

**UNIVERSIDADE FEDERAL DE SANTA CATARINA**  
**CENTRO TECNOLÓGICO**  
**Programa de Pós-graduação em Metrologia Científica e Industrial**

**Alexandre Victor Casella**

**FERRAMENTA FUZZY-BAYESIANA PARA  
IDENTIFICAÇÃO DO INSTANTE DE ENTRADA  
NO REGIME PERMANENTE EM ENSAIOS DE  
DESEMPENHO DE COMPRESSORES**

Dissertação submetida à Universidade Federal de Santa Catarina para  
obtenção do Grau de Mestre em Metrologia

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

Florianópolis, outubro de 2008.

**FERRAMENTA FUZZY-BAYESIANA PARA  
IDENTIFICAÇÃO DO INSTANTE DE ENTRADA NO  
REGIME PERMANENTE EM ENSAIOS DE  
DESEMPENHO DE COMPRESSORES**

**Alexandre Victor Casella**

**Esta dissertação foi julgada adequada para obtenção do título de**

**“MESTRE EM METROLOGIA”**

**e aprovada na sua forma final pelo**

**Programa de Pós-graduação em Metrologia Científica e Industrial**

**Prof. Carlos Alberto Flesch, Dr. Eng.**

**ORIENTADOR**

**Cesar Alberto Penz, M. Sc.**

**CO-ORIENTADOR**

**Prof. Armando Albertazzi Gonçalves Júnior, Dr.Eng.**

**COORDENADOR DO PROGRAMA DE PÓS-GRADUAÇÃO**

**BANCA EXAMINADORA:**

**Prof. Marcelo Ricardo Stemmer, Dr. Ing.**

**Prof. Saulo Güths, Dr. Eng.**

**Prof<sup>a</sup>. Silvia Modesto Nassar, Dr. Eng.**

**Marco Aurélio de Oliveira, M. Eng.**

*À minha esposa Kátia, pelos momentos  
sem minha presença!  
Ao meu filho Vinícius, que muitas vezes  
brincando só, desejava a companhia do pai!*

## **AGRADECIMENTOS**

Ao meu orientador, Prof. Carlos Alberto Flesch, pelos ensinamentos e pelo exemplo de profissional e pessoa.

Também ao meu co-orientador, Cesar Alberto Penz, pela competência na co-orientação da execução deste trabalho, por seu tempo dedicado e, principalmente, por sua paciência.

Às turmas 2006 e 2007, pelo clima agradável dentro do Labmetro e, em especial, para Miguel Burg Demay, pela disposição em ajudar. E à turma 2008, que se tornou a melhor turma com quem eu já convivi.

Ao pessoal da Embraco, Maikon Ronsani Borges, André Rosa e Marco Aurélio de Oliveira, pela oportunidade de desenvolver o projeto do mestrado.

Aos professores do Labmetro, pela competência e dedicação.

À Rosana, pelo seu profissionalismo.

A todos os funcionários do Labmetro e da Fundação CERTI, por esses anos de convívio.

## RESUMO

Ensaio de desempenho é uma atividade experimental de suma importância para análise de compressores de refrigeração. Os principais resultados obtidos são capacidade de refrigeração, potência consumida e coeficiente de performance. É demorado, demandando normalmente mais de quatro horas, divididas em dois períodos associados a regimes operacionais: transitório e permanente. A efetiva coleta de dados para compor os resultados dos ensaios se dá no regime permanente, o qual é estabelecido por norma em uma hora.

Diversos trabalhos estão sendo desenvolvidos visando reduzir o tempo de ensaio. Atualmente já se vislumbra viabilidade de, no futuro, se ter duração de transitório de aproximadamente uma hora. Embora tais regimes sejam bem definidos por normas, durante o ensaio não é trivial a identificação da passagem de um regime para outro. Essa identificação só se dá quando o ensaio é terminado. O que caracteriza que um ensaio é válido e que pode ser encerrado é a manutenção, por uma hora seguida, de condições de variabilidade das variáveis de ensaio em valores abaixo do previsto em norma. Por isso, só se conhece o instante em que o ensaio entrou em regime permanente após o seu término. A identificação em tempo real de que o regime permanente foi atingido pode possibilitar uma redução substancial do tempo em que as medições são feitas em tal regime, reduzindo a duração do ensaio.

Nesta dissertação foi desenvolvido um sistema especialista probabilístico utilizando redes bayesianas e lógica *fuzzy* para identificação do instante em que o sistema de ensaio entra em regime permanente no tocante à capacidade de refrigeração. O sistema se baseia numa análise conjunta do comportamento dinâmico de outras variáveis, como temperaturas e grandezas elétricas.

Avaliação experimental do sistema, com base em dados reais de ensaios de compressores, mostrou que a técnica é empregável e que possibilita a determinação do instante da entrada em regime com baixa incerteza. O emprego do método proposto pode ser autônomo ou, para aumento da confiabilidade, associado à outras técnicas.

## **ABSTRACT**

Performance tests are important experimental activities for refrigeration compressor analysis. The main results obtained are refrigerating capacity, power input and coefficient of performance. Typically, these tests take quite long time, lasting more than four hours. This time period is divided into two distinct operational states: transient and steady. However, only data collected during one hour in steady state is proper to compose the final test results.

Several research projects have been developed to decrease the test duration by reducing the transient state to a period shorter than one hour. Although such states can easily be identified after the tests are finished, the identification is not trivial while the tests are running. The characterization of a valid test, what leads to test ending, occurs after a set of variables is kept to within standard defined limits of variation. On-line identification of that transition contribute to reduce the amount of collected data to compose final test results, reducing, thus, the test time.

The aim of this dissertation was the development of an expert system, based on Bayesian networks and fuzzy logic, to identify the transition instant related to the refrigerating capacity. The proposed system analyzes the dynamical behavior of auxiliary variables, such as temperatures and electrical quantities, and relates them to the refrigerating capacity stability.

The system was evaluated using compressor real test data. This evaluation showed that the system is proper to identify the transition instant with low uncertainty. Additionally, it can be used alone or associated with other identification techniques.

## LISTA DE FIGURAS

Figura 1 – Instante de entrada em regime permanente para diferentes variáveis de ensaio (STEINBACH, 2008).....	14
Figura 2 – Modelo genérico de uma bancada de ensaio de compressores (SCUSSEL, 2006).....	18
Figura 3 – Regime transitório e permanente (HENKLEIN, 2006).....	22
Figura 4 – Instante de entrada em regime permanente e amostra dos valores medidos (STEINBACH, 2008).....	24
Figura 5 – Identificação do instante de regime para capacidade de refrigeração.....	25
Figura 6 – Topologia da rede do exemplo.....	34
Figura 7 – Rede bayesiana mostrando a topologia e as tabelas de probabilidade condicional.....	35
Figura 8 – Diferença entre sistema <i>crisp</i> e <i>fuzzy</i> .....	37
Figura 9 – Exemplos de funções de pertinência.....	38
Figura 10 – Ilustração das principais t-normas.....	40
Figura 11 – Ilustração das principais t-conormas.....	41
Figura 12 – Sistema de inferência <i>fuzzy</i> .....	41
Figura 13 – Métodos de desfuzzyficação.....	43
Figura 14 – Temperatura superficial do trocador e seu desvio padrão de Allan.....	47
Figura 15 – Tensão DC do calorímetro e seu desvio padrão de Allan.....	48
Figura 16 – Temperatura superficial do trocador em outro ensaio e seu desvio padrão de Allan.....	48
Figura 17 – Temperatura do corpo do compressor e seu desvio padrão de Allan.....	48
Figura 18 – Estabilidade da capacidade de refrigeração e variáveis auxiliares (PENZ, 2008).....	49
Figura 19 – Variância de Allan e funções <i>fuzzy</i> (PENZ, 2008).....	53
Figura 20 – $t_p = 1$ min e $\tau = 1$ .....	55
Figura 21 – $t_p = 1$ min e $\tau = 5$ .....	55
Figura 22 – $t_p = 3$ min e $\tau = 5$ .....	56
Figura 23 – Estabilidade das variáveis auxiliares e saída da rede bayesiana.....	59
Figura 24 – Resultado com a 1ª combinação.....	60
Figura 25 – Resultado com a 2ª combinação.....	61
Figura 26 – Resultado com a 3ª combinação.....	62
Figura 27 – Resultado com a 4ª combinação.....	62
Figura 28 – Resultado com a 5ª combinação.....	62
Figura 29 – Resultado com a 6ª combinação.....	63
Figura 30 – Resultado com a 7ª combinação.....	63
Figura 31 – Resultado com a 8ª combinação.....	64
Figura 32 – Resultado para rede bayesiana e rede fuzzy-bayesiana de um mesmo ensaio.....	65
Figura 33 – Erros apresentados pela rede híbrida.....	66
Figura 34 – Resultado da rede com médias de dois valores.....	67
Figura 35 – Resultado da rede com dois valores acima do patamar.....	68

Figura 36 – Resultado da rede com médias e dois valores acima do patamar.....	68
Figura 37 – Resultado da rede com análise do tempo de estabilidade da variável de entrada.....	69
Figura 38 – Resultado da rede com análise do tempo de estabilidade e dois valores acima do patamar.....	70
Figura 39 – Resultado da rede com análise do tempo de estabilidade com médias e dois valores acima do patamar. ....	70
Figura 40 – Comparativos com os falsos positivos.....	72
Figura 41 – Comparativo com os falsos negativos. ....	72
Figura 42 – Amostras de (3, 6, 9 e 12) minutos após entrada em regime real. ....	74
Figura 43 – Amostras de (3, 6, 9 e 12) minutos após entrada em regime da rede (valores medidos). ....	75
Figura 44 – Funções de pertinência para Atendimento e Qualidade da Comida. ....	90
Figura 45 – Função de pertinência para GORJETA. ....	91
Figura 46 – Exemplo de fuzzyficação. ....	91
Figura 47 – Exemplo de aplicação do operador de implicação. ....	91
Figura 48 – Agregação de todas as saídas. ....	92
Figura 49 – Conjunto difuso resultante. ....	93

## LISTA DE TABELAS

Tabela 1 - Resultados obtidos por STEINBACH (2008), valores em watts .....	26
Tabela 2 – Tabela de probabilidade condicional. ....	34
Tabela 3 – T-normas e t-conormas mais utilizadas.....	40
Tabela 4 – Variáveis escolhidas.....	57
Tabela 5 – Combinações de variáveis avaliadas. ....	58
Tabela 6 – Valores dos limites dos conjuntos <i>fuzzy</i> . ....	64
Tabela 7 – Configurações das redes para os gráficos falsos-positivos e falsos-negativos. ....	71
Tabela 8 – Resultado da capacidade (valores medidos em watt). ....	75
Tabela 9 – Tempo para inferência e amostragem adotados nos trabalhos.....	76
Tabela 10 – Comparação dos resultados de capacidade de refrigeração. ....	77

## LISTA DE ABREVIATURAS

ABNT	Associação Brasileira de Normas Técnicas
ASHRAE	<i>American Society of Heating, Refrigerating and Air-Conditioning Engineers</i>
AC	<i>Alternating current</i>
COP	<i>Coefficient of performance</i>
DC	<i>Direct current</i>
EMBRACO	Empresa Brasileira de Compressores
LABMETRO	Laboratório de Metrologia e Automação – UFSC
IA	Inteligência artificial
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
ISO	<i>International Organization for Standardization</i>
SE	Sistema especialista
SEP	Sistema especialista probabilístico
UFSC	Universidade Federal de Santa Catarina

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>13</b>
1.1	CONTEXTUALIZAÇÃO .....	13
1.2	OBJETIVO DO TRABALHO.....	15
1.3	ESTRUTURA DA DISSERTAÇÃO.....	15
<b>2</b>	<b>ENSAIO DE DESEMPENHO DE COMPRESSORES HERMÉTICOS .....</b>	<b>17</b>
2.1	BANCADAS DE ENSAIO .....	17
2.2	GRANDEZAS ENVOLVIDAS E MÉTODO DE ENSAIO .....	20
2.3	CARACTERIZAÇÃO DO REGIME PERMANENTE .....	21
2.4	DETERMINAÇÃO DO INSTANTE DE ENTRADA NO REGIME PERMANENTE.....	22
<b>3</b>	<b>FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL E ESTATÍSTICA .....</b>	<b>27</b>
3.1	INTELIGÊNCIA ARTIFICIAL .....	27
3.1.1	Sistemas especialistas .....	28
3.1.2	Lógica fuzzy.....	36
3.1.3	Abordagem híbrida: Bayes e fuzzy .....	43
3.2	VARIÂNCIA E DESVIO PADRÃO DE ALLAN .....	46
<b>4</b>	<b>DESCRIÇÃO DO MÉTODO DESENVOLVIDO.....</b>	<b>49</b>
4.1	CRITÉRIOS GERAIS PARA FORMAÇÃO DA BASE DE CONHECIMENTO .....	51
4.1.1	Critérios para seleção das variáveis para compor a base de conhecimento .....	51
4.1.2	Informações a serem incorporadas à base de conhecimento .....	51
4.2	PRÉ-PROCESSAMENTO DAS VARIÁVEIS DE ENTRADA.....	52
4.3	INFERÊNCIA HÍBRIDA .....	53
<b>5</b>	<b>IMPLEMENTAÇÃO DA FERRAMENTA PROPOSTA.....</b>	<b>54</b>
5.1	ESCOLHA DE VARIÁVEIS DE ENTRADA E LIMITES DE ESTABILIDADE .....	54
5.2	RESULTADOS OBTIDOS COM A REDE BAYESIANA.....	59
5.3	RESULTADOS OBTIDOS COM A REDE HÍBRIDA .....	64
5.4	PROCESSAMENTO DAS SAÍDAS DA REDE.....	67
5.4.1	Média.....	67
5.4.2	Dois resultados acima do patamar.....	67
5.4.3	Combinação de média com dois resultados acima do patamar .....	68
5.4.4	Verificação do tempo de estabilidade da capacidade.....	68
5.4.5	Combinação de tempo de estabilidade com dois resultados acima do patamar.....	69

5.4.6	Combinação de verificação de tempo de estabilidade com média e com dois resultados acima do patamar.....	70
5.5	<b>ANÁLISE DOS RESULTADOS FRENTE AOS ERROS NO INSTANTE DE ENTRADA EM REGIME PERMANENTE.....</b>	<b>71</b>
5.6	<b>AVALIAÇÃO DOS RESULTADOS FRENTE À MEDIÇÃO DE CAPACIDADE.....</b>	<b>73</b>
5.7	<b>ANÁLISE COMPARATIVA COM RESULTADOS OBTIDOS COM REDES NEURAIS.....</b>	<b>76</b>
5.8	<b>CONFIGURAÇÃO FINAL DO MÉTODO PROPOSTO .....</b>	<b>77</b>
6	<b>CONCLUSÕES E OPORTUNIDADES FUTURAS .....</b>	<b>78</b>
6.1	<b>CONCLUSÕES .....</b>	<b>78</b>
6.2	<b>OPORTUNIDADES FUTURAS.....</b>	<b>80</b>
	<b>REFERÊNCIAS.....</b>	<b>81</b>
	<b>APÊNDICE A – CONCEITOS DE PROBABILIDADE .....</b>	<b>85</b>
	<b>APÊNDICE B – EXEMPLO DE ABORDAGEM <i>FUZZY</i> .....</b>	<b>90</b>
	<b>APÊNDICE C – RESULTADOS DAS REDES BAYESIANA E HÍBRIDA.....</b>	<b>94</b>
	<b>APÊNDICE D – DESCRIÇÃO DE VARIÁVEIS DOS ENSAIOS.....</b>	<b>109</b>

# **1 INTRODUÇÃO**

## **1.1 CONTEXTUALIZAÇÃO**

No dia-a-dia das empresas fabricantes de compressores, os mais diferentes ensaios de compressores fazem parte da rotina, tanto para controle de qualidade quanto para pesquisa e desenvolvimento. Um dos ensaios mais representativos na determinação da qualidade de um compressor é o de desempenho. Esse ensaio demanda longo tempo – em média 4 horas – para sua realização.

Trabalhos estão sendo realizados no Laboratório de Metrologia e Automatização da UFSC – Labmetro, em parceria com a Whirlpool – Unidade Embraco de Compressores e Soluções de Refrigeração (Embraco), para reduzir de forma significativa o tempo de tal ensaio. Uma das frentes de trabalho, a que se insere esta dissertação, se propõe a empregar técnicas de inteligência artificial para obter tal redução.

Ensaio de desempenho que seguem a norma ISO 917 (1989) devem contemplar uma hora de ensaio em condições de regime permanente de operação (figura 1). O restante do tempo é gasto com o transitório que precede o regime permanente. SCUSSEL (2006), em seu trabalho, analisou a fase transitória, mostrando que pode ser viável reduzir o transitório para algo em torno de uma hora. Dessa forma o ensaio levaria uma hora de transitório e mais uma hora de regime, esta última prevista por norma (ISO, 1989). Considerando-se que mais de 70% dos ensaios realizados na Embraco são destinados à pesquisa e desenvolvimento – condição em que muito raramente a norma precisará ser respeitada – poder-se-ia reduzir esse tempo para algo tendendo a zero a partir do instante de entrada em regime. Isso é particularmente verdade em bancadas de ensaio como a desenvolvida através dos trabalhos de FLESCH (2006), POLETTO (2006) e PETROVIC (2007), que apresenta excelente estabilidade após entrada em regime. Em bancada com tal característica, durante a hora em que o sistema permanece em condições de regime, o ensaio tende a apresentar desvios muito pequenos em relação à tolerância permitida pela norma. Dessa forma, a medição das características do compressor poderia ser feita uma única vez no início do regime permanente.

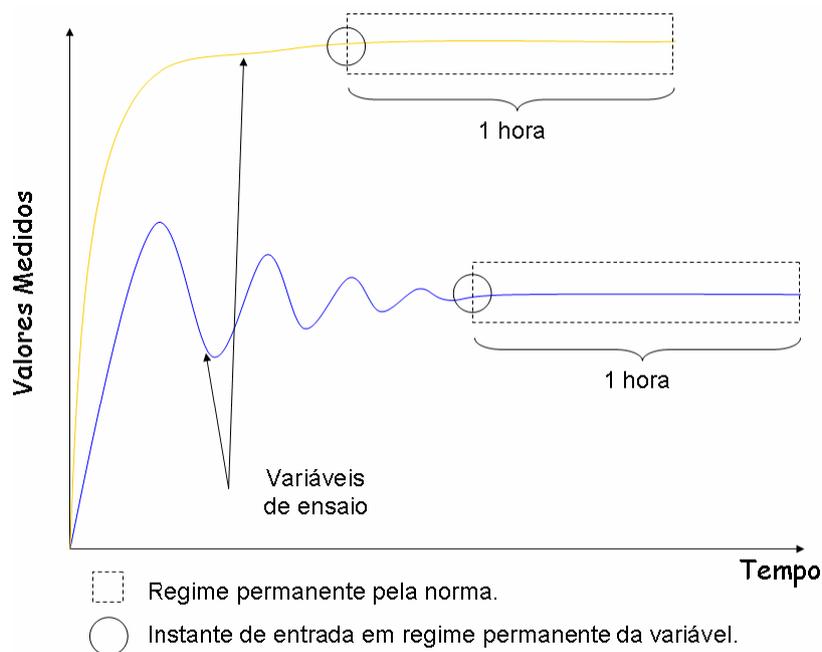


Figura 1 – Instante de entrada em regime permanente para diferentes variáveis de ensaio (STEINBACH, 2008).

Há um campo enorme para exploração da redução de tempo de ensaio, baseado nessa última hora prevista na norma. O sistema poderia também trabalhar de forma supervisionada: conhecendo-se de antemão o instante de entrada em regime permanente, o operador pode decidir por continuar o ensaio por uma hora – atendendo o estabelecido pela norma ISO 917 (1989) – ou fazer a aquisição das características desejadas e encerrar o ensaio.

Acontece, porém, que não há, atualmente, meios desenvolvidos para a identificação do instante no qual inicia o regime permanente. A caracterização de tal condição operacional é feita a posteriori, pela observação de que os desvios padrões das variáveis medidas mantiveram-se dentro de limites estabelecidos em norma por uma hora. Em outras palavras: o ensaio é considerado válido e é encerrado quando os valores das variáveis apresentarem baixos desvios durante uma hora. Dessa forma, só se sabe em que instante de tempo o sistema entrou em regime uma hora após esse evento efetivamente ter ocorrido.

STEINBACH (2008) propôs um sistema neural para identificação do instante de entrada em regime, com excelentes resultados, mostrando que é promissora tal identificação empregando técnicas de inteligência artificial.

## **1.2 OBJETIVO DO TRABALHO**

O objetivo desta dissertação é analisar a viabilidade de se empregar uma técnica de inteligência artificial – redes *fuzzy*-bayesianas – para identificação do instante de entrada em regime de ensaios de desempenho de compressores de refrigeração.

A técnica ora proposta poderá ser empregada isoladamente ou em conjunto com redes neurais artificiais, técnica empregada no trabalho de STEINBACH (2008). A aplicação conjunta das duas técnicas poderá conferir maior confiabilidade na identificação do instante de entrada em regime, já que são técnicas totalmente independentes.

Apesar das redes bayesianas terem surgido na década de 80 e as primeiras tentativas em solucionar os problemas gerados a partir de dados incertos datarem das décadas de 30 e 40, a utilização de estruturas deste tipo especificamente para inferência é bem recente (MAGALHÃES, 2007). A aplicação de redes bayesianas na indústria é crescente.

## **1.3 ESTRUTURA DA DISSERTAÇÃO**

O capítulo 2 apresenta uma breve explicação sobre bancadas de ensaios de desempenho de compressores, apresentando o método de ensaio F previsto na norma ISO 917, e os estudos desenvolvidos para a determinação do instante de entrada em regime permanente em trabalhos anteriores.

O capítulo 3 detalha as técnicas de inteligência artificial utilizadas para a implementação do método, destacando sistemas especialistas probabilísticos e lógica *fuzzy*. Também contém uma abordagem sobre hibridismo entre tais técnicas. Além disso, apresenta a variância de Allan como forma de analisar a variabilidade de dados não estacionários.

No capítulo 4 é feita uma descrição de forma genérica das etapas envolvidas no desenvolvimento, independentemente da plataforma a ser empregada. Também é mostrado o que se espera como resultados com a implementação.

O capítulo 5 apresenta o trabalho realizado, os resultados de testes necessários para a tomada de decisões, tais como a escolha de variáveis, e a

seleção da melhor configuração para a aplicação. Faz também comparação com os resultados que STEINBACH (2008) conseguiu utilizando rede neural artificial.

E por fim, no capítulo 6, são relacionadas as conclusões deste trabalho e as propostas para trabalhos futuros.

## 2 ENSAIO DE DESEMPENHO DE COMPRESSORES HERMÉTICOS

O ensaio de desempenho é um dos mais importantes meios de avaliação de um compressor, tanto no desenvolvimento quanto no controle de qualidade. Para viabilizar a comparação com o mercado e o controle de qualidade, os ensaios são realizados sob condições estabelecidas em normas. No entanto, ensaios relacionados para pesquisa e desenvolvimento de produtos, conforme necessidades internas, podem não seguir tais normas. O objetivo desses ensaios é determinar as características dos compressores quanto a:

- capacidade de refrigeração ( $\Phi_0$ ): que é uma medida da capacidade do compressor de gerar vazão mássica de refrigerante frente a um diferencial de pressão imposto entre a tomada de sucção e descarga do compressor (STOECKER, 2002);
- potência elétrica ativa consumida nos terminais do compressor (ISO-917, 1989);
- coeficiente de performance (COP): é uma medida da eficiência energética do compressor, calculado como a razão entre a capacidade de refrigeração e o consumo de potência ativa. É uma grandeza adimensional.

### 2.1 BANCADAS DE ENSAIO

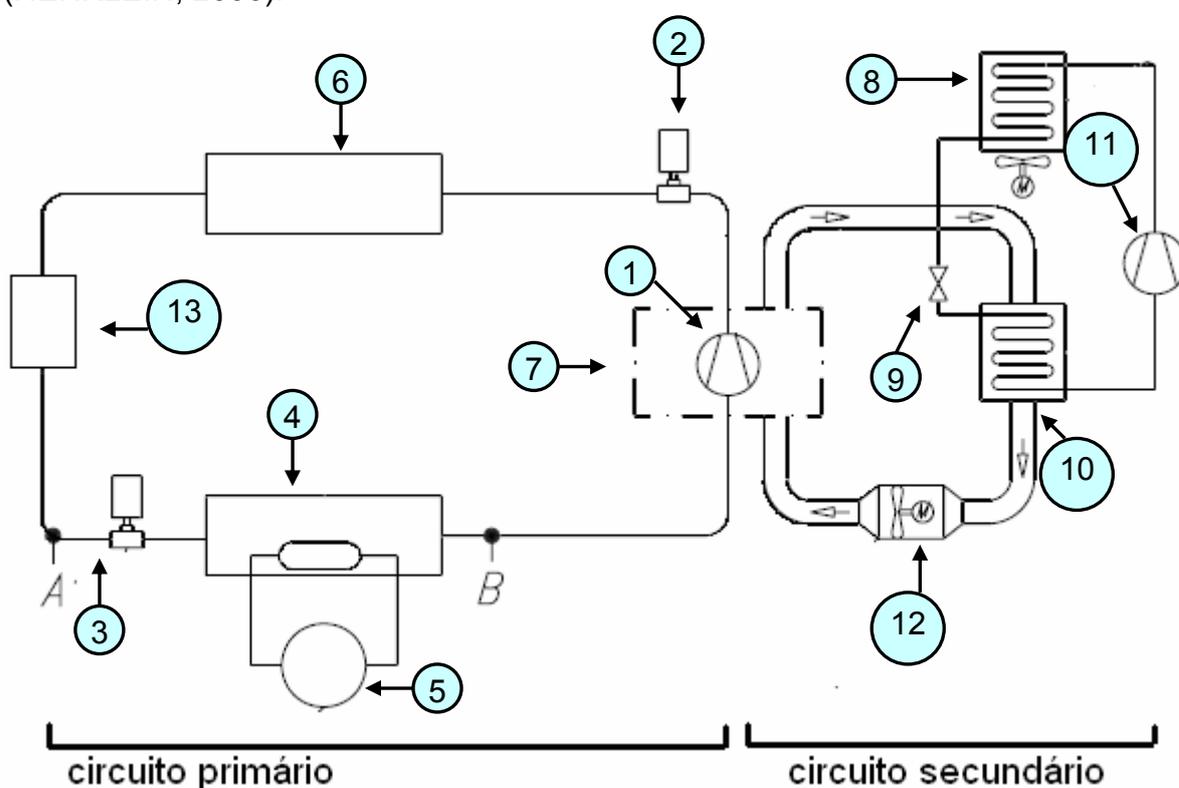
De acordo com a norma ISO 917 (1989), os ensaios de desempenho devem ser realizados em bancadas especiais, capazes de reproduzir diferentes condições de operação e realizar diversas medições. Nessas bancadas existem duas tarefas principais envolvidas: as operações de controle e as operações de medição.

As operações de controle garantem as condições de operação dentro de limites estabelecidos. A bancada deve possuir controladores, atuadores e medidores para que a malha de controle seja eficiente e capaz de colocar as variáveis controladas dentro de limites estabelecidos pela norma ou procedimento aplicável.

Existem vários métodos previstos na norma ISO 917 (1989) para realizar tais ensaios, 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.

Na bancada disponível no laboratório há dois circuitos de refrigeração envolvidos nas bancadas: um para o compressor em ensaio (primário) e circuito para realizar a climatização de um compartimento para o compressor em ensaio (secundário). Esses circuitos são mostrados na figura 2. Vários são os atuadores, como resistências de aquecimento e válvulas de pressão, que servem para impor a condição de operação, na qual é observado o desempenho do compressor (HENKLEIN, 2006).



Legenda:

- 1 - compressor sob ensaio;
- 2 - válvula reguladora da pressão da descarga;
- 3 - válvula reguladora da pressão da sucção;
- 4 - evaporador;
- 5 - fonte fornecedora de energia ao calorímetro;
- 6 - condensador;
- 7 - box (compartimento fechado onde fica o compressor ensaiado);
- 8 - condensador do circuito de refrigeração do box;
- 9 - capilar do circuito de refrigeração do box;
- 10 - evaporador do circuito de refrigeração do box;
- 11 - compressor do circuito de refrigeração do box;
- 12 - aquecedor e ventilador de ar para o box;
- 13 - medidor de vazão mássica.

**Figura 2 – Modelo genérico de uma bancada de ensaio de compressores (SCUSSEL, 2006).**

SCUSSEL (2006) descreveu o funcionamento de cada item que compõe a bancada.

Elementos do circuito primário:

1 – Compressor ensaiado sob condições controladas;

2 e 3 – Válvulas que impõem as pressões de sucção e de descarga sobre o compressor;

4 – Evaporador – onde ocorrem as trocas de calor que quantificam a vazão mássica de refrigerante. São medidas as pressões e temperaturas na entrada **A** e na saída **B**. Dessa forma são conhecidas, a partir de uma tabela de propriedades termodinâmicas de fluidos refrigerantes, as entalpias nestes locais.

5 – Fonte de energia para o evaporador – entrega um valor conhecido de potência elétrica para a resistência de aquecimento interna. Tal potência deve ser suficiente para evaporar completamente o fluido refrigerante no interior do evaporador e é utilizada na composição de um balanço de energia e massa para estimar o fluxo de massa de fluido refrigerante. Conhecendo-se o fluxo de massa é possível definir, a partir das exigências da norma ISO 917 (1989), os valores finais do ensaio.

13 – medidor de vazão mássica – esse equipamento fornece diretamente o fluxo mássico de fluido refrigerante que circula por ele.

Elementos do circuito secundário:

7 – Compartimento climatizado para garantir temperatura constante sobre o compressor ensaiado;

8, 9, 10 e 11 – Circuito de refrigeração para troca de calor entre a carcaça do compressor sob ensaio e ar de arrefecimento;

12 – Aquecedor e ventilador. Tem por função manter a temperatura e movimentação de ar em torno do compressor sob ensaio.

A norma ISO 917 (1989) prevê a necessidade de utilização de dois dos seguintes métodos de avaliação de fluxo de massa:

- Método A: balanço de energia no calorímetro de fluido secundário;
- Método B: balanço de energia no calorímetro inundado;

- Método C: balanço de energia no calorímetro a seco;
- Método D1 e D2: medição de fluxo de massa na fase gasosa;
- Método F: medição do fluxo de massa na fase líquida;
- Método G: balanço de energia na mistura do refrigerante condensado e o não condensado;
- Método K: balanço de energia no calorímetro na linha de descarga.

Essa norma estabelece ainda que os dois métodos sejam aplicados simultaneamente, e indica quais podem ser combinados. Os resultados precisam apresentar correlação menor ou igual à  $\pm 4\%$  entre eles.

## **2.2 GRANDEZAS ENVOLVIDAS E MÉTODO DE ENSAIO**

A norma ISO 917 (1989) estabelece que algumas variáveis sejam medidas e controladas para criar condições determinadas de operação. Essas variáveis são:

- pressão de descarga;
- pressão de sucção;
- temperatura de 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;
- sub-resfriamento do fluido refrigerante na entrada do trocador.

Algumas variáveis são somente medidas:

- 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.

Além de definir as variáveis que devem ser medidas e controladas, o método de ensaio define também os locais, os intervalos entre amostras e as incertezas de medição admissíveis.

O objetivo deste trabalho é a identificação do instante de entrada em regime permanente de variáveis de ensaio em um dos métodos apresentados. A bancada utilizada neste trabalho para realização dos ensaios satisfaz a norma ISO 917 (1989) através dos métodos C e F. Optou-se por analisar os dados obtidos através do método C.

### **2.3 CARACTERIZAÇÃO DO REGIME PERMANENTE**

Ao iniciar um ensaio de desempenho de um compressor, a bancada começa o processo de controle para que as variáveis atinjam os valores da condição de operação. Enquanto esses valores não estiverem continuamente dentro dos limites de variação permitidos pela norma, o ensaio encontra-se em período transitório. Do contrário, o ensaio é dito em regime permanente.

A norma ISO 917 (1989) caracteriza o período de regime permanente quando as variações apresentam-se dentro dos limites conforme a grandeza envolvida:

- pressões não podem ter variação superior a  $\pm 1\%$  do valor de referência;
- temperaturas não podem ter variação superior a  $\pm 3$  °C do valor de referência;
- tensão de alimentação do compressor não pode ter variação superior a  $\pm 3\%$  do valor de referência e a frequência  $\pm 1\%$  do valor de referência;
- fluxo de massa não pode ter variação superior a  $\pm 1\%$  do valor médio da última uma hora.

No regime permanente, as medições devem ser realizadas durante uma hora em períodos constantes.

Os valores de capacidade de refrigeração, potência ativa consumida pelo compressor e coeficiente de desempenho são calculados com os valores médios consecutivos de uma hora de ensaio em regime permanente (ISO 917, 1989).

## 2.4 DETERMINAÇÃO DO INSTANTE DE ENTRADA NO REGIME PERMANENTE

Não existe referência em norma de como fazer a identificação do instante de entrada no regime permanente. Trabalhos recentes, realizados no Labmetro, aplicaram ferramentas de inteligência artificial no estudo dos ensaios de desempenho durante período transitório. Através da utilização de redes neurais e lógica *fuzzy* foram investigados métodos para realização de prognósticos das características de desempenho bem como a identificação dos instantes de entrada em regime permanente.

O trabalho de HENKLEIN (2006) optou pela utilização de redes neurais devido à complexidade da análise dos dados no transitório e à ausência de regras explícitas para tal tarefa. O trabalho teve o objetivo de identificar e classificar o desempenho do compressor sob ensaio ainda durante o período transitório (figura 3).

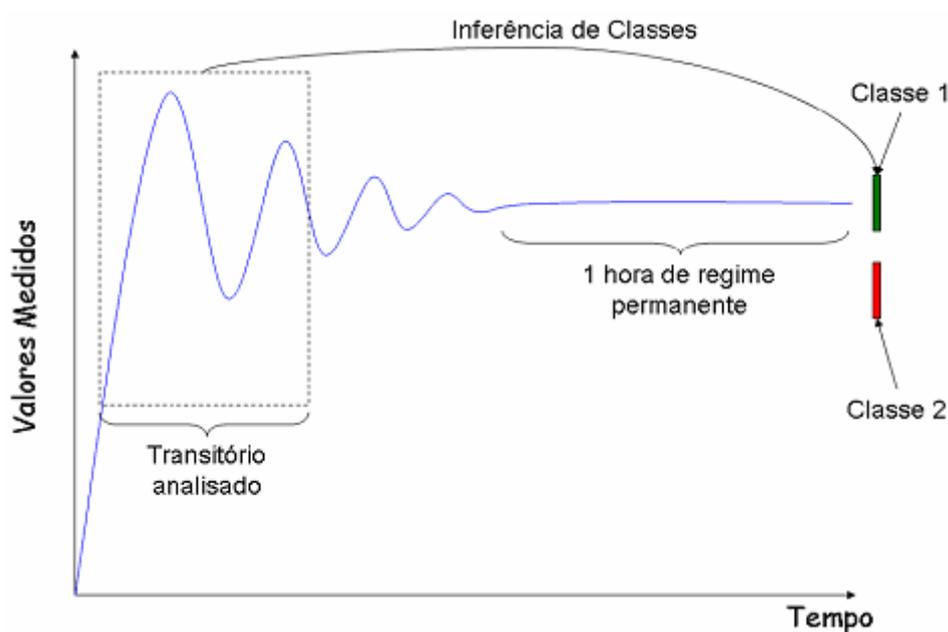


Figura 3 – Regime transitório e permanente (HENKLEIN, 2006).

HENKLEIN (2006) realizou um estudo de observação do comportamento de diversas variáveis no período transitório, incluindo variáveis que não fazem parte do

conjunto de variáveis definidas pelas normas, com intenção de encontrar variáveis que agregassem informações para a inferência. O trabalho gerou grande quantidade de dados sobre o período transitório. Teve grande importância devido ao seu caráter investigativo que incluiu: estudo e definição das medições; adequação do sistema atual de ensaios a aplicação das ferramentas de inteligência artificial; desenvolvimento do módulo de diagnóstico dos ensaios.

A priori todas as grandezas foram consideradas por tal autor como possíveis entradas para a rede neural que realiza o processo de inferência. Porém, após a execução de inúmeros treinamentos e avaliações de redes neurais, foram selecionadas as grandezas que agregam mais informação a respeito da capacidade de refrigeração e consumo de potência ativa.

As seguintes variáveis foram utilizadas para as entradas da rede neural proposta por HENKLEIN (2006) para classificação da capacidade de refrigeração:

- temperatura de descarga;
- temperatura do topo da carcaça;
- fluxo de massa de refrigerante (com e sem filtragem);
- potência dissipada nas resistências de aquecimento do calorímetro;
- capacidade instantânea calculada pelo fluxo de massa.

O tempo médio de ensaio para obtenção da capacidade de refrigeração utilizando a ferramenta desenvolvida por HENKLEIN (2006) foi de 38 minutos, aproximadamente um sexto do tempo médio de ensaio com o procedimento normal que é de 240 minutos.

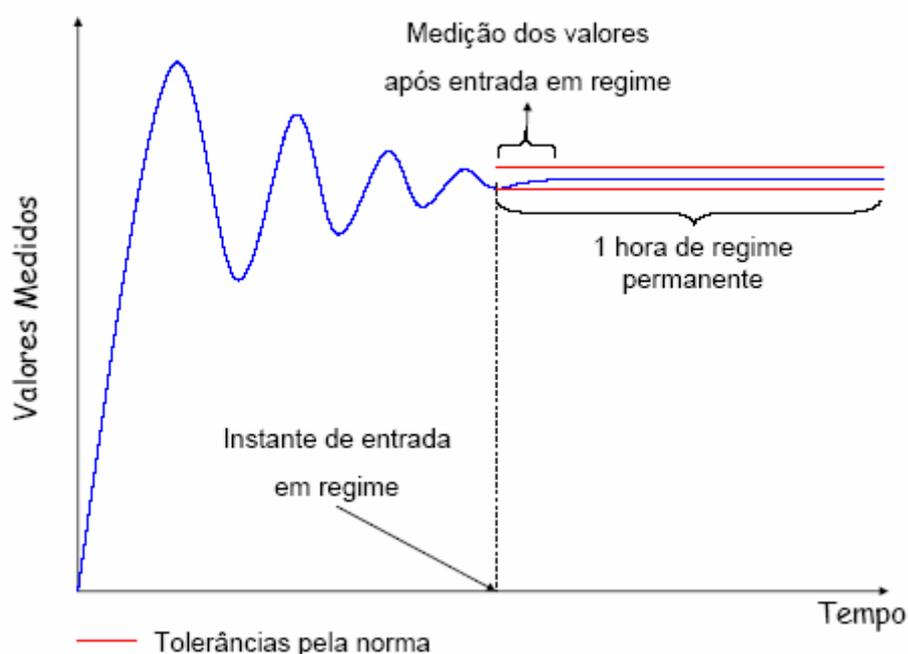
Para classificação do consumo de potência ativa foram utilizadas as seguintes variáveis para as entradas da rede neural proposta por HENKLEIN (2006):

- corrente eficaz do compressor;
- potência ativa instantânea consumida pelo compressor;
- potência reativa instantânea demandada pelo compressor;
- amplitude da componente fundamental (60 Hz) de corrente do compressor;
- amplitude da 3ª harmônica de corrente;
- amplitude da 5ª harmônica de corrente;
- amplitude da 7ª harmônica de corrente;

- temperatura de descarga;
- temperatura do topo da carcaça.

O tempo médio de ensaio para obtenção do consumo de potência ativa utilizando a ferramenta desenvolvida por HENKLEIN (2006) foi de 14 minutos, uma economia de 3 h 46 min em relação ao tempo médio de ensaio demandado pelo método tradicional.

STEINBACH (2008) propõe a redução do tempo demandado por esses ensaios também através do emprego de redes neurais artificiais. Dois caminhos foram explorados com sucesso: identificação do instante em que condições de regime são atingidas; inferência de valores de regime a partir de dados do transitório. O primeiro é uma proposta inédita (como mostrado na figura 4) e o segundo uma continuação do trabalho realizado por HENKLEIN (2006).



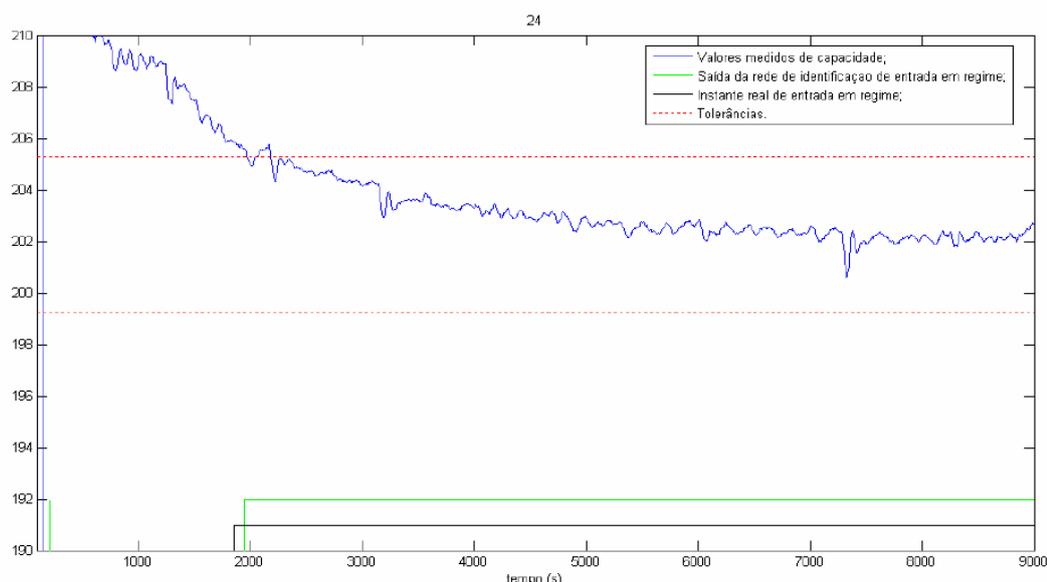
**Figura 4 – Instante de entrada em regime permanente e amostra dos valores medidos (STEINBACH, 2008).**

STEINBACH (2008) utilizou as seguintes variáveis de entrada para as redes de inferência e identificação do instante de regime permanente:

- temperatura de descarga do compressor;
- temperatura da carcaça do compressor;
- corrente elétrica consumida pelo compressor;
- potência elétrica ativa na entrada do compressor;

- fluxo de massa de refrigerante;
- capacidade calculada a partir do fluxo de massa (método F);
- 1ª média de capacidade (média de 15 amostras);
- 2ª média de capacidade (média de 15 amostras com atraso de 75 s);
- 3ª média de capacidade (média de 15 amostras com atraso de 150 s);
- derivada de 1ª ordem entre os valores da 1ª e da 2ª média da capacidade;
- derivada de 1ª ordem entre os valores da 2ª e da 3ª média da capacidade;
- derivada de 1ª ordem entre os valores da 1ª e da 3ª média da capacidade.

Um exemplo de resposta da rede neural para a identificação do instante de entrada em regime permanente da capacidade de refrigeração é apresentado na figura 5.



**Figura 5 – Identificação do instante de regime para capacidade de refrigeração obtido por STEINBACH (2008)**

Adicionalmente à rede para identificação do instante de entrada em regime da capacidade de refrigeração, STEINBACH (2008) desenvolveu as redes para avaliação da estabilidade do consumo de potência ativa e coeficiente de performance (COP). Após a entrada em regime permanente de uma variável, os valores medidos dessa variável estarão entre os limites de tolerância.

A tabela 1 resume os resultados de STEINBACH (2008). Para cada uma das variáveis são apresentados os erros médios – absolutos e relativos – e os

respectivos desvios padrão de amostras de 1 minuto após uma espera de 14 minutos. Essas amostras de 1 minuto foram realizadas em 3 situações: “regime real amostras medidas” – valores medidos após entrada em regime real; “regime rede amostras medidas” – valores medidos após entrada em regime proposta pela rede; “regime rede amostras inferidas” – valores inferidos após entrada em regime pela rede.

**Tabela 1 - Resultados obtidos por STEINBACH (2008), valores em watts para capacidade e consumo.**

		Capacidade	% em 200 W	Consumo	% em 140 W	COP	% em 1,3
Regime real	Média	1,82	0,91%	0,04	0,03%	0,0213	1,64%
Amostras medidas	Desvio Padrão	0,66	0,33%	0,45	0,32%	0,0101	0,78%
Regime rede	Média	1,56	0,78%	-0,05	-0,04%	0,0212	1,63%
Amostras medidas	Desvio Padrão	0,56	0,28%	0,55	0,39%	0,0083	0,64%
Regime rede	Média	0,33	0,17%	0,10	0,07%	0,0013	0,10%
Amostras inferidas	Desvio Padrão	0,53	0,27%	0,46	0,33%	0,0083	0,64%

Dos resultados da tabela 1 vale ressaltar os valores de inferência de capacidade feitas após a identificação do instante de entrada em regime pela rede: 0,17% de erro médio e 0,27% de desvio padrão. Esse resultado demonstra a robustez dos sistemas propostos para os ensaios usados.

A redução obtida no tempo médio de ensaio foi significativa, sem comprometer a confiabilidade dos resultados, abrindo novos caminhos para o emprego de recursos de inteligência artificial em ensaios de compressores.

### **3 FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL E ESTATÍSTICA**

Este capítulo descreve as técnicas de inteligência artificial empregadas na dissertação: redes bayesianas e lógica *fuzzy*. Apresenta também a variância de Allan como ferramenta estatística utilizada.

A escolha das redes bayesianas para a tarefa de identificação do instante de entrada em regime permanente se justifica pela necessidade de um meio alternativo à aplicação de redes neurais realizada por STEINBACH (2008). Tal necessidade é apresentada no trabalho de PENZ (2008) que estrutura um sistema para garantir a confiabilidade dos resultados obtidos pelas ferramentas de inteligência artificial nos ensaios de desempenho de compressores. PENZ (2008) propõe a utilização de ferramentas distintas, para realização da mesma tarefa, e posterior composição das diferentes respostas. O resultado, adequadamente composto, apresenta maior confiabilidade em relação às respostas individuais.

#### **3.1 INTELIGÊNCIA ARTIFICIAL**

Inteligência artificial (IA) pode ser definida como um campo de estudo que busca explicar e emular comportamentos inteligentes em termos de processos computacionais. A interpretação, do ponto de vista da engenharia, dado por SCHALKOFF (1990) é “...gerar representações e procedimentos que automaticamente resolvam problemas.”

A síntese de inteligência artificial pode ser dada, segundo RICH (1993), como “*a ciência de fazer o computador realizar tarefas que até agora, somente as pessoas podiam realizar.*”

Na metrologia, a IA é uma área de pesquisa em expansão, tendo aplicações em todas as atividades do processo de medição: estabelecimento de requisitos do sistema de medição; projeto do processo de medição; avaliação de incertezas; avaliação das medições; calibração de sistemas de medição; interpretação de resultados de medição (ALIPPI, 1998; HECKMANN, 1999).

Neste trabalho, IA é aplicada para análise em tempo real de valores gerados em ensaios de compressores. Para tanto, três técnicas serão estudadas: sistema especialista, sistema *fuzzy* e híbrido.

### 3.1.1 *Sistemas especialistas*

Sistema especialista (SE) também é conhecido como um sistema baseado em conhecimento. O conhecimento adquirido pelo sistema é a fonte de raciocínio do mesmo (RUSSELL, 2004). Esses sistemas são projetados para simular um raciocínio do tipo causa-efeito.

Estruturalmente, todo SE é constituído por duas partes principais: a base de conhecimento e a máquina de inferência (RICH, 1993).

A **base de conhecimento** contém o conhecimento heurístico sobre o domínio da aplicação, representado sob a forma de regras, quadros, redes semânticas ou outra forma qualquer (RABUSKE, 1995). É onde está representado o conhecimento sobre o domínio (BITTENCOURT, 2006).

A **máquina de inferência** compreende o interpretador de regras e o escalonador das regras, quando o sistema especialista envolve regras de produção. (BITTENCOURT, 2006).

Um SE deve ser capaz de tratar incertezas advindas de informações incompletas ou não-confiáveis de algum problema. Em alguns casos, as relações no domínio do problema podem ser aproximadas, requerendo raciocínio probabilístico.

A necessidade de se tratar a incerteza nos sistemas especialistas levou à construção de sistemas especialistas probabilísticos (SEP). Neste item está apresentada a definição desse tipo de sistema, o raciocínio que utiliza e a teoria estatística aplicada.

Sistemas especialistas probabilísticos são programas de inferência sobre uma base de conhecimentos específicos (TESSARI,1998). Esses sistemas têm em sua base de conhecimento fatos e regras que representam o conhecimento do especialista no domínio de aplicação. Aos fatos e regras é associada a incerteza presente no domínio e são explicitadas as crenças através de valores de probabilidade (TESSARI,1998).

Os conceitos de probabilidade, essenciais para o entendimento dos SEP, estão apresentados no apêndice A.

### 3.1.1.1 Raciocínio bayesiano

Esta teoria mostra uma maneira de calcular a probabilidade de um evento em particular, dado algum conjunto de observações que se tenha feito (RUSSELL, 2004). E por este motivo a teorema de Bayes se torna aplicável no método apresentado neste trabalho.

O teorema desenvolvido por Thomas Bayes é base útil para a probabilidade condicional. Segundo NASSAR (1998), “esse teorema é um método quantitativo para a revisão de probabilidades conhecidas, com base em nova informação amostral, sendo fundamental para se analisar um conjunto de informações disponíveis e se chegar a uma conclusão, expressa numericamente.”

Serão apresentados a seguir alguns teoremas e propriedades intrínsecos ao raciocínio bayesiano.

#### 3.1.1.1.1 Teorema de Bayes

Seja o espaço de amostral  $S$  e os eventos compostos  $E, H_1, H_2, \dots, H_K \subseteq S$ , desde que nenhum desses eventos tenha probabilidade nula, então (MONTGOMERY, 2003):

$$P(H_i | E) = \frac{P(E | H_i) \cdot P(H_i)}{P(E)} \quad (1)$$

Considerando que:

1. A probabilidade  $P(H_i \cap E) \neq 0$  para todo  $i$ ;
2. Os eventos  $H_1 \cup H_2 \cup \dots \cup H_k = S$  e  $H_i \cap H_j = \emptyset$  para todo  $i \neq j$  (isto é, as  $H_i$  formam uma partição do espaço  $S$ ).

Então:

$$E = (H_1 \cap E) \cup (H_2 \cap E) \cup \dots \cup (H_m \cap E) \quad (2)$$

$$P(E) = P(H_1) \cdot P(E | H_1) + P(H_2) \cdot P(E | H_2) + \dots + P(H_k) \cdot P(E | H_k) \quad (3)$$

resultando

$$P(H_i | E) = \frac{P(E | H_i) \cdot P(H_i)}{\sum_{j=1}^k (P(H_j) \cdot P(E | H_j))} \quad (4)$$

A equação (3) é conhecida como *teorema da probabilidade total* e a equação (4) é o *teorema de Bayes* (BARBETTA, 2004).

Nas aplicações dos sistemas especialistas probabilísticos os  $H_i$  são as hipóteses diagnósticas (saídas). O evento  $E$  pode ser visto como uma evidência (entrada). O conhecimento da ocorrência desta evidência leva à mudanças na probabilidade a priori  $P(H_i)$  para a probabilidade condicional  $P(H_i | E)$ , que por sua vez considera a evidência  $E$  (NASSAR, 1998).

### 3.1.1.1.2 *Independência de eventos bayesianos*

Generalizando a independência de eventos para o teorema de Bayes, tem-se para qualquer subconjunto  $E = \{E_{i1}, E_{i2}, \dots, E_{ijk}\}$  de  $\{E_1, E_2, \dots, E_n\}$ :

Se  $P(E_{i1} \wedge E_{i2} \wedge \dots \wedge E_{ijk} | H) = P(E_{i1} | H) \cdot P(E_{i2} | H) \dots P(E_{ijk} | H)$  então pode-se dizer que os eventos  $E_i$  são eventos mutuamente independentes sob a hipótese  $H$ .

### 3.1.1.1.3 *Teorema de Bayes com evidências múltiplas e independentes*

Considerando que temos as  $n$  evidências  $(E_1, E_2, \dots, E_n)$ , então a probabilidade da hipótese diagnóstica  $H_i$  é dada por:

$$P(H_i | E_1 \wedge E_2 \wedge \dots \wedge E_n) = \frac{P(E_1 \wedge E_2 \wedge \dots \wedge E_n | H_i) \cdot P(H_i)}{P(E_1 \wedge E_2 \wedge \dots \wedge E_n)} \quad (5)$$

Supondo que as evidências são independentes sob a hipótese  $H_i$  então:

$$P(H_i | E_1 \wedge E_2 \wedge \dots \wedge E_n) = \frac{(P(E_1 | H_i) \cdot P(E_2 | H_i) \dots P(E_n | H_i)) \cdot P(H_i)}{P(E_1 \wedge E_2 \wedge \dots \wedge E_n)} \quad (6)$$

Resultando em:

$$P(H_i | E_1 \wedge E_2 \wedge \dots \wedge E_n) = \frac{P(H_i) \cdot \prod_{k=1}^n P(E_k | H_i)}{P(E_1 \wedge E_2 \wedge \dots \wedge E_n)} \quad (7)$$

### 3.1.1.1.4 *Atualização bayesiana para uma nova evidência*

Uma característica da regra de atualização de Bayes é seu esquema computacional recursivo e incremental, que propaga cada informação (*entrada*) dada à rede (NASSAR, 2007).

Seja  $H_i$  uma hipótese, e  $E^n = E_1, E_2, \dots, E_n$  uma seqüência de dados condicionalmente independentes observados no passado e  $E$  um novo fato, a probabilidade condicional é igual a (NASSAR, 2007):

$$P(H_i | E^n \wedge E) = \frac{P(H_i \wedge E^n \wedge E)}{P(E^n \wedge E)} = \frac{P(E^n) \cdot P(H_i | E^n) \cdot P(E | E^n \wedge H_i)}{P(E^n) \cdot P(E | E^n)} \quad (8)$$

Resultando em

$$P(H_i | E^n \wedge E) = P(H_i | E^n) \cdot \frac{P(E^n \wedge H_i)}{P(E | E^n)} \quad (9)$$

Supondo válida a independência condicional sob a hipótese  $H_i$  então

$$P(H_i | E^n \wedge E) = P(H_i | E^n) \cdot \frac{P(E | H_i)}{P(E | E^n)} \quad (10)$$

Observe que  $P(H_i | E^n)$  mostra o estado da rede para a informação da ocorrência do evento  $E^n$  no passado.  $P(E | H_i) / P(E | E^n)$  é a atualização da rede para a nova informação  $E$ .

### 3.1.1.1.5 *Hipóteses multivaloradas*

Nas aplicações de SEP é comum a existência de várias hipóteses concorrentes, cada uma com um conjunto distinto de evidências. Diz-se, então, que o sistema tem um conjunto multivalorado de hipóteses. Assim, o SEP deve selecionar a hipótese (saída), mais provável a partir de um conjunto de evidências conhecidas (entradas) e que representam os dados de uma nova consulta ao sistema (NASSAR, 2007).

Supondo que se tenha  $m$  hipóteses e  $n$  evidências, o vetor de probabilidades condicionais das várias hipóteses concorrentes é obtido de acordo com o procedimento a seguir.

Dado um conjunto de evidências  $E_1, E_2, E_3, \dots, E_k, \dots, E_n$ , a crença na  $i$ -ésima hipótese  $H_i$  é dada por:

$$P(H_i | E_1 \wedge E_2 \wedge \dots \wedge E_k \dots \wedge E_n) = \frac{P(E_1, E_2, \dots, E_k \dots E_n | H_i) \cdot P(H_i)}{P(E_1 \wedge E_2 \wedge \dots \wedge E_k \dots \wedge E_n)} \quad (11)$$

Chamando a probabilidade  $[P(E_1, E_2, E_3, \dots, E_k, \dots, E_n)]^{-1}$  de constante de normalização e denotando por  $\alpha$ , e supondo a independência condicional das evidências com relação a cada hipótese  $H_i$ , então:

$$P(H_i | E_1 \wedge E_2 \wedge \dots \wedge E_n) = \alpha P(H_i) \cdot \prod_{k=1}^n P(E_k | H_i) \quad (12)$$

Note que:

a)  $P(H_i)$  é o vetor de probabilidades a priori das diferentes hipóteses em consideração;

b) A constante de normalização  $\alpha$  deve ser calculada pela restrição de soma unitária das probabilidades  $P(H_i | E_1 \wedge E_2 \wedge E_3 \dots \wedge E_k \dots \wedge E_n)$ .

Assumindo ainda que para evidência  $E_k$  define-se o vetor  $\lambda^k$  de probabilidades condicionais das  $m$  hipóteses, isto é:

$$\lambda^k = (\lambda_1, \lambda_2, \dots, \lambda_m) \text{ onde } \lambda_i = P(E_k | H_i).$$

Finalmente, pode-se reescrever a equação original na seguinte forma:

$$P(H_i | E_1 \wedge E_2 \wedge E_3 \dots \wedge E_k \dots \wedge E_n) = \alpha \cdot P(H_i) \Delta. \quad (13)$$

$$\text{onde } \Delta = \lambda^1 \cdot \lambda^2 \cdot \lambda^3 \cdot \dots \cdot \lambda^n.$$

Assim, fica computacionalmente mais fácil obter o vetor de probabilidades condicionais das hipóteses  $H_i$  dado um conjunto de evidências. Por outro lado, com a expressão acima, fica também fácil verificar que a regra de atualização bayesiana apresenta um esquema computacional recursivo e incremental a cada evidência nova informada ao sistema (NASSAR, 2007).

A equação (13) é utilizada pela rede bayesiana para atualização da probabilidade dada uma nova evidência.

### 3.1.1.2 Rede bayesiana

Segundo RUSSEL (2004) uma rede bayesiana é um grafo orientado acíclico, sendo que os nós representam variáveis aleatórias e os arcos são as relações probabilísticas entre variáveis conectadas. As variáveis que constituem os nós da rede podem ser discretas ou contínuas e são unidas aos pares por arcos orientados. Um conjunto de vínculos orientados, ou setas, conecta pares de nós. Se houver uma seta do nó  $X$  até o nó  $Y$ ,  $X$  será denominado *pai* de  $Y$  (RUSSEL, 2004).

Cada nó está relacionado com uma tabela de probabilidade condicional  $P(X_i | pais(X_i))$ , cujo tamanho está vinculado aos condicionamentos existentes para aquela variável (RUSSEL, 2004).

A estrutura de uma rede bayesiana consiste de duas partes:

- Qualitativa – corresponde à estrutura gráfica da rede, composta pelas variáveis de entrada (evidências), variáveis de saída (hipótese) e os arcos (relação de dependência entre elas ou regras);
- Quantitativa – é o conjunto de probabilidades condicionais associadas aos arcos existentes no modelo gráfico e às probabilidades estimadas a priori das hipóteses diagnosticadas.

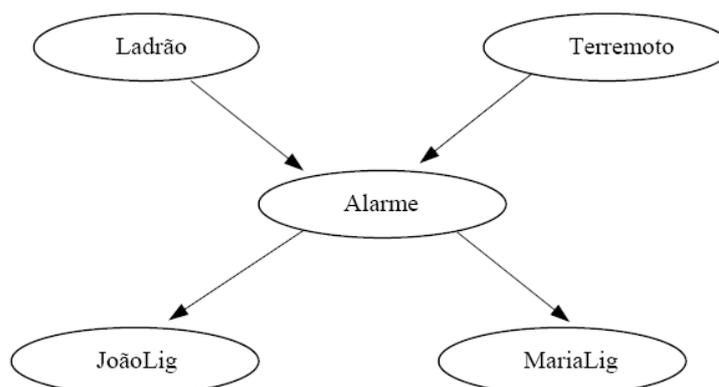
A topologia da rede – conjunto de nós e vínculos – especifica os relacionamentos de independência condicional que são válidos no domínio. O significado de uma seta em uma rede é que  $X$  tem uma influência direta sobre  $Y$  (RUSSEL, 2004).

As regras que geram as probabilidades de saída (*a posteriori*) não são expressas como as regras SE-ENTÃO dos sistemas especialistas tradicionais. Nas redes bayesianas, o teorema de Bayes é o responsável por gerar os valores de probabilidade de cada estado da variável de saída. Pode-se entender que a seguinte regra **SE A ENTÃO B** com 80% de certeza, pode ser representada por  $P(B | A) = 80\%$ .

Considere-se o exemplo as seguir (PEARL, 1988): “Você possui um novo alarme residencial. Esse alarme é muito confiável, entretanto ele também pode disparar caso ocorra um terremoto. Você tem dois vizinhos, João e Maria, os quais prometeram lhe telefonar caso esteja ausente e o alarme dispare. João sempre liga

quando ouve o alarme, entretanto, algumas vezes, confunde o alarme com o telefone e também liga nesses casos. Maria, por outro lado, gosta de ouvir música alta e às vezes não escuta o alarme.” Dada a evidência de quem telefonou ou não telefonou, é possível estimar a probabilidade de um roubo.

Esse exemplo pode ser representado como na figura 6.



**Figura 6 – Topologia da rede do exemplo.**

Uma vez definida a topologia, é necessário definir a tabela de probabilidades condicionais para cada nó. Cada linha na tabela contém a probabilidade condicional para cada caso condicional dos nós pais. Um caso condicional é uma possível combinação dos valores para os nós pais (RUSSEL, 2004).

Por exemplo, para a variável aleatória Alarme tem-se:

**Tabela 2 – Tabela de probabilidade condicional.**

Ladrão	Terremoto	$P(\text{Alarme} \mid \text{Ladrão}, \text{Terremoto})$	
		Verdadeiro	Falso
Verdadeiro	Verdadeiro	0,950	0,050
Verdadeiro	Falso	0,950	0,050
Falso	Verdadeiro	0,290	0,710
Falso	Falso	0,001	0,999

A figura 7 apresenta a rede bayesiana para o exemplo e suas probabilidades condicionais. As letras *L*, *T*, *A*, *J* e *M*, representam *Ladrão*, *Terremoto*, *Alarme*, *João Liga* e *Maria Liga*, respectivamente.

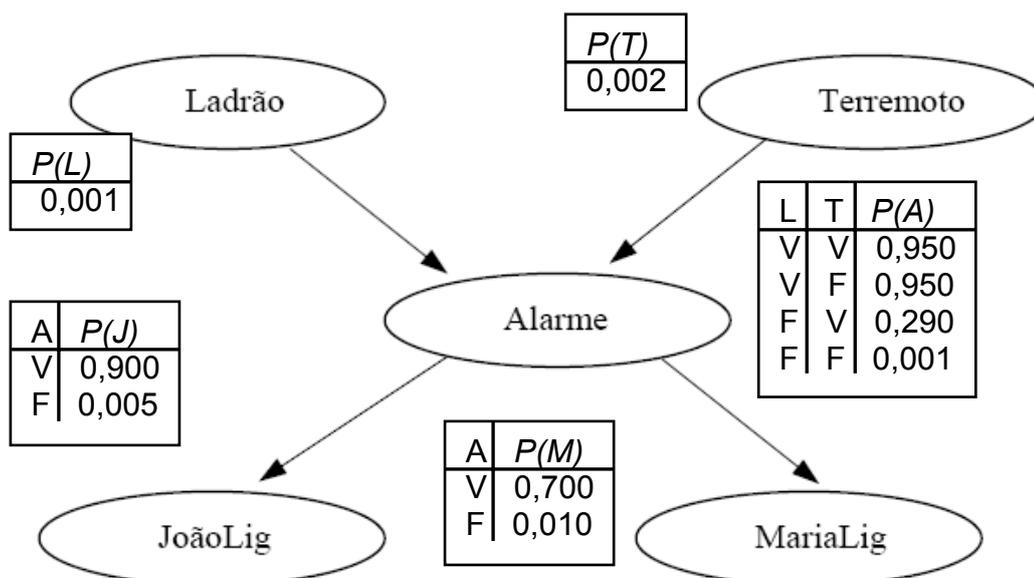


Figura 7 – Rede bayesiana mostrando a topologia e as tabelas de probabilidade condicional.

Cada linha deve somar 1, porque as entradas representam um conjunto exaustivo de casos para a variável. Uma vez conhecido que a probabilidade de um valor verdadeiro é  $p$ , a probabilidade de um falso tem de ser  $1 - p$ , e, assim pode-se omitir o segundo número (RUSSEL, 2004).

Cada entrada da tabela de conjunção de probabilidades pode ser calculada a partir da conjunção das variáveis atribuídas aos devidos valores,  $P(X_1 = x_1 \wedge \dots \wedge X_n = x_n)$ , ou  $P(x_1, \dots, x_n)$ . O valor de uma entrada é então dado por (RUSSEL, 2004):

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i \mid \text{pais}(X_i)) \quad (14)$$

Assim, cada entrada da tabela é representada pelo produto dos elementos apropriados das tabelas de probabilidades condicionais. Essas tabelas constituem uma representação distribuída da tabela de conjunção de probabilidades do problema (RUSSEL, 2004).

Como exemplo, é mostrado na equação (15), como é calculada a probabilidade do alarme ter tocado, nem um ladrão nem um terremoto aconteceram, e, João e Maria ligaram.

$$\begin{aligned}
 P(J \wedge M \wedge A \wedge \neg L \wedge \neg T) &= P(J \mid A).P(M \mid A).P(A \mid \neg L \wedge \neg T).P(\neg L).P(\neg T) \\
 &= 0,9 \times 0,7 \times 0,001 \times 0,999 \times 0,998 = 0,00062
 \end{aligned} \quad (15)$$

Assim, a probabilidade do alarme tocar sem motivo, e João e Maria ligarem é de 0,062%.

### 3.1.2 Lógica fuzzy

O interesse por sistemas que empregam lógica *fuzzy* vem sendo estabelecido devido ao fato desses sistemas serem bastante robustos em aplicações envolvendo informações imprecisas e vagas, além de contemplarem aplicações envolvendo objetivos conflitantes (CARDOSO, 2003). Outro aspecto atrativo é o pouco esforço computacional envolvido e a simplicidade de implementação (BARRETO, 1997).

Existem na comunicação cotidiana diversas palavras e sentenças com significado não preciso ou vago (RABUSKE, 1995). Isso acontece porque tanto quem fala como quem ouve não necessita de informações mais precisas e está acostumado a lidar com tais tipos de imprecisão.

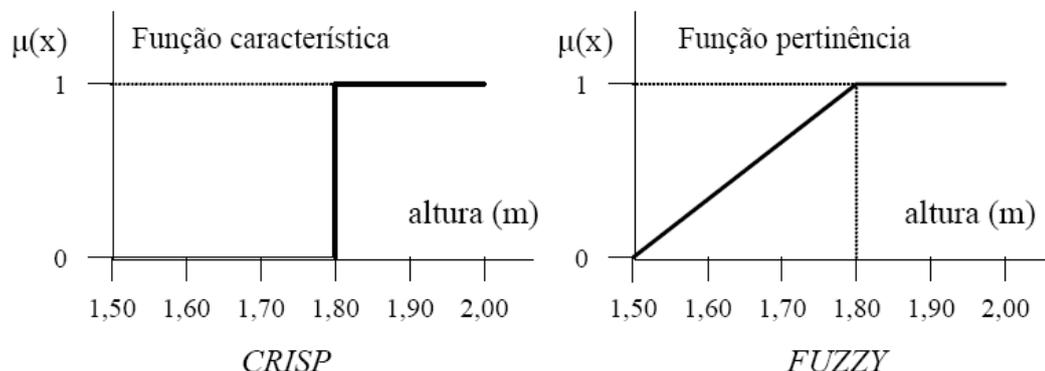
Os conjuntos *fuzzy* foram propostos por Zadeh em 1965 como uma alternativa para tratar o aspecto vago da informação. Segundo Zadeh (1965), um conjunto não apresenta limites bem definidos, podendo um elemento pertencer parcialmente a ele. O que vai caracterizá-lo será o grau de pertinência, que é uma medida que quantifica o quanto este elemento pertence a um determinado conjunto (MARKS, 1994). A lógica *fuzzy* foi concebida como uma forma de processar dados com pertinência parcial a um conjunto, e não somente com pertinência binária (ROSS, 1995).

A lógica *fuzzy* tem como objetivo modelar o modo aproximado de raciocínio. Permite inferir uma resposta precisa para uma questão baseada em um conhecimento que é incompleto ou não totalmente confiável. Devido às suas características intrínsecas, é capaz de incorporar tanto o conhecimento objetivo quanto o conhecimento subjetivo. É aplicada em sistemas de suporte à decisão onde a descrição do problema não pode ser feita de forma precisa (RICH, 1993).

#### 3.1.2.1 Conjuntos *fuzzy* e funções de pertinência

A teoria dos conjuntos *fuzzy* permite que se tenha uma função característica,  $\mu(x)$ , chamada de função de pertinência. Essa função assume valores no intervalo de 0 a 1 e faz com que um objeto passe a não mais ser classificado como estritamente pertencente ou não a um conjunto, mas lhe designa um grau de pertinência em relação a diferentes conjuntos (ROSS, 1995).

Como exemplo, a figura 8 ilustra a representação do conceito “pessoa alta” em um sistema clássico (*crisp*) e em um sistema *fuzzy*, considerando como alta uma pessoa com altura maior que 1,80 m.



**Figura 8 – Diferença entre sistema *crisp* e *fuzzy*.**

Assim, supondo um conjunto A:

a) para aqueles elementos que com certeza pertencem ao conjunto A é atribuído um grau de pertinência igual a 1, ou seja  $\mu_A(x) = 1$ ;

b) para os elementos que com certeza não pertencem ao conjunto A é atribuído um grau de pertinência igual a 0, ou seja  $\mu_A(x) = 0$ ;

c) para os elementos sobre os quais não se pode afirmar com certeza se pertencem ou não ao conjunto A é atribuído um valor intermediário, tendendo a 1, na medida em que crescem as razões para incluir este elemento no conjunto A. ( $0 < \mu(x) < 1$ ).

Um conjunto A da teoria clássica dos conjuntos – *crisp* – pode ser visto como um caso específico de conjuntos *fuzzy*, para o qual  $\mu_A(x) = 0$  ou  $\mu_A(x) = 1$ , ou seja, a pertinência é do tipo “tudo ou nada” - pertence totalmente ou não pertence (SANDRI, 1999).

Funções de pertinência são utilizadas para atribuir graus de pertinência a elementos de um conjunto *fuzzy*. Também são utilizadas para representar os limites dos conjuntos *fuzzy* pertencentes a uma variável. Podem ser definidas a partir da perspectiva do usuário, mas é comum fazer uso de funções de pertinência padrão, como, por exemplo, as de forma triangular, trapezoidal ou gaussiana. Em aplicações práticas as formas escolhidas inicialmente podem sofrer ajustes em função dos resultados observados.

As características das funções de pertinência mais importantes são (RABUSKE, 1995):

- forma – a triangular é uma das mais comuns, porém normal, trapezoidal, S, gama, L e exponencial também são utilizadas com frequência (BARRETO, 1997). Outros tipos de funções devem ser estudados antes da utilização, levando em conta, inclusive, fatores como complexidade computacional;
- magnitude – freqüentemente a magnitude é normalizada a 1, mas, em aplicações específicas, outros valores são possíveis;
- largura da base – a largura da base irá definir a abrangência da função.

Alguns exemplos de funções de pertinência são mostrados na figura 9.

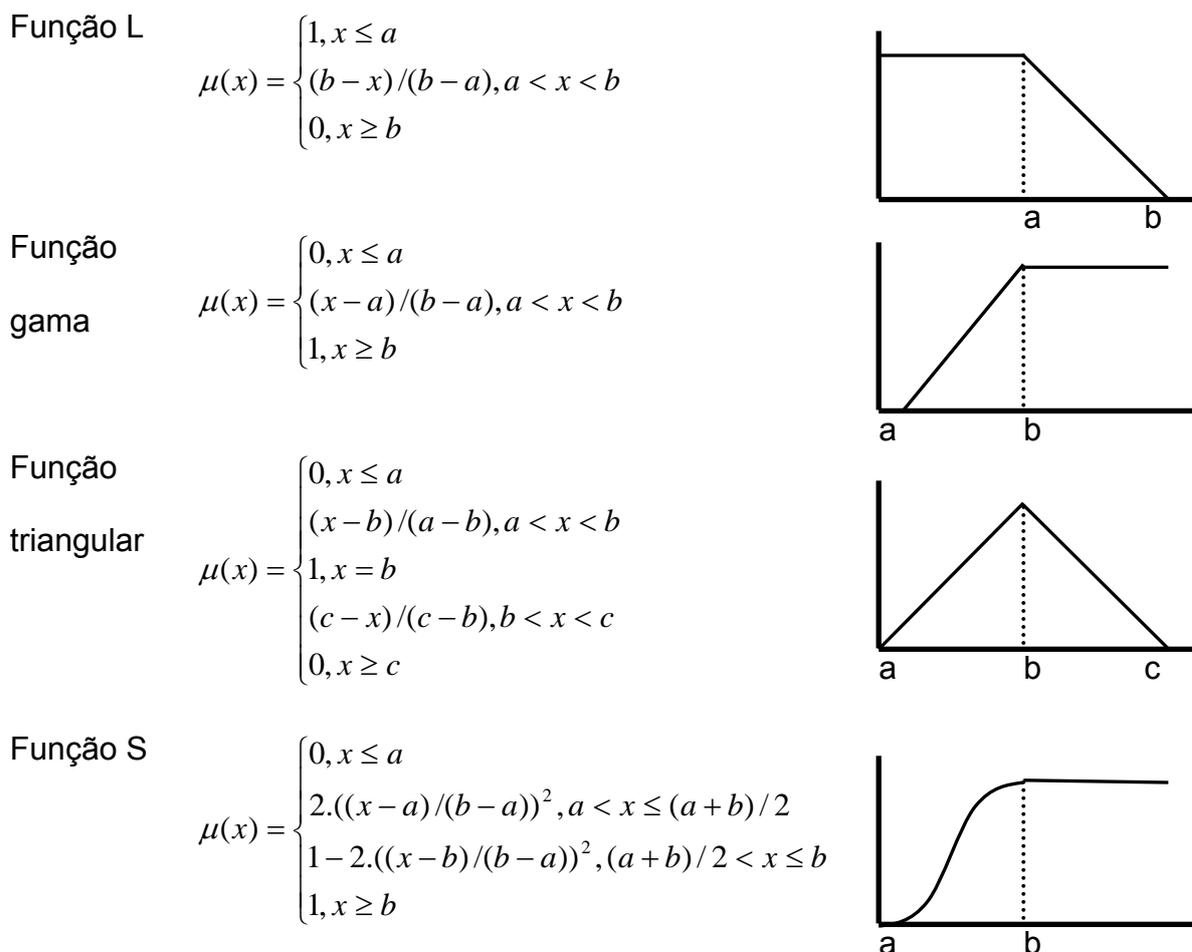


Figura 9 – Exemplos de funções de pertinência.

### 3.1.2.2 Operações entre conjuntos *fuzzy*

Zadeh (1965) introduziu as definições para as operações de complemento, intersecção e união, sendo esses chamados de operadores clássicos (ZADEH, 1965).

Dados três conjuntos *fuzzy* **A**, **B** e **C** definidos num mesmo universo de discurso, então as seguintes propriedades e teoremas são válidas (SHAW, 1999):

**Propriedade comutativa:**

$$A \cap B = B \cap A$$

$$A \cup B = B \cup A$$

**Propriedade associativa:**

$$(A \cap B) \cap C = A \cap (B \cap C)$$

$$(A \cup B) \cup C = A \cup (B \cup C)$$

**Independência:**

$$A \cap A = A$$

$$A \cup A = A$$

**Distributividade em relação à intersecção:**

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

**Distributividade em relação à união:**

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

**Teorema de Morgan:**

$$\neg(A \cap B) = \neg A \cup \neg B$$

$$\neg(A \cup B) = \neg A \cap \neg B$$

Na teoria dos conjuntos *fuzzy*, a intersecção é implementada por uma família de operadores denominados de t-normas, e a união é implementada por uma família de operadores denominados de t-conormas ou s-normas (SANDRI; 1999).

Diversos pesquisadores desenvolveram suas próprias t-normas e t-conormas, dando-lhes seus próprios nomes. As t-normas e t-conormas mais utilizadas são mostradas na tabela 3 (AYYUB, 2006).

Tabela 3 – T-normas e t-conormas mais utilizadas.

t-normas	t-conormas	nome
$\min(A(x), B(x))$	$\max(A(x), B(x))$	Zadeh
$A(x).B(x)$	$A(x) + B(x) - A(x).B(x)$	probabilista
$\max(A(x) + B(x) - 1, 0)$	$\min(A(x) + B(x), 1)$	Lukasiewicz
$\frac{A(x)B(x)}{\beta + (1 - \beta)(A(x) + B(x) - A(x)B(x))}$ $\beta \in (0, \infty), \beta \neq 1$	$\frac{A(x) + B(x) - (\beta - 2)A(x)B(x)}{1 + (\beta - 1)A(x)B(x)}$ $\beta \in (0, \infty)$	Hamacher
$\log_{\beta} \left[ 1 + \frac{(\beta^{A(x)} - 1)(\beta^{B(x)} - 1)}{\beta - 1} \right]$ $\beta \in (0, \infty)$	$\frac{A(x) + B(x) - (\beta - 2)A(x)B(x)}{1 + (\beta - 1)A(x)B(x)}$ $\beta \in (0, \infty)$	Frank
$1 - \min \left[ 1, \sqrt[\beta]{(1 - A(x))^{\beta} + (1 - B(x))^{\beta}} \right]$ $\beta \in (0, \infty)$	$\min \left[ 1, \sqrt[\beta]{(A(x))^{\beta} + (B(x))^{\beta}} \right]$ $\beta \in (0, \infty)$	Yager
$\frac{A(x)B(x)}{\max(A(x), B(x), \beta)}$ $\beta \in [0, \infty]$	$1 - \frac{(1 - A(x))(1 - B(x))}{\max(A(x), B(x), 1 - \beta)}$ $\beta \in [0, \infty]$	Dubbois and Prade
$\left[ 1 + \left[ \left( \frac{1}{A(x)} - 1 \right)^{\beta} + \left( \frac{1}{B(x)} - 1 \right)^{\beta} \right]^{\frac{1}{\beta}} \right]^{-1}$ $\beta \in (0, \infty)$	$\left[ 1 + \left[ \left( \frac{1}{A(x)} - 1 \right)^{-\beta} + \left( \frac{1}{B(x)} - 1 \right)^{-\beta} \right]^{\frac{-1}{\beta}} \right]^{-1}$ $\beta \in (0, \infty)$	Dombi
$\left[ \max(0, (A(x))^{\beta} + (B(x))^{\beta} - 1) \right]^{\frac{1}{\beta}}$ $\beta \neq 0$	$1 - \left[ \max(0, (1 - A(x))^{\beta} + (1 - B(x))^{\beta} - 1) \right]^{\frac{1}{\beta}}$ $\beta \neq 0$	Scweizer and Sklar

$\beta$  é chamado de fator de intensidade (AYYUB, 2006).

Para ilustrar o resultado dessas operações sobre os conjuntos, foram utilizadas as t-normas e t-conormas probabilista e a de Zadeh. A figura 10 ilustra operadores t-normas, enquanto que a figura 11 as t-conormas, em relação a dois conjuntos *fuzzy* **A** e **B** (SANDRI, 1999).

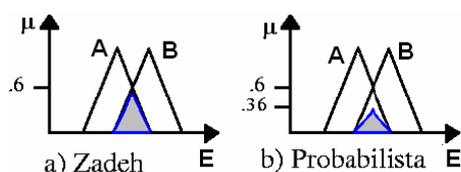


Figura 10 – Ilustração das principais t-normas.

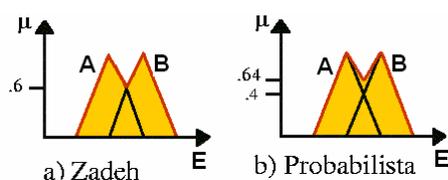


Figura 11 – Ilustração das principais t-conormas.

### 3.1.2.3 Sistema especialista *fuzzy*

Um sistema de inferência *fuzzy* é mostrado na figura 12. Nesse sistema, consideram-se entradas *crisp*, resultantes de medições, que é o caso da grande maioria das aplicações práticas. Em virtude disto, é necessário efetuar-se um mapeamento desses dados *crisp* para os conjuntos *fuzzy* relevantes, o que é realizado no estágio de fuzzyficação. Nesse estágio ocorre também a ativação das regras relevantes para uma dada situação.

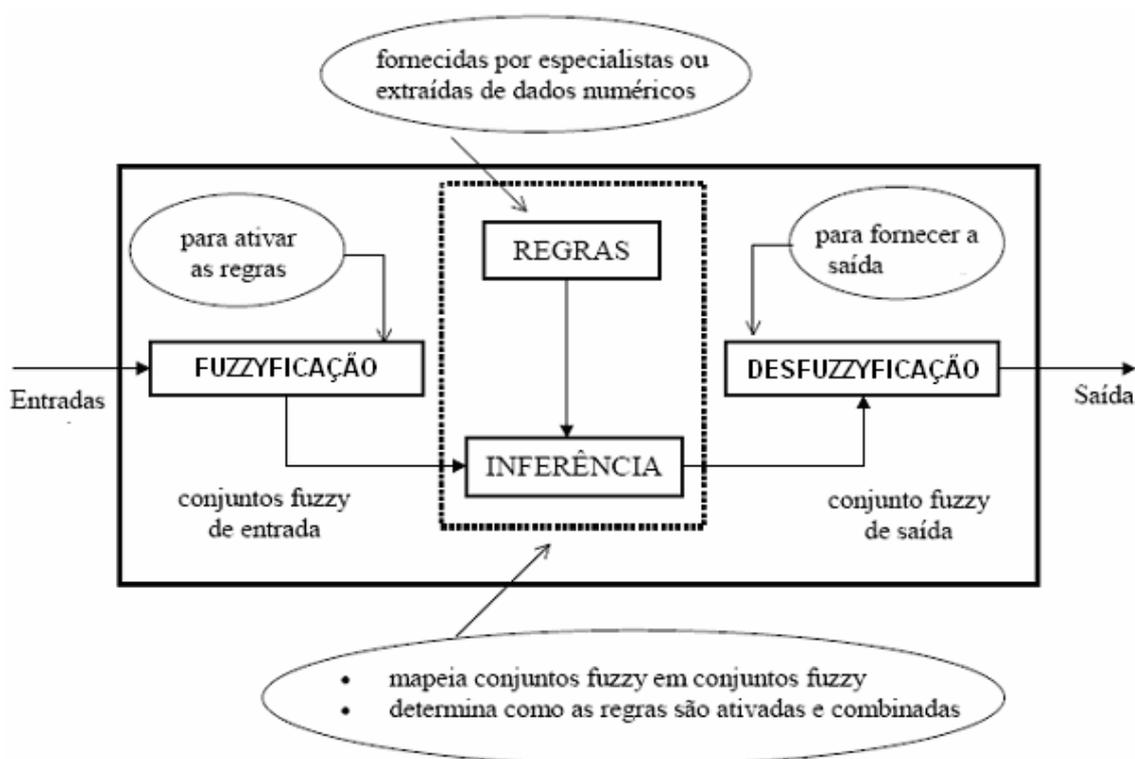


Figura 12 – Sistema de inferência *fuzzy*.

Uma vez obtido o conjunto *fuzzy* de saída, no estágio de defuzzyficação é efetuada uma interpretação dessa informação. Isso se faz necessário, pois em aplicações práticas, geralmente são requeridas saídas *crisp*.

Os subitens seguintes explicam com mais detalhes cada parte do sistema especialista *fuzzy*.

### 3.1.2.3.1 **Fuzzyficação**

Nesta etapa são mapeados os valores numéricos de entrada em conjuntos *fuzzy*. Isso é necessário para ativar regras que estão expressas através de variáveis lingüísticas, as quais possuem conjuntos *fuzzy* associados (BARRETO, 1997).

A fuzzyficação, então, descreve a transição de um sistema *crisp* para um sistema *fuzzy*, atribuindo os valores de pertinência entre 0 e 1 para cada característica, através de uma função de pertinência (SHAW, 1999).

### 3.1.2.3.2 **Base de conhecimento**

A base de conhecimento consiste de uma base de dados e de uma base de regras. Na de dados ficam armazenadas as definições sobre discretização e normalização dos universos de discurso e, na de regras, as definições das funções de pertinência dos termos *fuzzy* (SANDRI, 1999).

A *base de regras* é formada por estruturas do tipo:

**SE <premissa> ENTÃO <conclusão>**

É importante que existam tantas regras quantas forem necessárias para mapear totalmente as combinações dos termos das variáveis, isto é, que a base seja completa (SANDRI, 1999).

### 3.1.2.3.3 **Desfuzzyficação**

Desfuzzyficação é o processo que mapeia a saída de conjuntos *fuzzy* em valores numéricos *crisp*. Em uma aplicação de controle, por exemplo, seria um número correspondente à uma ação de controle ou, em uma aplicação de processamento de sinais, poderia corresponder a uma predição do comportamento do sinal observado (BARRETO, 1997)

Pode-se dizer que a desfuzzyficação é o processo inverso da fuzzyficação, transformando os valores *fuzzy* em *crisp* (SHAW, 1999).

Existem vários métodos pesquisados e popularizados, porém os mais utilizados são (SANDRI, 1999; PASSINO, 1998):

- centro da área – o valor de saída é o centro de gravidade da função de distribuição de possibilidade da função resultante;

- primeiro máximo – encontra o valor de saída através do ponto em que o grau de pertinência da distribuição da ação de controle atinge o primeiro valor máximo;
- média dos máximos – encontra o ponto médio entre os valores que têm o maior grau de pertinência inferido pelas regras.

A figura 13 mostra os métodos descritos, de maneira gráfica.

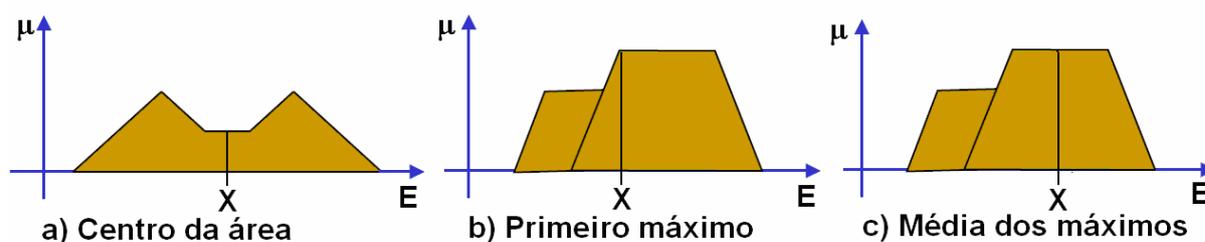


Figura 13 – Métodos de desfuzzyficação.

### 3.1.3 Abordagem híbrida: Bayes e fuzzy

É fundamental compreender a maneira com que essas teorias efetuam o processamento do raciocínio artificial. Deve-se evidenciar a diferença principal entre tais técnicas, visto que ambas são utilizadas para o modelamento de incertezas, mas de tipos distintos (BRIGNOLI, 2001). A teoria da probabilidade trata a aleatoriedade, enquanto que a teoria dos conjuntos *fuzzy* trata a imprecisão ou vagueza (TIBIRIÇÁ, 2005).

Pode-se pensar em uma união entre essas duas técnicas. O fato a ser evidenciado aqui é que pode existir uma probabilidade vinculada a valores incertos por existência de imprecisão; uma espécie de probabilidade *fuzzy* (BRIGNOLI, 2001).

De acordo com o modelo de probabilidade condicional  $P(H_i|E)$ , sabe-se que  $H_i$  representa um vetor de probabilidades de ocorrência das hipóteses condicionadas às evidências  $E$ . Dessa forma pode-se partir do princípio que haja imprecisão nas evidências, fazendo com que torne também imprecisa a probabilidade das hipóteses, ou seja (BRIGNOLI, 2001):

“Dado um intervalo  $I[x_i, x_j]$ , sendo que  $I$  é subintervalo de probabilidades  $[0,1]$ , considera-se uma probabilidade  $p\%$  munida de imprecisão como sendo um número  $p \in I$ ; assim  $p$  passa a representar uma *probabilidade de evento fuzzy*.”

O hibridismo *fuzzy*-bayesiano permite trabalhar com a incerteza por imprecisão nas entradas de uma rede bayesiana. As variáveis com características de imprecisão são *fuzzy*ficadas e propagadas utilizando o teorema de Bayes modificado, gerando uma redistribuição do vetor de probabilidades da saída da rede híbrida (TIBIRIÇÁ, 2005).

### 3.1.3.1 Implementação do sistema *fuzzy*-bayesiano

As equações (16) e (17) são as do teorema de Bayes, utilizadas para calcular as probabilidades condicionais das variáveis que não apresentam características de imprecisão, ou seja, são probabilísticas (NASSAR, 2007).

$$P(H_i | E) = \frac{P(E | H_i) \cdot P(H_i)}{P(E)} \quad (16)$$

$$P(E) = P(E | H_i) + P(E | \neg H_i) \quad (17)$$

Considere-se agora a existência de eventos difusos compondo a rede bayesiana (BRIGNOLI, 2001). Assim,  $\delta$  representa um evento munido de imprecisão, ou seja, a *possibilidade* de existência de  $\delta$  está no intervalo ]0,1[. Sendo assim, apresenta-se  $\phi = f(\rho, \delta)$  como uma notação matemática que expressa sob a forma de função, um qualificador para o modelo híbrido. Entende-se então que  $\Phi$  é o que causará a redistribuição das probabilidades da rede bayesiana tendo  $\rho$  como uma probabilidade condicional e,  $\delta$  representando um ou mais eventos difusos. Para tal, utilizou-se a fórmula do teorema de Bayes com algumas modificações em sua forma original, equações (18),(19) e (20):

$$P(H_i | \delta) = \frac{P(\delta | H_i) \cdot P(H_i)}{P(\delta)} \quad (18)$$

$$P(\delta | H_i) = P(H_i) \cdot [P(\delta | H_i) \cdot \mu_{\varepsilon_1}(\delta) + (1 - P(\delta | H_i)) \cdot \mu_{\varepsilon_2}(\delta)] \quad (19)$$

e,

$$P(\delta) = \sum_{i=1}^n P(H_i) \cdot [P(\delta | H_i) \cdot \mu_{\varepsilon_1}(\delta) + (1 - P(\delta | H_i)) \cdot \mu_{\varepsilon_2}(\delta)] \quad (20)$$

$P(H_i | \delta)$  representa a probabilidade da hipótese, dado um evento *fuzzy*. Os símbolos  $\mu_{\varepsilon_1}$  e  $\mu_{\varepsilon_2}$  representam os graus de pertinência dos conjuntos *fuzzy* envolvidos (BRIGNOLI, 2001; TIBIRIÇÁ, 2003).

Após ser aplicada a função  $\Phi$  de qualificação, a propriedade  $\sum_{i=1}^n P(H_i) = 1$  continua verdadeira, de acordo a teoria da probabilidade, no entanto a soma das pertinências das entradas não necessariamente deve ser unitária. (BRIGNOLI, 2001).

Em termos de generalização da equação (19), estende-se o caso para três ou mais estados de cada variável de entrada e, naturalmente para o mesmo número de conjuntos *fuzzy* para os quais cada um desses estados seja submetido (BRIGNOLI, 2001). Assim tem-se a equação (21):

$$P(\delta | Hi) = P(Hi) \cdot [P_1(\delta | Hi) \cdot \mu_{\varepsilon_1}(\delta) + P_2(\delta | Hi) \cdot \mu_{\varepsilon_2}(\delta) + \dots + P_r(\delta | Hi) \cdot \mu_{\varepsilon_r}(\delta)] \quad (21)$$

Se  $s$  representa o número de estados para cada variável de entrada, então:

$$P(\delta) = \sum_{i=1}^n P(Hi) \cdot \sum_{r=1}^s P_r(\delta | Hi) \cdot \mu_{\varepsilon_r}(\delta) \quad (22)$$

Para tornar mais ampla a validação do modelo híbrido, mostra-se uma alteração na estrutura das equações (19) e (20), de modo a considerar o cálculo de hipóteses diagnosticadas a partir de vários eventos, ou seja,  $\delta = \{e_1, e_2, \dots, e_m\}$  (BRIGNOLI, 2001).

Dessa forma, sendo  $n$  o número de hipóteses diagnosticadas da rede bayesiana e,  $m$  o número de eventos difusos desta rede, tem-se (equação (23)):

$$\begin{aligned} P(e_1 \cap e_2 \cap \dots \cap e_m | Hi) &= P(Hi) \cdot ([P(e_1 | Hi) \cdot \mu_{\varepsilon_1}(e_1) + (1 - P(e_1 | Hi)) \cdot \mu_{\varepsilon_2}(e_1)] \times \\ &x [P(e_2 | Hi) \cdot \mu_{\varepsilon_1}(e_2) + (1 - P(e_2 | Hi)) \cdot \mu_{\varepsilon_2}(e_2)] \times \dots \\ &\dots x [P(e_m | Hi) \cdot \mu_{\varepsilon_1}(e_m) + (1 - P(e_m | Hi)) \cdot \mu_{\varepsilon_2}(e_m)]) \end{aligned} \quad (23)$$

Então, se  $\delta = \{e_1, e_2, \dots, e_m\}$  tem-se:

$$P(\delta / Hi) = P(Hi) \cdot \prod_{k=1}^m [P(e_k | Hi) \cdot \mu_{\varepsilon_1}(e_k) + (1 - P(e_k | Hi)) \cdot \mu_{\varepsilon_2}(e_k)] \quad (24)$$

e

$$P(\delta) = \sum_{i=1}^n P(Hi) \cdot \prod_{k=1}^m [P(e_k | Hi) \cdot \mu_{\varepsilon_1}(e_k) + (1 - P(e_k | Hi)) \cdot \mu_{\varepsilon_2}(e_k)] \quad (25)$$

Observando a equação (25) nota-se que a rede híbrida funciona com uma espécie de ponderação entre as probabilidades e os graus de pertinência (PENZ,

2008). No caso de ocorrência de um grau de pertinência  $\mu_{ijm} = 1$ , e consequentemente  $\mu_{ijp} = 0$ , tem-se a rede bayesiana tradicional.

As ferramentas da inteligência artificial apresentadas neste capítulo compõem a base de solução do problema de identificação do instante de entrada em regime permanente da capacidade de refrigeração analisada neste trabalho.

### 3.2 VARIÂNCIA E DESVIO PADRÃO DE ALLAN

Para utilizar a técnica proposta com redes *fuzzy*-bayesianas é necessário determinar o instante em que as variáveis de entrada se estabilizam. E determinar isso computacionalmente só é possível se existir um condicionamento das variáveis de entrada para que se possa obter um comportamento padrão das mesmas, independentemente dos valores em que elas se estabilizam. Normalmente, as variáveis não se estabilizam com valores muito próximos em diferentes ensaios, o que torna inviável a verificação do seu valor direto.

Na estatística clássica, a variância, ou o desvio padrão, são usados para medir dispersão de valores em relação à média do conjunto (MONTGOMERY, 2003). A variância é usada em dados estacionários, para os quais os resultados são independentes do tempo. É característica dos dados estacionários possuírem média e variância invariantes no tempo (BOX, 1994). Para dados estacionários, a média e a variância convergem para valores particulares com o aumento do número de medições. Para dados não-estacionários, a média e a variância não convergem nunca para qualquer valor particular. Ao invés disto, tem-se uma média móvel que varia a cada vez que se acrescenta o dado de uma nova medição, sem haver convergência para qualquer valor (KRONENBERG, 2007).

Para estimar-se a estabilidade de uma variável, no domínio do tempo, a estatística utilizada é a variância de Allan ou desvio padrão de Allan (KRONENBERG, 2007).

A equação para o desvio padrão de Allan é:

$$\sigma_Y(\tau) = \sqrt{\frac{1}{2(m-1)} \sum_{i=1}^{m-1} (y_{i+1} - y_i)^2} \quad (26)$$

Sendo  $m$  o número de valores do conjunto de dados  $y_i$  e os dados amostrados em intervalos de tempo iguais de  $\tau$ .

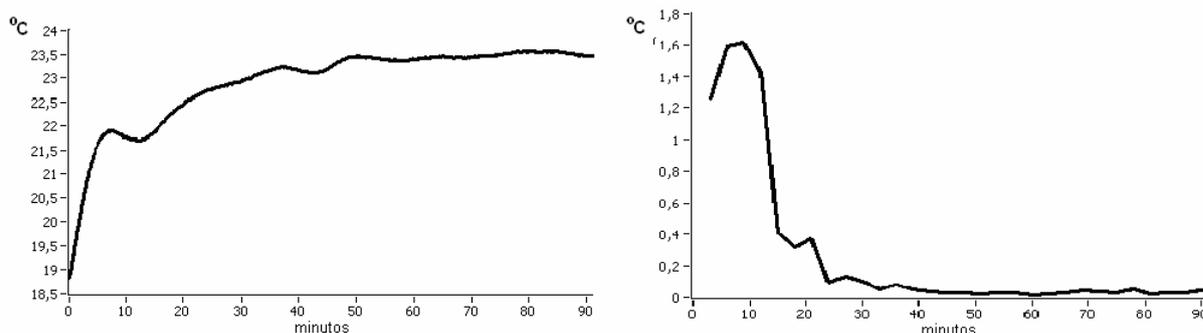
No equacionamento de variância clássica, em termos subtrativos que compõe a somatória, subtrai-se o valor médio de cada valor obtido, enquanto que na variância de Allan, subtrai-se de cada valor obtido o valor imediatamente anterior (ALLAN, 1987).

A aplicação mais comum para a variância de Allan é verificar a estabilidade de osciladores. Devido a características físicas intrínsecas dos osciladores, medidas de frequência de um oscilador são dados não-estacionários, pois contêm componentes de ruído dependentes do tempo – derivas – e, que devem ser consideradas na determinação do valor do desvio de frequência (NIST, 2006). A estabilidade em osciladores reflete as flutuações de frequência e não o deslocamento de frequência. Então, na variância de Allan, os pontos de dados sucessivos são subtraídos para remover a parte de ruído dependente do tempo.

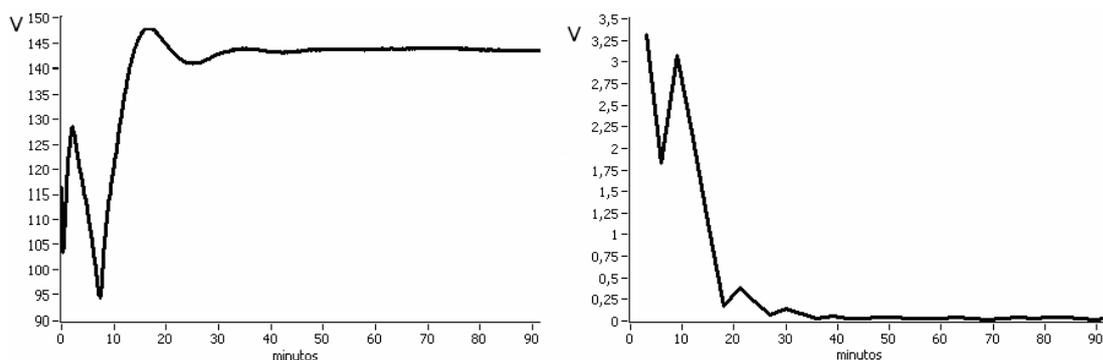
Por recomendação do *Institute of Electrical and Electronics Engineers* (IEEE), o desvio de Allan é usado pelos fabricantes de equipamentos geradores de frequência como parâmetro de especificação para caracterizar a estabilidade de frequência (NIST, 2006).

Neste trabalho, o desvio padrão de Allan é utilizado para verificar a estabilidade de uma grandeza. Para tanto, fez-se uma análise da evolução de tal desvio padrão com o desenvolver do ensaio, para diferentes grandezas envolvidas.

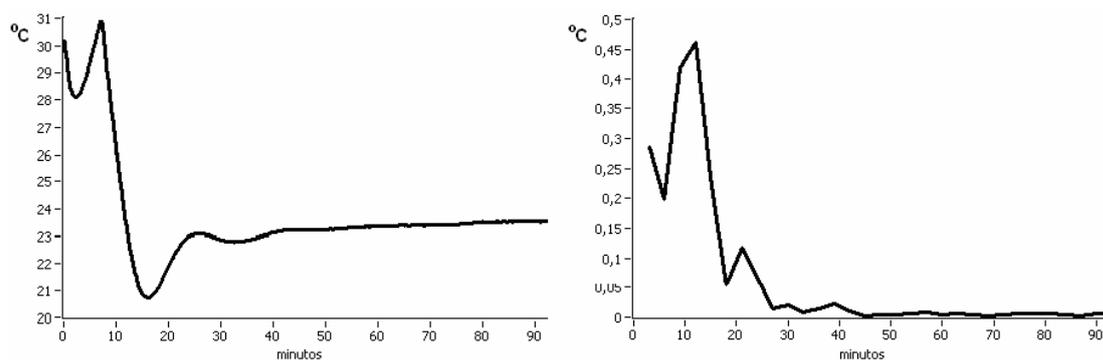
No caso deste trabalho, considera-se uma variável como estável quando sua variação é menor do que um limite e não necessariamente zero. Para exemplificar, a figura 14 mostra num gráfico a variável de temperatura superficial do trocador e no outro o seu desvio padrão de Allan ao longo do tempo. Nota-se, pelas figuras 14 à 17 que independentemente do valor em que a variável se estabiliza, o seu desvio padrão de Allan tende a um valor baixo.



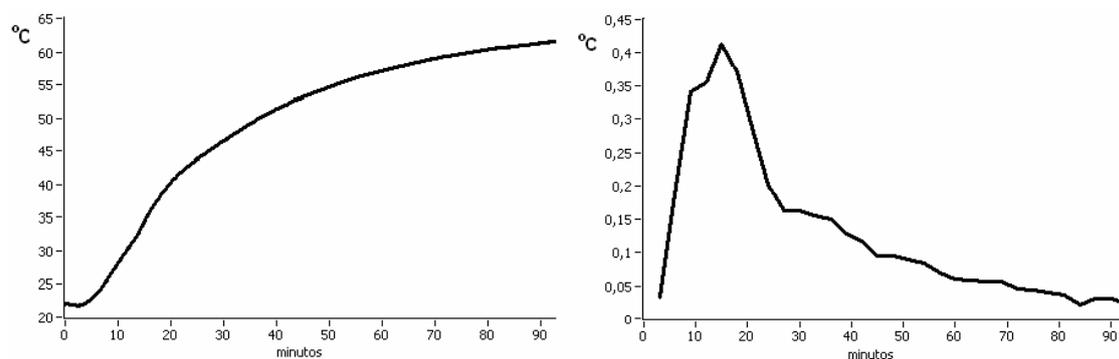
**Figura 14 – Temperatura superficial do trocador e seu desvio padrão de Allan.**



**Figura 15 – Tensão DC do calorímetro e seu desvio padrão de Allan.**



**Figura 16 – Temperatura superficial do trocador em outro ensaio e seu desvio padrão de Allan.**



**Figura 17 – Temperatura do corpo do compressor e seu desvio padrão de Allan.**

Neste trabalho se propõe utilizar o desvio de Allan para analisar se uma variável está estabilizada, e nesse caso, determinar em que instante de tempo ocorreu a estabilização. Basta que para cada variável seja determinado um limite para o valor do desvio de Allan para considerar estável ou instável.

## 4 DESCRIÇÃO DO MÉTODO DESENVOLVIDO

O objetivo deste trabalho é estabelecer um método de identificação do instante em que a capacidade de refrigeração entra em regime permanente, utilizando redes bayesianas integradas com lógica *fuzzy*.

Este capítulo descreve, de forma genérica, as etapas envolvidas no desenvolvimento.

A partir da análise da estabilidade de outras variáveis presentes no ensaio de desempenho – doravante chamadas variáveis auxiliares – se deseja identificar a estabilidade da capacidade de refrigeração. Essa inferência relaciona a probabilidade da capacidade de refrigeração estar estável dependendo da estabilidade das variáveis auxiliares. A figura 18 mostra a idéia da modelagem estatística dessa rede, sendo o primeiro gráfico da capacidade de refrigeração e os outros três exemplificam um conjunto de variáveis auxiliares.

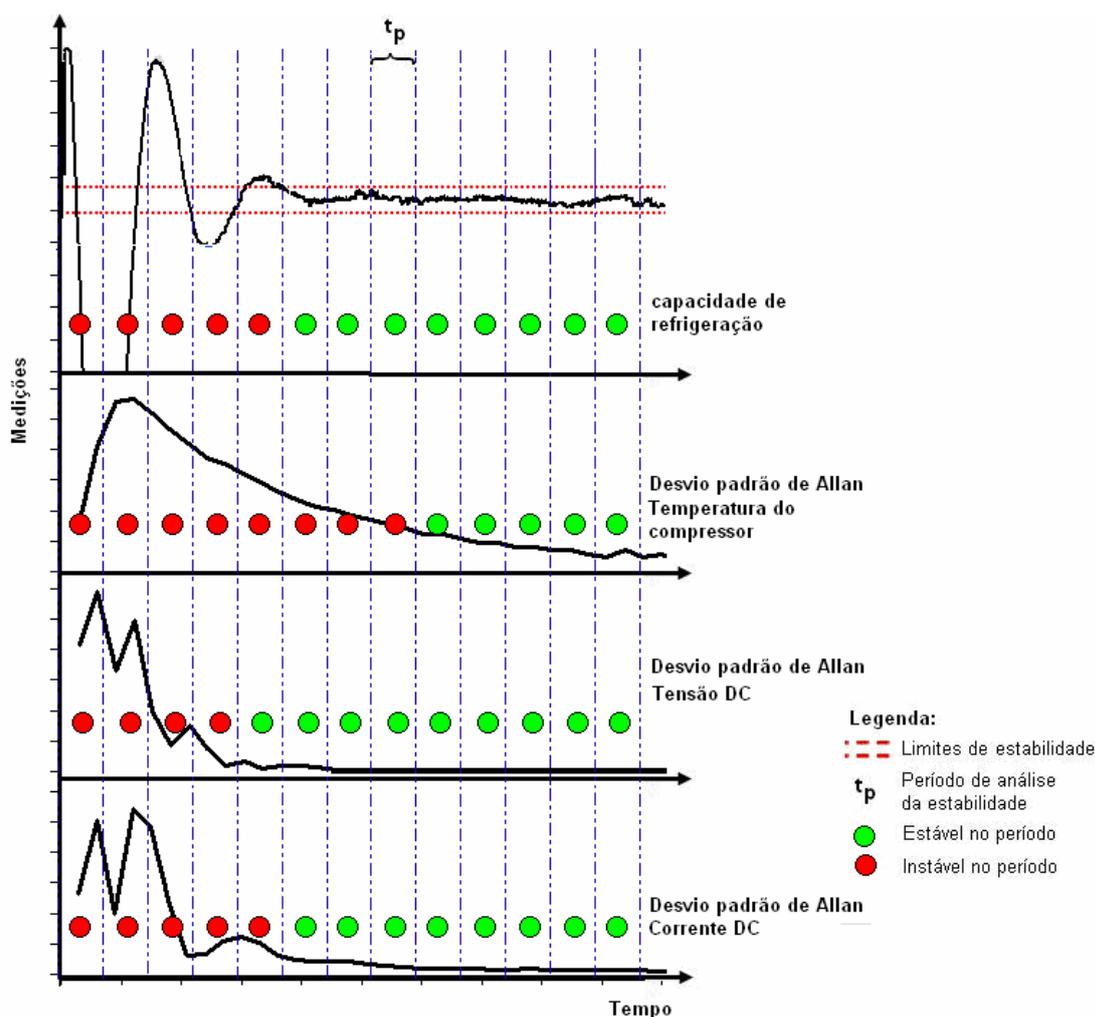


Figura 18 – Estabilidade da capacidade de refrigeração e variáveis auxiliares (PENZ, 2008).

O limite de estabilidade mostrado na figura 18 é o limite estabelecido por norma (ISO, 1987) de  $\pm 1\%$  da média da capacidade de refrigeração durante um período de 1 hora durante o qual um conjunto de variáveis permaneceu estável.

O ensaio é dividido em períodos de tempo ( $t_p$ ) de, por exemplo, 3 minutos. A capacidade de refrigeração é considerada estável se todos os valores medidos durante  $t_p$  estiverem dentro do referido limite. Pode-se considerar uma tolerância para pontos instáveis e assim desconsiderar erros de medição grosseiros causados por comportamentos atípicos do sistema.

As variáveis auxiliares no exemplo apresentado na figura 18 são temperatura do compressor, tensão DC e corrente DC do calorímetro.

A estabilidade das variáveis auxiliares é estabelecida por medidas de desvio padrão de Allan calculados para as medições realizadas durante  $t_p$ . Se esse desvio estiver abaixo de um determinado limite – a definir – a variável é considerada estável no período  $t_p$  em questão.

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

Uma característica importante dessa modelagem é o relacionamento entre a condição de estabilidade definida por norma, isto é, a condição de estabilidade completa do ensaio, e a estabilidade das variáveis auxiliares.

A criação da base de conhecimento para este trabalho utilizou-se de uma base de dados formada por 29 ensaios realizados em 8 compressores de mesmo modelo. Essa base de dados foi construída por HENKLEIN (2006).

A partir da base de conhecimento, o resultado do método deve prever para futuros ensaios de compressores, em tempo real, o instante de entrada em regime.

## **4.1 CRITÉRIOS GERAIS PARA FORMAÇÃO DA BASE DE CONHECIMENTO**

A criação da base de conhecimento da rede bayesiana é *off-line* e utiliza a base de dados de ensaios de compressores de mesmo modelo. A base de dados é resultado de um conjunto de ensaios realizados numa bancada automatizada.

### **4.1.1 Critérios para seleção das variáveis para compor a base de conhecimento**

Para a criação da base de conhecimento é necessário selecionar as variáveis que estabilizam num tempo próximo à variável de capacidade de refrigeração. Como critério de estabilidade foi empregado o estabelecido pela norma ISO 917 (1989) para a variável capacidade de refrigeração e para as demais variáveis pela variabilidade inferior a um limite pré-estabelecido.

Para determinar o momento em que as variáveis auxiliares estabilizam não se verificou o seu valor em si, mas o desvio padrão de Allan dos valores, em intervalos de tempo pré-determinados.

Quanto mais próximo esse valor estiver de zero, menor é a variação da variável analisada. É necessário estipular um limite máximo de variação para considerar a variável estável.

### **4.1.2 Informações a serem incorporadas à base de conhecimento**

A base de conhecimento é construída com informações de todos os ensaios realizados da base de dados. As informações da base de conhecimento são:

- Probabilidades da variável capacidade de refrigeração:
  - $P(\text{capacidade} = \text{estável})$ ;
  - $P(\text{capacidade} = \text{instável})$ .
- Probabilidade de cada evento ocorrer, sendo que os eventos são as outras variáveis escolhidas quando estão estabilizadas e quando estão não-estabilizadas:
  - $P(\text{variável auxiliar} = \text{estável})$ ;
  - $P(\text{variável auxiliar} = \text{instável})$ .

- Probabilidade da variável auxiliar estar estável ou instável dada a estabilidade ou instabilidade da capacidade de refrigeração:
  - $P(\text{variável auxiliar} = \text{estável} \mid \text{capacidade} = \text{estável})$ ;
  - $P(\text{variável auxiliar} = \text{estável} \mid \text{capacidade} = \text{instável})$ ;
  - $P(\text{variável auxiliar} = \text{instável} \mid \text{capacidade} = \text{estável})$ ;
  - $P(\text{variável auxiliar} = \text{instável} \mid \text{capacidade} = \text{instável})$ .

## 4.2 PRÉ-PROCESSAMENTO DAS VARIÁVEIS DE ENTRADA

Assim como na criação da base de conhecimento, é necessário fazer um pré-processamento das variáveis de entrada para que o sistema de inferência possa fazer a análise dos dados em um mesmo formato.

Esse pré-processamento consta do cálculo do desvio padrão de Allan, na verificação se a variável alcançou a estabilidade, comparado com informações predefinidas sobre cada grandeza e a determinação através de lógica *fuzzy* do grau de estabilidade.

Existe uma incerteza sobre o limite de estabilização, pois não é possível determinar um valor exato para ele. A lógica *fuzzy* contribui inserindo um grau do quanto uma variável está estável ou instável para os valores próximos a esse limite. A contrapartida causa um atraso na resposta da rede.

A figura 19 apresenta um exemplo hipotético – porém factível – de comportamento do desvio padrão de Allan para uma variável auxiliar. Supõe-se que o limite para definição de estabilidade é 0,2 unidade da variável auxiliar. A figura 19 mostra também a representação das funções de pertinência com as quais o hibridismo *fuzzy*-bayesiano pode ser estabelecido.

Um par de funções de pertinência referenciando “acima” (em vermelho) ou “abaixo” (em preto) do patamar de estabilidade do desvio padrão considerado insere a informação de que a variável auxiliar está estabilizando ou desestabilizando.

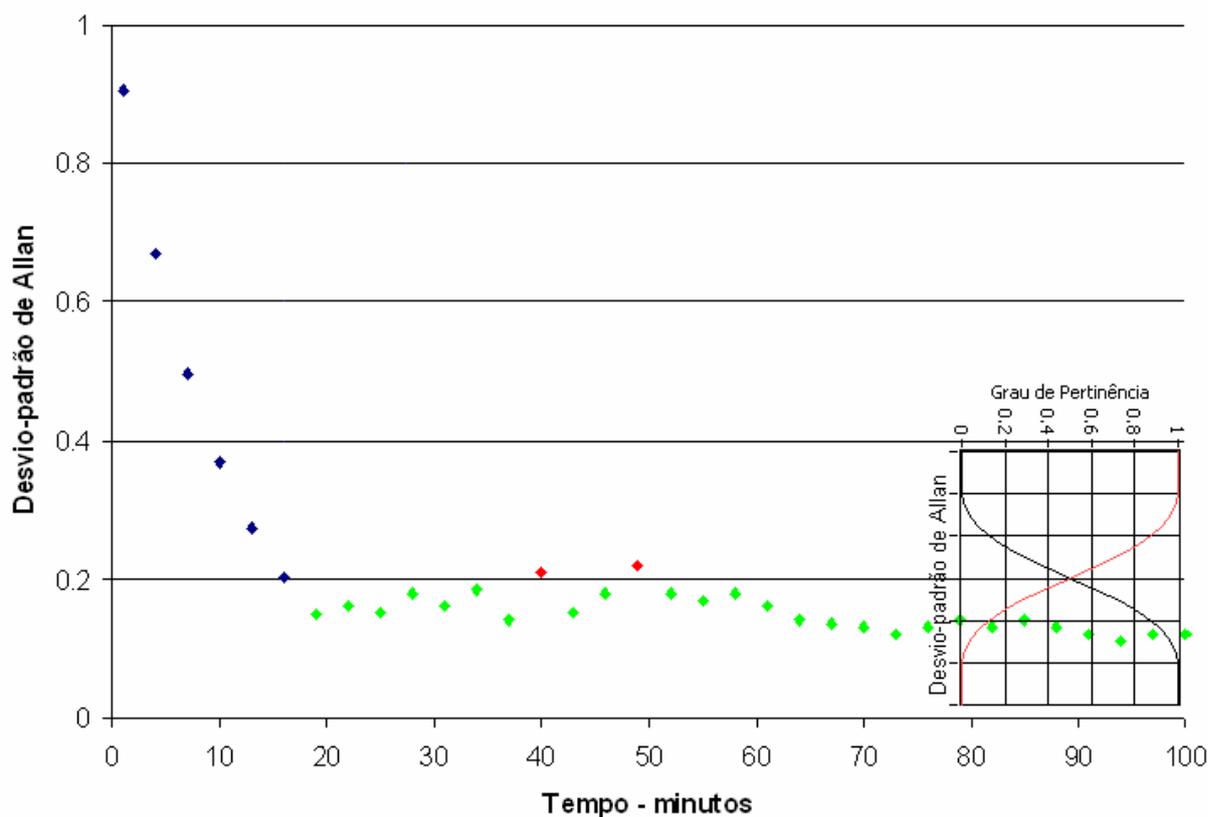


Figura 19 – Variância de Allan e funções *fuzzy* (PENZ, 2008).

### 4.3 INFERÊNCIA HÍBRIDA

A tarefa básica da inferência é computar a distribuição de probabilidades. O bloco de inferência vai fornecer a probabilidade da variável capacidade estar estável dado os estados das variáveis auxiliares:  $P(\text{capacidade} = \text{estável} | e_1 \wedge e_2 \wedge \dots \wedge e_n)$ , sendo  $e_1$  a  $e_n$  as os estados das variáveis auxiliares.

Essa tarefa é feita utilizando a fórmula do teorema de Bayes com as devidas modificações necessárias já descritas no capítulo 3, para tratar eventos *fuzzy* ao invés de *crisp* (sub-item 3.1.2.1).

O valor de  $P(\text{capacidade} = \text{estável} | e_1 \wedge e_2 \wedge \dots \wedge e_n)$  já fornece o quanto a variável capacidade está estável com um intervalo de  $[0,1]$ , mas que está sujeita a influências das variáveis externas ao ensaio e variações fora do controle.

## 5 IMPLEMENTAÇÃO DA FERRAMENTA PROPOSTA

Este capítulo descreve a parte prática do desenvolvimento deste trabalho. Como software para implementação foi utilizado o *Labview*, para facilitar sua integração junto a trabalhos de automação de bancada de ensaio de desempenho no Labmetro.

### 5.1 ESCOLHA DE VARIÁVEIS DE ENTRADA E LIMITES DE ESTABILIDADE

Foram analisadas todas as 126 variáveis que estavam disponíveis no trabalho de HENKLEIN (2006). Inicialmente foram realizadas simulações para definição do tamanho da janela de tempo ( $t_p$ ) e do parâmetro  $\tau$  referente ao cálculo do desvio padrão de Allan.

Valor alto de  $\tau$  implica maiores oscilações nos resultados dos desvios padrão. Para valores menores, as variações são mais suaves. Para tempo de janela curto, tem-se também mais oscilação. Tempo de janela maior, causa atraso nos resultados.

As figuras 20, 21 e 22 mostram exemplos com a variável *Temperatura da saída evaporador* num mesmo ensaio com configurações diferentes de  $\tau$  e tempo de janela ( $t_p$ ). Em cada figura, o gráfico superior apresenta o desvio padrão de Allan da variável analisada e uma linha que representa limite definido entre estável e não-estável. Quando o valor do desvio padrão está abaixo desse limite, a variável está estável, e, acima, está instável. O gráfico inferior mostra o tempo em que o ensaio passou para regime permanente (estabilizou) pelo método da norma ISO 917 (1989) e a classificação da variável analisada em estável (alto) ou não-estável (baixo).

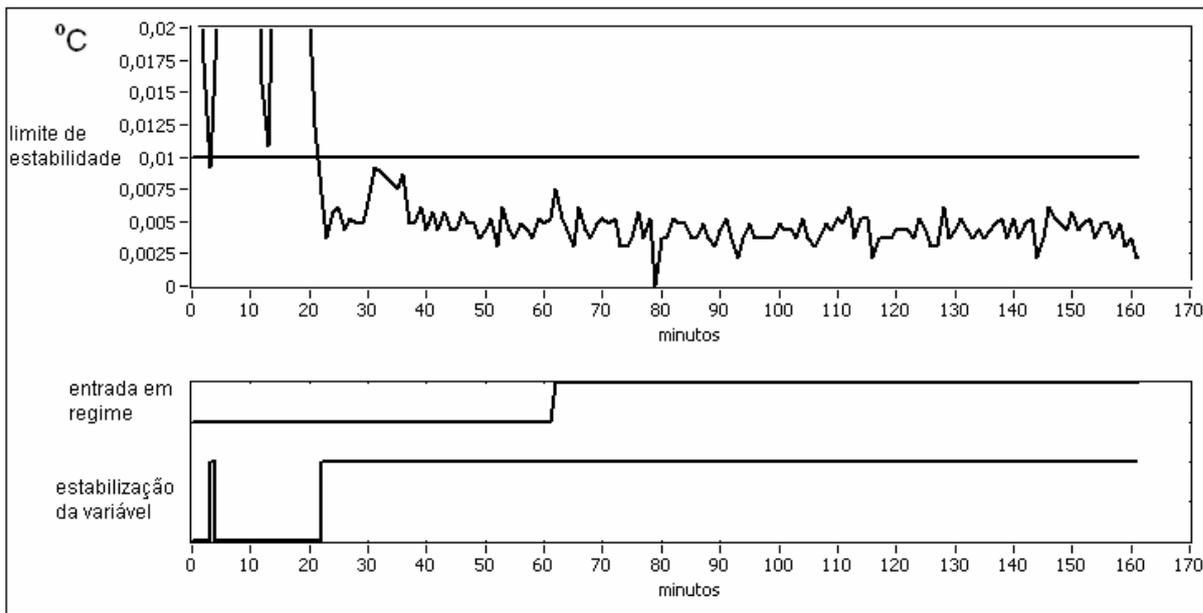


Figura 20 –  $t_p = 1$  min e  $\tau = 1$ .

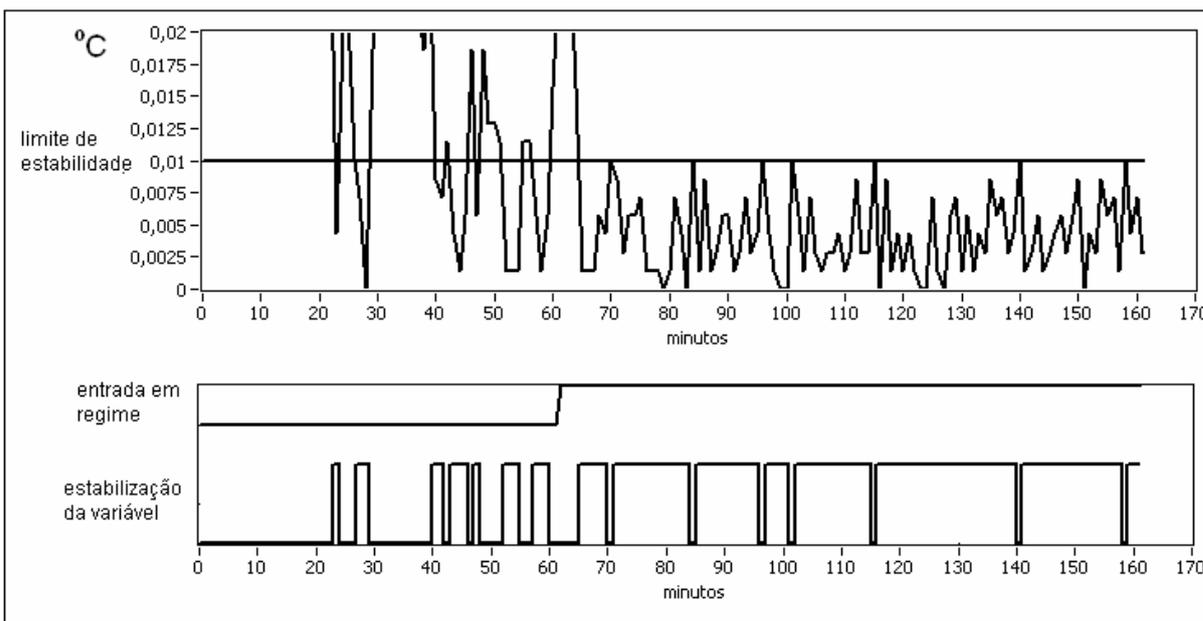
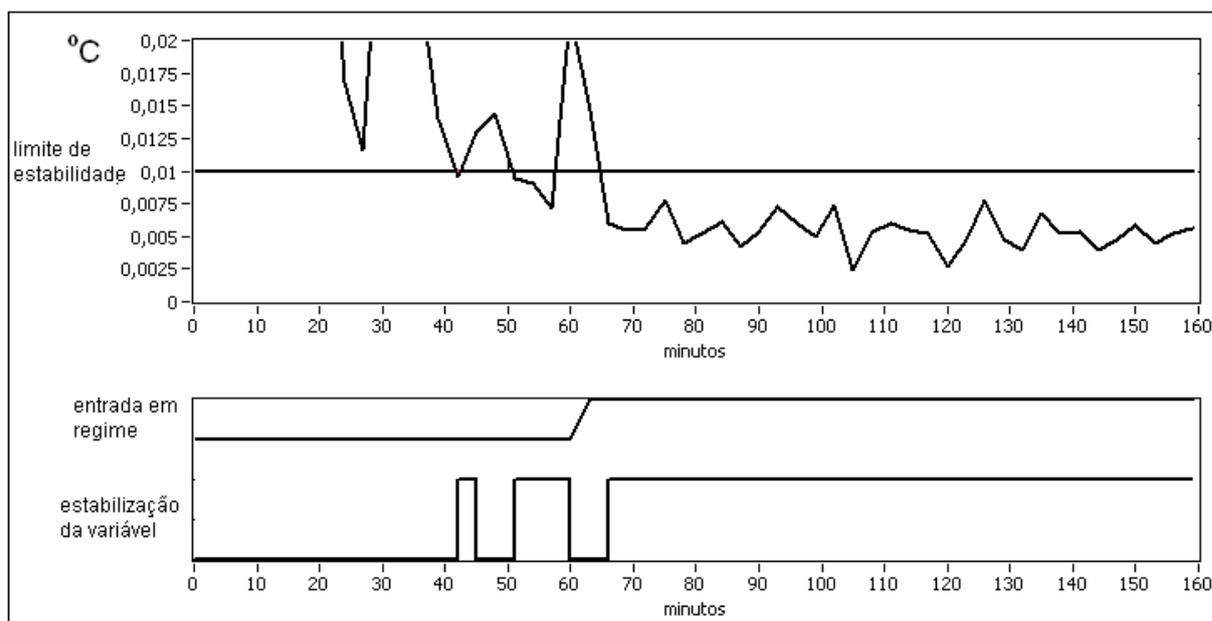


Figura 21 –  $t_p = 1$  min e  $\tau = 5$ .



**Figura 22 –  $t_p = 3$  min e  $\tau = 5$ .**

A escolha do limite é influenciada pelo  $\tau$  e pelo tempo de janela ( $t_p$ ). É importante ajustar esses valores para conseguir que a estabilidade da variável analisada seja muito próxima, na maioria dos casos, da estabilização da variável capacidade. Essa mesma análise foi repetida para as 126 variáveis, testando diversas combinações de tempo de janela ( $t_p$ ) e  $\tau$ . Com esses testes foi possível perceber que janelas de 3 minutos e  $\tau$  igual a 5, são valores que apresentaram resultados satisfatórios para a maioria das variáveis, conseguindo detectar todas as variações bruscas no desvio padrão de Allan, sem causar muito atraso na resposta.

Algumas variáveis alcançam a estabilização muito antes da variável capacidade de refrigeração. Esse tipo de variável não contribui no sistema de inferência.

Das 126 variáveis disponíveis, as que apresentaram melhor comportamento são mostradas na tabela 4, juntamente com os limites estabelecidos:

Tabela 4 – Variáveis escolhidas.

Variável	Limite de estabilização	Unidade
<i>Temperatura corpo</i>	0,10	°C
<i>Temperatura saída trocador</i>	0,010	°C
<i>Temperatura superficial calorímetro</i>	0,010	°C
<i>Temperatura carcaça topo (T1)</i>	0,15	°C
<i>Temperatura carcaça curva do óleo (T2)</i>	0,10	°C
<i>Temperatura carcaça solda (T3)</i>	0,10	°C
<i>Temperatura carcaça fundo (T4)</i>	0,10	°C
<i>Tensão DC calorímetro (via placa de aquisição)</i>	0,050	V
<i>Tensão DC calorímetro (via instrumento)</i>	0,040	V
<i>Corrente DC calorímetro (via placa de aquisição)</i>	0,0005	A
<i>Corrente DC calorímetro (via instrumento)</i>	0,0008	A
<i>Corrente DC calorímetro (shunt)</i>	0,0005	A
<i>Corrente RMS compressor (via instrumento)</i>	0,0020	A
<i>Potência DC calorímetro (via placa de aquisição)</i>	0,15	W
<i>Potência DC calorímetro (via instrumento)</i>	0,20	W
<i>Potência Real compressor (via instrumento)</i>	0,20	W
<i>Capacidade via calorímetro</i>	0,20	W
<i>Capacidade via fluxo de massa</i>	0,25	W
<i>Fluxo de massa do fluido refrigerante-filtrado</i>	0,0025	kg/s

Os nomes adotados neste trabalho para as variáveis dizem respeito à sua grandeza e característica de aquisição, descrição mais detalhada sobre essas variáveis é apresentada no apêndice D.

Realizaram-se testes para eliminar variáveis que não interferem no resultado esperado. Uma quantidade muito grande de variáveis não fornecerá informações melhores do que um conjunto bem definido.

É importante perceber que é tão diferente a maneira de análise deste método que as variáveis escolhidas não foram iguais às escolhidas por STEINBACH (2008) em seu trabalho utilizando redes neurais. Como exemplo, a variável *fluxo de massa do refrigerante*, que neste método foi considerada uma variável muito ruim para uso, foi útil no trabalho de STEINBACH (2008).

Com essas variáveis selecionadas e determinados os seus limites de estabilização, foi criada a base de conhecimento.

Foram criadas 8 combinações de banco de conhecimento com as variáveis escolhidas, com o propósito de eliminar as variáveis que não acrescentaram informações importantes ou redundantes, como a leitura da corrente, que foi feita de duas maneiras diferentes, mas que possuem a mesma variação.

A tabela 5 mostra as combinações criadas e analisadas, sendo que a oitava combinação é a que foi escolhida e sobre a qual foram realizados testes em que se comparou o resultado de cada uma com o valor real de estabilização, obtendo-se os melhores resultados.

**Tabela 5 – Combinações de variáveis avaliadas.**

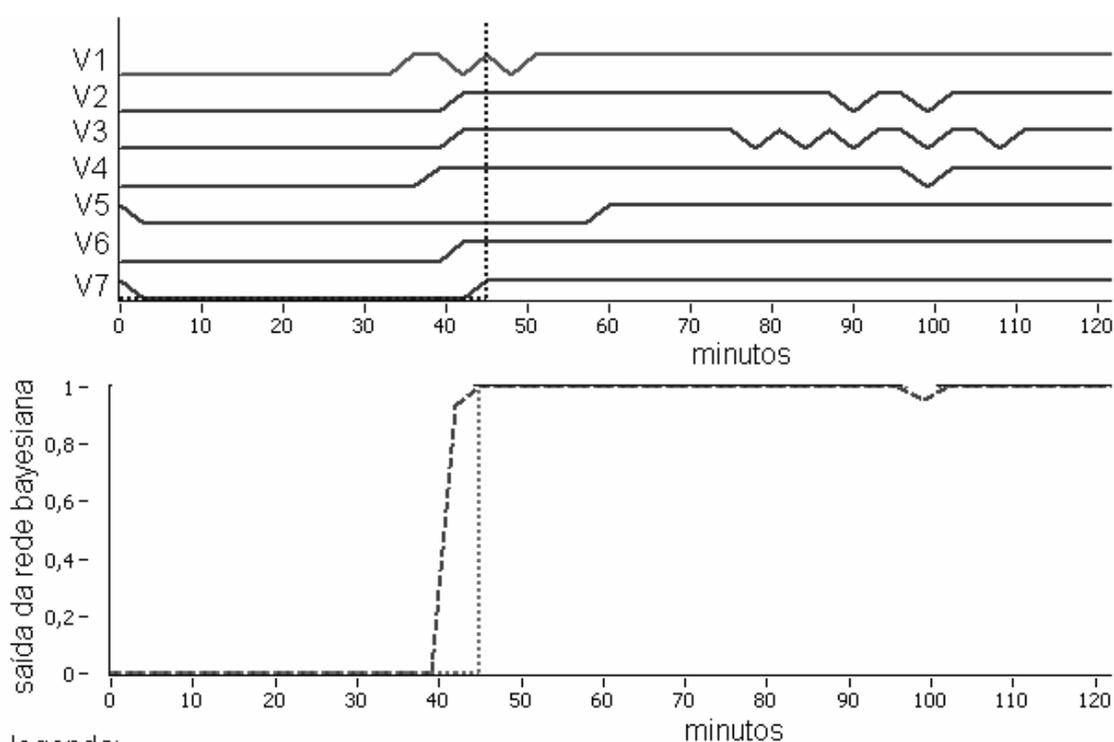
<b>1ª combinação</b>	<b>2ª combinação</b>
<i>Temperatura corpo;</i> <i>Temperatura saída do trocador;</i> <i>Temperatura superficial calorímetro;</i> <i>Tensão DC calorímetro (via placa de aquisição);</i> <i>Corrente DC calorímetro (via placa de aquisição);</i> <i>Potência DC calorímetro (via placa de aquisição);</i> <i>Corrente DC calorímetro (via placa de aquisição);</i> <i>Capacidade via fluxo de massa.</i>	<i>Temperatura corpo;</i> <i>Temperatura saída do trocador;</i> <i>Temperatura superficial calorímetro;</i> <i>Tensão DC calorímetro (via placa de aquisição);</i> <i>Corrente DC calorímetro (via placa de aquisição);</i> <i>Potência DC calorímetro (via placa de aquisição);</i> <i>Corrente DC calorímetro (via instrumento);</i> <i>Capacidade via fluxo de massa;</i> <i>Temperatura carcaça topo (T1);</i> <i>Temperatura carcaça curva do óleo (T2);</i> <i>Temperatura carcaça solda (T3);</i> <i>Temperatura carcaça fundo (T4);</i> <i>Potência DC calorímetro (via instrumento);</i> <i>Corrente DC calorímetro (via Shunt);</i> <i>Capacidade via calorímetro.</i>
<b>3ª combinação</b>	<b>4ª combinação</b>
<i>Temperatura corpo;</i> <i>Temperatura saída do trocador;</i> <i>Temperatura superficial calorímetro;</i> <i>Tensão DC calorímetro (via placa de aquisição);</i> <i>Corrente DC calorímetro (via placa de aquisição);</i> <i>Potência DC calorímetro (via placa de aquisição);</i> <i>Capacidade via fluxo de massa;</i> <i>Corrente DC calorímetro (via Shunt);</i> <i>Potência DC calorímetro (via instrumento).</i>	<i>Temperatura corpo;</i> <i>Temperatura saída do trocador;</i> <i>Temperatura superficial calorímetro;</i> <i>Tensão DC calorímetro (via placa de aquisição).</i>
<b>5ª combinação</b>	<b>6ª combinação</b>
<i>Temperatura corpo;</i> <i>Temperatura saída do trocador;</i> <i>Temperatura superficial calorímetro;</i> <i>Tensão DC calorímetro (via placa de aquisição);</i> <i>Capacidade via calorímetro.</i>	<i>Temperatura descarga compressor;</i> <i>Temperatura corpo;</i> <i>Corrente RMS (via instrumento);</i> <i>Potência real (via instrumento);</i> <i>Fluxo de massa do fluido refrigerante-filtrado;</i> <i>Capacidade via fluxo de massa.</i>
<b>7ª combinação</b>	<b>8ª combinação</b>
<i>Temperatura descarga compressor;</i> <i>Temperatura Corpo;</i> <i>Corrente RMS (via instrumento);</i> <i>Potência real (via instrumento);</i> <i>Fluxo de massa do fluido refrigerante-filtrado;</i> <i>Capacidade via calorímetro.</i>	<i>Temperatura corpo;</i> <i>Temperatura saída do trocador;</i> <i>Temperatura superficial calorímetro;</i> <i>Tensão DC calorímetro (via placa de aquisição);</i> <i>Corrente DC calorímetro (via placa de aquisição);</i> <i>Potência DC calorímetro (via placa de aquisição);</i> <i>Capacidade via fluxo de massa.</i>

Os itens a seguir demonstram a análise feita para a escolha das variáveis da rede e os resultados alcançados com a aplicação da rede bayesiana pura, isto é, sem considerar o aspecto *fuzzy* na avaliação da estabilidade das variáveis auxiliares. No item 5.3 são apresentados os resultados da rede híbrida *fuzzy*-bayesiana.

## 5.2 RESULTADOS OBTIDOS COM A REDE BAYESIANA

Na figura 23 tem-se um exemplo do resultado da rede bayesiana proposta. O gráfico na parte superior da referida figura apresenta o comportamento da indicação de estabilidade das variáveis auxiliares. Nota-se que, com o decorrer do ensaio, tais indicações mudam de estado. Essas alterações dependem do alcance ou não do limite de estabilidade para cada variável auxiliar.

No gráfico inferior da figura 23 está apresentada a saída da rede bayesiana para indicação da estabilidade da capacidade de refrigeração. Nota-se que a rede indicou a estabilidade da capacidade pouco menos de 10 minutos antes da entrada em regime real (representada pela linha tracejada), mas isso não representa um comportamento padrão da rede, já que em alguns ensaios também foram observados atrasos na identificação desse instante.



legenda:

..... tempo em que ocorreu a estabilização identificado pelo método tradicional

V1 - capacidade via fluxo de massa

V5 - temperatura superficial do calorímetro

V2 - Potencia DC calorímetro (via placa de aquisição)

V6 - temperatura superficial do trocador

V3 - Corrente DC calorímetro (via placa de aquisição)

V7 - temperatura do corpo do compressor

V4 - Tensão DC calorímetro (via placa de aquisição)

**Figura 23 – Estabilidade das variáveis auxiliares e saída da rede bayesiana.**

A figura 23 apresenta a aplicação da rede bayesiana desenvolvida para um ensaio da base de dados disponível. O apêndice C traz as respostas da rede para os outros ensaios da base.

A saída da rede varia de 0 a 1, o que leva a uma necessidade de saber quais as faixas de valores de saída da rede serão consideradas para diferenciação entre regime transitório e permanente, este valor é chamado de patamar. Quando o resultado da rede estiver acima desse patamar o ensaio será considerado no regime permanente.

A análise dos resultados foi feita pelo erro entre o tempo indicado pelo método tradicional e o tempo fornecido pela rede considerando patamares de decisão variando entre 0,6 a 0,9, inclusive. O patamar escolhido deverá ficar acima de 0,5. A indicação de 0,5 significa que o ensaio pode estar estável ou instável com 50% de probabilidade. Essa situação reflete uma condição de total ignorância quanto ao estado do ensaio.

A análise foi realizada para os 27 ensaios disponíveis no banco de dados. Para se conseguir melhores resultados com a rede bayesiana, procurou-se a melhor combinação de variáveis de entrada. Este processo de seleção das variáveis consistiu em criar diferentes combinações das variáveis com comportamentos de desvio padrão o mais próximo do esperado. Fez-se então a primeira combinação, e em seguida a segunda combinação, com todas as variáveis selecionadas, para comparação. Os resultados são mostrados nas figuras 24 e 25.

Devido à característica dicotômica da modelagem probabilística, em diversos ensaios os erros apresentados são idênticos implicando sobreposição das curvas.

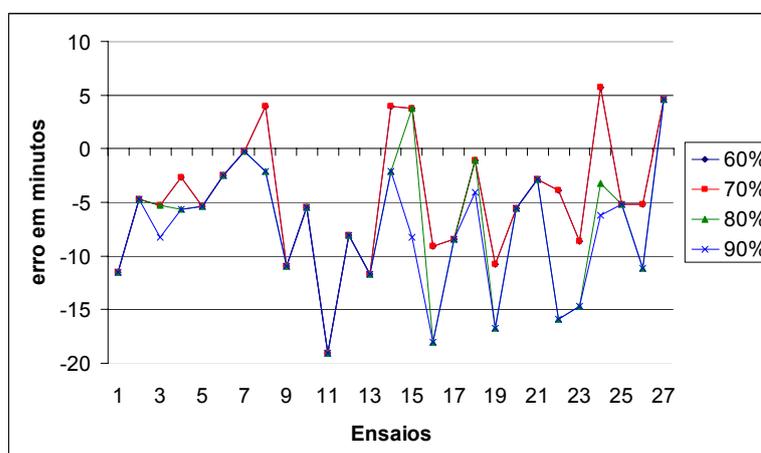
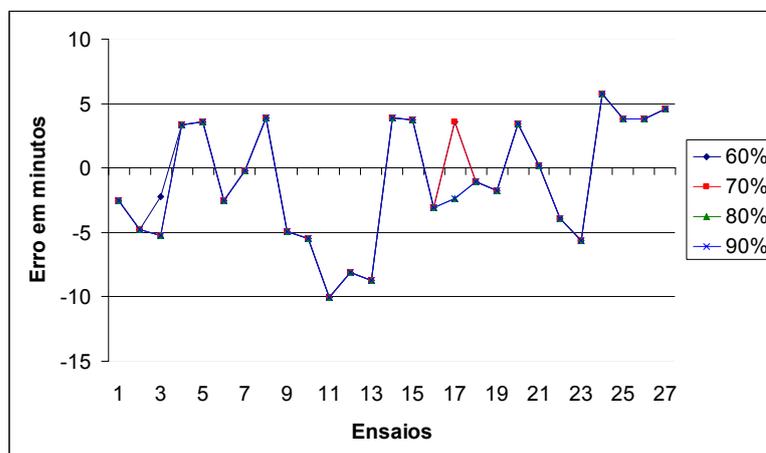


Figura 24 – Resultado com a 1ª combinação.

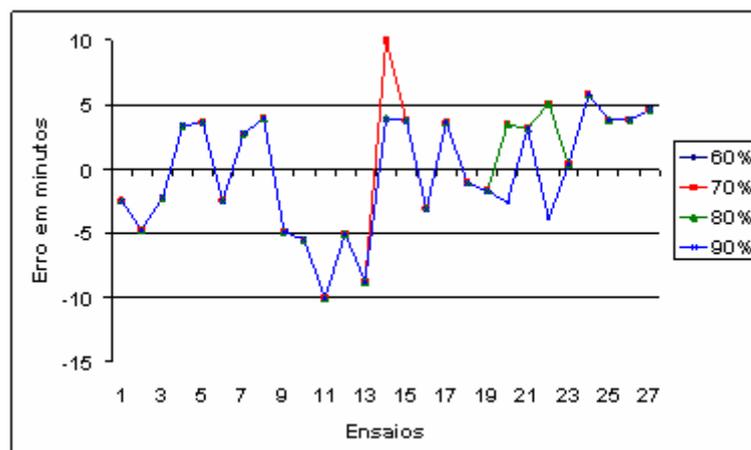
Os erros de indicação do instante de estabilização para a capacidade de refrigeração distribuíram-se entre atrasados e adiantados em relação ao instante real. Nota-se uma leve tendência ao erro negativo que caracteriza o atraso na resposta da rede.



**Figura 25 – Resultado com a 2ª combinação.**

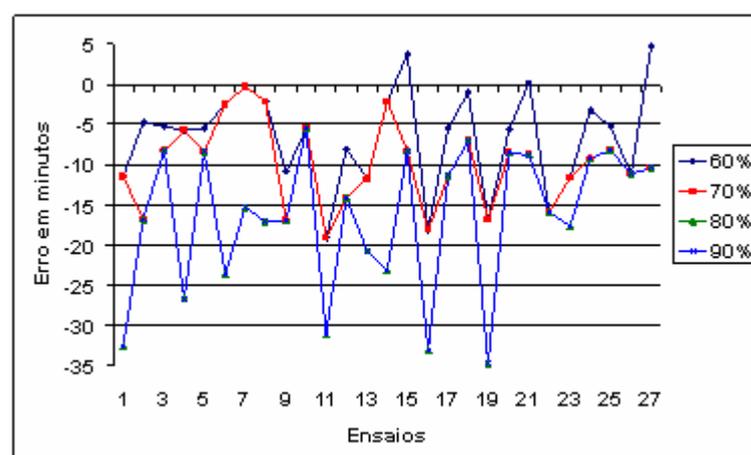
A segunda combinação apresentou melhores que a primeira. Os testes seguintes foram realizados para encontrar a melhor combinação a partir das variáveis utilizadas nas anteriores.

Inicialmente excluíram-se as variáveis que tinham comportamento muito parecido, como por exemplo, medições de corrente por mais de um método. Optou-se por deixar as que já estavam previstas pela norma e a corrente medida pelo método desenvolvido por BARBOSA (2006), que utiliza divisores resistivos, *shunts* e placas de aquisição. O resultado desta combinação é mostrado na figura 26. Observa-se que não houve grande perda de informação, em geral houve pouca alteração na resposta da rede, apenas um ensaio se sobressaiu em relação aos outros, se adiantando quase 10 minutos. De forma geral esta rede tem resposta muito boa com o benefício da redução de variáveis para análise, o que deixa o processamento mais leve.

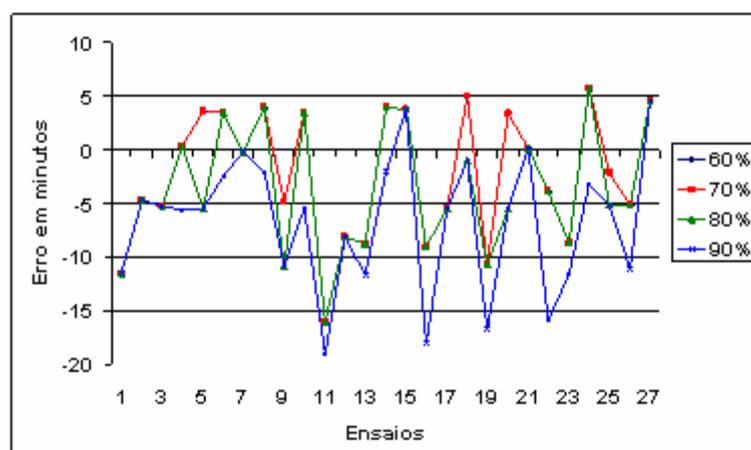


**Figura 26 – Resultado com a 3ª combinação.**

Nas quarta e a quinta combinações, figuras 27 e 28, tentou-se uma redução mais radical de variáveis a partir da terceira combinação, e essas redes apresentaram resultados ruins quando comparados aos alcançados pelas combinações anteriores.

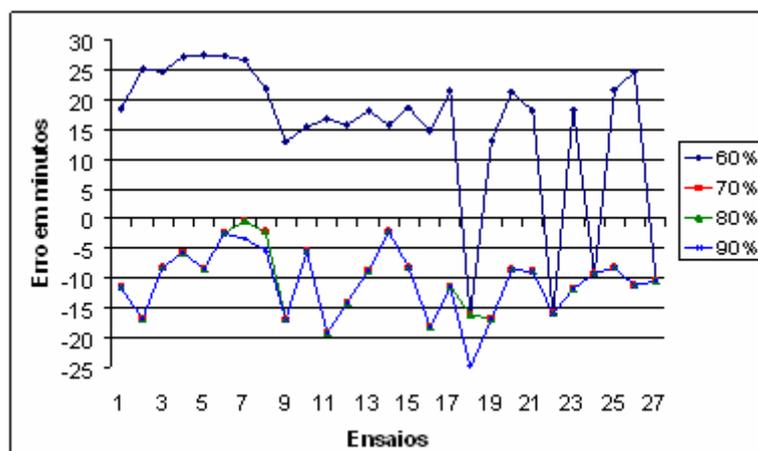


**Figura 27 – Resultado com a 4ª combinação.**

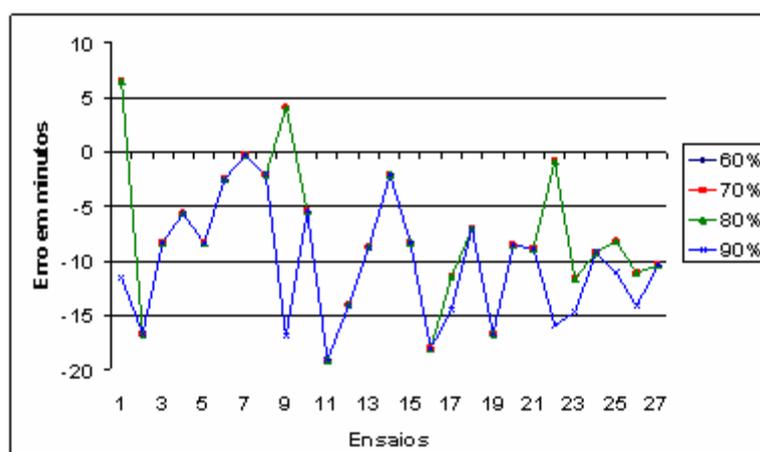


**Figura 28 – Resultado com a 5ª combinação.**

As sexta e a sétima combinações, figuras 29 e 30, foram feitas a partir de outro conjunto, que haviam sido retirados da terceira combinação por serem medições que não são padrão nas bancadas.



**Figura 29 – Resultado com a 6ª combinação.**



**Figura 30 – Resultado com a 7ª combinação.**

Os resultados da rede com essas combinações apresentaram maiores atrasos em relação às combinações anteriores.

Retomado a terceira combinação foram retiradas: uma medição de corrente e outra de potência que eram redundantes, mas por métodos diferentes. O resultado é mostrado na figuras 31, perdeu-se um pouco de informação, causando um pouco mais de atraso na rede. Essa perda de informação não foi considerada prejudicial à rede e diminuiu significativamente o número de variáveis de entrada. Essa combinação foi escolhida para dar continuidade ao trabalho.

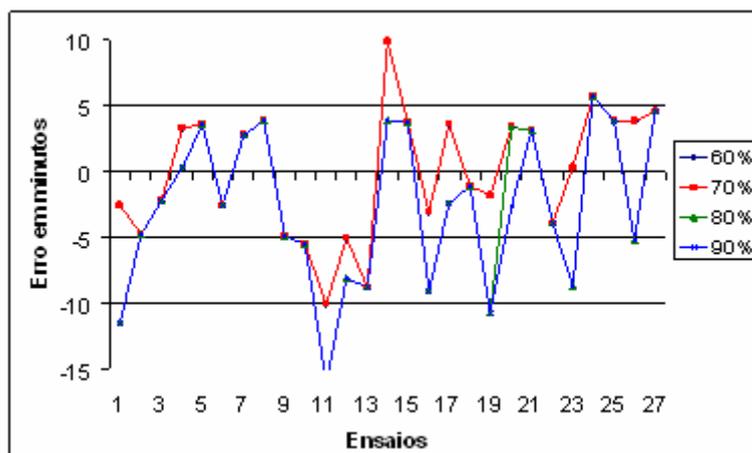


Figura 31 – Resultado com a 8ª combinação.

### 5.3 RESULTADOS OBTIDOS COM A REDE HÍBRIDA

Para melhorar a resposta da rede bayesiana foi adicionada a lógica *fuzzy*. Para isso, a base de conhecimento não precisa ser alterada, mas a rede bayesiana sim, para que a informação *fuzzy* possa ser inserida.

Para aplicar o hibridismo há necessidade de definição dos limites de cada conjunto *fuzzy* e da função de pertinência relacionada a cada variável auxiliar.

Os limites mínimos e máximos desses conjuntos foram determinados observando-se todos os ensaios, de forma que englobasse as leituras das variáveis que estivessem com estado coerente com o resultado da variável capacidade. Os valores obtidos são mostrados na tabela 6.

Tabela 6 – Valores dos limites dos conjuntos *fuzzy*.

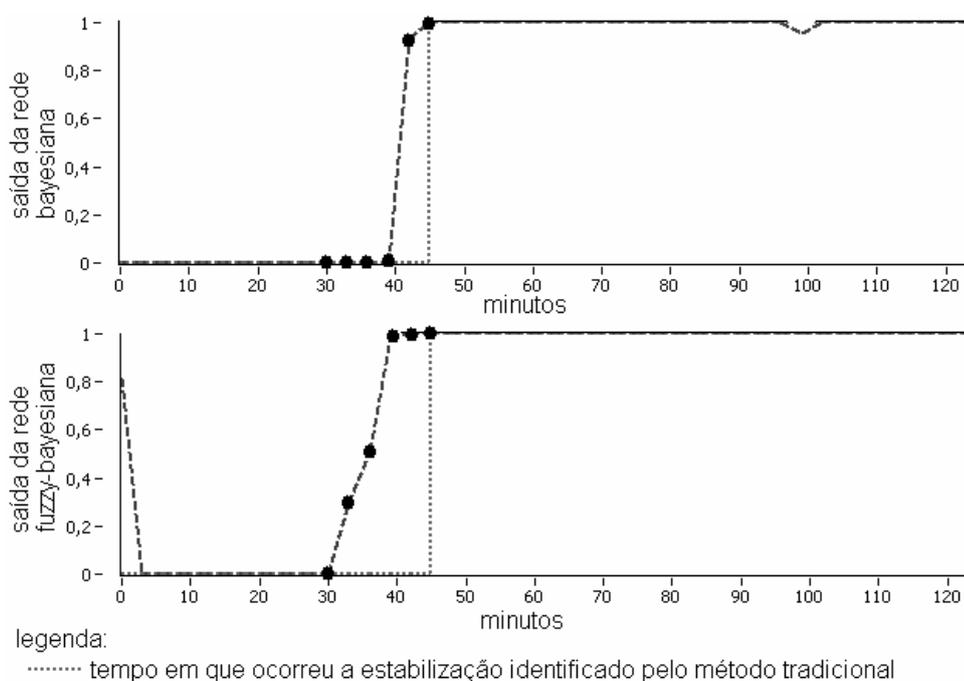
Variável	Limite mínimo do conjunto <i>fuzzy</i>	Limite máximo do conjunto <i>fuzzy</i>	Unidade
Temperatura corpo	0,050	0,15	°C
Temperatura saída do trocador	0,0040	0,16	°C
Temperatura superficial calorímetro	0,0025	0,017	°C
Tensão DC calorímetro (via instrumento)	0,010	0,090	V
Corrente DC calorímetro (via instrumento)	0,00012	0,00088	A
Potência DC calorímetro (via instrumento)	0,050	0,25	W
Capacidade via fluxo de massa	0,15	0,35	W

Foram testadas duas funções de pertinência para avaliar a estabilidade das variáveis auxiliares: função gama e função S.

Apesar das funções serem diferentes, sendo uma linear e a outra quadrática na faixa de transição, não houve diferença significativa nos resultados, devido à

quantidade de valores lidos dentro da faixa de transição não ser muito representativa. Optou-se por utilizar a função S.

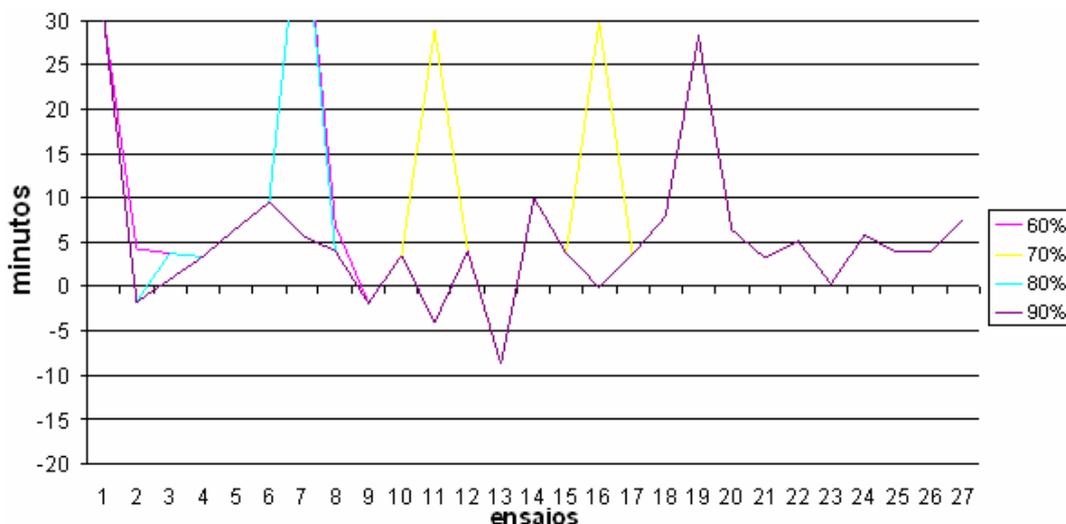
A figura 32 mostra o resultado da rede somente bayesiana e o resultado da rede *fuzzy*-bayesiana. Os dois gráficos são para o mesmo ensaio.



**Figura 32 – Resultado para rede bayesiana e rede fuzzy-bayesiana de um mesmo ensaio.**

Nota-se na figura 32 que a saída da rede híbrida inicia a indicação de que a capacidade está estabilizando muito próximo dos 30 minutos de ensaio. Evidênciam-se, ainda, a presença de estados intermediários de estabilização, o que não ocorria na rede puramente bayesiana.

A figura 33 mostra os erros nos tempos determinados pela rede híbrida para todos os ensaios.



**Figura 33 – Erros apresentados pela rede híbrida.**

Observa-se que houve melhoria somente de alguns casos, diminuindo o erro, mas a rede se adiantou muito na maioria dos casos. Isso se deve a dois motivos:

- ocorrência de dois períodos transitórios durante o ensaio – em alguns ensaios, após terem atingido o regime permanente, ocorreu alguma perturbação externa causadora de instabilidade. Tal perturbação foi, então, contornada pelo sistema de controle, reestabilizando o ensaio. Como o instante de estabilização definido por norma considera todos os dados do ensaio, o segundo período transitório prevaleceu para tal. Dessa forma, a rede apresentou erro acentuado, pois identificou o primeiro instante de entrada em regime permanente. Esse comportamento da rede é vantajoso já que identificou o comportamento de estabilidade;
- a rede *fuzzy*-bayesiana não distingue a ocorrência de pontos estáveis ocasionais de instantes de entrada de regimes permanentes. O processamento numérico da rede *fuzzy*-bayesiana aliado às medições das diferentes variáveis, pode gerar, ocasionalmente, indicações de estabilidade em meio ao período transitório. Dessa forma deve-se prover artifícios à rede no intuito de minimizar o efeito dessas ocorrências.

## 5.4 PROCESSAMENTO DAS SAÍDAS DA REDE

Foram testadas seis técnicas de para eliminar as interpretações errôneas das variáveis de entrada. Após a apresentação dos testes com cada técnica é feita uma avaliação geral no item 5.5, no qual será realizada a escolha da técnica mais adequada.

### 5.4.1 Média

Testou-se a média entre os dois últimos valores fornecidos pela rede. Limitou-se a dois o número de termos para evitar atrasos consideráveis nos resultados da rede. A figura 34 mostra o erro entre os tempos reais e o resultado da rede com média de dois valores.

Com esta técnica, houve um atraso diferente para cada nível de patamar de decisão.

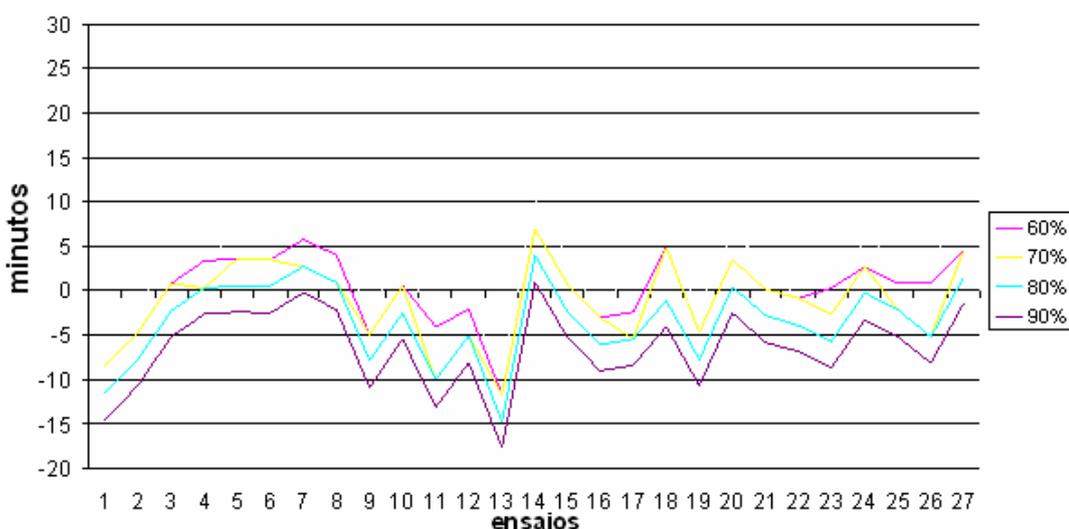


Figura 34 – Resultado da rede com médias de dois valores.

### 5.4.2 Dois resultados acima do patamar

Nesta técnica considera-se que a probabilidade indicada pela rede é verdadeira se dois valores consecutivos fornecidos pela rede estiverem acima do respectivo patamar.

A figura 35 mostra o erro do resultado obtido para cada ensaio. Esta técnica causou o mesmo atraso em todos os patamares de decisão.

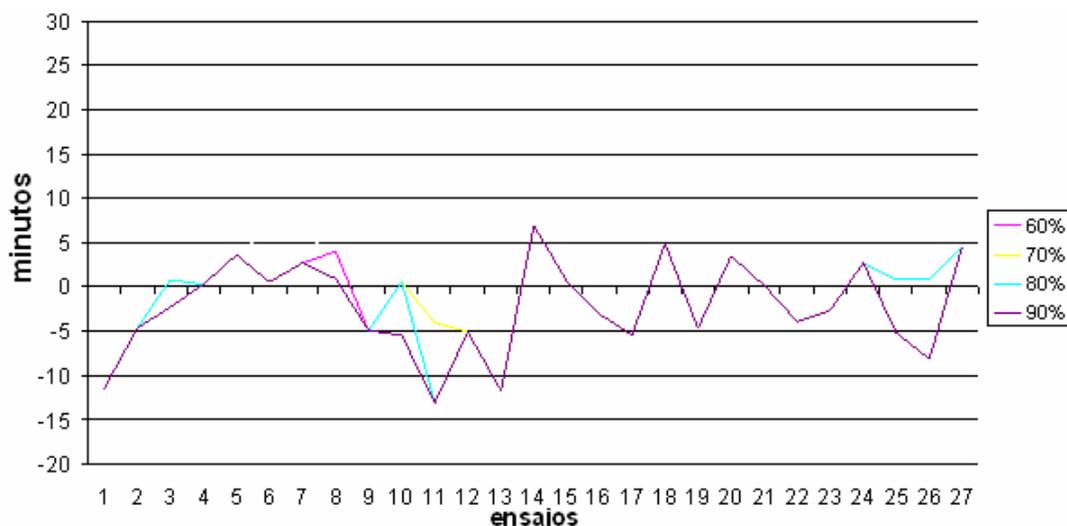


Figura 35 – Resultado da rede com dois valores acima do patamar.

#### 5.4.3 Combinação de média com dois resultados acima do patamar

Aqui é feita a média de dois valores e depois é feita a verificação se dois valores estão acima da probabilidade. A figura 36 apresenta os erros para esse tipo de processamento.

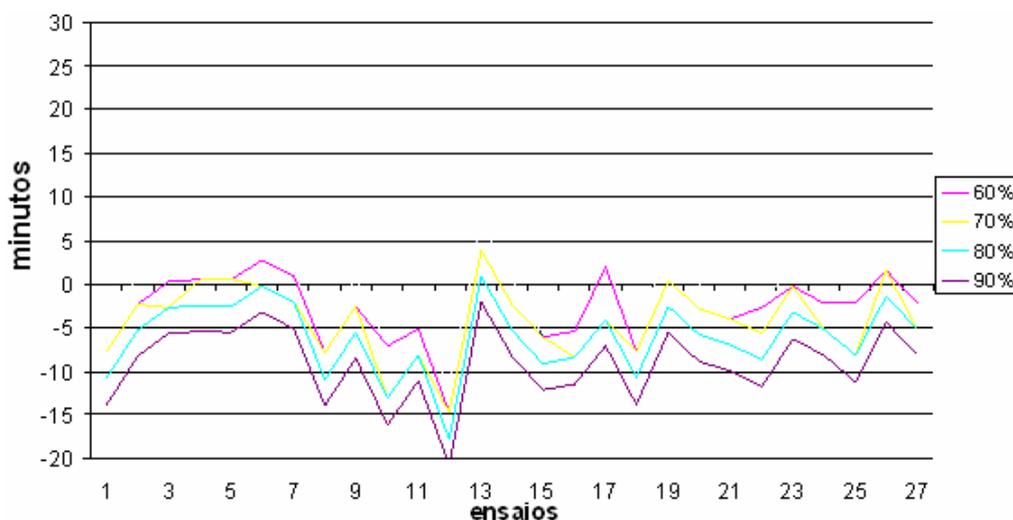


Figura 36 – Resultado da rede com médias e dois valores acima do patamar.

#### 5.4.4 Verificação do tempo de estabilidade da capacidade

Esta técnica consiste em associar um valor *fuzzy* à capacidade de refrigeração, classificando esta variável quanto ao seu grau de pertinência ao conjunto estável. Quanto mais tempo a variável estiver estável maior será o grau de

pertinência. Se a variável volta a tornar-se instável, o valor do grau de pertinência é reduzido.

Para associar essa informação, é necessário utilizar uma operação t-norma entre as variáveis *fuzzy*: a saída da rede híbrida e o tempo de estabilidade.

Foram testadas seis operações t-nomas: probabilista, *Zadeh*, *Lukasiewicz*, *Hamacher*, *Dubbois and Prade* e *Scweizer and Sklar* (item 3.1.2). Mas entre os resultados não houve diferenças significativas.

A utilização desta técnica não acrescentou informações novas no resultado da rede, ficando muito parecida com o resultado usando a técnica descrita anteriormente.

A figura 37 mostra os erros obtidos utilizando a operação t-norma de *Zadeh*.

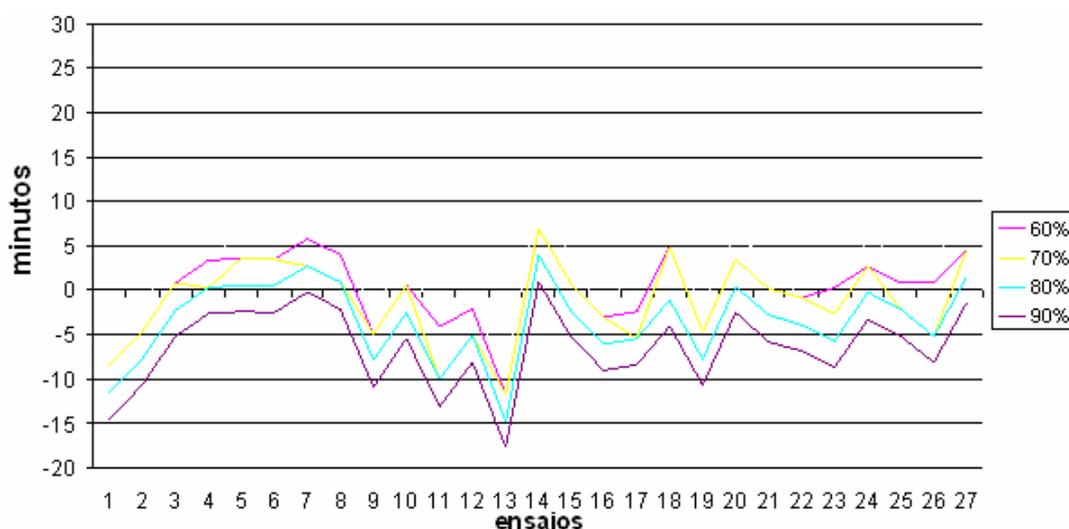


Figura 37 – Resultado da rede com análise do tempo de estabilidade da variável de entrada.

#### 5.4.5 Combinação de tempo de estabilidade com dois resultados acima do patamar

Consiste da aplicação da mesma técnica anterior, com a verificação de dois resultados consecutivos acima da probabilidade esperada. Essa combinação causou maior atraso nos resultados.

A rede com esta configuração já começa a apresentar atrasos significativos na saída. Isso é um indicativo de que pode não tratar-se da melhor técnica para ser aplicado neste trabalho.

A figura 38 mostra os erros que essa configuração causa.

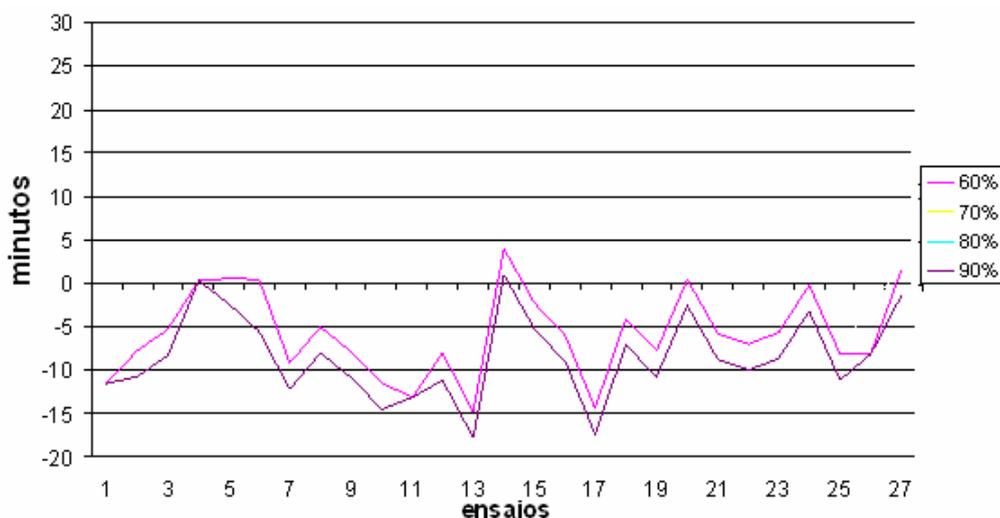


Figura 38 – Resultado da rede com análise do tempo de estabilidade e dois valores acima do patamar.

#### 5.4.6 Combinação de verificação de tempo de estabilidade com média e com dois resultados acima do patamar

Consiste da aplicação da mesma técnica anterior, com a utilização adicional da média de resultados consecutivos. Essa combinação causou maior atraso nos resultados. A figura 39 mostra os erros dessa rede.

Em geral, a rede atrasou em todos os ensaios, por este motivo, a rede com esta combinação de técnicas não será utilizada.

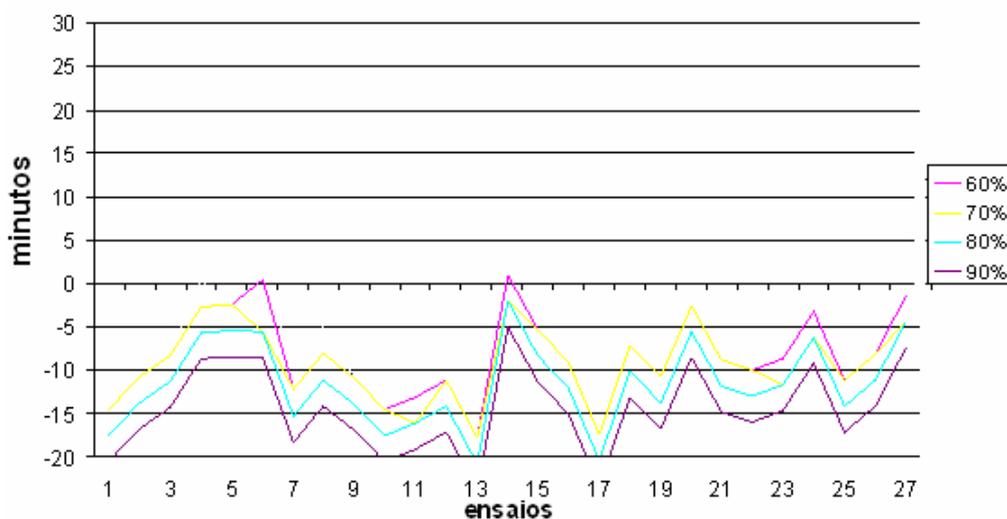


Figura 39 – Resultado da rede com análise do tempo de estabilidade com médias e dois valores acima do patamar.

## 5.5 ANÁLISE DOS RESULTADOS FRENTE AOS ERROS NO INSTANTE DE ENTRADA EM REGIME PERMANENTE

Quando se trata de problemas de classificação binária, costuma-se medir o desempenho da rede através do seu poder de discriminação. Isto é feito calculando-se algumas estatísticas descritivas, tais como falso-positivos, falso-negativos, sensibilidade e especificidade, que podem fornecer resultados mais significantes.

Neste trabalho não foram utilizadas a sensibilidade e nem a especificidade. Apenas as avaliações de falsos positivos e falsos negativos foram consideradas suficientes para a escolha do método a ser utilizado.

Diz-se que um resultado é falso-positivo quando a rede afirma que um resultado é verdadeiro, quando não é. E, quando a rede afirma que um resultado é falso quando é verdadeiro, é chamado de falso-negativo.

Neste trabalho considera-se que a rede informa *positivo* quando identifica que a variável capacidade está estável e, como *negativo*, quando a rede ainda não identifica a estabilidade da variável capacidade.

O resultado obtido com a rede híbrida, sem nenhum tratamento, não pode ser utilizado, pelos problemas que ela apresenta, e que já foram descritos no item 5.2.

A última combinação testada – tempo de estabilidade com dois resultados acima do patamar – também foi descartada devido ao grande atraso em sua resposta.

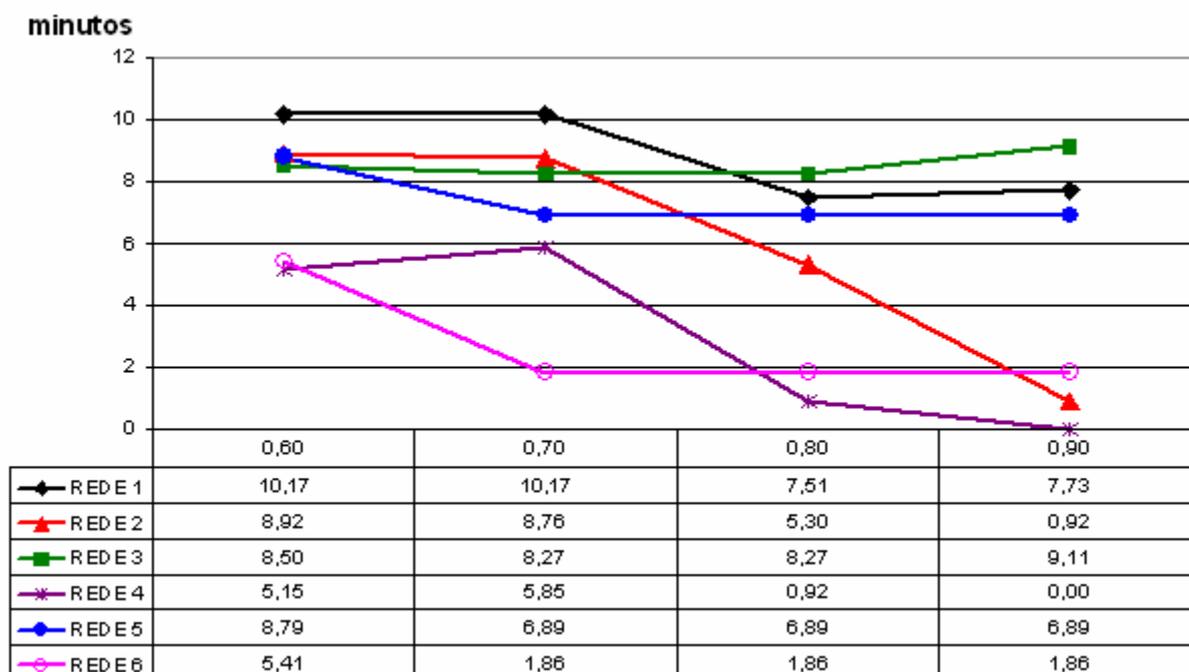
A figura 40 mostra os gráficos dos falsos-positivos para todas as combinações avaliadas e a figura 41 mostra os gráficos dos falsos-negativos, para as redes com as diferentes configurações descritas na tabela 7.

**Tabela 7 – Configurações das redes para os gráficos falsos-positivos e falsos-negativos.**

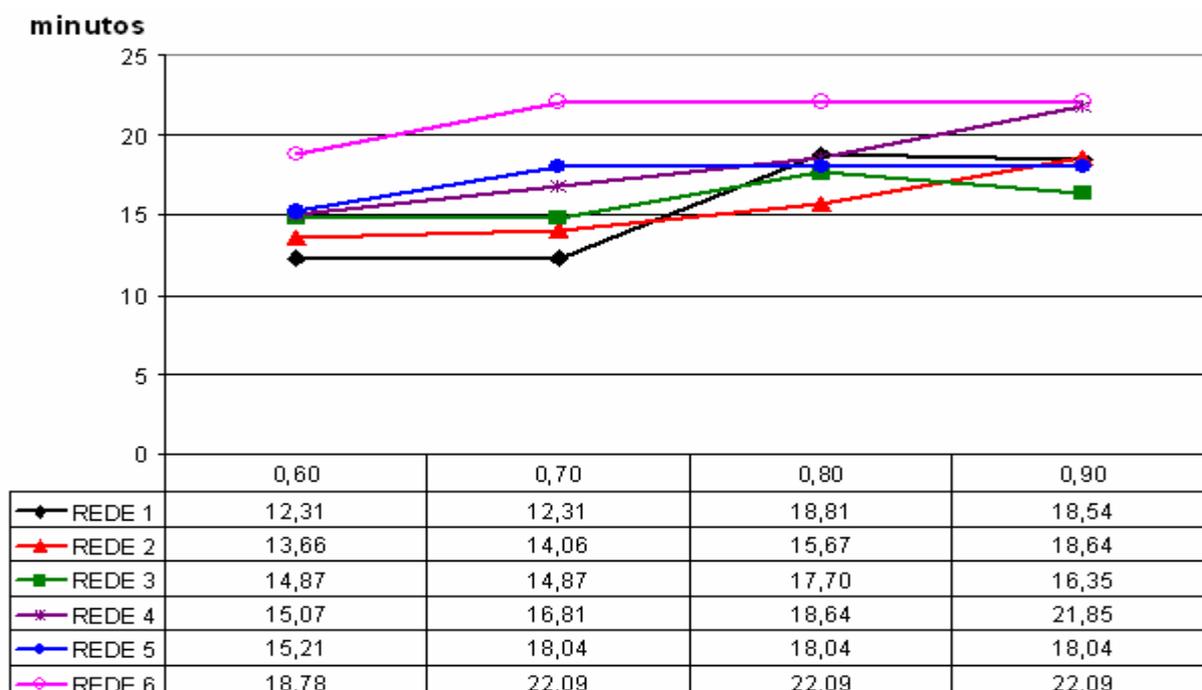
Nome	Configuração
REDE 1	Somente rede bayesiana.
REDE 2	Rede bayesiana com <i>fuzzy</i> e média de dois valores.
REDE 3	Rede bayesiana com <i>fuzzy</i> e dois pontos verdadeiros.
REDE 4	Rede bayesiana com <i>fuzzy</i> , média e dois pontos verdadeiros.
REDE 5	Rede bayesiana com <i>fuzzy</i> , média e tempo de estabilidade da entrada.
REDE 6	Rede bayesiana com <i>fuzzy</i> , dois pontos verdadeiros e tempo de estabilidade da entrada.

As colunas 0,6 a 0,9 representam os patamares de decisão empregados. Pode-se associar esse patamar como o limiar entre estabilidade e não-estabilidade.

O eixo Y é a diferença de tempo média em relação ao esperado, com três desvios padrão. Para falso-positivo o tempo corresponde a quanto a rede se adiantou; para falso-negativo quanto a rede se atrasou.



**Figura 40 – Comparativos com os falsos positivos.**



**Figura 41 – Comparativo com os falsos negativos.**

Falsos-positivos são mais críticos do que falsos-negativos, pois uma indicação de que a capacidade está estável antes de estar causará erros nos

resultados dos ensaios. Falsos-negativos indicam que o ensaio já estabilizou e a rede ainda não detectou o fato. Isso aumenta o tempo de ensaio além do necessário.

Para aumentar a confiabilidade da indicação pela rede de que a condição de estabilidade foi atingida, deve-se compensar o tempo de falso-positivo. Para isso basta adicionar um tempo de espera após a rede informar o instante de entrada no regime permanente. Não há como se compensar o falso-negativo. Mas é interessante se optar por redes que apresentam baixos valores de falso-negativo, pois o seu atraso ainda será acrescido do tempo de espera para se evitar os falsos positivos.

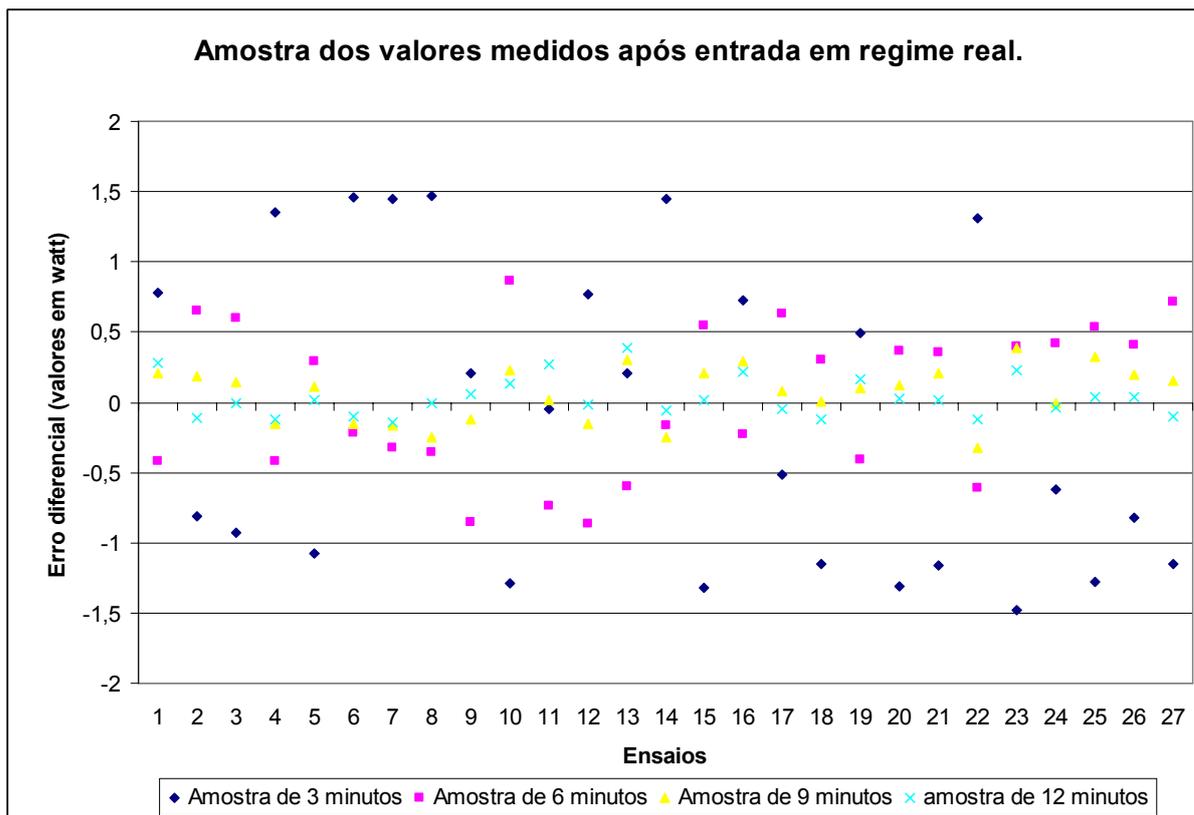
Para seleção do método, descartaram-se os que apresentavam muito atraso, ficando com a configuração da REDE 2 e da REDE 3. O tempo de resposta entre as duas não são muito diferentes, mas a REDE 2 apresenta a resposta progredindo mais suave. Dessa forma, optou-se pela configuração da rede híbrida *fuzzy-bayesiana* com média dos dois últimos valores de saída da rede (REDE 2), com patamar de decisão de 0,7.

Para evitar os casos de falsos-positivos, propõe-se que seja esperado um tempo para informar que a estabilidade foi alcançada. O valor apresentado na tabela da figura 40, na linha REDE 2 coluna 0,7 é 8,76 minutos. Como o desvio padrão de Allan fornece resultados a cada 3 minutos, este valor deve ser um múltiplo de 3. Por isso a escolha de 9 minutos.

## **5.6 AVALIAÇÃO DOS RESULTADOS FRENTE À MEDIÇÃO DE CAPACIDADE**

Para avaliação do resultado do método é necessária a medição da capacidade após a entrada em regime real, como parâmetro, para comparação com a capacidade após a entrada em regime identificada pela rede. Os valores reais de capacidade medidos em ensaios completos com uma hora de regime permanente variam de 195 W a 205 W.

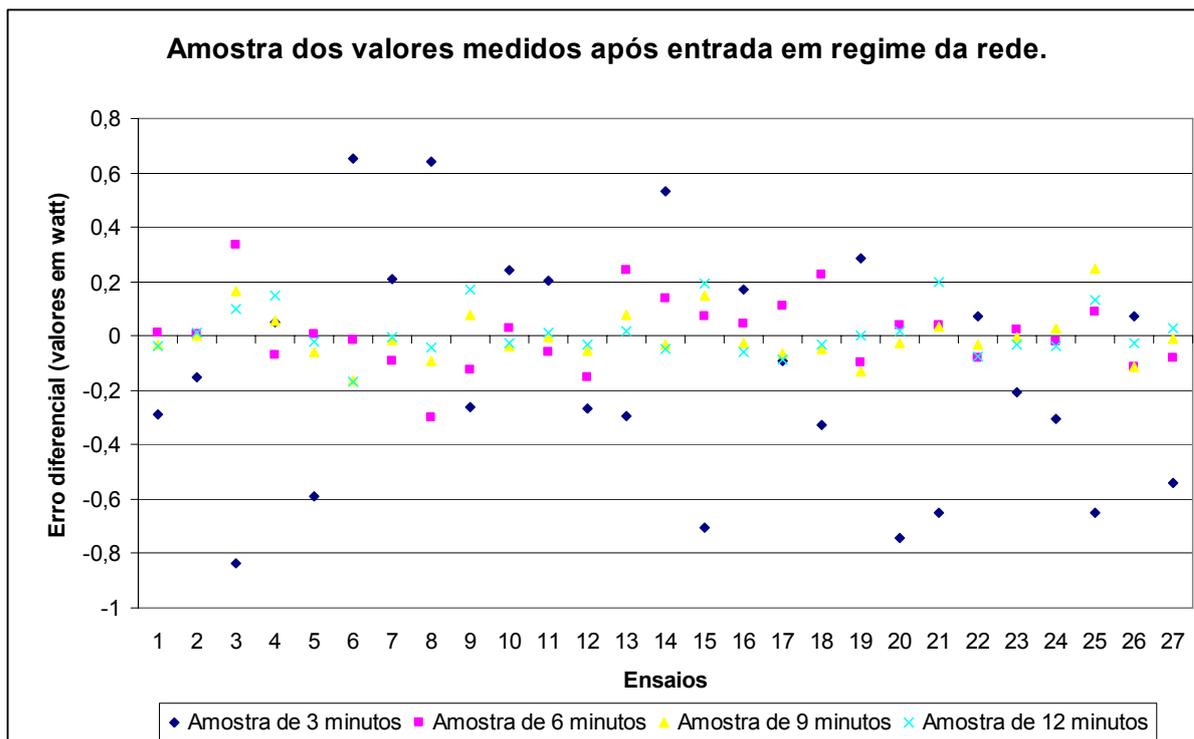
A figura 42 mostra as diferenças entre o valor esperado e o valor médio após o instante de estabilização real, para (3, 6, 9 e 12) minutos de aquisição.



**Figura 42 – Amostras de (3, 6, 9 e 12) minutos após entrada em regime real.**

Observa-se que o aumento do tamanho da amostra após a entrada em regime diminui o erro diferencial. Isso se deve ao fato de que o valor de capacidade entrou em regime, mas ainda está variando, de forma que a medição nesse instante difere daquela correspondente à média de uma hora de ensaio.

A figura 43 mostra as diferenças entre o valor esperado e o valor que seria medido – para amostras de (3, 6, 9 e 12) minutos – após a identificação do instante de estabilização pela rede. Nesse caso, há o proposto tempo de espera de 9 minutos antes da obtenção das amostras. Os valores apresentados correspondem aos apresentados pela configuração escolhida (REDE 2, com média dos dois últimos valores e patamar de 0,7). Como era de se esperar, também é possível verificar que o aumento do tamanho da amostra diminui o erro diferencial.



**Figura 43 – Amostras de (3, 6, 9 e 12) minutos após entrada em regime da rede (valores medidos).**

Para efeito de comparação, os dados de média e desvio padrão estão na tabela 8. A redução dos desvios padrão se deve ao tempo de atraso da rede (falsos negativos). Eles fazem com que a leitura seja feita num período de maior estabilidade e não no início da estabilização.

**Tabela 8 – Resultado da capacidade (valores medidos em watt).**

Tempo das amostras	3 min		6 min		9 min		12 min		Unidade
	Erro médio	Desvio padrão							
Valores reais <sup>(1)</sup>	-0,12	1,08	0,032	0,539	0,063	0,197	0,032	0,143	W
Valores rede <sup>(2)</sup>	-0,14	0,42	0,0075	0,132	-0,004	0,090	0,012	0,090	W

<sup>(1)</sup> Valores medidos após estabilização real;

<sup>(2)</sup> Valores medidos após estabilização indicada pela rede.

O maior erro encontrado foi de 0,33% em relação ao valor esperado (200 W) para média num período de 3 minutos.

## 5.7 ANÁLISE COMPARATIVA COM RESULTADOS OBTIDOS COM REDES NEURAIS

Neste item é apresentada uma análise conjunta dos resultados deste trabalho e dos obtidos por STEINBACH (2008) – que usou redes neurais – em relação à identificação do início do regime permanente e a influência dessa informação na medição do valor da capacidade de refrigeração.

Há uma diferença entre as abordagens dos trabalhos: STEINBACH (2008) cita amostragem de 15 minutos, mas, no entanto, parte desse tempo é de espera e parte é efetivamente usado na amostragem. Adicionalmente, o tempo de falsos-positivos é aguardado. Em tal trabalho, os melhores resultados foram encontrados para um tempo de espera, adicional ao de falsos-positivos, de 14 minutos e amostragem de 1 minuto. No método aplicado nesta dissertação não existe este tempo de espera adicional ao de falsos-positivos e a amostragem é de 3 minutos. Isso é válido para todas as comparações.

A tabela 9 apresenta um resumo dos tempos de entrada em regime (máximo e mínimo) e dos intervalos usados para espera e amostragem.

**Tabela 9 – Tempo para inferência e amostragem adotados nos trabalhos.**

Técnica de IA	Menor instante de estabilização (minutos)	Maior instante de estabilização (minutos)	Tempo de erros falsos-positivos (minutos)	Amostragem (minutos)	Tempo total (minutos)
Rede neural	25,0	42,0	8,9 + 14 <sup>(1)</sup>	1,0	48,9 a 65,9
Rede híbrida	33,0	45,0	9,0	3,0	45,0 a 57,0

<sup>(1)</sup> Tempo adicional ao de falsos positivos empregado por STEINBACH (2008) para obtenção de seus melhores resultados.

É importante salientar que os trabalhos analisaram a capacidade de refrigeração obtida por métodos diferentes – ambos definidos na norma ISO 917: STEINBACH (2008) analisou dos dados do método F que utiliza o medidor de vazão mássica de fluido refrigerante na fase líquida; esta dissertação abordou o método C através do balanço de energia no calorímetro a seco.

Independentemente da procedência dos dados analisados, os resultados obtidos pelos dois trabalhos corroboram a aplicabilidade das ferramentas adotadas. Tal confirmação procede, pois o fenômeno físico – vazão mássica de fluido refrigerante imposta pelo compressor – é comum aos dois métodos analisados e os dados são diferenciados pelos princípios de medição adotados.

A seguir é feita a comparação entre valores da capacidade de refrigeração que seriam medidos empregando-se as duas técnicas para indicação do instante de entrada em regime – redes neurais e redes *fuzzy*-bayesianas. A tabela 10 resume os resultados. Para cada um é apresentado o erro médio e o desvio padrão para os 27 ensaios analisados.

**Tabela 10 – Comparação dos resultados de capacidade de refrigeração.**

<b>Técnica de IA</b>	<b>Estatística</b>	<b>Erro absoluto capacidade</b>	<b>Erro percentual % em 200 W</b>
<b>Rede neural</b>	Média	0,33 W	0,17%
	Desvio padrão	0,53 W	0,27%
<b>Rede <i>fuzzy</i>-bayesiana</b>	Média	-0,14 W	0,07%
	Desvio padrão	0,42 W	0,21%

Os resultados obtidos pelos dois trabalhos convergiram vista a proximidade dos erros apresentados. Independente do método de ensaio – o qual originou os dados analisados – os erros obtidos nas medições de capacidade de refrigeração após a indicação de regime permanente permaneceram abaixo de 1% - condição estabelecida por norma para caracterização de estabilidade.

## **5.8 CONFIGURAÇÃO FINAL DO MÉTODO PROPOSTO**

Após todas as análises feita, o método ficou com a seguinte configuração da rede *fuzzy*-bayesiana.

- ✓ Variáveis de entrada:
  - temperatura corpo;
  - temperatura saída do trocador;
  - temperatura superficial calorímetro;
  - tensão DC calorímetro (instrumento);
  - corrente DC calorímetro (instrumento);
  - potência DC calorímetro (instrumento);
  - capacidade via fluxo de massa.
- ✓ Tratamento da resposta da rede: média entre duas respostas consecutivas da rede.
- ✓ Patamar de decisão pra considerar em regime permanente: 0,7.
- ✓ Tempo de espera (falsos-positivos): 9 minutos.
- ✓ Tempo de amostra ( $t_p$ ): 3 minutos.
- ✓ Tamanho do conjunto ( $\tau$ ): 5.

## 6 CONCLUSÕES E OPORTUNIDADES FUTURAS

### 6.1 CONCLUSÕES

O objetivo principal – estabelecer um método para identificar o instante de entrada em regime permanente da variável capacidade de refrigeração em ensaios de desempenho de compressores herméticos – foi alcançado. Dessa forma este trabalho se constitui numa contribuição para redução do tempo demandado por tais ensaios. Conseguiu-se mostrar que é viável a aplicação de redes híbridas *fuzzy*-bayesianas para esse fim.

Os resultados obtidos com a rede bayesianas neste trabalho, vêm reforçar a tendência de aplicações de redes bayesianas na indústria, que tem relativamente poucos trabalhos publicados em comparação com outras áreas do conhecimento.

A utilização de redes bayesianas com lógica *fuzzy* fez com que este trabalho seguisse um caminho diferente do trabalho desenvolvido anteriormente por STEINBACH (2008), que utilizou redes neurais com a mesma finalidade.

O método *fuzzy*-bayesiano, desenvolvido e analisado neste trabalho apresentou excelentes resultados, mesmo partindo de uma base de dados pequena, se comparado às bases normalmente aplicadas em sistemas probabilísticos. A lógica *fuzzy* mudou o comportamento da rede, fazendo com que ela ficasse mais sensível, assim, a rede pode dar indicações de que estava se aproximando do instante de início do regime permanente.

A utilização do desvio padrão de Allan proporcionou grande robustez ao método, pois seu resultado apresenta comportamento bem definido, facilitando a análise da estabilidade das variáveis de entrada, sem necessidade de estabelecer parâmetros diferentes para uma mesma variável em diversos ensaios.

O método com a configuração escolhida apresentou falsos-positivos (quando a rede identifica o instante de entrada no regime permanente antes de ocorrer) de 8,76 minutos, e apresentou falsos-negativos (quando a rede identifica o instante de entrada no regime permanente após ocorrer) de 14,06 minutos, ambos valores calculados com 3 desvios padrões.

Esses resultados foram, no mínimo, tão bons quanto os conseguidos com redes neurais. Além disso, na rede *fuzzy*-bayesiana não há possibilidade dela “decorar” (*overfitting*) os dados usados no treinamento, como pode ocorrer em redes neurais. Adicionalmente, a aplicação de redes bayesianas tornou a técnica proposta muito leve em termos de esforço computacional, tanto para a construção quanto para utilização da base de conhecimento. Pelo fato da base de conhecimento ser formada por uma pequena tabela de combinações de probabilidades, construída previamente com os históricos dos comportamentos dos compressores ensaiados, a técnica não exige significativos esforços computacionais. A integração com a lógica *fuzzy* demandou pequeno processamento adicional, mas nada crítico aos padrões atuais de microcomputadores pessoais.

Pode-se preferir fazer uma leitura de valores da capacidade de refrigeração num momento com maior confiabilidade de estabilidade, para isso é melhor aumentar o tempo de espera após a rede informar o início do regime permanente do que alterar os valores  $t_p$  e  $\tau$ . A alteração de  $t_p$  e  $\tau$  não garante que se conseguirá que a rede indique o tempo de estabilização mais tarde, apenas modificará o sinal do desvio padrão de Allan, deixando-a com mais ou menos oscilações. Uma alternativa mais eficiente é alterar o limite de estabilização da variável, assim, limites menores farão com que a rede demore mais para identificar a estabilização da variável, e conseqüentemente, este atraso será refletido na resposta da rede.

Em relação à medição do valor de capacidade, os resultados foram muito próximos dos resultados de STEINBACH (2008). Diferenças significativas só iriam ocorrer se houvesse discrepâncias de grande monta entre os instantes de entrada em regime identificados pelas duas técnicas.

De uma forma geral, os resultados dos dois métodos comparados: o proposto neste trabalho e o de STEINBACH (2008) convergem, o que tornaria um sistema que os utilizasse paralelamente muito mais robusto.

## **6.2 OPORTUNIDADES FUTURAS**

Durante a realização da dissertação várias oportunidades para dar seqüência a este trabalho foram identificadas:

- Fazer um estudo comparativo entre diversos modelos de compressores e em condições de operacionais diferentes e criar um método utilizando uma base de conhecimento simplificada, criada sem a base de dados prévia, na qual alguns parâmetros pudessem ser ajustados conforme o modelo do compressor, criando assim um método genérico para diversos compressores ou para qualquer condição operacional.
- Realizar uma análise metrológica em busca da definição da incerteza do processo de inferência, assegurando a confiabilidade dos resultados em aplicações na indústria.
- Elaborar uma atualização da base de conhecimento após o final do ensaio. Assim, a base de conhecimento pode se ajustar às condições de medição da bancada. Ou então, uma nova base de conhecimento pode ser criada com novos modelos de compressores. Tornando a rede bayesiana dinâmica.
- Buscar novos tipos de hibridismos com o sistema especialista probabilístico, por exemplo, usando redes neurais. Esse hibridismo tem se mostrado bastante promissor em trabalhos correlatos voltados a outras aplicações.
- O método apresentado é capaz de identificar o momento em que ocorreu a passagem para regime permanente, mas não pode prever, antecipadamente, quando vai ocorrer. Então, pode-se estudar um novo método que seja capaz disso, adicionando informações temporais, usando modelo markoviano ou filtros de Kalman.

## REFERÊNCIAS

- ALIPPI, C.; FERERO A.; PIURI, V. Artificial intelligence for instruments and measurement applications. **IEEE Instrumentation and measurement magazine**. v.1, n.6, p.9-17, 1998.
- ALLAN, D. W. Time and frequency (time domain) characterization, estimation and prediction of precision clocks and oscillators. **IEEE Transactions on ultrasonics, ferroelectrics, and frequency control**. n.34, p.647-654, 1987.
- AMERICAN SOCIETY OF HEATING, REFRIGERATING AND AIR-CONDITIONING ENGINEERS, INC. **ANSI/ASHRAE 23: Methods of testing for rating displacement refrigerant compressors and condensing units**. Atlanta, EUA, 2005.
- AYYUB, B. M.; KLIR, G. J. **Uncertainty modeling and analysis in engineering and the sciences**. Chapman & Hall/CRC, New York, 2006.
- BARBETTA, P. A.; REIS, M. M.; BORNIA, A. C. **Estatística: para custos de engenharia e informática**. Atlas S.A. São Paulo, 2004.
- BARBOSA, F. Q. **Redução das incertezas nas medições de grandezas elétricas em uma bancada de ensaios de desempenho de compressores**. Dissertação de mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 2006.
- BARRETO, J. M. **Inteligência artificial no limiar do século XX**. 2 ed. UFSC. Florianópolis, 1997.
- BITTENCOURT, G. **Inteligência artificial: ferramentas e teorias**. 3 ed. UFSC. Florianópolis, 2006.
- BOX, G.; JENKINS, G.; REINSEL, G. **Time series analysis: forecasting and control**. 3 ed. Prentice Hall. New Jersey, 1994.
- BRIGNOLI, J. T. **Modelo híbrido difuso-probabilístico – uma alternativa para sistemas especialistas**. Dissertação de mestrado. Curso de Pós-graduação em Ciência da Computação, UFSC, 2001.
- CARDOSO J. R. G. **Estimação da seção em falta em sistemas elétricos de potência via redes neurais e sistemas especialistas realizada em nível de centro de controle**. Tese de doutorado. Curso de Pós-graduação em Engenharia Elétrica. UFSC. Florianópolis, 2003.
- FLESCH, R. C. C. **Desenvolvimento e instalação de recursos de automação aplicados a ensaios de compressores de refrigeração da embraco**. Monografia. Curso de Engenharia de Controle e Automação Industrial, UFSC. Florianópolis, 2006.

HECKMANN, J. R. **Identificação de potenciais aplicações da inteligência artificial na metrologia**. Dissertação de mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 1999.

HECKMANN, J. R.; FLESCHE, C. A. **Minimização de incertezas em circuitos de linearização de transdutores através de algoritmos genéticos**. In: "III SEMETRO" – Seminário Internacional de Metrologia Elétrica. Rio de Janeiro, 1998.

HENKLEIN, P. **Análise de ensaios de desempenho de compressores herméticos durante o transitório**. Dissertação de Mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 2006.

JANG, J.; GULLEY, N. **MATLAB - Fuzzy Logic Toolbox User's Guide**. The MathWorks, Inc. 2 ed., USA. 1997.

KOEHLER, C. **Uma abordagem probabilística para sistemas especialistas**. Dissertação de Mestrado. Curso de Pós-graduação em Ciência da Computação, UFSC. Florianópolis, 1998.

KRONENBERG, J. L. M. **Fundamentos da expressão da incerteza de medição de TF**. Dissertação de mestrado. Curso de Pós-graduação em Metrologia do Centro Técnico, PUC-RJ. Rio de Janeiro, 2007.

MAGALHÃES, I. B. **Avaliação de redes bayesianas para imputação em variáveis qualitativas e quantitativas**. Tese de Doutorado. Programa de Pós-graduação em Engenharia de Controle e Automação Mecânica, EP-SP. São Paulo, 2007.

MARKS, R. J. **Fuzzy logic technology and applications**. IEEE. New York, 1994.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros**. 2. ed. LTC. Rio de Janeiro, 2003.

NASSAR, S. M.; KOEHLER, C.; PIRES, M. **Uma abordagem probabilística para sistemas especialistas: avaliação do estado nutricional em crianças de 0 a 2 anos**. In: "III SIMPÓSIO NACIONAL DE INFORMÁTICA". Santa Maria, 1998.

NASSAR, S. M. **Tratamento de incerteza: sistemas especialistas probabilísticos**. 2007. Disponível em: <<http://www.inf.ufsc.br/~silvia/disciplinas/sep/MaterialDidatico.pdf>> Acesso em agosto, 2007

NETO, O. P. C.; CYMBALISTA, M. **Probabilidades**. 2 ed. Edgard Blücher. São Paulo, 2006.

NIST, **An introduction to frequency calibration, NIST frequency measurement and analysis system: operator's manual - Appendix A**. 2006.

PACHECO, A. L. S. **Desenvolvimento de sistema para medir a resistência de enrolamento em motores de compressores energizados**. Dissertação de Mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 2007.

PASSINO, K. M.; YURKOVICH, S. **Fuzzy control**. Addison Wesley Longman, Inc. California, 1998.

PEARL, J. **Probabilistic reasoning in intelligent system: networks of plausible inference**. Morgan Kaufmann. Califórnia, 1988.

PENZ, C. A. **Procedimentos para garantia da confiabilidade na aplicação de redes neurais artificiais em ensaios de desempenho de compressores herméticos**. Documento de Qualificação de Doutorado em Engenharia Mecânica. Curso de Pós-graduação em Engenharia Mecânica, UFSC. Florianópolis, 2008.

PETROVIC, S. A. B. **Proposta de arquitetura do sistema de automação aplicado a ensaios de desempenho de compressores herméticos de refrigeração**. Dissertação de Mestrado. Curso de Pós-Graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 2007.

POLETTO, E. L. **Aprimoramento de uma bancada de ensaios de desempenho de compressores herméticos visando reduzir incertezas de medição**. Dissertação de Mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 2006.

PASSINO, K. M.; YURKOCICH, S. **Fuzzy control**. Addison Wesley Longman, Inc. Califórnia, 1998.

RABUSKE, R. A. **Inteligência artificial**. UFSC. Florianópolis, 1995.

RICH, E.; KNIGHT, K. **Inteligência artificial**. 2 ed. McGraw-Hill. São Paulo, 1993.

ROSS, T. J. **Fuzzy logic with engineering applications**. McGraw-Hill Inc. New York, 1995.

RUSSELL, S. J.; NORVIG, P. **Inteligência artificial: tradução da segunda edição**. Campus. Rio de Janeiro, 2004.

SANDRI, S.; CORREA, C. **Lógica nebulosa**. Escola de Redes Neurais. Anais da V Escola de Redes Neurais, São José dos Campos, 1999.

SCHALKOFF, R. J. **Artificial intelligence: an engineering approach**. McGraw-Hill. New York, 1990.

SCUSSEL, J. N. **Propostas de ações para reduzir o tempo demandado por ensaio de desempenho de compressores herméticos**. Dissertação de Mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis: 2006.

SHAW, Ian S.; Simões, M. G. **Controle e modelagem fuzzy**. Editora Edgard Blücher Ltda. São Paulo, 1999.

SOUSA, C. P. **Um texto introdutório a lógica nebulosa**. Disponível em: <<http://www.deti.ufc.br/~pimentel/>>. Acesso em fevereiro 2008

STEINBACH, K. **Identificação do instante de entrada em condição de regime permanente em ensaio de desempenho de compressores.** Dissertação de Mestrado. Curso de Pós-graduação em Metrologia Científica e Industrial, UFSC. Florianópolis, 2008.

ISO 917: **Testing of refrigerant compressors.** 2 ed. Genève (Switzerland), 1989.

STOECKER, W. F.; JABARDO J. M. S. **Refrigeração industrial.** 2ª ed. Edgard Blücher Ltda, São Paulo, 2002.

TESSARI, G. **Raciocínio probabilístico em sistemas especialistas.** Departamento de Informática e Estatística, UFSC. Florianópolis, 1998.

TIBIRIÇÁ, C. A. G. **Uma abordagem híbrida fuzzy-bayesiana para a modelagem de incertezas.** Dissertação de Mestrado. Curso de Pós-graduação em Ciência da Computação, UFSC. Florianópolis, 2005.

ZADEH, L. A. Fuzzy Sets. **Information and control.** Vol.8 p.338-353, 1965.

## APÊNDICE A – Conceitos de probabilidade

Probabilidade pode ser entendida como a medida de crença que um observador possui na ocorrência de um evento. A probabilidade estatística se baseia no valor do qual se aproxima à frequência relativa de ocorrências desse evento em um grande número de repetições. (RUSSELL, 2004).

Nos sistemas especialistas probabilísticos, os valores de probabilidade refletem a crença do especialista sobre o que ele espera que ocorra em situações similares àquelas que têm aprendido ao longo de sua vivência. Isto é, o especialista está tentando extrapolar com base em sua experiência e aprendizado no domínio de aplicação (NASSAR, 2007).

### A.1 Espaço amostral e eventos

O conjunto de todos os possíveis resultados de um experimento é chamado de *espaço amostral* e é denotado por  $S$ . O espaço amostral é usualmente definido com base nos objetivos da análise (MONTGOMERY, 2003).

Por exemplo, jogam-se dois dados, um branco e outro preto, o espaço amostral correspondente está representado por  $S_1$ , onde o primeiro número de cada par indica o número do dado branco e o segundo indica o número do dado preto.

$$S_1 = \left\{ \begin{array}{l} (1,1)(2,1)(3,1)(4,1)(5,1)(6,1) \\ (1,2)(2,2)(3,2)(4,2)(5,2)(6,2) \\ (1,3)(2,3)(3,3)(4,3)(5,3)(6,3) \\ (1,4)(2,4)(3,4)(4,4)(5,4)(6,4) \\ (1,5)(2,5)(3,5)(4,5)(5,5)(6,5) \\ (1,6)(2,6)(3,6)(4,6)(5,6)(6,6) \end{array} \right\}$$

Evento é um subconjunto de um espaço amostral e define um resultado bem determinado. Podem ser simples ou compostos, conforme se constituam de um ou mais resultados de  $S$  (COSTA NETO, 2006).

Dentre os eventos possíveis, devem ser considerados o próprio  $S$  (evento certo) e o conjunto vazio  $\emptyset$  (evento impossível) (COSTA NETO, 2006).

Por exemplo, sejam os eventos em  $S_1$  (COSTA NETO, 2006):

$E$  = dar 1 nos dois dados;

$F$  = soma dos números igual a quatro;

$G$  = soma dos pontos menor ou igual a cinco;

$H$  = dar dois no dado branco.

Teremos:

$E = \{ (1, 1) \}$ ;

$F = \{ (1, 3), (2, 2), (3, 1) \}$ ; etc...

O evento  $E$  é simples, enquanto que os eventos  $F$ ,  $G$  e  $H$  são compostos.

Para um espaço amostral discreto, a probabilidade de um evento  $E$ , denotado por  $P(A)$ , é igual à soma das probabilidades dos resultados em  $E$ , ou seja (MONTGOMERY, 2003):

$$P(A) = \sum_{E \in A} (E) \quad (27)$$

A soma das probabilidades de todos os eventos do universo de discurso é igual a 1:

$$\sum_{i=1}^n P(E_i) = 1 \quad (28)$$

Diz-se que um evento ocorre quando um dos resultados que o compõem ocorre (BARBETTA, 2004). Com base no exemplo anterior, se o dado branco ficar com 1 e o dado preto com 3, então ocorrem os eventos  $F$  e  $G$ , mas não ocorrem os eventos  $E$  e  $H$ .

Como um evento é um subconjunto do espaço amostral, então todos os conceitos da teoria de conjuntos podem ser aplicados a eventos (BARBETTA, 2004).

As principais operações entre dois conjuntos quaisquer  $A$  e  $B$  são:

- União:  $A \cup B$ . Reúne os elementos de ambos os conjuntos – ocorre quando ocorrer pelo menos um deles.
- Interseção:  $A \cap B$ . Formado somente pelos elementos que estão em  $A$  e  $B$  – ocorre quando ocorrer ambos eventos.
- Complementar:  $\neg A$ . Formado pelos elementos que não estão em  $A$  – ocorre quando não ocorrer o evento  $A$ .

## A.2 Conectivos E e OU

Considerando dois eventos  $A$  e  $B$  e adotando a terminologia  $\wedge$  e  $\vee$  para os conectivos **e** e **ou**, respectivamente (NASSAR, 2007), então:

$P(A \wedge B)$  significa a probabilidade de que ambos os eventos ocorram. Ou seja, é a probabilidade do evento  $A$  ocorrer e do evento  $B$  ocorrer.

$P(A \vee B)$  significa a probabilidade de que pelo menos um dos eventos ocorra. Ou seja, é a probabilidade do evento  $A$  ocorrer ou do evento  $B$  ocorrer.

## A.3 Eventos disjuntos

Denotando por  $\cup$  e  $\cap$  a união e a interseção de conjuntos, respectivamente, então:

$$A \cup B = \{ E: E \in A \text{ ou } E \in B \}$$

$$A \cap B = \{ E: E \in A \text{ e } E \in B \}$$

Se  $A \cap B = \emptyset$  então  $A$  e  $B$  são ditos eventos disjuntos ou mutuamente excludentes (COSTA NETO, 2006), neste caso  $P(A \wedge B) = 0$ .

## A.4 Axiomas e propriedades de probabilidade

Segundo a definição clássica, a probabilidade obedece a três axiomas (NETO, 2006):

- a)  $P(S) = 1$ ;
- b)  $0 \leq P(A) \leq 1$ ;
- c)  $P(A \vee B) = P(A) + P(B)$  se  $A$  e  $B$  forem eventos disjuntos;

Desses axiomas, diversas outras propriedades podem ser deduzidas como teoremas, tais como:

- d) Se  $A \subseteq B \subseteq S$  então  $0 \leq P(A) \leq P(B) \leq 1$ ;
- e) Se  $A, B \subseteq S$  então  $P(A \wedge B) + P(A \wedge \neg B) = P(A)$  e  $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$ ;
- f)  $P(\neg A) = 1 - P(A)$ ;
- g) Se  $A_i \subseteq S$  para  $1 \leq i \leq n$  e  $A_i \cap A_j = \emptyset$  então para todo  $i \neq j$ :

$$P(A_1 \vee A_2 \vee \dots \vee A_n) = P(A_1) + P(A_2) + \dots + P(A_n).$$

## A.5 Probabilidade incondicional

A probabilidade incondicional, denotada por  $P(A)$  é a probabilidade de uma proposição  $A$  ser verdadeira, desde que não seja fornecida nenhuma evidência.

Proposições podem também incluir igualdades envolvendo variáveis aleatórias. Por exemplo, caso haja interesse em uma variável aleatória, *tempo*, pode-se considerar:

a.  $P(\text{tempo} = \text{ensolarado}) = 0.7$

b.  $P(\text{tempo} = \text{chuvoso}) = 0.2$

c.  $P(\text{tempo} = \text{nublado}) = 0.1$

As proposições podem assumir também o domínio booleano (*verdadeiro ou falso*). Nesse caso, a expressão  $P(A)$  pode ser vista como  $P(A = \text{verdadeiro})$  e, analogamente,  $P(\neg A) = P(A = \text{falso})$ .

## A.6 Probabilidade condicional

Nossa estimativa da probabilidade de um evento é freqüentemente atualizada com o resultado de uma informação adicional (MONTGOMERY, 2003). Denota-se por  $P(A | B)$  à probabilidade do evento  $A$  ocorrer sabendo que  $B$  ocorreu; ou simplesmente: probabilidade de  $A$  condicionada a  $B$  (NETO, 2006).

É importante ressaltar que  $P(A | B)$  pode ser utilizado apenas quando toda informação disponível é  $B$ . Sendo que outra variável,  $C$ , conhecida, deve-se reconsiderar para  $P(A | B \wedge C)$ . A probabilidade incondicional  $P(A)$  pode ser vista como um caso especial da probabilidade condicional  $P(A | \cdot)$ , onde a probabilidade é condicionada a nenhuma evidência (RUSSELL, 2004).

## A.7 Propriedade da probabilidade condicional

Seja um espaço de probabilidade  $S$ . Se  $C \subseteq S$  então  $P(C) \neq 0$ . Segue-se que (NASSAR, 2007):

1.  $P(A|C) = P(A \wedge C) / P(C)$  ;

2. Se  $A \subseteq B \subseteq S$  então  $0 \leq P(A|C) \leq P(B|C) \leq 1$ ;

3. Se  $A, B \subseteq S$  então  $P(A|C) = P(A \cap B | C) + P(A \cap \neg B | C)$  e  $P(A \cup B | C) = P(A|C) + P(B|C) - P(A \cap B | C)$ ;

4. Se  $A_i \subseteq S$  para  $1 \leq i \leq n$  e  $A_i \cap A_j = \emptyset$  então para todo  $i \neq j$ ;

$$P(A_1 \cup A_2 \cup \dots \cup A_n | C) = P(A_1 | C) + P(A_2 | C) + \dots + P(A_n | C);$$

5. Se  $A \subseteq S$ ,  $B_1 \cup B_2 \cup \dots \cup B_n$  para  $1 \leq i \leq n$  e  $B_i \cap B_j = \emptyset$  para todo  $i \neq j$  então

$$P(A) = P(A|B_1) \cdot P(B_1) + P(A|B_2) \cdot P(B_2) + \dots + P(A|B_n) \cdot P(B_n).$$

## A.8 Independência de eventos

Dois ou mais eventos são independentes quando a ocorrência de um dos eventos não influencia a probabilidade da ocorrência dos outros (BARBETTA, 2004). Ou seja: dados os eventos  $E_1, E_2, \dots, E_n$ , eles serão independentes se e somente, para qualquer subconjunto  $E_{i_1}, E_{i_2}, \dots, E_{i_k}$   $P(E_{i_1} \cap E_{i_2} \cap \dots \cap E_{i_k}) = P(E_{i_1}) \cdot P(E_{i_2}) \cdot \dots \cdot P(E_{i_k})$ .

A idéia básica subjacente ao conceito probabilístico de independência entre dois eventos é que o conhecimento de certa informação sobre um evento não traz informação adicional sobre o outro. Isto é, se e somente se, saber que o evento  $E_1$  ocorreu não trazer informação sobre o evento  $E_2$  e saber que o evento  $E_2$  ocorreu também não trazer informação sobre o evento  $E_1$  (NASSAR, 2007).

## APÊNDICE B – Exemplo de abordagem *fuzzy*

Exemplo extraído do manual do usuário do programa MATLAB – *Fuzzy Logic Toolbox* (JANG, 1997). É proposto um problema em relação ao valor da gorjeta a ser pago num restaurante, a partir de dados sobre a qualidade da comida e do atendimento, para caracterizar uma abordagem *fuzzy*.

Têm-se então as seguintes variáveis: QUALIDADE\_DA\_COMIDA e ATENDIMENTO. E as regras:

- R1: SE ATENDIMENTO é ruim ou QUALIDADE\_DA\_COMIDA é ruim ENTÃO GORJETA é baixa;
- R2: SE ATENDIMENTO é bom ENTÃO GORJETA é média;
- R3: SE ATENDIMENTO é excelente ou QUALIDADE\_DA\_COMIDA é excelente ENTÃO GORJETA é alta;

A partir das regras são criadas funções de pertinência das variáveis ATENDIMENTO e QUALIDADE\_DA\_COMIDA. Essas funções de pertinências estão mostradas na figura 44.

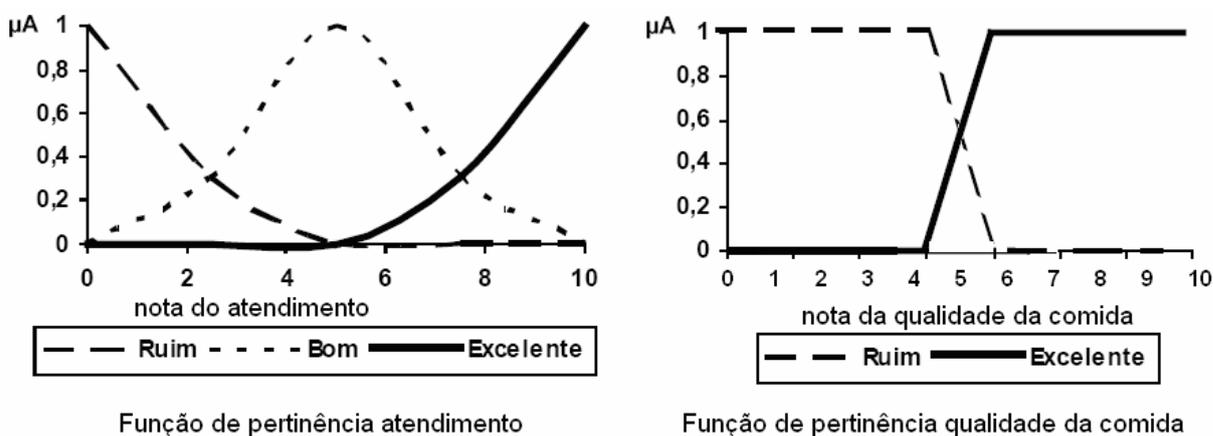


Figura 44 – Funções de pertinência para Atendimento e Qualidade da Comida.

E as funções de pertinência dos termos lingüísticos baixa, média e alta da variável GORJETA, são mostradas na figura 45.

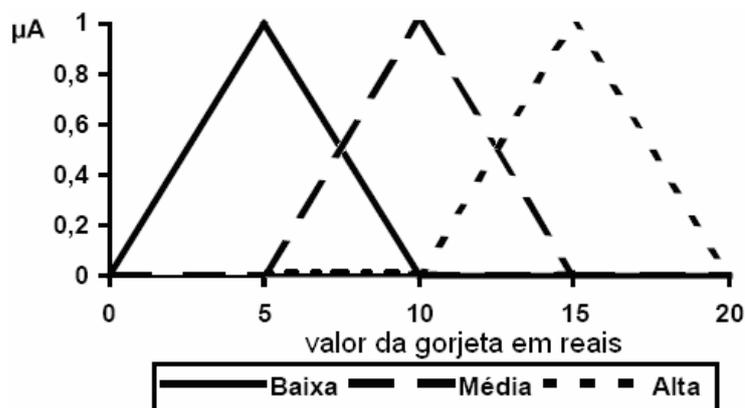


Figura 45 – Função de pertinência para GORJETA.

A figura 46 apresenta um exemplo de fuzzyficação da qualidade do atendimento do garçom. Mostra o conjunto “atendimento excelente”.

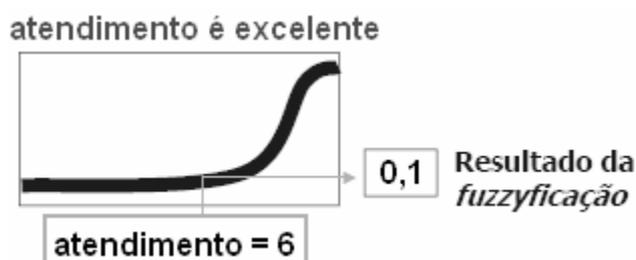


Figura 46 – Exemplo de fuzzyficação.

A figura 47 mostra um exemplo de implicação do atendimento do garçom e qualidade da comida no valor da gorjeta. Neste caso se o atendimento do garçom foi excelente ou se a comida for deliciosa então a gorjeta dada ao garçom será generosa, a função *fuzzy* usada é  $\max[\mu(\text{atendimento}), \mu(\text{qualidade da comida})]$ .



Figura 47 – Exemplo de aplicação do operador de implicação.

As regras R1, R2 e R3 são então selecionadas. Tomando-se como exemplo, os valores *crisp* de 6 para ATENDIMENTO e 8 para QUALIDADE\_DA\_COMIDA, inicia-se o processo de avaliação dos antecedentes das regras para definição do valor da variável GORJETA. Antes de ativar as regras, os valores *crisp* devem ser fuzzyficados.

Neste exemplo os valores resultantes da fuzzyficação são os denominados abaixo:

R1: ATENDIMENTO é ruim ou QUALIDADE\_DA\_COMIDA é ruim:

$\mu_{\text{ATENDIMENTO\_RUI}}(6) = 0,1$  e  $\mu_{\text{QUALIDADE\_DA\_COMIDA\_RUI}}(8) = 0,8$ , então:

$$\max[0,1 \text{ e } 0,0] = 0,1$$

R2: ATENDIMENTO é bom:

$\mu_{\text{ATENDIMENTO\_BOM}}(6) = 0,8$

R3: ATENDIMENTO é excelente ou QUALIDADE\_DA\_COMIDA é excelente:

$\mu_{\text{ATENDIMENTO\_EXCELENTE}}(6) = 0,1$  e  $\mu_{\text{QUALIDADE\_DA\_COMIDA\_EXCELENTE}}(8) = 0,6$ , então:

$$\max[0,1 \text{ e } 0,6] = 0,6$$

A figura 48 apresenta a agregação de todas as saídas deste exemplo. Todas as saídas são combinadas em um único conjunto *fuzzy* onde as entradas são as funções retornadas pela implicação e a saída é um conjunto *fuzzy* para cada variável de saída.

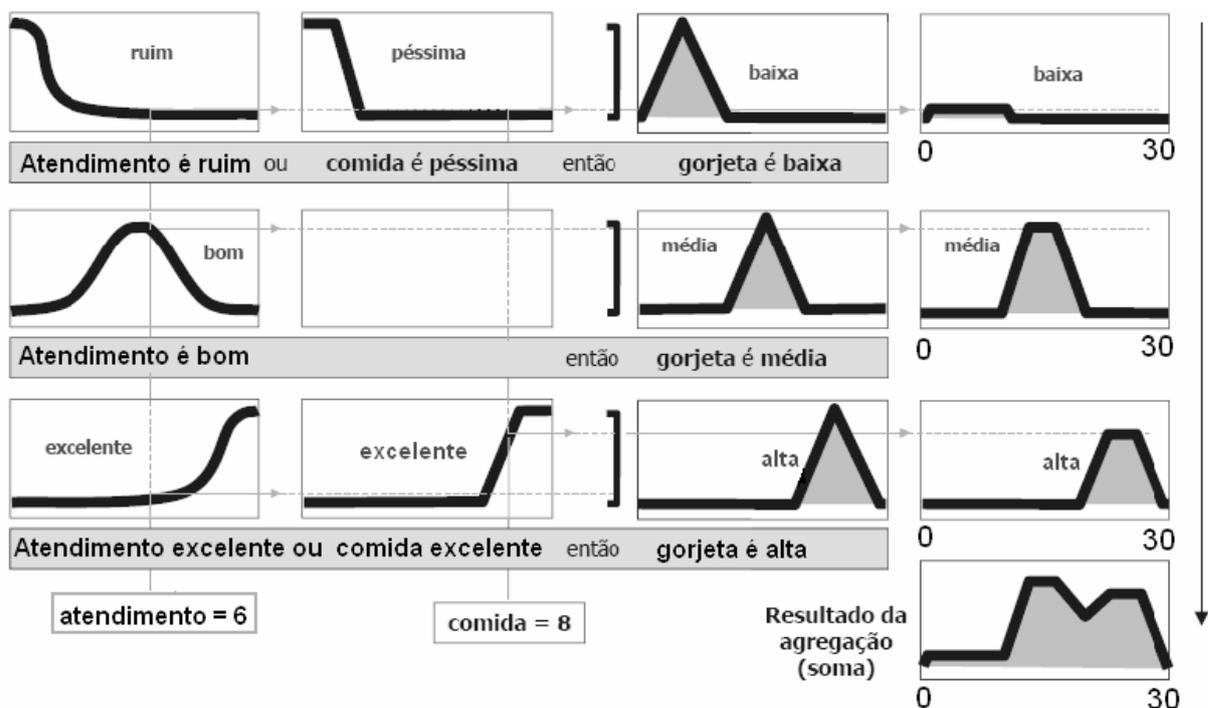


Figura 48 – Agregação de todas as saídas.

Uma vez obtido o conjunto *fuzzy* de saída, figura 49, por meio do processo de inferência, no estágio de desfuzzyficação é efetuada uma interpretação dessa informação.

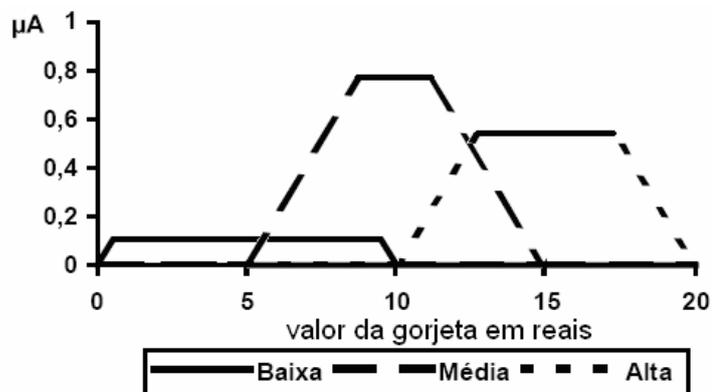


Figura 49 – Conjunto difuso resultante.

Este conjunto deve passar, então, pelo processo de desfuzzyficação para apresentar o valor resultante da GORJETA. Utilizando-se o método do centro das áreas se encontrará um valor próximo a R\$ 11,50.

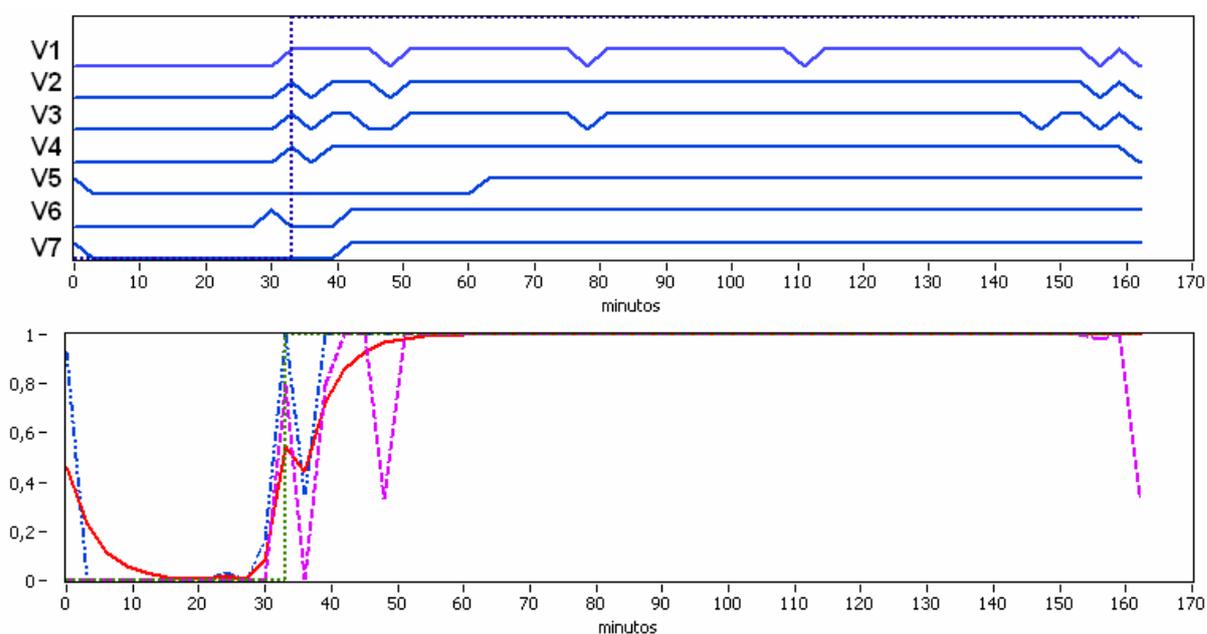
$$GORJETA = \frac{0,1 \cdot 5 + 0,8 \cdot 10 + 0,6 \cdot 15}{0,1 + 0,8 + 0,6} = 11,66$$

## APÊNDICE C – Resultados das redes bayesiana e híbrida

Os gráficos a seguir mostram as seguintes informações para os ensaios individuais:

- estado das variáveis (estável – alto, ou instável – baixo);
- tempo de entrada em regime permanência real (tempo de estabilização);
- estimativas das redes bayesiana e híbrida.

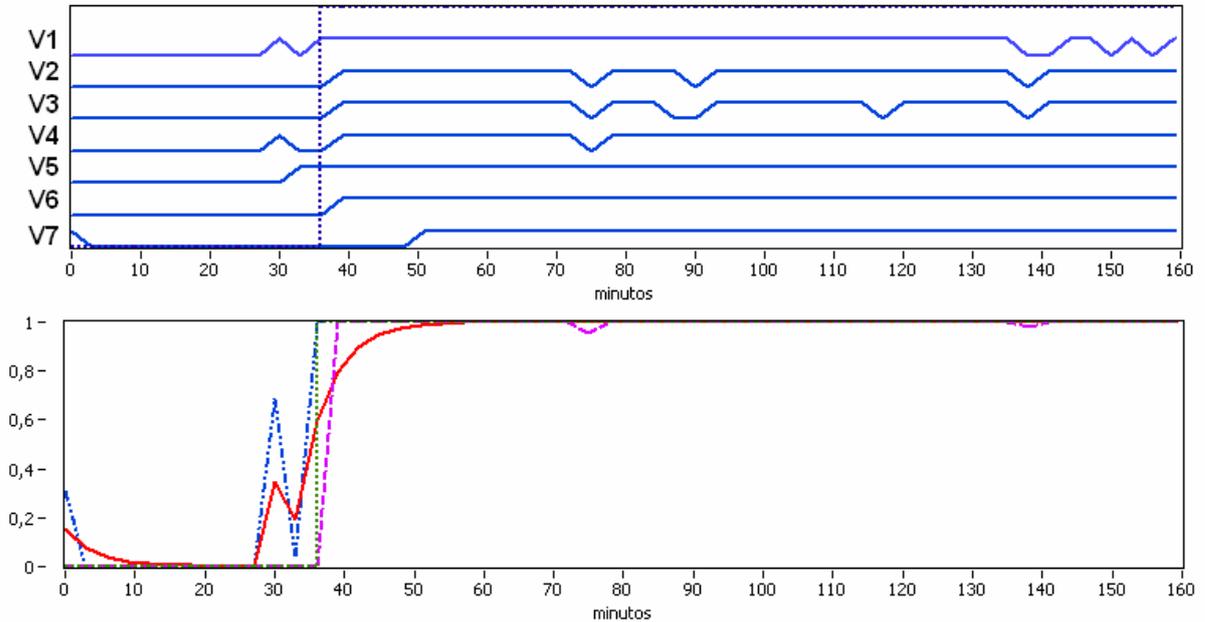
Ensaio 1:



Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

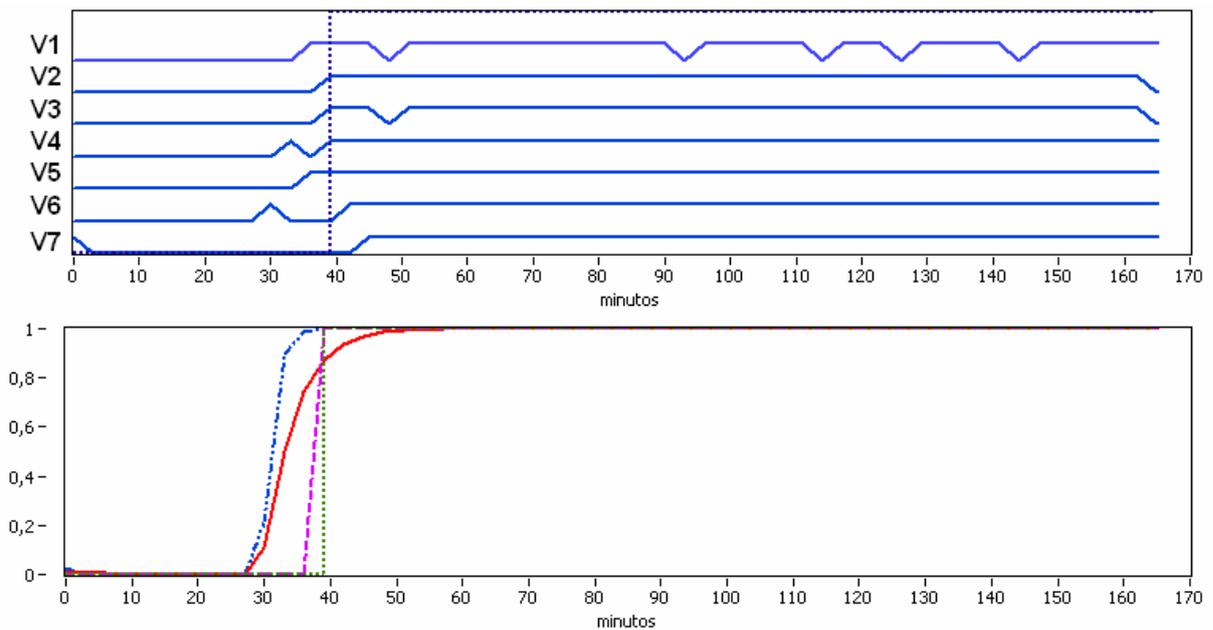
Ensaio 2:



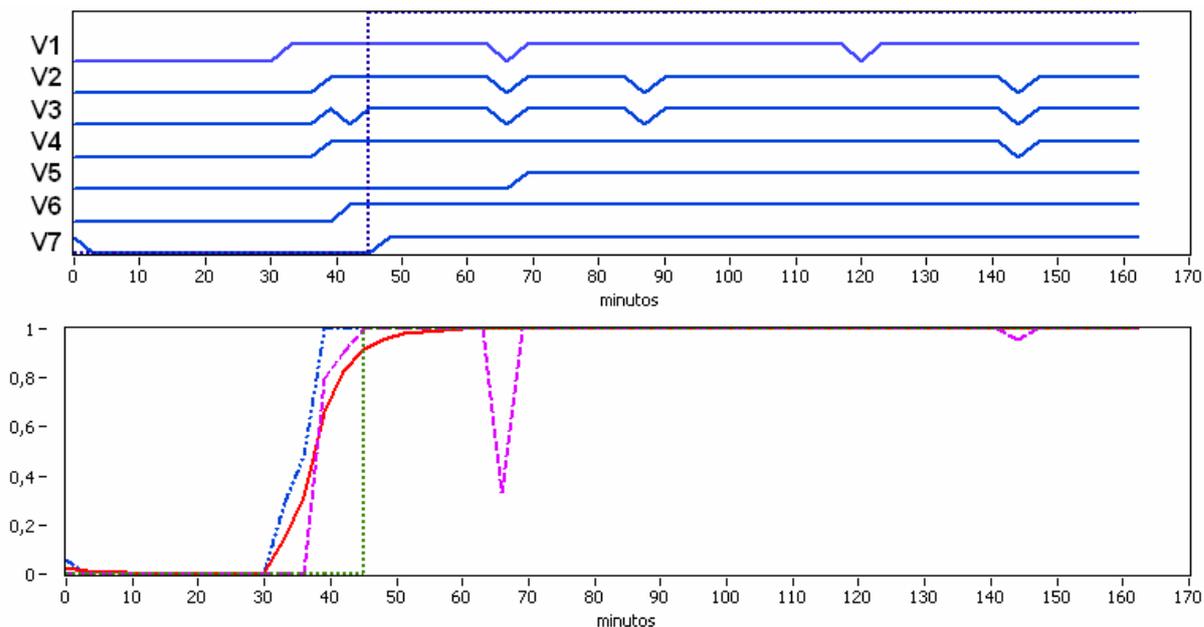
Legenda:

- ⋯ entrada em regime permanente
- rede bayesiana
- - - rede fuzzy-bayesiana
- rede fuzzy-bayesiana com média
- V1 – temperatura Corpo
- V2 – temperatura saída do trocador
- V3 – temperatura Superficial Calorímetro
- V4 – tensão DC calorímetro (placa de aquisição)
- V5 – corrente DC calorímetro (placa de aquisição)
- V6 – potência DC calorímetro (placa de aquisição)
- V7 – capacidade via Fluxo de Massa

Ensaio 3:



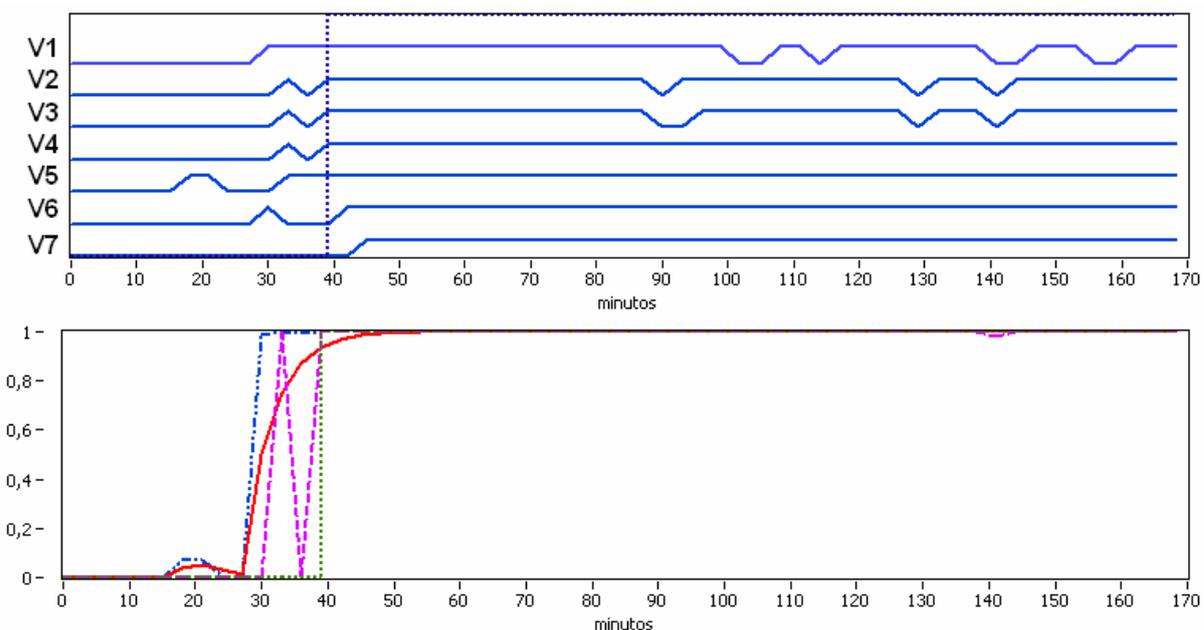
## Ensaio 4:



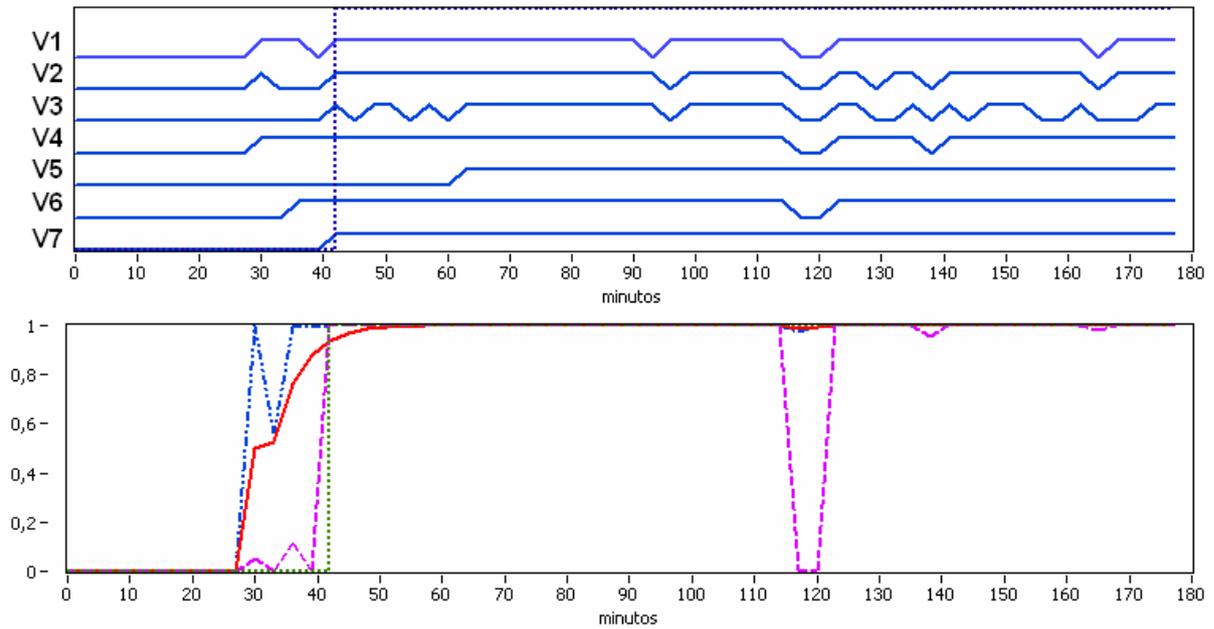
## Legenda:

- |  |                                |   |
|--|--------------------------------|---|
|  | entrada em regime permanente   | V1 – temperatura Corpo                            |
|  | rede bayesiana                 | V2 – temperatura saída do trocador                |
|  | rede fuzzy-bayesiana           | V3 – temperatura Superficial Calorímetro          |
|  | rede fuzzy-bayesiana com média | V4 – tensão DC calorímetro (placa de aquisição)   |
|  |                                | V5 – corrente DC calorímetro (placa de aquisição) |
|  |                                | V6 – potência DC calorímetro (placa de aquisição) |
|  |                                | V7 – capacidade via Fluxo de Massa                |

## Ensaio 5:



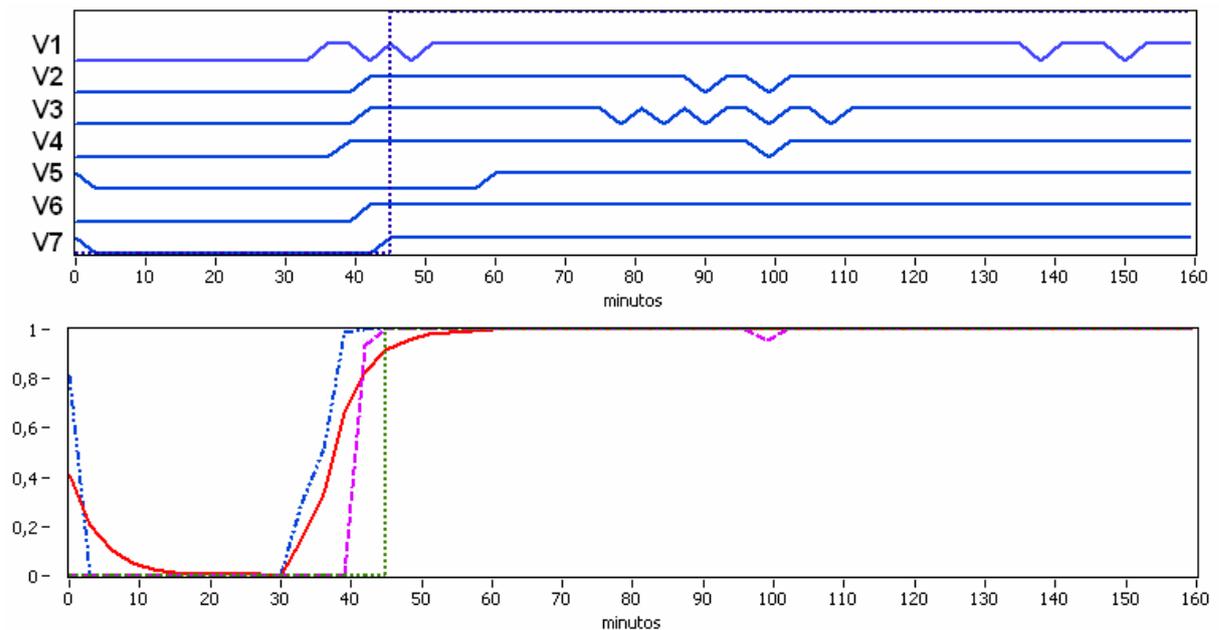
Ensaio 6:



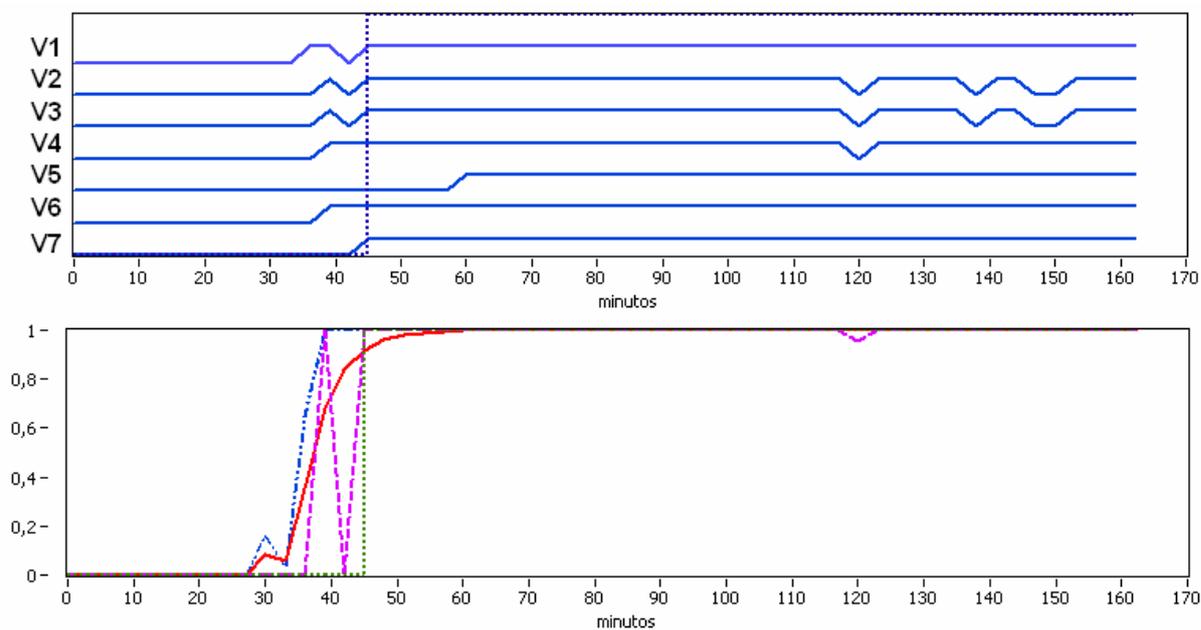
Legenda:

- |  |                                |   |
|--|--------------------------------|---|
|  | entrada em regime permanente   | V1 – temperatura Corpo                            |
|  | rede bayesiana                 | V2 – temperatura saída do trocador                |
|  | rede fuzzy-bayesiana           | V3 – temperatura Superficial Calorímetro          |
|  | rede fuzzy-bayesiana com média | V4 – tensão DC calorímetro (placa de aquisição)   |
|  |                                | V5 – corrente DC calorímetro (placa de aquisição) |
|  |                                | V6 – potência DC calorímetro (placa de aquisição) |
|  |                                | V7 – capacidade via Fluxo de Massa                |

Ensaio 7:



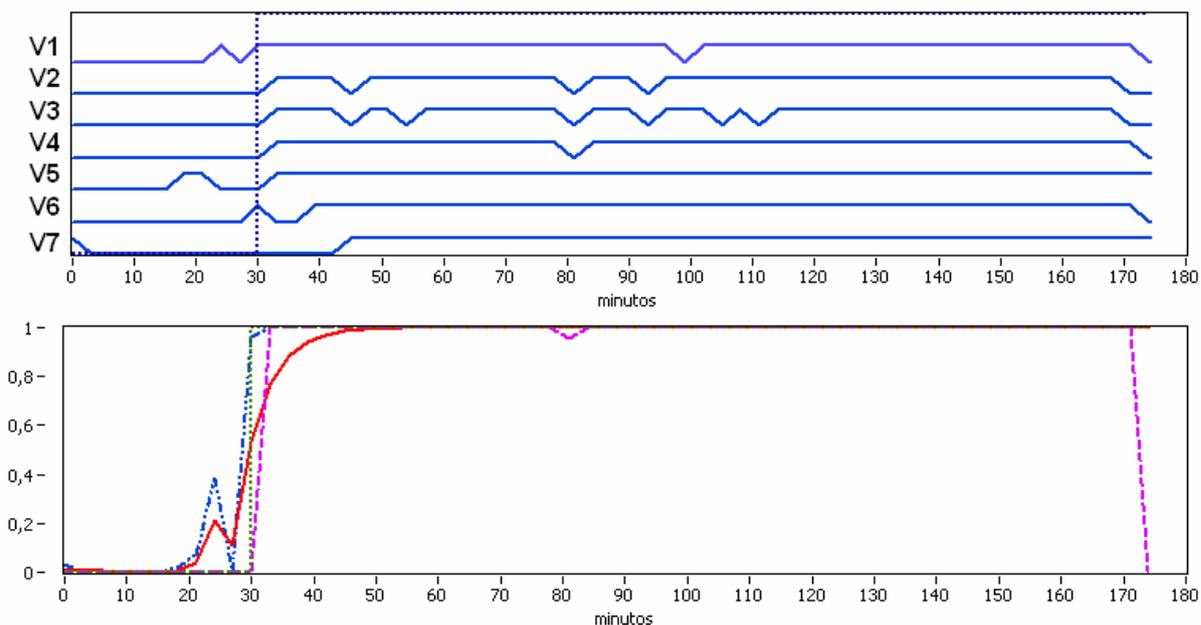
## Ensaio 8:



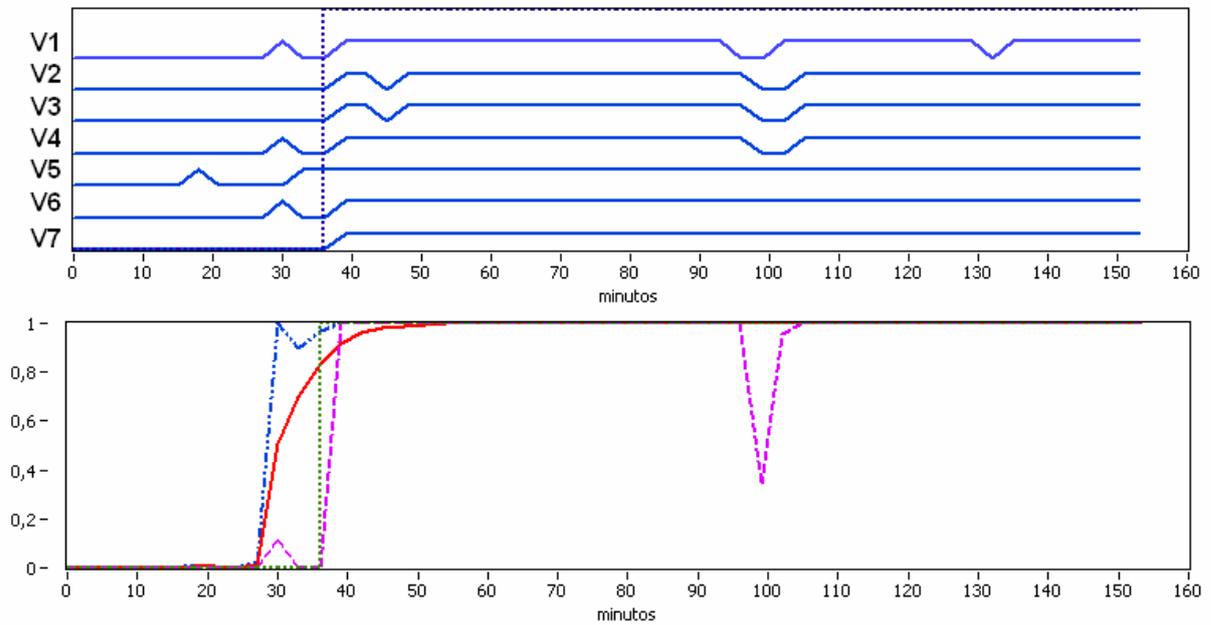
## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## Ensaio 9:



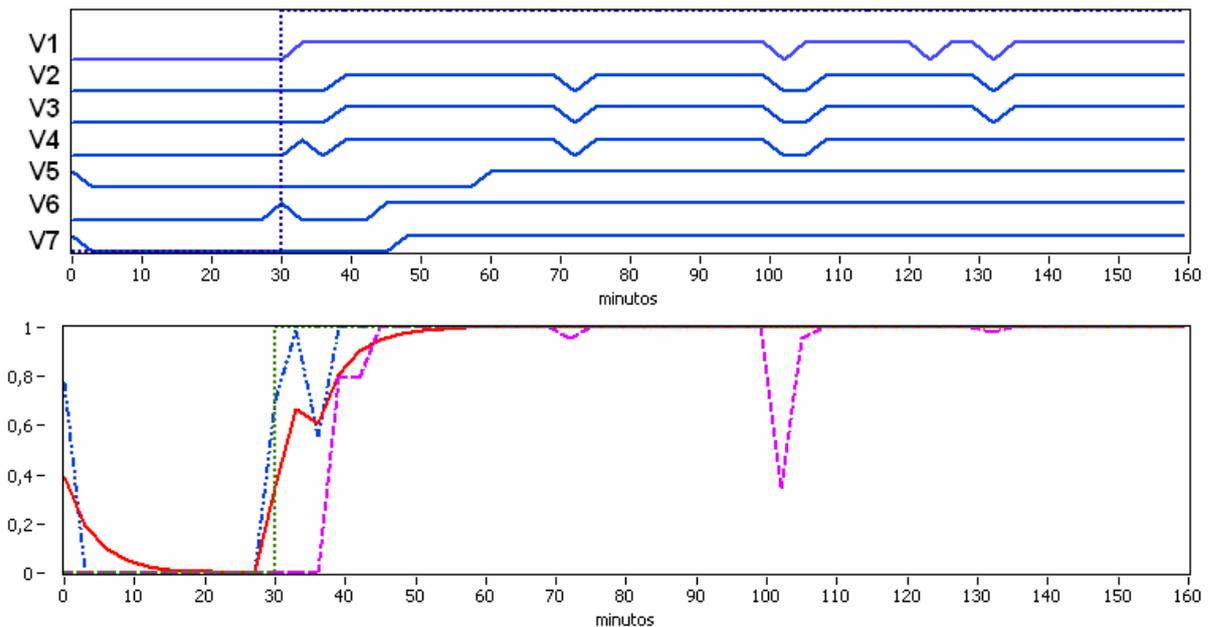
Ensaio 10:



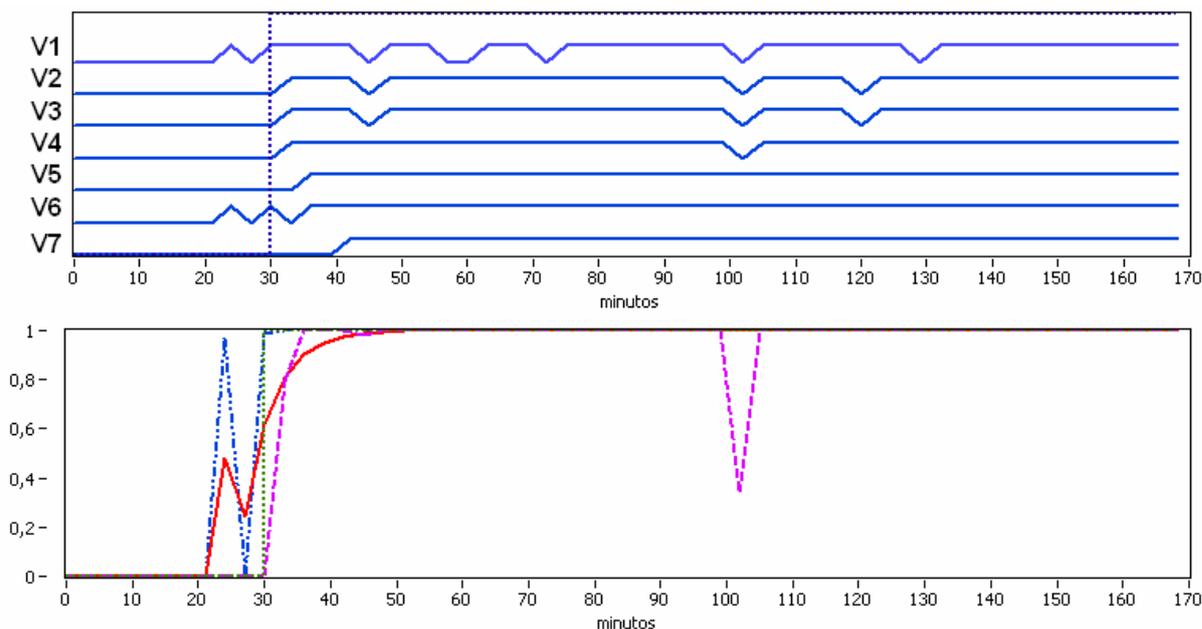
Legenda:

- |  |                                |   |
|--|--------------------------------|---|
|  | entrada em regime permanente   | V1 – temperatura Corpo                            |
|  | rede bayesiana                 | V2 – temperatura saída do trocador                |
|  | rede fuzzy-bayesiana           | V3 – temperatura Superficial Calorímetro          |
|  | rede fuzzy-bayesiana com média | V4 – tensão DC calorímetro (placa de aquisição)   |
|  |                                | V5 – corrente DC calorímetro (placa de aquisição) |
|  |                                | V6 – potência DC calorímetro (placa de aquisição) |
|  |                                | V7 – capacidade via Fluxo de Massa                |

Ensaio 11:



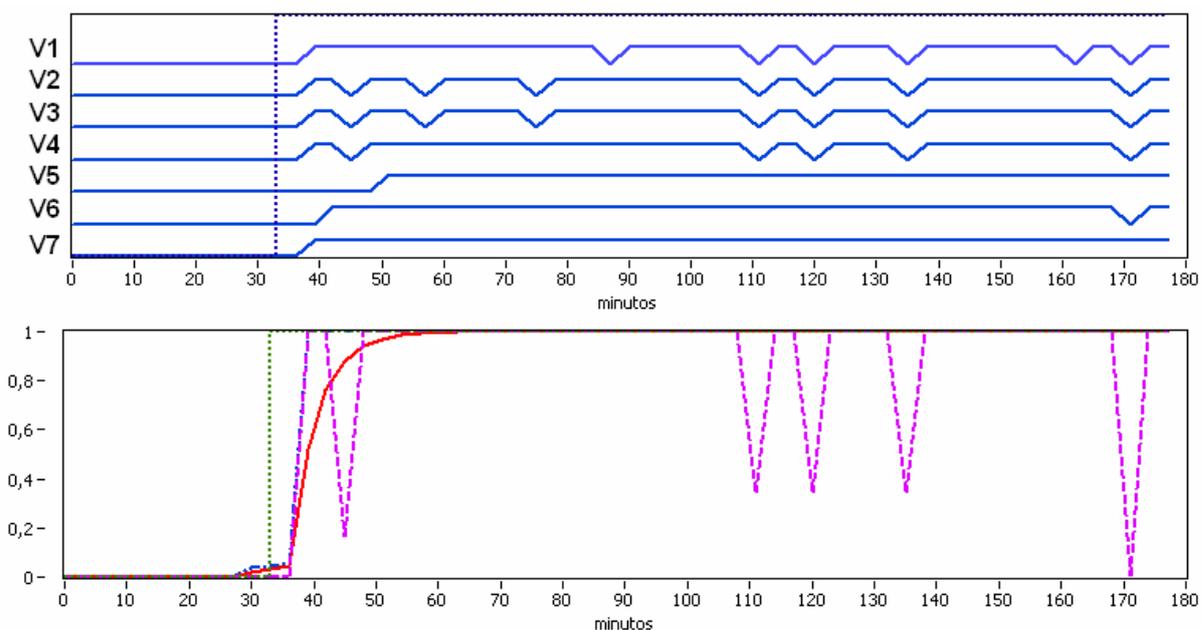
## Ensaio 12:



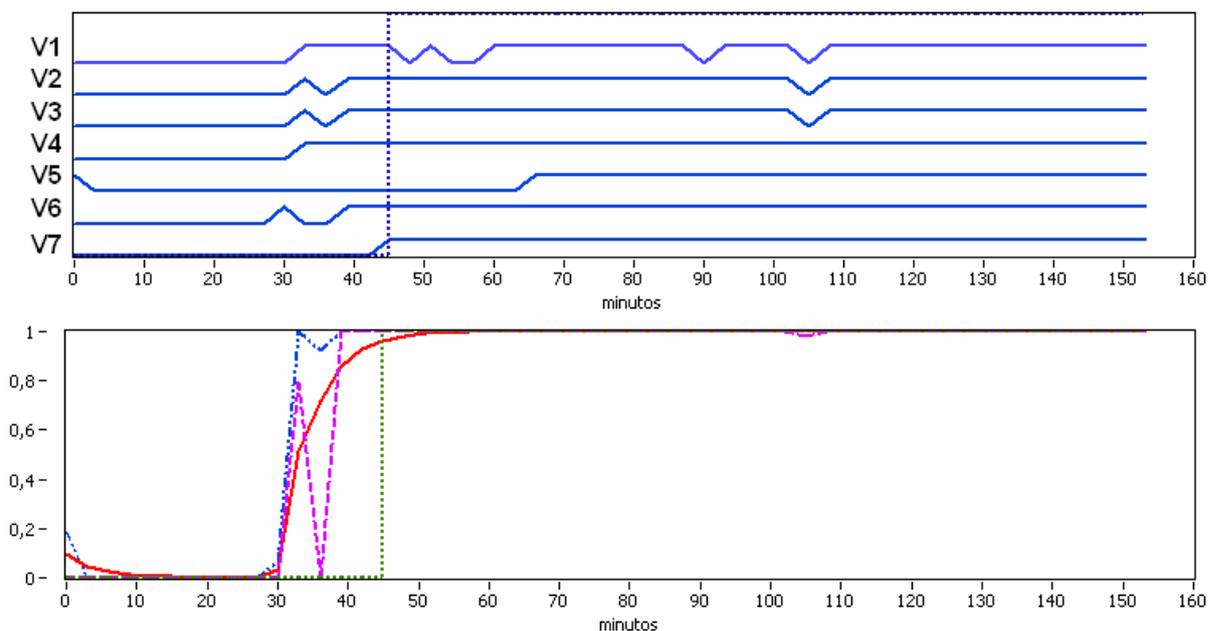
## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## Ensaio 13:



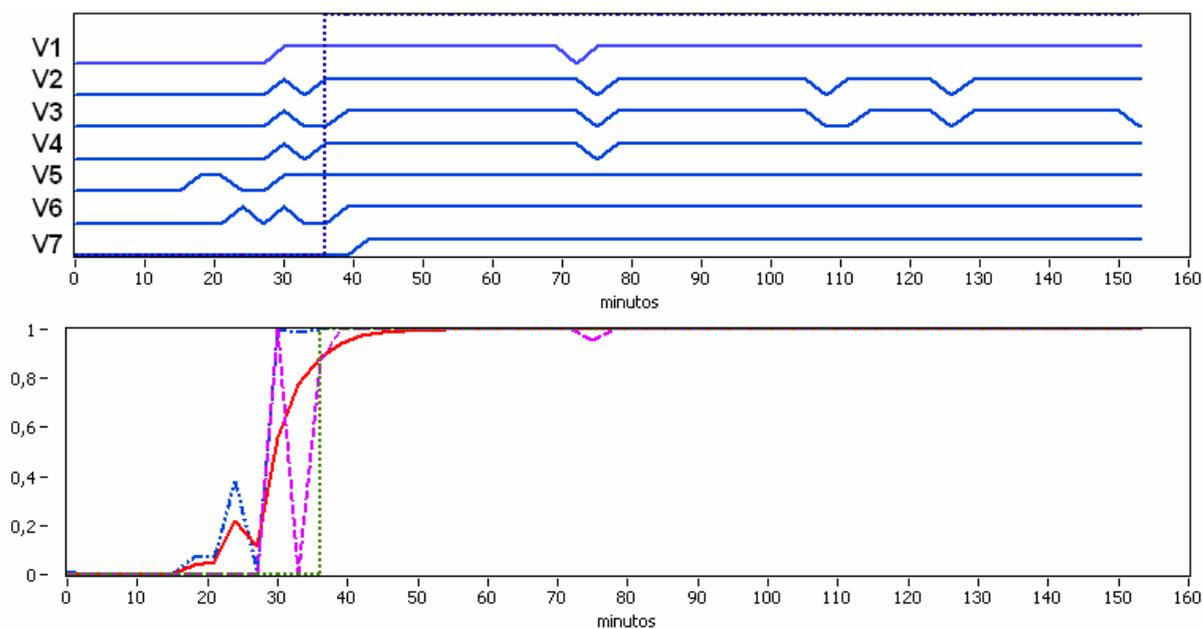
## Ensaio 14:



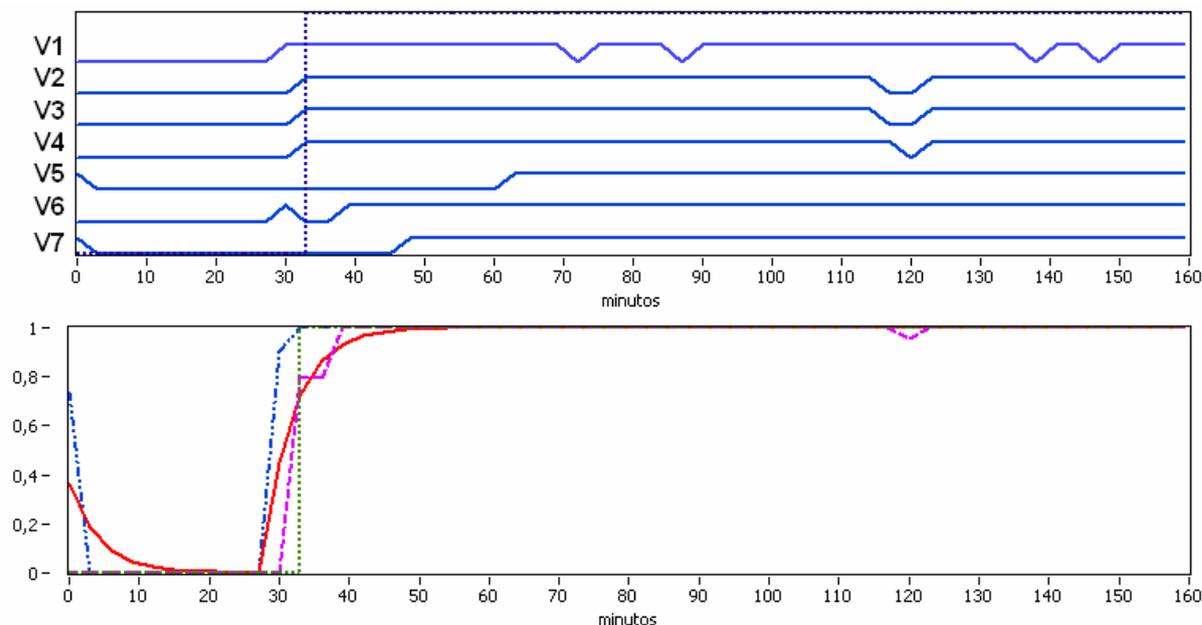
## Legenda:

- |   |                                |   |
|---|--------------------------------|---|
|   | entrada em regime permanente   | V1 – temperatura Corpo                            |
|  | rede bayesiana                 | V2 – temperatura saída do trocador                |
|  | rede fuzzy-bayesiana           | V3 – temperatura Superficial Calorímetro          |
|  | rede fuzzy-bayesiana com média | V4 – tensão DC calorímetro (placa de aquisição)   |
|   |                                | V5 – corrente DC calorímetro (placa de aquisição) |
|   |                                | V6 – potência DC calorímetro (placa de aquisição) |
|   |                                | V7 – capacidade via Fluxo de Massa                |

## Ensaio 15:



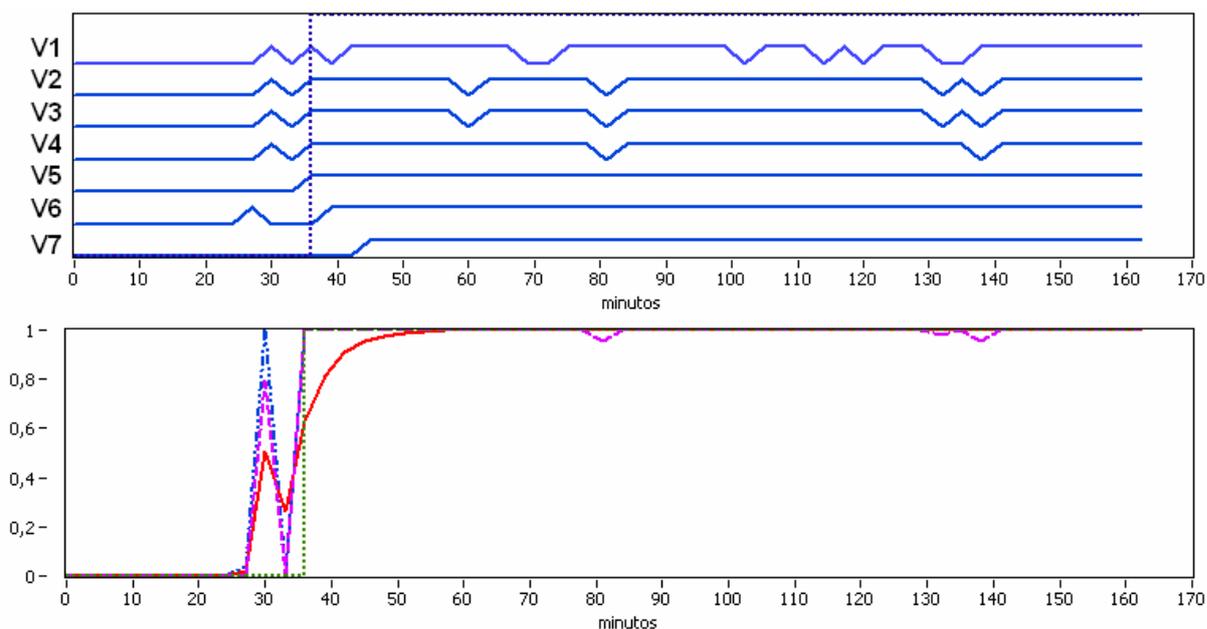
## Ensaio 16:



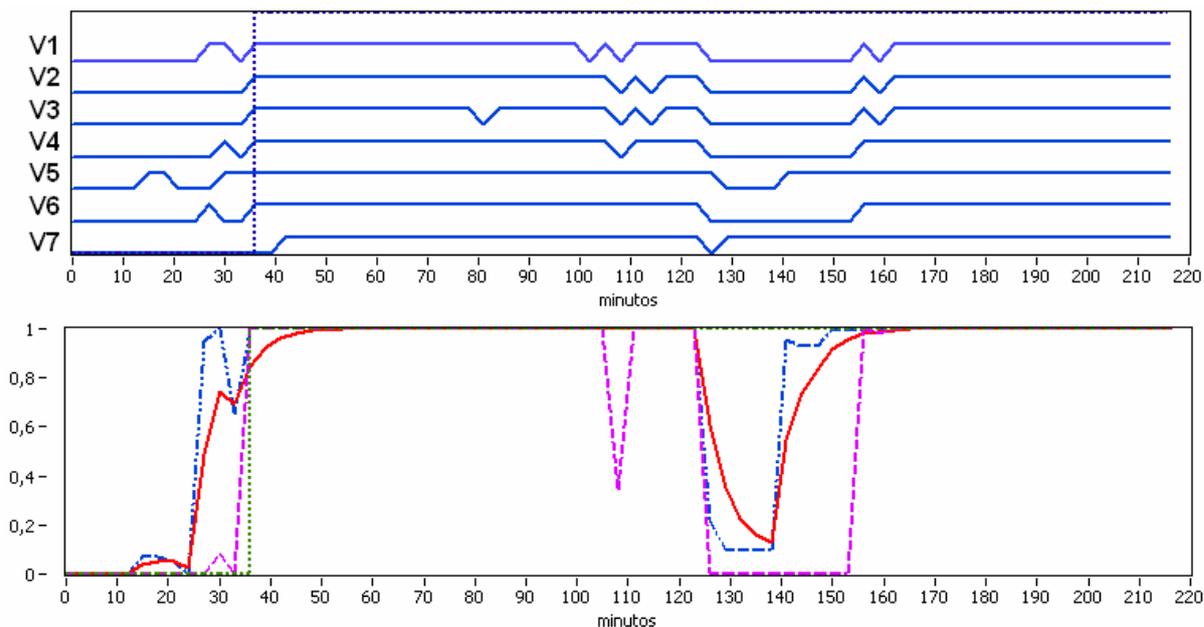
## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## Ensaio 17:



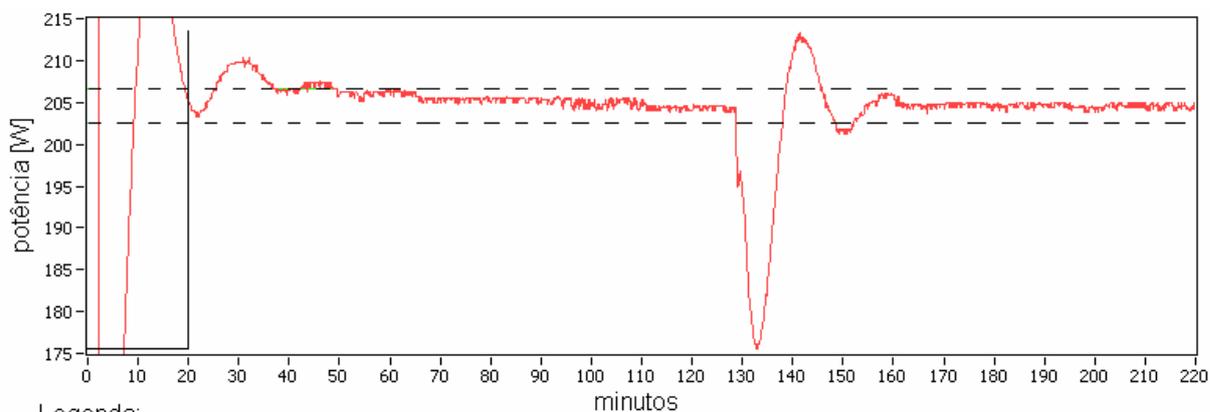
## Ensaio 18:



## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

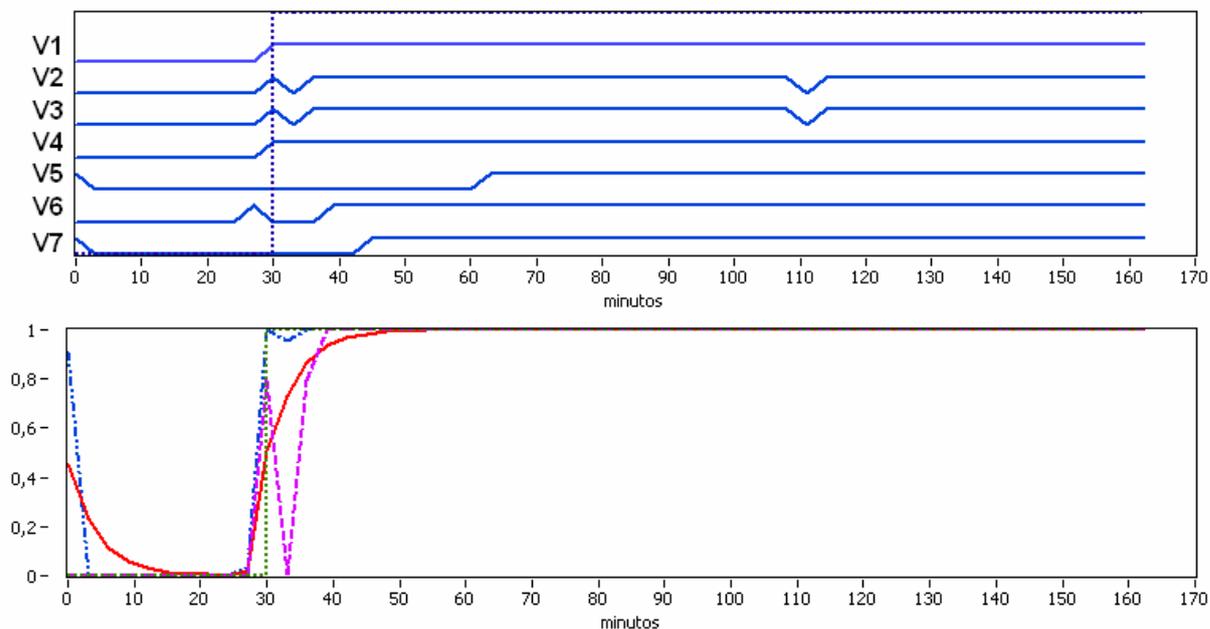
Nesse ensaio ocorreu alguma perturbação que fez com que as variáveis se desestabilizassem. E a rede foi capaz de detectar isso. A figura a seguir mostra a capacidade de refrigeração desse ensaio.



## Legenda:

- - - limites de estabilidade
- instante de entrada em regime permanente

## Ensaio 19:

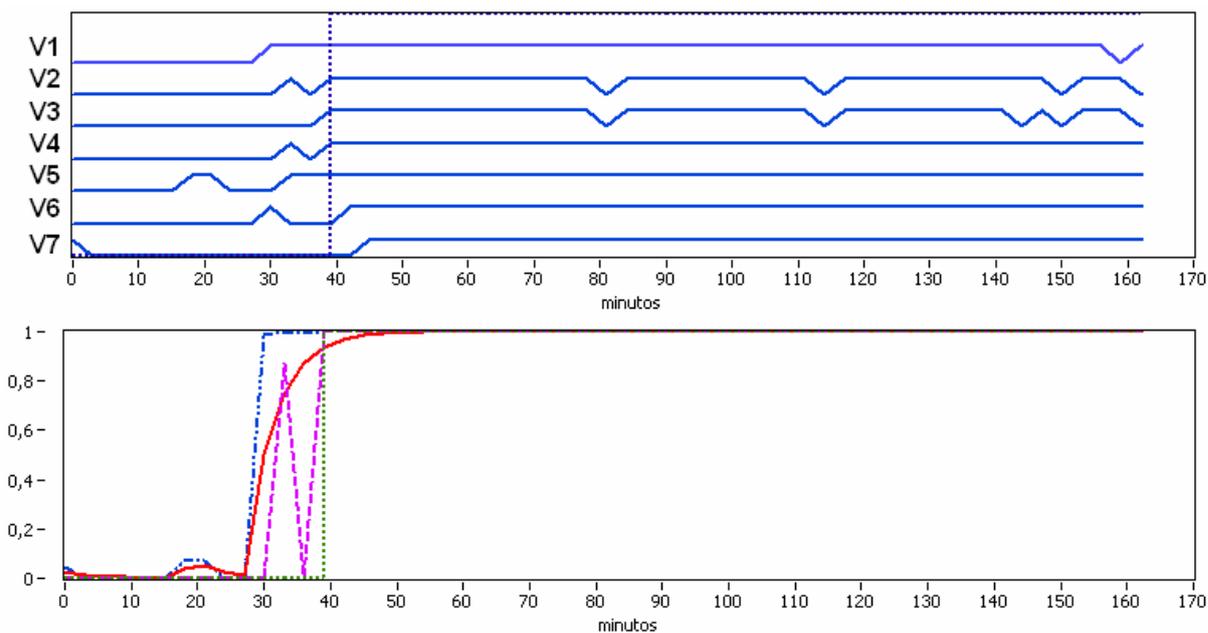


## Legenda:

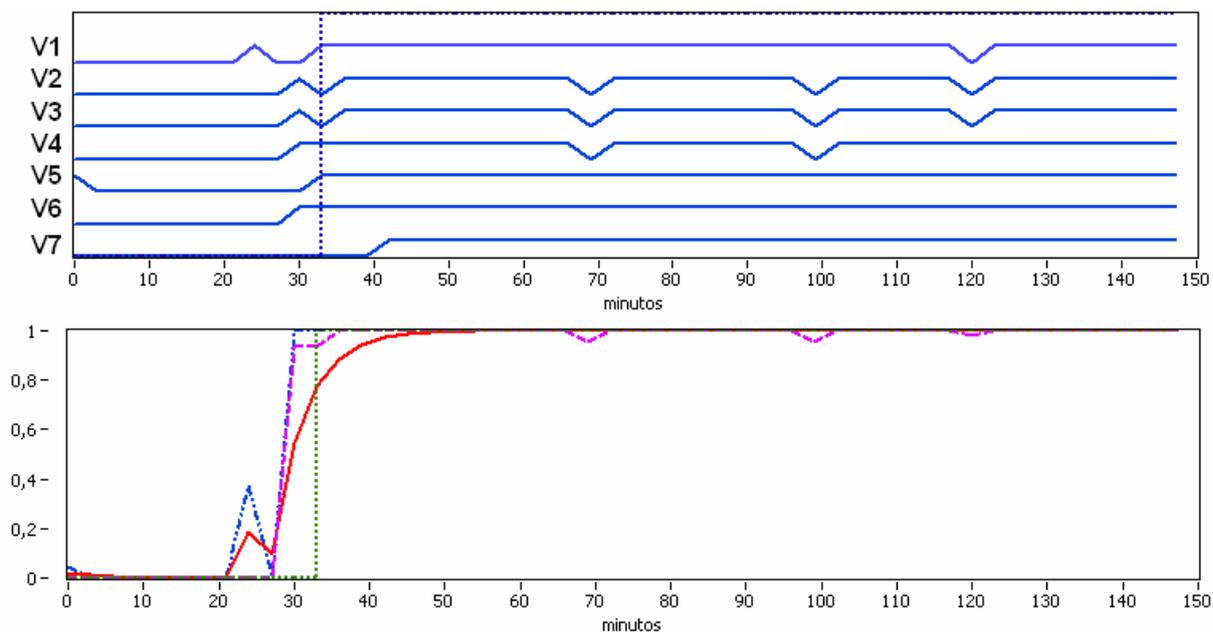
-  entrada em regime permanente
-  rede bayesiana
-  rede fuzzy-bayesiana
-  rede fuzzy-bayesiana com média

- V1 – temperatura Corpo
- V2 – temperatura saída do trocador
- V3 – temperatura Superficial Calorímetro
- V4 – tensão DC calorímetro (placa de aquisição)
- V5 – corrente DC calorímetro (placa de aquisição)
- V6 – potência DC calorímetro (placa de aquisição)
- V7 – capacidade via Fluxo de Massa

## Ensaio 20:



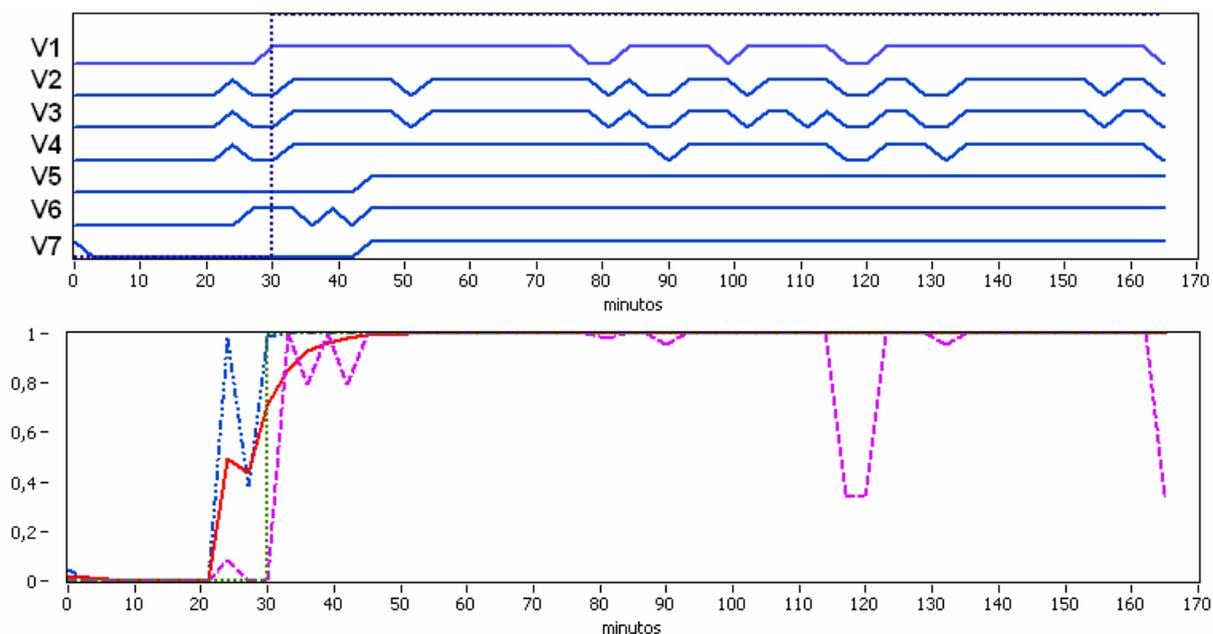
## Ensaio 21:



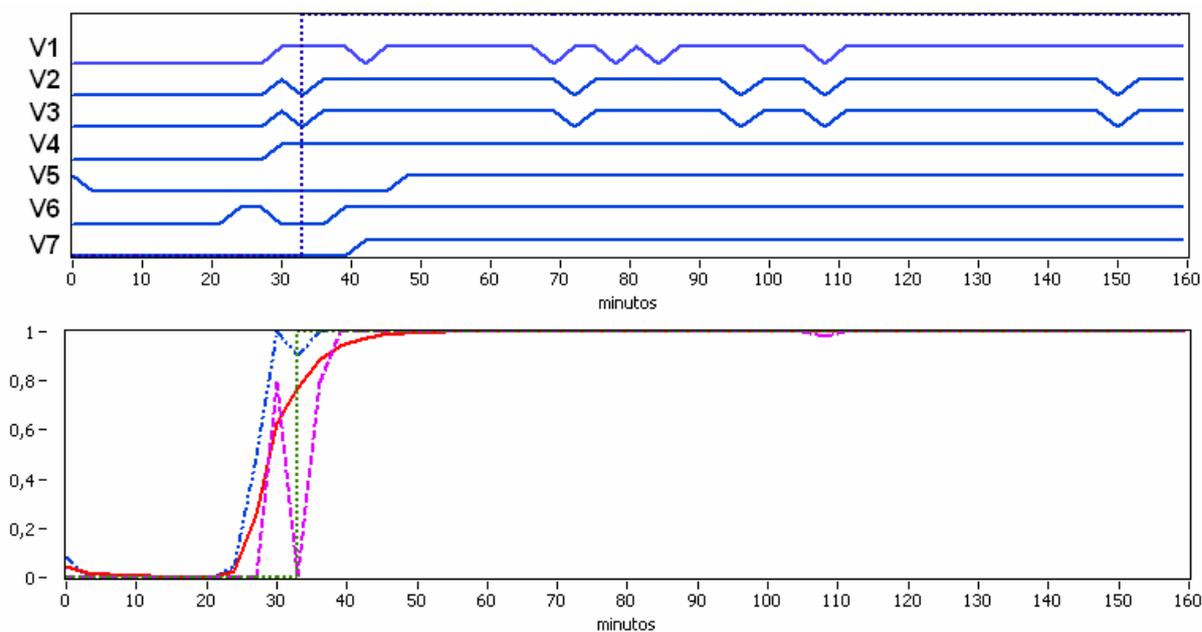
## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## Ensaio 22:



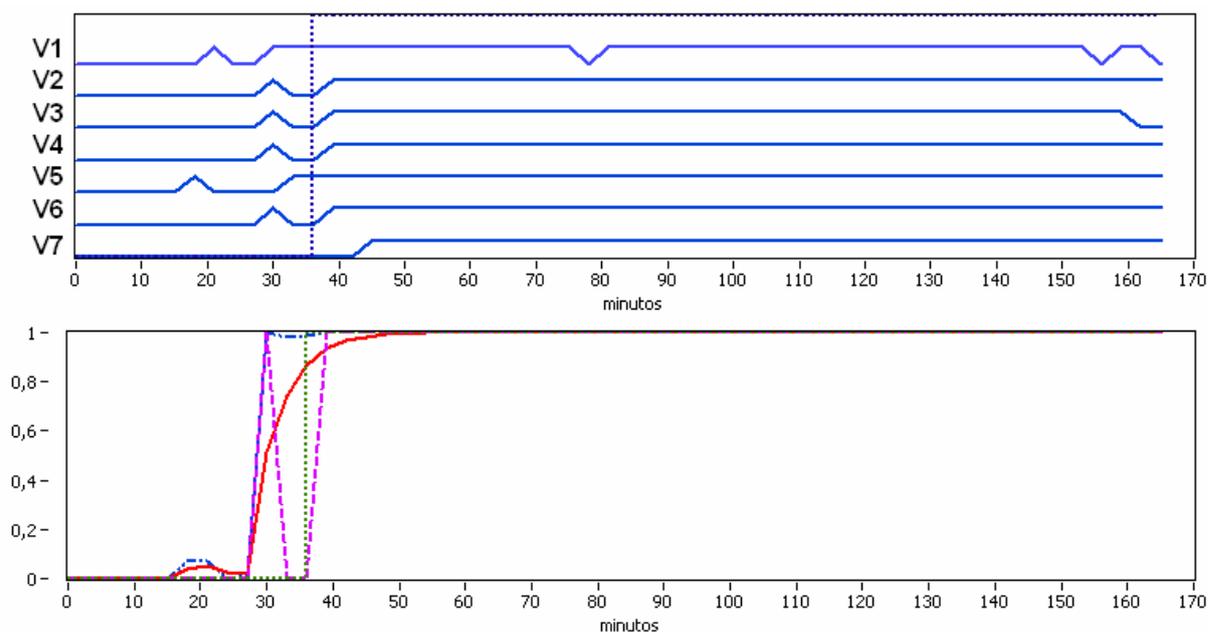
## Ensaio 23:



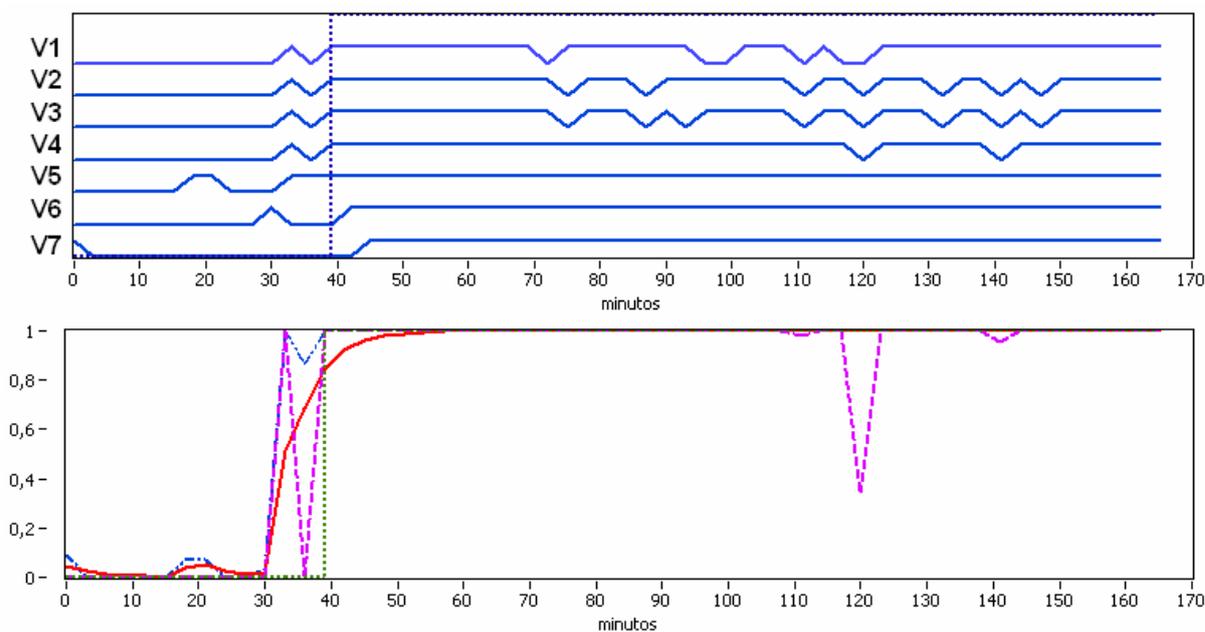
## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## Ensaio 24:



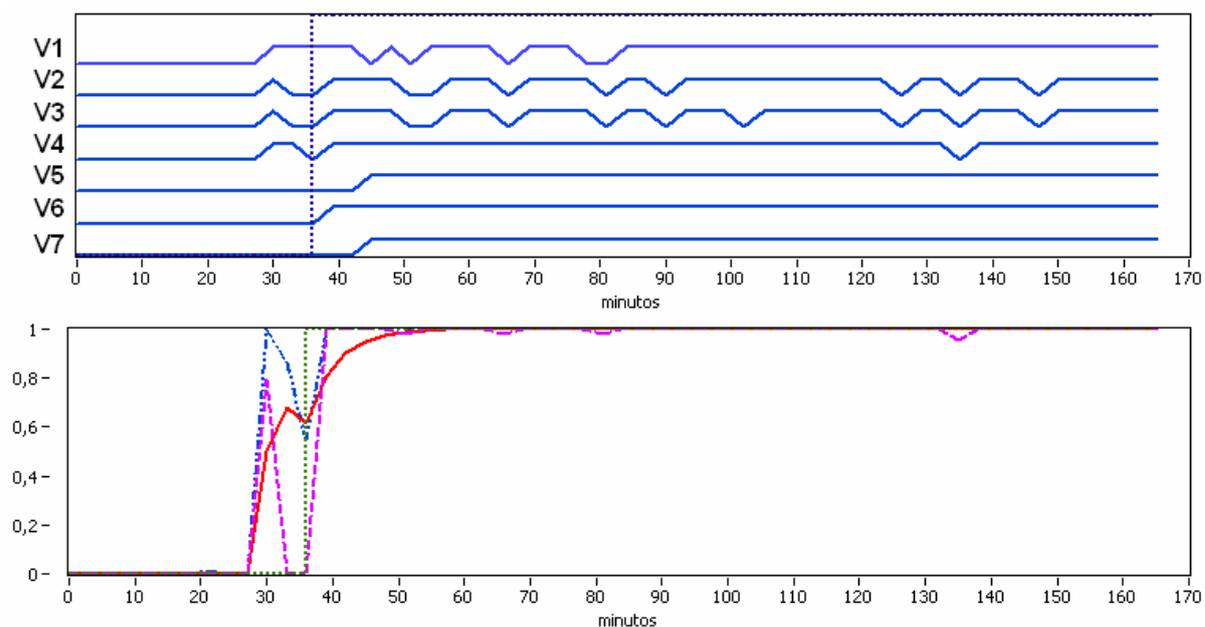
## Ensaio 25:



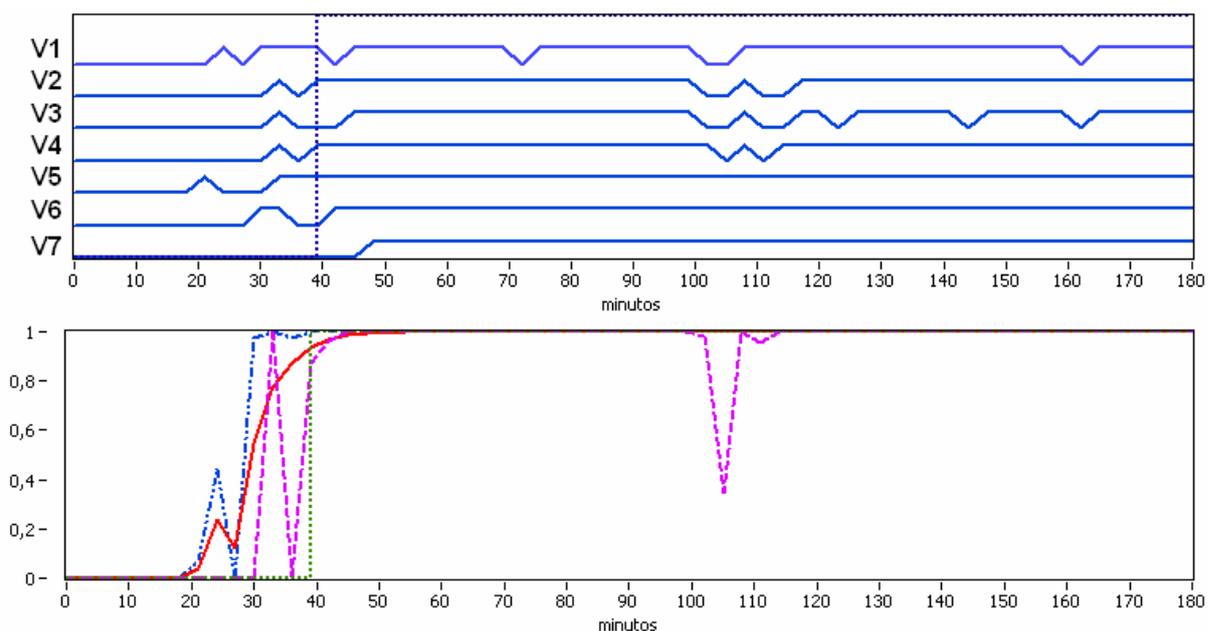
## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## Ensaio 26:



## Ensaio 27:



## Legenda:

	entrada em regime permanente	V1 – temperatura Corpo
	rede bayesiana	V2 – temperatura saída do trocador
	rede fuzzy-bayesiana	V3 – temperatura Superficial Calorímetro
	rede fuzzy-bayesiana com média	V4 – tensão DC calorímetro (placa de aquisição)
		V5 – corrente DC calorímetro (placa de aquisição)
		V6 – potência DC calorímetro (placa de aquisição)
		V7 – capacidade via Fluxo de Massa

## **APÊNDICE D – Descrição de variáveis dos ensaios**

A seguir são apresentadas as variáveis utilizadas no trabalho, sua descrição e local de medição. Estas variáveis foram selecionadas dentre as disponíveis que apresentam comportamento adequado ao método desenvolvido. No total existem 126 variáveis disponíveis, mas as variáveis não utilizadas no método não são descritas devido a grande quantidade.

Temperatura corpo: temperatura do corpo do compressor no lado oposto à etiqueta de identificação. Medida com termoresistor de platina (Pt-100). Aquisição através do medidor Eurotherm.

Temperatura saída trocador: temperatura na saída do evaporador medida com termoresistor de platina (Pt-100). Aquisição através do medidor Eurotherm.

Temperatura superficial calorímetro: média de quatro temperaturas medidas, em diferentes pontos da superfície do calorímetro, através de quatro termorresistores de platina (Pt-100). Aquisição através do medidor Eurotherm.

Temperatura carcaça topo (T1): temperatura no topo da carcaça do compressor. Medida com termoresistor de platina (Pt-100) e por meio de placa de aquisição e uma interface de hardware composta de amplificadores de instrumentação seguindo o modelo de Anderson Loop.

Temperatura carcaça curva do óleo (T2): temperatura na altura onde se encontra o óleo acumulado do compressor. Medida com termoresistor de platina (Pt-100) e por meio de placa de aquisição e uma interface de hardware composta de amplificadores de instrumentação seguindo o modelo de Anderson Loop.

Temperatura carcaça solda (T3): temperatura na solda da carcaça do compressor. Medida com termoresistor de platina (Pt-100) e por meio de placa de aquisição e uma interface de hardware composta de amplificadores de instrumentação seguindo o modelo de Anderson Loop.

Temperatura carcaça fundo (T4): temperatura da parte inferior do compressor. Medida com termoresistor de platina (Pt-100) e por meio de placa de aquisição e uma interface de hardware composta de amplificadores de instrumentação seguindo o modelo de Anderson Loop.

Tensão DC calorímetro (placa de aquisição): tensão DC aplicada no resistor de aquecimento do evaporador. Medição através de placa de aquisição e divisor resistivo.

Tensão DC calorímetro (instrumento): tensão DC aplicada no resistor de aquecimento do evaporador. Medição fornecida pela fonte de alimentação DC.

Corrente DC calorímetro (placa de aquisição): corrente DC medida no resistor de aquecimento do evaporador. Medição através de placa de aquisição e divisor resistivo.

Corrente DC calorímetro (instrumento): corrente DC medida no resistor de aquecimento do evaporador. Medição fornecida pela fonte de alimentação DC.

Corrente DC calorímetro (shunt): corrente DC medida no resistor de aquecimento do evaporador. Medição através do transdutor de potência DC adicional controlado pela fonte de alimentação AC.

Corrente RMS compressor (instrumento): Corrente RMS do compressor. Medição fornecida pela fonte de alimentação.

Potência DC calorímetro (placa de aquisição): potência DC medida no resistor de aquecimento do evaporador. A potência é calculada a partir das medições de corrente e tensão DC no calorímetro.

Potência DC calorímetro (instrumento): Potência DC medida no resistor de aquecimento do evaporador. Medida fornecida pela fonte de alimentação DC.

Potência real compressor (instrumento): potência real fornecida ao compressor. Medição fornecida pela fonte de alimentação.

Capacidade via calorímetro: capacidade de refrigeração usando variáveis obtidas através do balanço de energia no calorímetro (método C da norma ISO 917).

Capacidade via fluxo de massa: capacidade de refrigeração usando variáveis obtidas com a medição do fluxo de massa (método F da norma ISO 917).

Fluxo de massa do fluido refrigerante-filtrado: fluxo de massa do fluxo refrigerante no estado líquido, resultados são filtrados através de média móvel. Medição fornecida pelo fluxímetro (equipamento específico para medição de fluxo de massa).