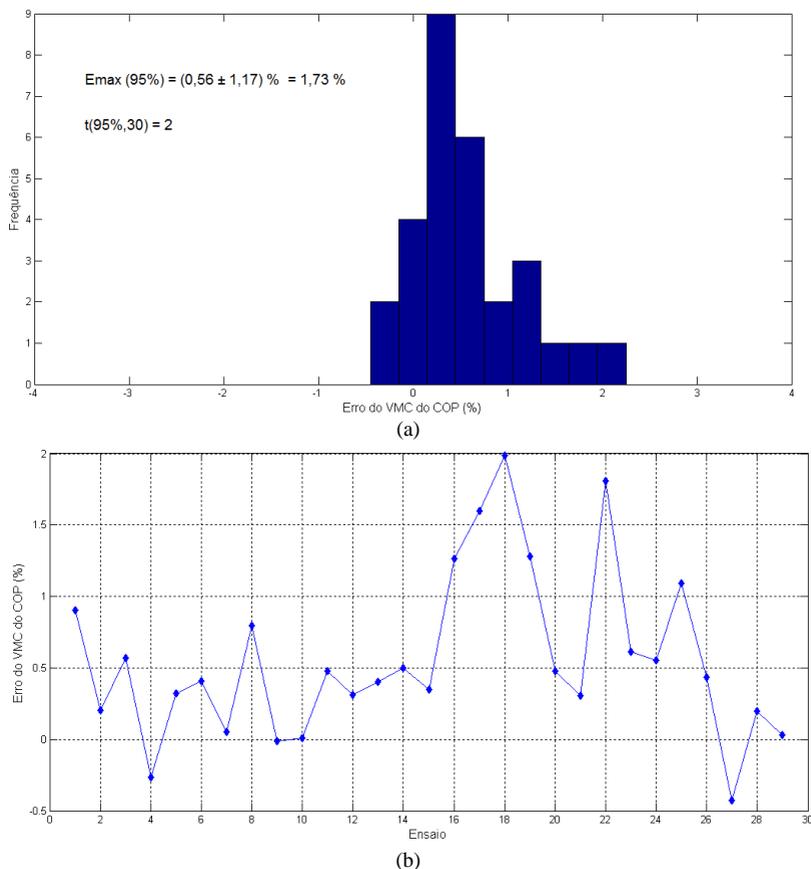


Figura 57 - Erro percentual do VMC do COP: (a) Histograma de erro.
(b) Erro do VCM % x ensaio.

Como pode ser visto na figura 56 e figura 57, os erros percentuais da inferência e do VMC do COP no instante de detecção de entrada em regime pela rede neural do COP não ultrapassaram os limites de $\pm 2\%$, exceto para um ensaio. A grande maioria dos ensaios apresentou erro percentual da inferência (23 ensaios) e do VMC (26 ensaios) entre -0.5% e 1.5% .

A rede de regime do COP não detectou o instante de entrada em regime desta variável para o sexto ensaio. Portanto, nas figuras figura 56, figura 57 e figura 59, o ensaio 6 corresponde na realidade ao ensaio 7, já o ensaio 7 corresponde ao ensaio 8, e assim sucessivamente. A razão exata da rede de regime do COP não ter atuado é difícil de dizer, até porque toda rede neural, após treinamento, ainda está susceptível a erros. Mas é bem provável que a rede tenha se perdido pelo fato da variável COP para este ensaio ter apresentado níveis elevados de variação dentro da faixa de tolerância, conforme pode ser constatado no registro desta variável na figura 58.

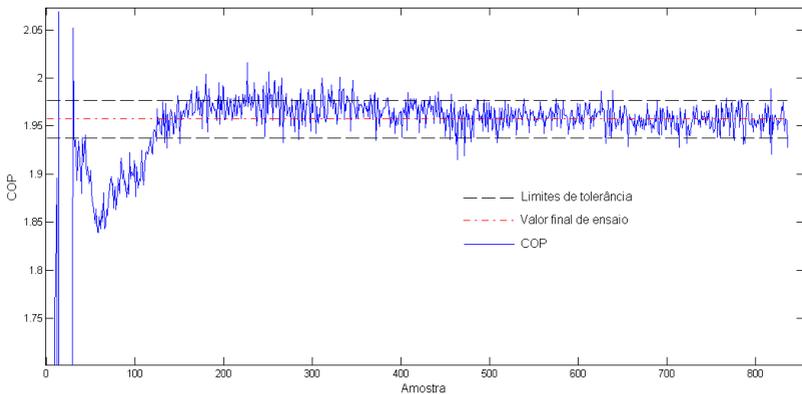


Figura 58 - Registro da variável COP para o ensaio 6.

A figura 59 apresenta o histograma do ganho de tempo percentual em relação ao tempo final de ensaio para a inferência e o VMC do COP no instante de detecção de entrada em regime pela rede neural do COP, bem como o gráfico deste ganho de tempo percentual em função de cada ensaio.

A figura 59 mostra que a grande maioria dos ensaios apresentou ganho percentual de tempo para inferência e VMC do COP entre 40 % e 60 %. Vê-se também que, em média, o ganho de tempo é de 50 % em relação ao tempo total de ensaio³³, o que é um ganho bastante expressivo.

³³ Este ganho de tempo médio foi calculado desconsiderando os *outliers* detectados com auxílio da ferramenta matemática Matlab.

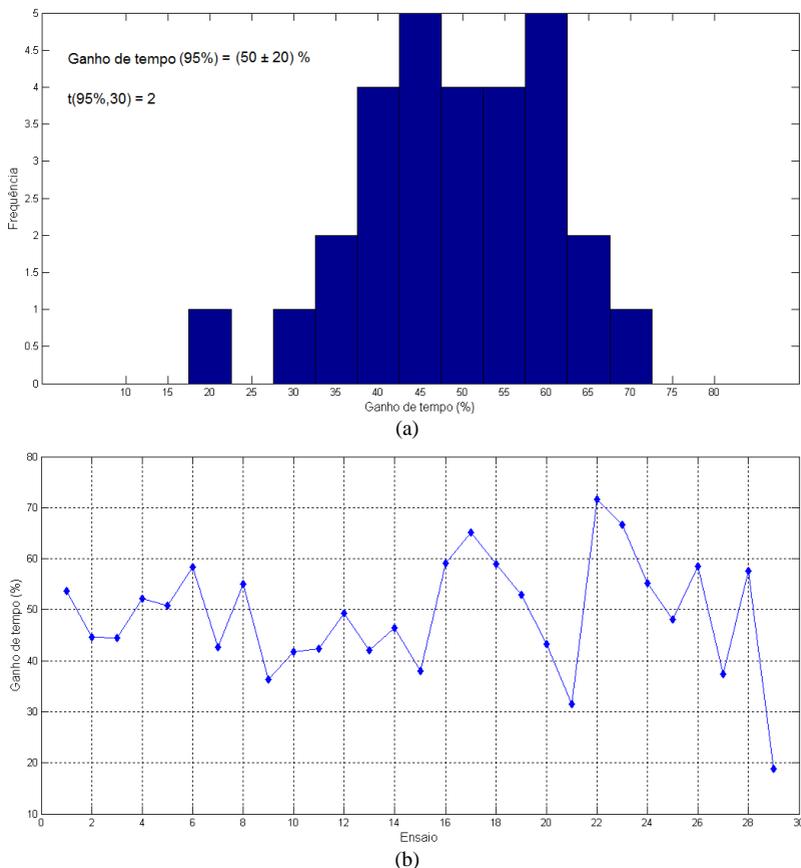


Figura 59 - Ganho percentual de tempo para a inferência e VCM do COP:
 (a) Histograma. (b) Ganho de tempo % x ensaio.

6.4. COP obtido a partir dos módulos neurais de capacidade e consumo

Conforme já descrito no item 4.1, o resultado do COP pode ser obtido a partir dos resultados de inferência e VMC fornecidos pelos módulos neurais de capacidade e consumo. Pretende-se com isso obter o resultado de COP, o mais breve possível, a partir das inferências de capacidade e consumo dadas por suas respectivas redes neurais. Obviamente, como já foi explicado no item 4.1, o instante em que o resultado do COP é fornecido corresponde ao instante no qual a última inferência, seja ela da capacidade ou do consumo, é fornecida.

Para a análise dos erros percentuais em relação ao valor final de ensaio do COP assim obtido, foram levantados dois histogramas: erro percentual do COP obtido a partir das inferências de capacidade e consumo; erro percentual do COP obtido a partir do VMC da capacidade e do consumo. Também foi levantado o histograma do ganho de tempo em relação ao tempo final de ensaio para os dois casos citados acima.

A figura 60 apresenta o histograma do erro percentual em relação ao valor final de ensaio para o COP obtido a partir das inferências de capacidade e consumo, bem como o gráfico deste erro percentual em função de cada ensaio.

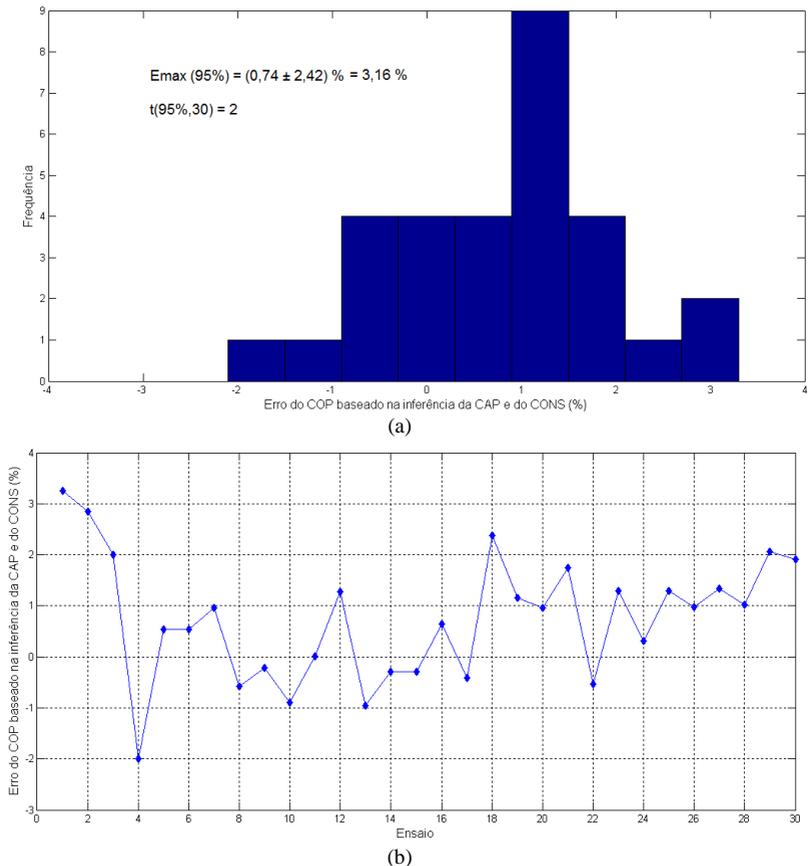


Figura 60 - Erro percentual do COP obtido a partir das inferências da CAP e do CONS: (a) Histograma de erro. (b) Erro do COP % x ensaio.

Analisando a figura 60, percebe-se que 27 ensaios apresentaram erro percentual do COP contido na faixa de $\pm 2\%$ e 3 ensaios apresentaram erro acima de 2% . Como o COP, neste caso, é obtido pela razão entre a inferência da capacidade e a inferência do consumo, o erro do COP em relação ao valor final de ensaio depende dos erros de inferência da capacidade e do consumo em relação aos seus respectivos valores finais de ensaio. Mas, nem sempre um alto erro no COP está associado somente a altos erros de inferência da capacidade ou do consumo. Muitas vezes uma combinação desses dois últimos erros leva a um alto erro no COP, apesar dos erros de inferência da capacidade e do consumo estarem individualmente dentro de valores aceitáveis. A tabela 10 ilustra bem esta situação para os 3 ensaios que apresentaram erro do COP acima de 2% .

Tabela 10 - Influência dos erros de inferência da CAP e CONS no erro do COP.

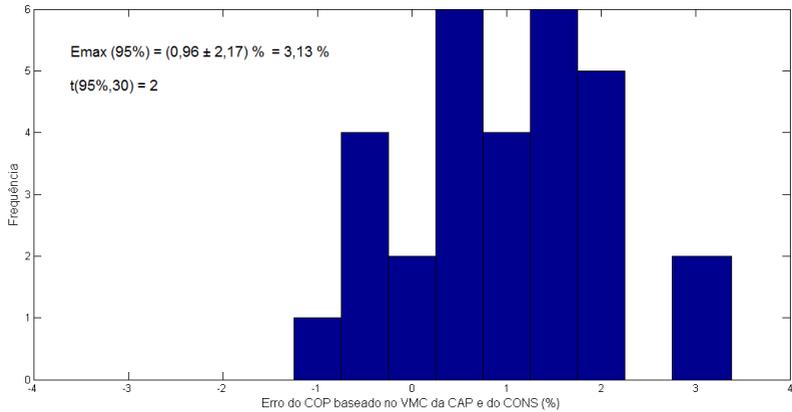
Ensaio	Erro inf. CAP (%)	Erro inf. CONS (%)	Erro COP (%)
1	2.38	-0.86	3.26
2	1.53	-1.28	2.84
18	1.57	-0.79	2.38

Analisando a tabela 10, percebe-se que os valores de erro do COP se devem a dois fatores: aos valores individuais de erro das inferências de capacidade e consumo e à combinação desses dois erros, já que tais erros são divergentes (o primeiro é positivo e o segundo negativo). Pode-se notar que, no caso dos ensaios 2 e 18, apesar dos erros individuais de inferência da capacidade e do consumo estarem dentro de limites aceitáveis (abaixo de 2%) a combinação entre eles levou a um erro no COP próximo do limite de tolerância (3%).

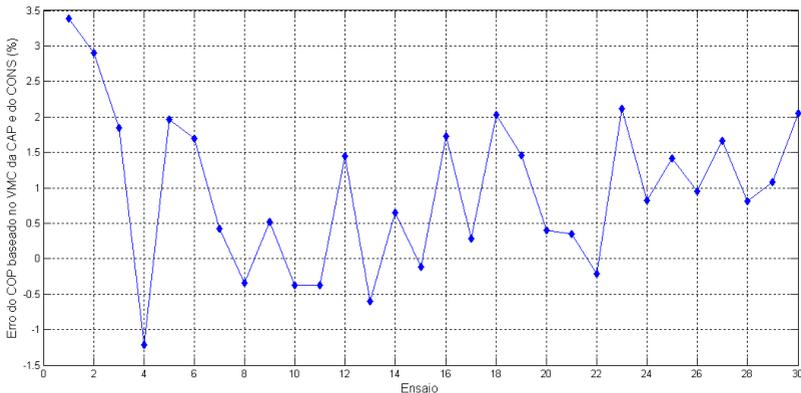
A figura 61 apresenta o histograma do erro percentual em relação ao valor final de ensaio para o COP obtido a partir do VMC da capacidade e do consumo, bem como o gráfico deste erro percentual em função de cada ensaio.

Analisando a figura 61, percebe-se que 25 ensaios apresentaram erro percentual do COP contido na faixa de $\pm 2\%$ e 5 ensaios apresentaram erro acima de 2% . O valor do COP aqui calculado é obtido pela razão entre o VMC da capacidade e o VMC do consumo. Portanto, o erro do COP em relação ao valor final de ensaio depende dos erros do VMC da capacidade e do consumo em relação aos seus respectivos valores finais de ensaio. A tabela 11 apresenta os erros do VMC da ca-

pacidade e do consumo, bem como o valor de erro do COP calculado para os 5 ensaios que apresentaram erro do COP acima de 2 %.



(a)



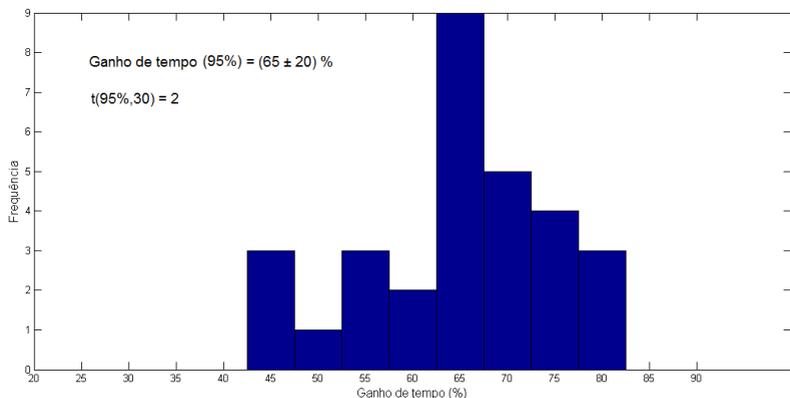
(b)

Figura 61- Erro percentual do COP obtido a partir do VMC da CAP e do CONS: (a) Histograma de erro. (b) Erro do COP % x ensaio.

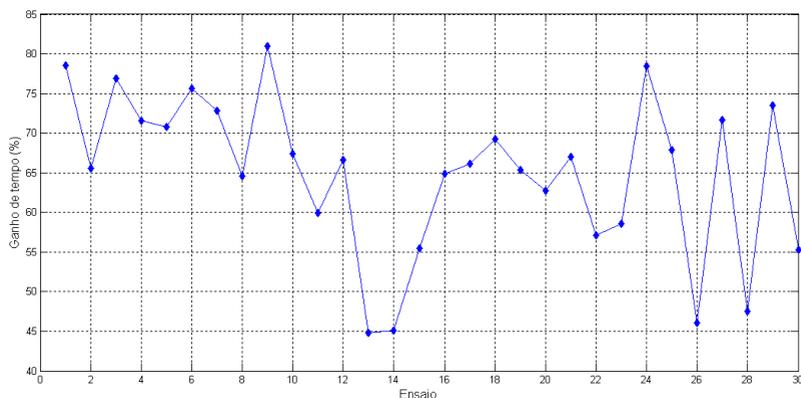
Tabela 11- Influência dos erros do VMC da CAP e CONS no erro do COP.

Ensaio	Erro VMC CAP (%)	Erro VMC CONS (%)	Erro COP (%)
1	3.05	-0.32	3.38
2	2.13	-0.75	2.90
18	1.01	-1.01	2.03
23	1.97	-0.15	2.12
30	0.58	-1.44	2.05

A figura 62 apresenta o histograma do ganho de tempo percentual em relação ao tempo final de ensaio para o COP obtido a partir da inferência ou do VMC da capacidade e do consumo, bem como o gráfico deste ganho de tempo percentual em função de cada ensaio.



(a)



(b)

Figura 62 - Ganho percentual de tempo para o COP obtido a partir da inferência ou do VMC da capacidade e do consumo: (a) Histograma do ganho de tempo.

(b) Ganho de tempo % x Ensaio.

A figura 62 mostra que a grande maioria dos ensaios apresentou ganho percentual de tempo para o COP obtido a partir da inferência ou VMC da capacidade e do consumo entre 55 % e 75 %. Vê-se também

que, em média, o ganho de tempo é de 65 % em relação ao tempo total de ensaio.

6.5. Resultados do módulo neural da temperatura do corpo

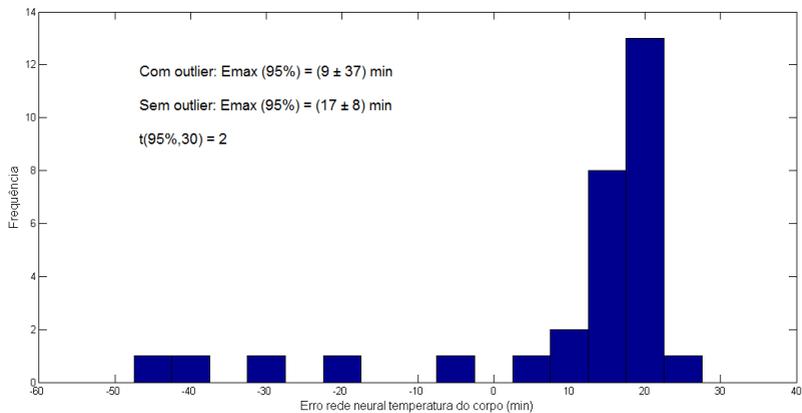
Conforme já descrito no item 4.1, o módulo neural da temperatura do corpo é o responsável pela detecção da entrada em regime permanente da variável temperatura do corpo. A partir desse instante, pretende-se analisar qual o comportamento das variáveis de interesse (CAP, CONS e COP). Para isso, são realizados cálculos de média e desvio padrão dessas variáveis de interesse a fim de averiguar o quão próximas tais variáveis estão do valor final de ensaio e qual o grau de dispersão das mesmas num determinado período.

O sucesso dessa análise está atrelado ao grau de acerto da rede de detecção de entrada em regime da temperatura do corpo. A figura 63 apresenta o histograma de erro, em minutos, do instante de detecção de regime da temperatura do corpo pela rede neural em relação ao instante de regime real, bem como o gráfico desse erro de regime em função do ensaio.

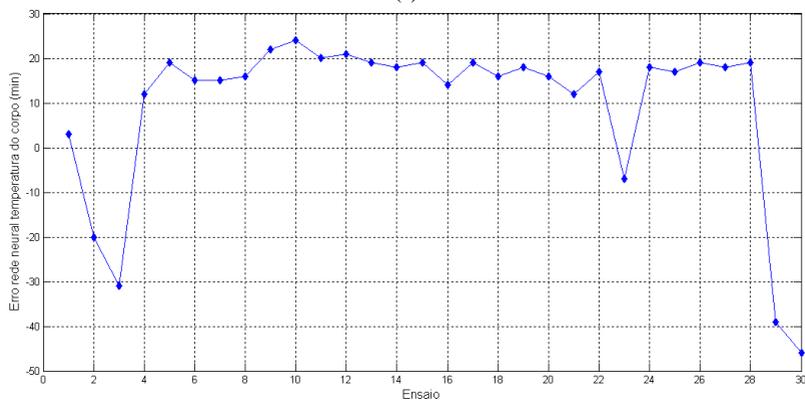
Analisando a figura 63, fica claro que se tem uma maior incidência de erros na faixa compreendida entre 10 e 25 min. A figura 64 apresenta o diagrama de caixa para os erros de regime da rede de temperatura do corpo³⁴. Se os *outliers* não forem considerados (5 no total), pode-se dizer que a rede de regime da temperatura do corpo apresenta um erro sistemático de falso negativo na ordem de 17 min. Uma solução para minimizar os erros de falso negativo seria reduzir o patamar de decisão da saída da rede e o tempo de espera para confirmação da rede³⁵.

³⁴ Diagrama obtido pelo comando *boxplot* do Matlab.

³⁵ Tais parâmetros foram descritos no item 5.1.4.1.



(a)



(b)

Figura 63 - Erro da rede de regime da temperatura do corpo:
 (a) Histograma de erros. (b) Erro da rede x Ensaio.

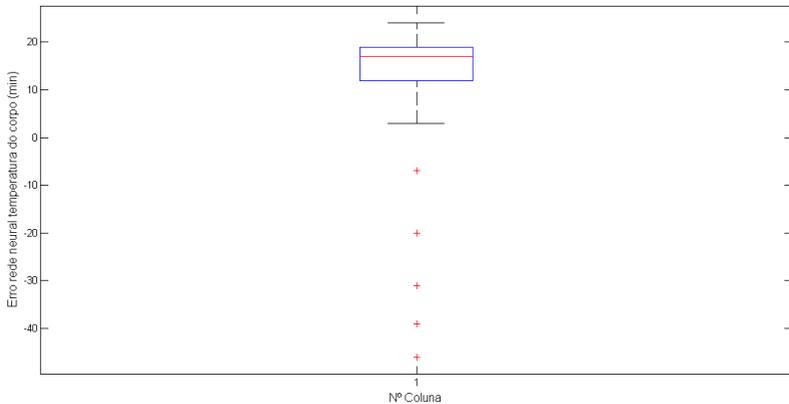


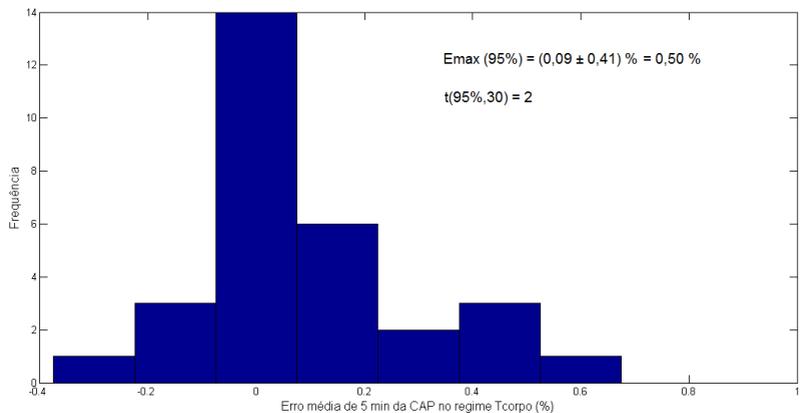
Figura 64 – Diagrama de caixa dos erros de regime da rede de temperatura do corpo.

6.6. Medições na entrada em regime da temperatura do corpo

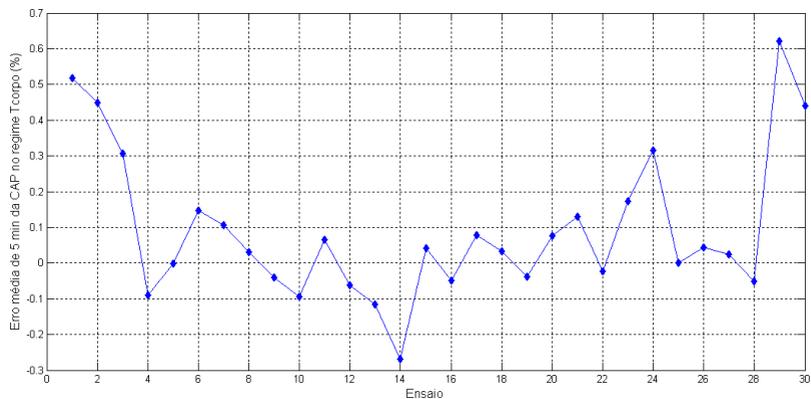
Conforme já descrito no item 4.1, a partir do instante de detecção de entrada em regime da temperatura do corpo pela rede neural dessa variável, são realizadas medições de média e desvio padrão das três variáveis de interesse do ensaio de desempenho (CAP, CONS e COP). Tanto a média quanto o desvio padrão são calculados num intervalo de 5 min anteriores ao instante de detecção de entrada em regime da rede de temperatura.

6.6.1. Medições da capacidade

A figura 65 apresenta o histograma do erro percentual do valor médio da capacidade, no intervalo de 5 min anteriores à detecção de regime da temperatura do corpo pela rede neural, em relação ao valor final de ensaio dessa variável, bem como o gráfico desse erro em função do ensaio.



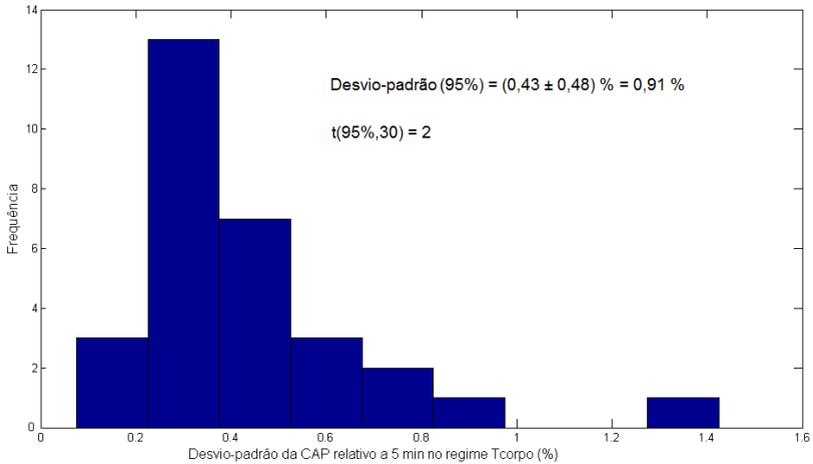
(a)



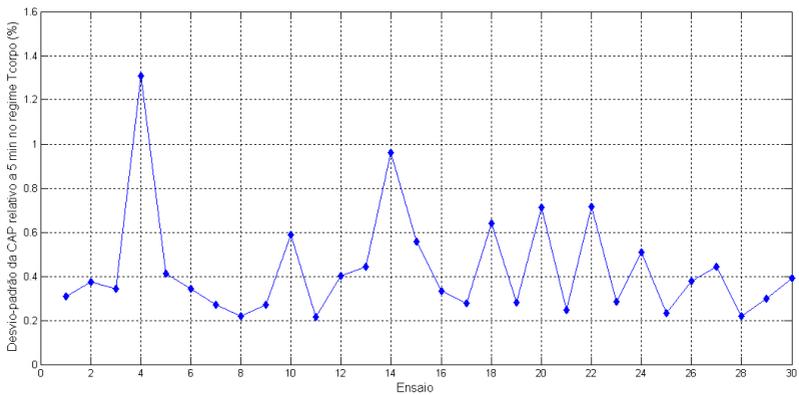
(b)

Figura 65 - Erro percentual da média de 5 min da CAP no regime da Tcorpo:
(a) Histograma de erro. (b) Erro % x Ensaio.

A figura 66 apresenta o histograma do desvio-padrão percentual da capacidade no intervalo de 5 min anteriores à detecção de regime da temperatura do corpo pela rede neural e calculado em relação ao valor médio da capacidade nesse intervalo, bem como o gráfico desse desvio-padrão em função do ensaio.



(a)

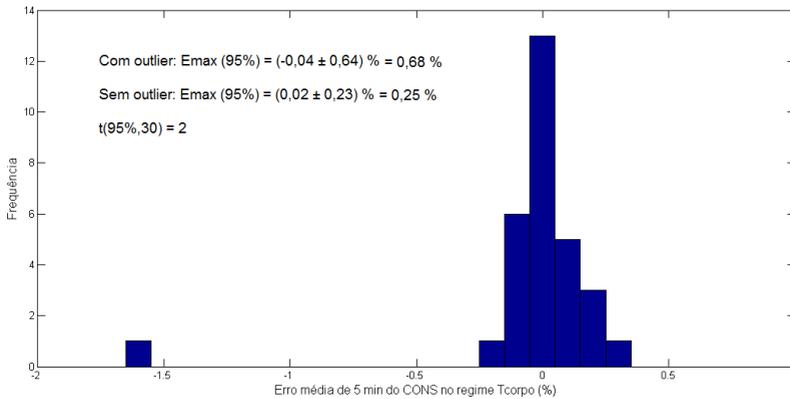


(b)

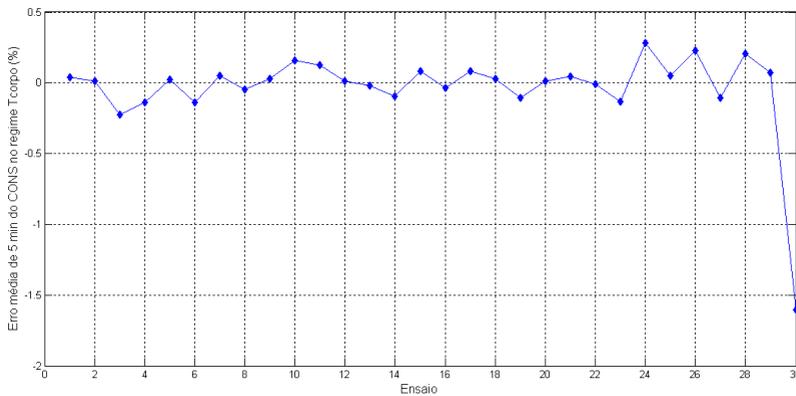
Figura 66 - Desvio-padrão percentual da CAP em 5 min no regime da Tcorpo:
 (a) Histograma. (b) Desvio-padrão % x Ensaio.

6.6.2. Medições do consumo

A figura 67 apresenta o histograma de erro percentual do valor médio do consumo no intervalo de 5 min anteriores à detecção de regime da temperatura do corpo pela rede neural em relação ao valor final de ensaio dessa variável, bem como o gráfico desse erro em função do ensaio.



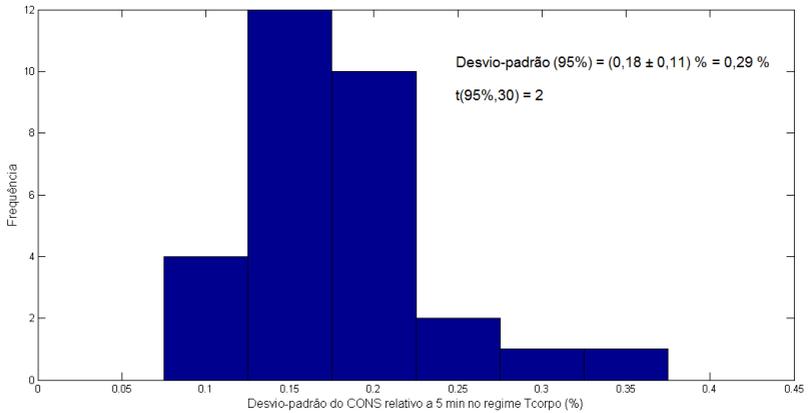
(a)



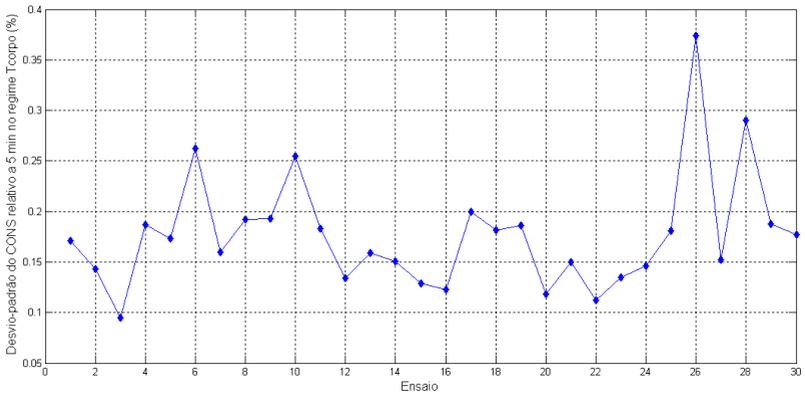
(b)

Figura 67 - Erro percentual da média de 5 min do CONS no regime da Tcorpo:
 (a) Histograma de erro. (b) Erro % x Ensaio.

A figura 68 apresenta o histograma do desvio-padrão percentual do consumo no intervalo de 5 min anteriores à detecção de regime da temperatura do corpo pela rede neural e calculado em relação ao valor médio do consumo nesse intervalo, bem como o gráfico desse desvio-padrão em função do ensaio.



(a)

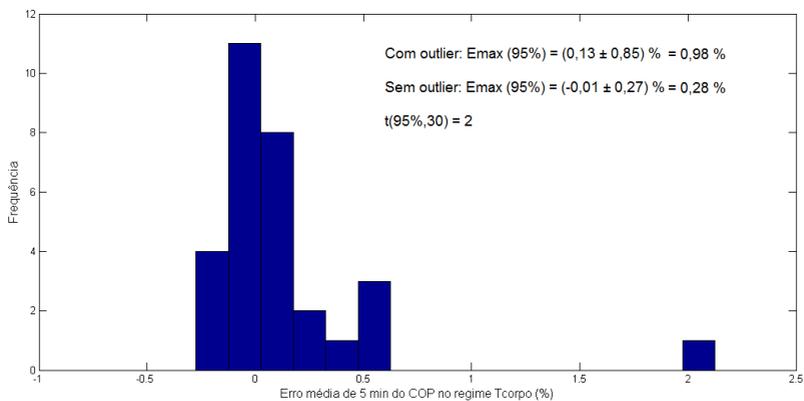


(b)

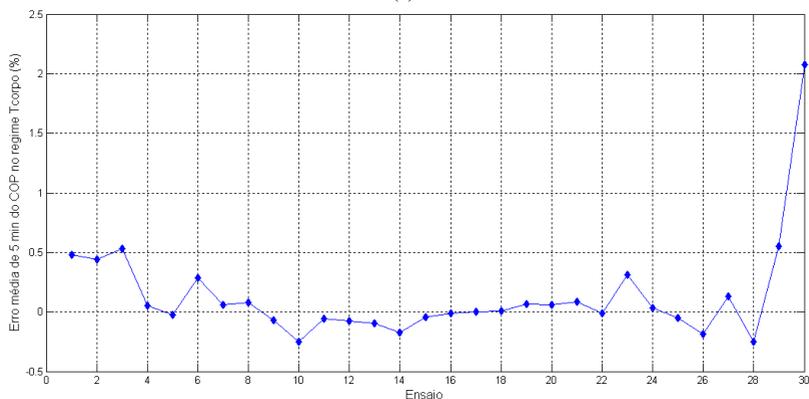
Figura 68 - Desvio-padrão percentual do CONS em 5 min no regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.

6.6.3. Medições do COP

A figura 69 apresenta o histograma de erro percentual do valor médio do COP no intervalo de 5 min anteriores à detecção de regime da temperatura do corpo pela rede neural em relação ao valor final de ensaio dessa variável, bem como o gráfico desse erro em função do ensaio.



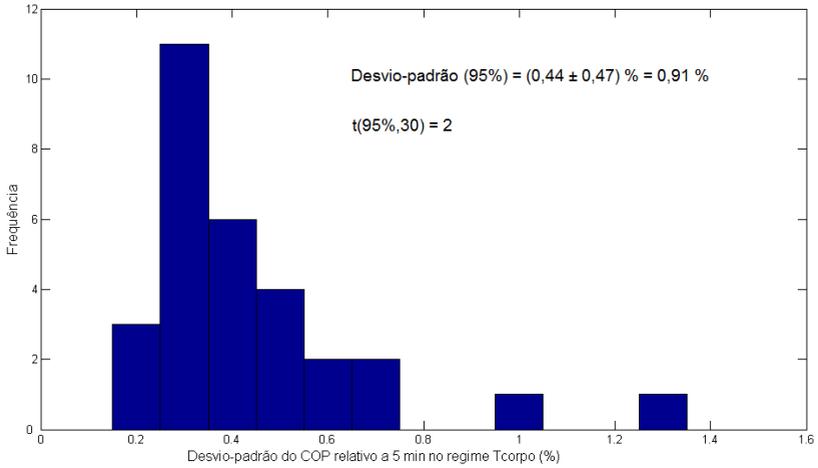
(a)



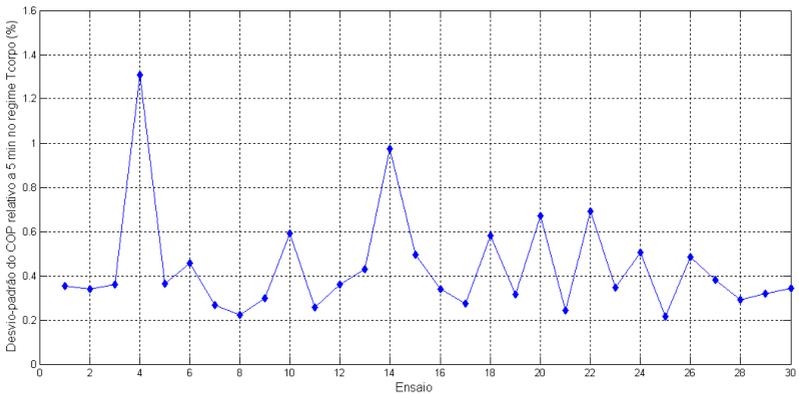
(b)

Figura 69 - Erro percentual da média de 5 min do COP no regime da Tcorpo:
 (a) Histograma de erro. (b) Erro % x Ensaio.

A figura 70 apresenta o histograma do desvio-padrão percentual do COP no intervalo de 5 min anteriores à detecção de regime da temperatura do corpo pela rede neural e calculado em relação ao valor médio do COP nesse intervalo, bem como o gráfico desse desvio-padrão em função do ensaio.



(a)



(b)

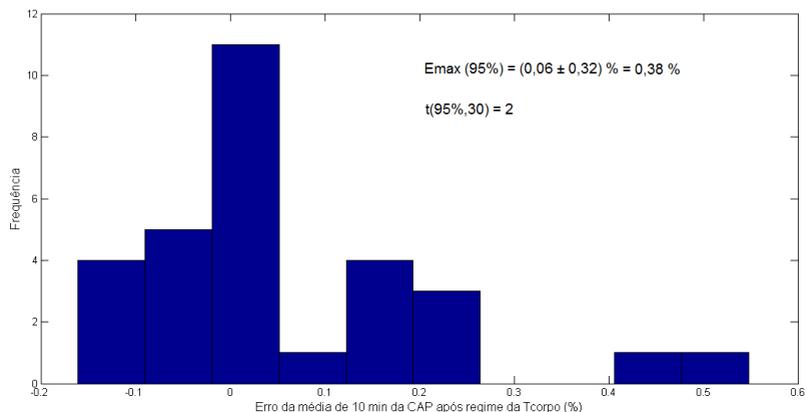
Figura 70 - Desvio-padrão percentual do COP em 5 min no regime da Tcorpo:
 (a) Histograma. (b) Desvio-padrão % x Ensaio.

6.7. Medições na entrada em regime da temperatura do corpo + 10 min.

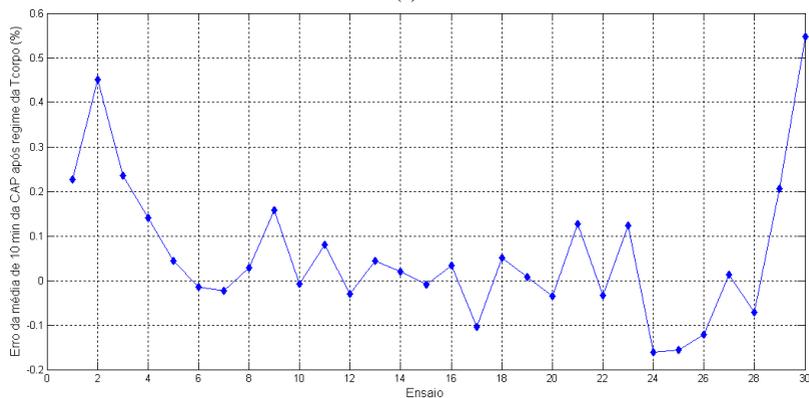
Conforme já descrito no item 4.1, também são realizadas medições de média e desvio padrão das três variáveis de interesse do ensaio de desempenho (CAP, CONS e COP) durante um intervalo de 10 minutos contados a partir da detecção de entrada em regime da temperatura do corpo pela rede neural dessa variável.

6.7.1. Medições da capacidade

A figura 71 apresenta o histograma do erro percentual do valor médio da capacidade, no intervalo de 10 min posteriores à detecção de regime da temperatura do corpo pela rede neural, em relação ao valor final de ensaio dessa variável, bem como o gráfico desse erro em função do ensaio.



(a)

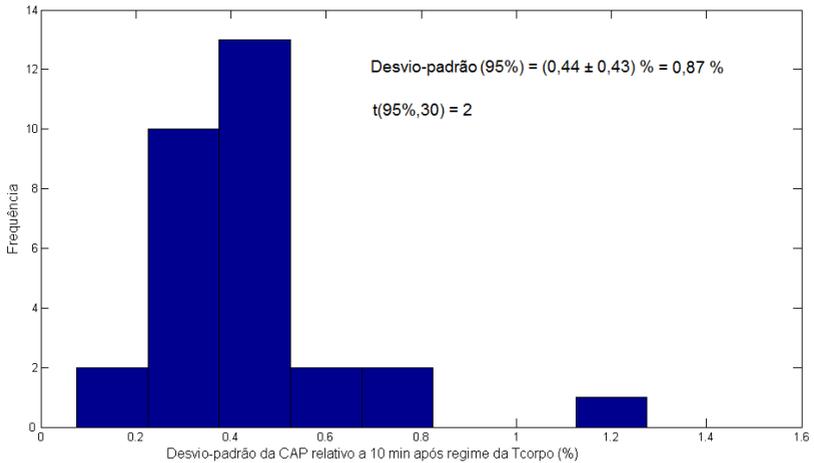


(b)

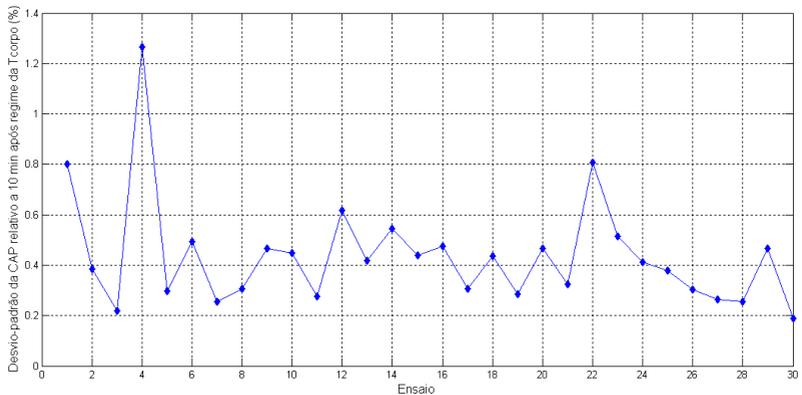
Figura 71 - Erro percentual da média de 10 min da CAP após regime da Tcorpo:
(a) Histograma de erro. (b) Erro % x Ensaio.

A figura 72 apresenta o histograma do desvio-padrão percentual da CAP no intervalo de 10 min posteriores à detecção de regime da temperatura do corpo pela rede neural e calculado em relação

ao valor médio da CAP nesse intervalo, bem como o gráfico desse desvio-padrão em função do ensaio.



(a)



(b)

Figura 72 - Desvio-padrão percentual da CAP em 10 min após regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.

6.7.2. Medições do consumo

A figura 73 apresenta o histograma do erro percentual do valor médio do consumo, no intervalo de 10 min posteriores à detecção de regime da temperatura do corpo pela rede neural, em relação ao valor final de ensaio dessa variável, bem como o gráfico desse erro em função do ensaio.

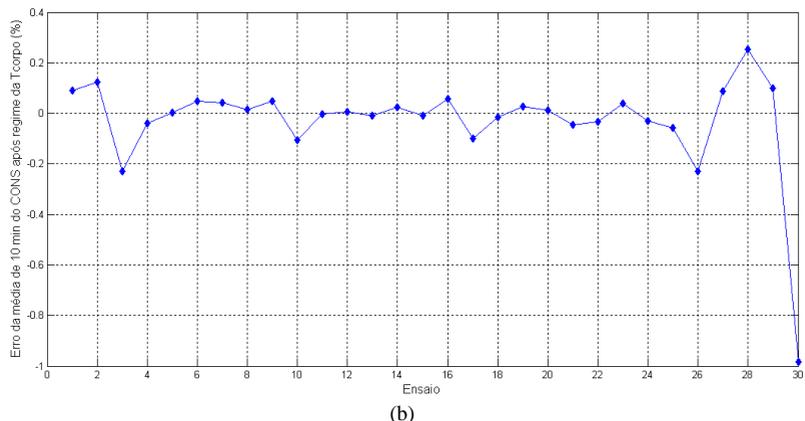
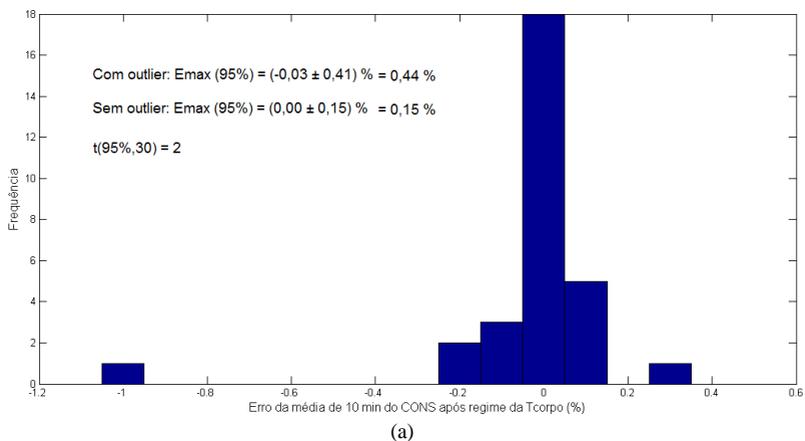
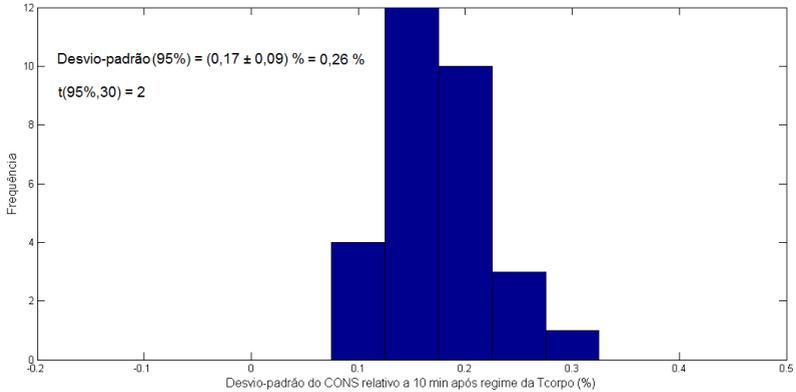
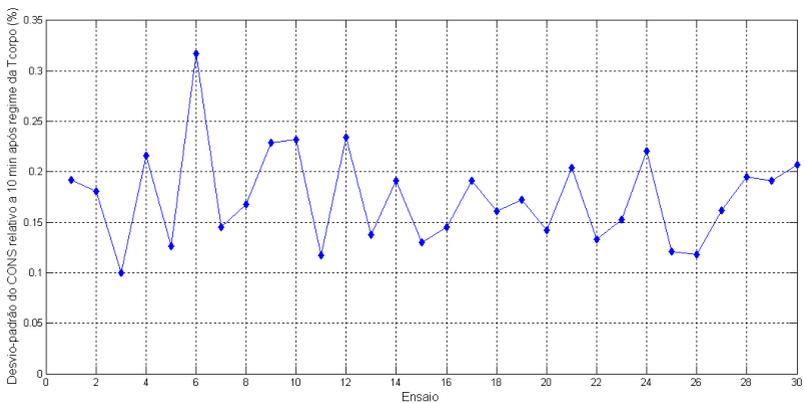


Figura 73 - Erro percentual da média de 10 min do CONS após regime da Tcorpo: (a) Histograma de erro. (b) Erro % x Ensaio.

A figura 74 apresenta o histograma do desvio-padrão percentual do CONS no intervalo de 10 min posteriores à detecção de regime da temperatura do corpo pela rede neural e calculado em relação ao valor médio do CONS nesse intervalo, bem como o gráfico desse desvio-padrão em função do ensaio.



(a)



(b)

Figura 74 - Desvio-padrão percentual do CONS em 10 min após regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.

6.7.3. Medições do COP

A figura 75 apresenta o histograma do erro percentual do valor médio do COP, no intervalo de 10 min posteriores à detecção de regime da temperatura do corpo pela rede neural, em relação ao valor final de ensaio dessa variável, bem como o gráfico desse erro em função do ensaio.

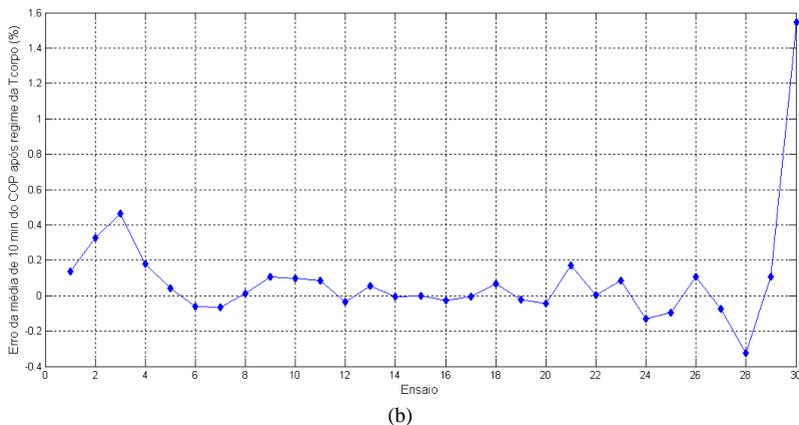
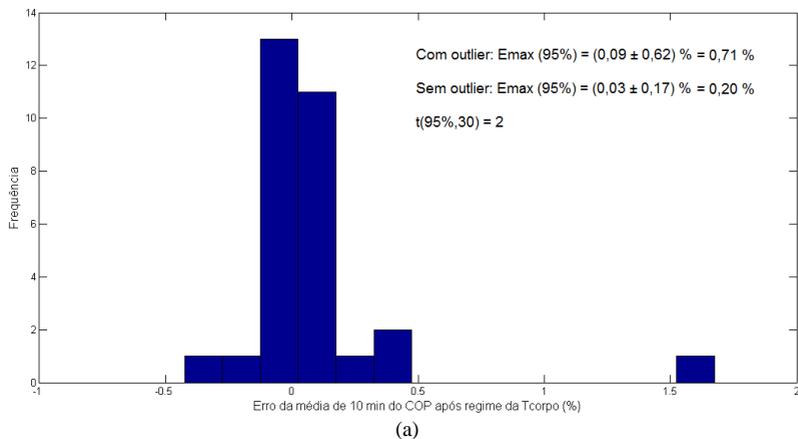
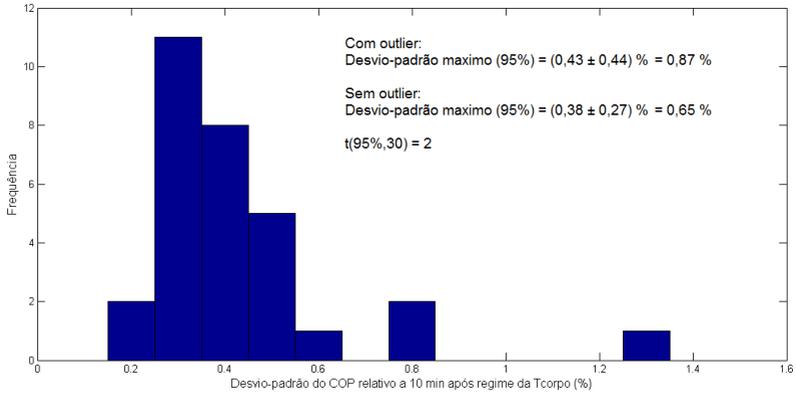
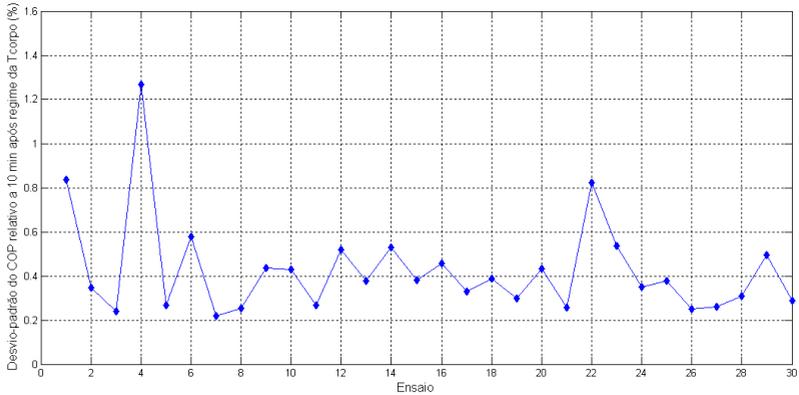


Figura 75 - Erro percentual da média de 10 min do COP após regime da Tcorpo:
 (a) Histograma de erro. (b) Erro % x Ensaio.

A figura 76 apresenta o histograma do desvio-padrão percentual do COP no intervalo de 10 min posteriores à detecção de regime da temperatura do corpo pela rede neural e calculado em relação ao valor médio do COP nesse intervalo, bem como o gráfico desse desvio-padrão em função do ensaio.



(a)



(b)

Figura 76 - Desvio-padrão percentual do COP em 10 min após regime da Tcorpo: (a) Histograma. (b) Desvio-padrão % x Ensaio.

6.8. Desempenho operacional da rede

A tabela 12 apresenta uma síntese dos resultados dos módulos neurais em termos de valor médio e dispersão. Para os erros percentuais de inferência e VMC são apresentados também os valores máximos. Os valores de dispersão foram calculados para um número de amostras igual a 30 e 95 % de nível de confiança ($t_{student} = 2$).

Os resultados de erro médio de inferência ficaram bem inferiores aos limites de erro estabelecidos pela empresa parceira³⁶. Em termos de erro máximo, os resultados de inferência dos módulos de CONS e COP (1,67 % e 2,13 % respectivamente) ficaram abaixo dos limites de erro aceitáveis. No módulo da CAP, o resultado de erro máximo da inferência ficou em 2,38 %, ou seja, 0,38 % acima do limite de erro aceitável. Considerando que as redes foram treinadas e testadas em condições não muito estáveis da bancada de ensaios e que os métodos de ensaio utilizados durante o treinamento e uso das redes foram distintos, pode-se dizer que os resultados são satisfatórios.

Os resultados de erro máximo (erro médio \pm dispersão de erro) do VMC são da mesma ordem de grandeza dos resultados de erro máximo da inferência. Os erros médios do VMC também ficaram bem abaixo dos limites admissíveis de erro e possuem o mesmo sinal dos respectivos erros médios de inferência. Isso demonstra que o cálculo do VMC para definição da faixa de comparação da inferência da rede é bastante aplicável antes de apresentar os resultados de inferência das redes neurais.

Os ganhos de tempo obtidos com o uso dos módulos neurais são significativos. Em média, o resultado do COP calculado é fornecido em 35 % do tempo normal de ensaio sem uso dos módulos neurais, o qual é da ordem de 140 min³⁷. Já os resultados dos módulos neurais da CAP e do CONS são fornecidos, em média, em 32 % e 30 % do tempo normal de ensaio, respectivamente.

Os resultados do COP calculado são, em média, melhores que os da rede do COP (menor erro de inferência e maior ganho de tempo). Entretanto, o resultado do erro de inferência do COP calculado apresenta maior dispersão em relação ao do erro de inferência do COP. Tal dispersão, no caso do COP calculado, é uma combinação das dispersões dos erros de inferência da CAP e do CONS. Para se ter uma redução do erro máximo de inferência do COP calculado deve-se trabalhar na redução das dispersões dos erros de inferência da CAP e do CONS. Para tanto, torna-se necessária a realização de novos treinamentos das redes neurais com dados de ensaios mais estáveis e realizados nas mesmas condições de ensaio no uso das redes.

36 A empresa parceira estabeleceu como limites de erro admissíveis os seguintes valores: 2% para CAP, 2% para CONS e 3% para COP.

37 Esse tempo de 2 h e 30 min é o típico no painel de ensaios da empresa parceira utilizado neste trabalho. No geral, o tempo de ensaio médio é da ordem de 4 h e 30 min.

Uma desvantagem do COP calculado em relação ao módulo neural do COP é que o primeiro depende dos resultados de dois outros módulos neurais (módulo neural da CAP e do CONS), o que representa um inconveniente caso o módulo neural da CAP ou o módulo neural do CONS não forneçam resultado. Porém, tal situação pode ser facilmente contornada com técnicas de uso dos módulos neurais. Por exemplo, poder-se-ia aplicar a seguinte técnica: se até a detecção de regime da rede do COP um dos dois módulos neurais (CAP ou CONS) ou os dois não tiverem apresentado resultados, apresenta-se o resultado do módulo neural do COP, caso contrário, apresenta-se o resultado do COP calculado.

Tabela 12 – Resultados dos módulos neurais

Módulo Neural / Variável	Erro Inferência (%)	Erro VMC (%)	Ganho de tempo (%)	Erro regime (min)
CAP	$(0,36 \pm 2,02)$: 2,38	$(0,68 \pm 2,03)$: 2,71	68 ± 23	-
CONS	$(- 0,37 \pm 1,30)$: 1,67	$(- 0,27 \pm 1,25)$: 1,52	70 ± 13	-
COP	$(1,09 \pm 1,04)$: 2,13	$(0,56 \pm 1,17)$: 1,73	50 ± 20	-
COP calculado	$(0,74 \pm 2,42)$: 3,16	$(0,96 \pm 2,17)$: 3,13	65 ± 20	-
Tcorpo	-	-	-	17 ± 8

A tabela 13 apresenta uma síntese dos resultados dos valores de média e desvio-padrão calculados a partir do instante de detecção de entrada em regime da temperatura do corpo pela rede neural. Os valores de média calculados no regime da temperatura do corpo apresentaram erros bem inferiores aos erros de inferência dos módulos neurais para as mesmas variáveis. Os valores de desvio-padrão representam uma dispersão muito baixa, demonstrando que as variáveis se encontram bem estabilizadas nessa região. Isso significa que, na pior das hipóteses, podem ser apresentados os resultados de CAP, CONS e COP no instante de detecção de entrada em regime da temperatura do corpo pela rede neural simplesmente calculando-se o valor médio dessas variáveis durante um pequeno intervalo de tempo (5 min). Com isso, haveria um ganho de tempo no ensaio da ordem de 45 min.

Tabela 13 – Resultados das medições no regime da Tcorpo

Variável	Medições nos 5 min anteriores à detecção de regime da Tcorpo		Medições nos 10 min posteriores à detecção de regime da Tcorpo	
	Erro da média (%)	Desvio-padrão (%)	Erro da média (%)	Desvio-padrão (%)
CAP	(0,09 ± 0,41): 0,50	(0,43 ± 0,48): 0,91	(0,06 ± 0,32): 0,38	(0,44 ± 0,43): 0,87
CONS	(0,02 ± 0,23): 0,25	(0,18 ± 0,11): 0,29	(0,00 ± 0,15): 0,15	(0,17 ± 0,09): 0,26
COP	(- 0,01 ± 0,27): 0,28	(0,44 ± 0,47): 0,91	(0,03 ± 0,17): 0,20	(0,38 ± 0,27): 0,65

7. CONCLUSÕES E PROPOSIÇÕES PARA TRABALHOS FUTUROS

7.1. Conclusões

Os objetivos estabelecidos foram alcançados: validação da técnica de redução de tempos de ensaios de desempenho de compressores de refrigeração através do uso de RNA; desenvolvimento de um sistema neural artificial; implantação do sistema neural em bancada de ensaios de desempenho de compressores de refrigeração.

Os resultados obtidos confirmam a aplicabilidade das redes neurais artificiais em bancadas de ensaio de desempenho de compressores de refrigeração.

Para facilitar a apresentação das conclusões, essas foram divididas em três itens:

7.1.1. Software

As redes neurais artificiais foram treinadas em software Matlab versão 2007a utilizando dados de ensaios reais fornecidos pela empresa parceira e o sistema neural final foi implementado em software Labview versão 8.5. Tais softwares apresentaram bastante robustez e facilidade de programação, o que demonstra a total aplicabilidade dos mesmos para o proposto neste trabalho. Em caso de novos treinamentos das redes, basta atualizar arquivos em *txt* contendo as matrizes de pesos, de bias e dos parâmetros de normalização. A estruturação do sistema neural em módulos neurais permite maior clareza e praticidade em caso de alterações futuras no programa.

Apesar das redes terem sido treinadas utilizando o *toolkit* de redes neurais do Matlab, a implementação final das mesmas foi feita diretamente em ambiente Labview. Isso representa um grande avanço em termos de praticidade e, adicionalmente, ganho de tempo de processamento, comparando com o aplicativo final proposto por HENKLEIN (2006), o qual previa interface para troca de dados entre o software Matlab (contendo as redes neurais treinadas) e o software Labview (contendo o programa principal). Na proposta desenvolvida no âmbito deste trabalho, o módulo neural programado em Labview é uma sub-rotina (*subVI*) do programa principal da bancada de ensaios de desempenho.

Conforme descrito no item 5, o sistema neural permite a geração de um relatório em Excel, após a finalização de cada ensaio, contendo os resultados do ensaio e das redes neurais. Tais dados também são

adicionados a uma base de dados em formato *txt*. Tal base de dados, juntamente com os relatórios gerados, permitirá a realização de futuras análises e a obtenção de conclusões a respeito do desempenho das técnicas neurais utilizadas.

7.1.2. Treinamento, validação e teste das redes neurais

As etapas de pré-processamento dos dados de entrada das redes – eliminação das variações abruptas; equalização das variáveis; inserção de atrasos e derivadas; limitação do intervalo de ensaio; normalização – constituíram peças importantes no processo de convergência e generalização das redes bem como na obtenção de tempos de treinamento reduzidos³⁸.

O número de ensaios utilizados para treinamento e validação das redes se mostrou bastante razoável. De qualquer forma seria válida a tentativa de se treinar futuramente as redes com número menor ou maior de ensaios e verificar de que forma isso afeta o grau de generalização.

Uma mesma rede neural foi treinada e testada para diferentes compressores grandes e médios. Esse fato é muito positivo uma vez que, até então, não se tinha certeza sobre a viabilidade de se usar uma única rede neural para compressores de faixas distintas de capacidade. No trabalho anterior (STEINBACH, 2008) as redes tinham sido treinadas e testadas somente para modelos de compressores grandes.

Os dados de ensaio para treinamento das redes foram obtidos numa fase na qual a bancada de ensaios se encontrava em testes, apresentando certo grau de instabilidade, com medições sem um comportamento padronizado. Tal situação dificultou o processo de treinamento e generalização das redes.

Um fato motivador é que as redes foram treinadas com dados extraídos de ensaios reais realizados no ambiente laboratorial da empresa parceira. Até então, os estudos tinham sido feitos com dados obtidos da bancada de ensaios do laboratório da universidade e não se sabia como a técnica neural iria se comportar frente à realidade de uso final na indústria.

7.1.3. Desempenho das redes

Conforme apresentado no item 6, o sistema neural implantado em bancada de ensaio de desempenho da empresa parceira e submetido a 30

³⁸ Tais tempos normalmente não ultrapassaram 15 min.

ensaios rotineiros, envolvendo compressores grandes e médios, apresentou ótimos resultados em termos de erro de inferência e ganho de tempo de ensaio. Isso é especialmente motivador considerado que: durante o período de treinamento e uso das redes, a bancada de ensaios ainda se encontrava em fase de validação e apresentando um comportamento não muito estável; os métodos de ensaio utilizados durante o treinamento e uso das redes foram distintos. Acredita-se fortemente que tais resultados possam ser ainda melhorados com a realização de novos treinamentos a partir de dados de ensaios mais estáveis e do uso das redes com a bancada de ensaios nas mesmas condições de ensaio utilizadas durante a fase de treinamento. Na situação atual da bancada (junho/2010) isso já seria viável.

Uma grande vantagem do sistema neural é que os resultados de inferência das variáveis de interesse são fornecidos de forma independente. Muitas vezes deseja-se quantificar o resultado de somente uma variável. Dessa forma, o ensaio poderia ser terminado assim que o resultado da variável de interesse – seja ela CAP, CONS ou COP – fosse fornecido pelo sistema neural.

Com exceção de um resultado de inferência (CAP do ensaio 1), todos os demais foram fornecidos quando as respectivas variáveis de interesse se encontravam na região de regime permanente e não apresentavam tendência a sair dos limites de tolerância. Pode-se então afirmar que as redes de detecção de entrada em regime cumpriram com seu papel principal de apontar a região de regime propícia para efetuar a inferência do valor final de ensaio; a qual não necessariamente coincidia com o exato instante de entrada em regime. No contexto deste trabalho, não houve preocupação em determinar os valores de erro de falso negativo das redes de detecção de entrada em regime, mas sim quantificar o percentual de ganho de tempo de ensaio e o grau de acerto das redes de inferência em relação ao valor final de ensaio.

Conforme comprovam resultados obtidos, o cálculo do VMC é aplicável para fornecimento de uma faixa de comparação para a resposta de inferência da rede. Cabe lembrar que o VMC não substitui a inferência da rede, mas funciona como um balizador para o resultado da mesma.

Os resultados de média e desvio-padrão nos intervalos de 5 min anteriores e 10 min posteriores ao instante de detecção de entrada em regime da rede da Tcorpo demonstram que as variáveis de interesse já se encontram bem acomodadas no valor final de ensaio e com baixíssimas variações em relação a esse. Além disso, como pode ser visto na tabela 13, os resultados da média nos 5 min antecedentes e 10 min posteriores

à detecção de regime da rede da Tcorpo divergem em apenas 0,1 %. Dessa forma, como último recurso, o resultado da média da variável de interesse referente a 5 min anteriores à detecção de entrada em regime da Tcorpo poderia ser apresentado nesse instante como resultado final de ensaio. Assim, na pior das hipóteses, ganhar-se-ia um tempo de ensaio da ordem de 45 min.

7.2. Oportunidades futuras

Ao longo deste trabalho foram identificadas oportunidades de aprofundamento ou de novas frentes de trabalho que, por fugirem do escopo ou por inviabilidade de tempo, deixaram de ser exploradas. Tais são apresentadas na sequência como propostas para futuros trabalhos na área.

Realizar novos treinamentos das redes neurais com dados obtidos da bancada em sua condição atual (métodos de ensaio A e F; variáveis mais estáveis; comportamento padrão das variáveis).

Desenvolver uma técnica de identificação das potenciais variáveis para treinamento das redes. Até agora a escolha das variáveis foi feita baseada na experiência do projetista das redes. Poder-se-ia desenvolver uma técnica baseada, por exemplo, em análise de componentes principais (ACP).

Desenvolver técnica de utilização do sistema neural no chão de fábrica e interface com o usuário, envolvendo a definição dos seguintes pontos: intervalo entre treinamentos; forma automática de treinamento e atualização dos arquivos de parâmetros das redes (bias; pesos; parâmetros de normalização); número de ensaios necessário para treinamento; quais ensaios selecionar para treinamento (compressores pequenos, médios ou grandes); algoritmo de atualização de arquitetura das redes no Labview.

Realizar avaliação de incerteza do sistema neural implantado na bancada de ensaio de desempenho.

Avaliação e aplicação da técnica neural em compressores pequenos, definindo se um único sistema neural pode ser aplicado a todas as faixas de capacidade de compressores ou se para os compressores pequenos deve-se ter um sistema neural próprio.

Testar a técnica de equalização das variáveis de entrada das redes neurais calculando o valor percentual de tais variáveis em relação ao valor típico por modelo de compressor e não em relação ao valor médio por faixa de compressor.

Treinar as redes de inferência com início da janela de treinamento a partir do instante de detecção de entrada em regime da rede neural de regime e não do instante de entrada em regime real. Adicionalmente, fazer com que a saída da rede de inferência seja igual a um valor correspondente à diferença entre o valor instantâneo medido e o valor final de ensaio. Melhor dizendo, essa diferença seria uma correção que depende das características da variável sendo medida³⁹ e que seria aplicada ao valor instantâneo a fim de obter o valor final de ensaio. Pretende-se com isso evitar o não fornecimento da inferência pelo fato da mesma não ter entrado na faixa de comparação estabelecida pelo VMC, como acontece em alguns casos.

Treinar as redes de inferência com uma janela maior em relação à atual⁴⁰ na tentativa da rede compreender melhor o comportamento da variável na região de detecção de entrada em regime pela rede neural de regime.

Testar a técnica neural em ensaios submetidos a técnicas de aquecimento forçado para aceleração de transitório.

³⁹ Tais características seriam extraídas pela rede em função do comportamento da variável nos instantes antecedentes, tais como: derivadas, desvio-padrão, valores medidos.

⁴⁰ A atual janela de treinamento das redes de inferência é definida no item 4.2.2.4.

REFERÊNCIAS

ANSI/ASHARE 23. Methods of Testing for Rating Positive Displacement Refrigerant Compressors and Condensing Units. Atlanta: [s.n.], 1993. 12 p.

BARRETO, J. M. Introdução às redes neurais artificiais. V Escola Regional de Informática da SBC Regional Sul, Santa Maria, Florianópolis, Maringá. [S.l.]: [s.n.]. 1997. p. 41-71.

BET, S. Aperfeiçoamento de algoritmo genético para seleção de variáveis de entrada para rede neural para previsão de carga elétrica ativa de curto prazo. Universidade Federal de Santa Catarina. Florianópolis, p. 65. 2005.

BITTENCOURT, G. Inteligência Artificial: Ferramentas e Teorias. 3ª Edição. ed. Florianópolis: Editora da UFSC, 2006.

BRAGA, A. L. S. VANNGen – Uma Ferramenta CAD Flexível para a Implementação de Redes Neurais Artificiais em Hardware. Universidade de Brasília. Brasília, p. 135. 2005.

CHAMON, J. D. C. Digital VLSI Implementation of Artificial Neural Network Systems. Faculty of Texas Tech University. [S.l.], p. 223. 1993.

DEMUTH, H.; BEALE, M.; HAGAN, M. Neural Network Toolbox™ 6 User's Guide. 6.0.3. ed. [S.l.]: The MathWorks, Inc, 2009.

DINCER, I. Refrigeration systems and applications. [S.l.]: Wiley, 2003.

DOSSAT, R. J. **Princípios de refrigeração**. São Paulo: Hemus, 2004. 884 p.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms and applications**. New Jersey: Prentice-Hall, Inc., 1994.

FERNANDO, T. M. K. G. et al. **Efficient Selection of Inputs for Artificial Neural Network Models**. MODSIM 2005 International Congress on Modelling and Simulation. Adelaide, Australia: Modelling & Simulation Society of Australia & New Zealand. 2005. p. 1806-1812.

FLESCH, R. C. C. **Desenvolvimento e instalação de recursos de automação aplicados a ensaios de compressores de refrigeração da Embraco**. Florianópolis. 2006.

FRANCESCHI, A. S. M.; BARRETO, J. M.; ROISENBERG, M. **Desenvolvimento de agentes autônomos em gerência de redes de computadores**. XVIII Simpósio Brasileiro de Telecomunicações. Gramado: [s.n.]. 2000.

GARSON, G. D. Interpreting neural-network connection weights. **AI EXPERT**, v. 6, n. 4, p. 46-51, 1991.

GOH, A. T. C. Back-propagation neural networks for modeling complex systems. **Artificial Intelligence in Engineering**, v. 9, p. 143-151, 1995.

GUPTA, M. M.; JIN, L.; HOMMA, N. **Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory**. [S.l.]: IEEE PRESS, 2003.

HANLON, P. C. **Compressor Handbook**. [S.l.]: McGRAW-HILL, 2001.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. Tradução de Paulo Martins Engel. Porto Alegre: Bookman, 2001.

HECHT-NIELSEN, R. **Theory of the backpropagation neural network**. International Joint Conference on Neural Networks. Washington DC: [s.n.]. 1989. p. 593-605.

HECKMANN, J. R. **Identificação de Potenciais Aplicações da Inteligência Artificial na Metrologia**. Universidade Federal de Santa Catarina. Florianópolis, p. 142. 1999.

HENKLEIN, P. **Análise de ensaios de desempenho de compressores herméticos durante o transitório**. Universidade Federal de Santa Catarina. Florianópolis, p. 136. 2006.

INFANTOSI, A. F. C. et al. **Definição de Variáveis em Redes Neurais Artificiais por Análise de Componentes Principais: Aplicação em Transplante Renal**. XVIII Congresso Brasileiro de Engenharia Biomédica. São José dos Campos (SP): [s.n.]. 12 Setembro 2002.

INMETRO. **Vocabulário internacional de termos fundamentais e gerais de Metrologia**: portaria Inmetro nº 029 de 1995. 5ª Edição. ed. Rio de Janeiro: SENAI, 2007.

INMETRO, A. **Guia para a Expressão da Incerteza de Medição**. Rio de Janeiro: Terceira Edição Brasileira do "Guide to the Expression of Uncertainty in Measurement" publicado em 1995 pelo BIPM/IEC/IFCC/ISO/IUPAC/IUPAP/OIML, 2003.

ISO 917. **Testing of refrigerant compressors**. 2nd edition. ed. Genève: [s.n.], 1989. 31 p.

LEANDRO, A. L. J. . J. M. D. P. Avaliação de Desempenho e Simulação de Compressores de Refrigeração por Meio de um Ciclo Superaquecido Alternativo. **16º POSMEC. FEMEC/UFU**, Uberlândia - MG, 2006.

LECUN, Y. Efficient BackProp. In: ORR, G. B.; MÜLLER, K.-R. **Neural Networks: Tricks of the Trade**. [S.l.]: Springer, v. 1524, 1998. p. 9–50.

LOURAKIS, A. M. I. **A Brief Description of the Levenberg-Marquardt Algorithm Implemented by levmar**. Institute of Computer Science Foundation for Research and Technology - Hellas. Heraklion, Crete, GREECE, p. 6. 2005.

MAYA, R. J. et al. Non-linear variable selection for artificial neural networks using partial mutual information. **Environmental Modelling & Software**, v. 23, p. 1312–1326, 2008.

MOLZ, R. F.; ENGEL, P. M.; MORAES, F. G. **Uso de um Ambiente Codesign para a Implementação de Redes Neurais**. Proceedings of the IV Brazilian Conference on Neural Networks - IV Congresso Brasileiro de Redes Neurais. São José dos Campos - SP: [s.n.]. 1999. p. 13-18.

NIEVOLA, J. C. **Redes Neurais Artificiais**. VI ERI. Vitória/ES: SBC. 2007.

PETROVIC, S. A. B. **Proposta de arquitetura do sistema de automação aplicado a ensaios de desempenho de compressores herméticos de refrigeração**. Universidade Federal de Santa Catarina. Florianópolis, p. 115. 2007.

POLETTO, E. L. **Aprimoramento de uma bancada de ensaios de desempenho de compressores herméticos**

visando reduzir incertezas de medição. Universidade Federal de Santa Catarina. Florianópolis, p. 107. 2006.

RANGANATHAN, A., 8 Junho 2004. Disponível em: <<http://www.ananth.in/misc.html>>.

ROSSI, F. et al. Mutual information for the selection of relevant variables in spectrometric nonlinear modelling. **Chemometrics and Intelligent Laboratory Systems**, v. 80, p. 215– 226, 2006.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representations by error propagation. In: RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing: explorations in the microstructure of cognition**, vol. 1: foundations. Massachusetts: MIT Press, 1986. p. 318 - 362.

SCUSSEL, J. N. **Propostas de ações para reduzir o tempo demandado por ensaio de desempenho de compressores herméticos.** Universidade Federal de Santa Catarina. Florianópolis, p. 153. 2006.

SORAES, A. M. **Implementação Digital de Redes Neurais Artificiais para o Controle de Motor de Indução.** Universidade Federal de Mato Grosso do Sul. Campo Grande, p. 120. 2006.

STEINBACH, K. **Identificação do instante de entrada em condição de regime permanente em ensaios de desempenho de compressores.** Universidade Federal de Santa Catarina. Florianópolis, p. 198. 2008.

STOECKER, W. F.; JONES, J. W. **Refrigeration and Air Conditioning**. 2ª Edição. ed. Universidade de Michigan: McGraw-Hill, Inc., 1982.

TALEB, R.; MEROUFEL, A.; WIRA, P. Neural Network Control of Asymmetrical Multilevel Converters. **Leonardo Journal of Sciences**, n. 15, Julho 2009. 53-70.

TORRES-HUITZILL, C.; GIRAU, B.; GAUFFRIAUX, A. Hardware/Software Codesign for Embedded Implementation of Neural Networks. In: _____ **Reconfigurable Computing: Architectures, Tools and Applications**. [S.l.]: Springer Berlin / Heidelberg, v. 4419/2007, 2007. p. 167-178.

VALENÇA, M. J. S.; LUDERMIR, T. B. **Explicando a relação entre as variáveis de uma rede neural - "iluminando a caixa preta"**. XVII Simpósio Brasileiro de Recursos Hídricos. São Paulo: [s.n.]. 25 a 29 Novembro 2007.

VIEIRA, R. C.; ROISENBERG, M. **Redes Neurais Artificiais: Um breve tutorial**. IT Conference SUCESU-MT. Cuiabá: [s.n.]. 2002.

WANG, S. K. **Handbook of air conditioning and refrigeration**. Second edition. ed. [S.l.]: McGraw-Hill, 2000.

WEBSTER, J. G. **Mechanical variables measurement: solid, fluid and thermal**. Florida: CRC Press LLC, 2000.

WELCH, A. R. T. A. T. **Refrigeration and Air-Conditioning**. 3ª Edição. ed. Oxford: Butterworth-Heinemann, 2000.

WIDROW, B. Generalization and Information Storage in Networks of Adaline Neurons. **Self-Organizing Systems**, Washington, DC, p. 435-461, 1962.

WIDROW, B.; HOFF, M. E. **Adaptative Switching Circuits.**
IRE WESCON Convention Record. New York: [s.n.]. 1960. p.
96-104.