



DETECÇÃO DE FALHAS EM SISTEMAS DE REFRIGERAÇÃO, PROPOSTA DE METODOLOGIA.

Tumialán, J. A.

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica
Laboratório de Energia e Sistemas Térmicos
Av. João Naves de Ávila, 2.121. Campus Santa Mônica, Bloco 1M
CEP 38400-902, Uberlândia – MG, Brasil
e-mail: jtumialan@mecanica.ufu.br

Oliveira, J. E.; Hernandez, O. S.; Pico, C. E.; Martins, G

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica
Laboratório de Energia e Sistemas Térmicos
Av. João Naves de Ávila, 2.121. Campus Santa Mônica, Bloco 1M
CEP 38400-902, Uberlândia – MG, Brasil
e-mail: {jeolivei; oscarhm; capico; gmartins}@mecanica.ufu.br

Resumo. *Este trabalho utiliza Redes Neurais Artificiais (ANNs) com o algoritmo de "backpropagation", como modelo experto de detecção de falhas. Apresenta o esquema de treinamento realizado com dados empíricos colhidos de um protótipo de sistema de refrigeração por compressão a vapor, operando em condições normais de funcionamento recomendadas pelos fabricantes. Uma vez treinada a rede neural são introduzidas algumas falhas artificiais no sistema, pelo método de erros residuais e usando análise estatística identifica e diagnostica a falha. O trabalho apresenta os resultados do treinamento, diagnósticos realizados e faz considerações sobre as potencialidades da metodologia utilizada.*

Palavra chave: *Deteção de falha, Refrigeração, Ar condicionado, Redes neurais.*

1. INTRODUÇÃO

Os sistemas de refrigeração e ar condicionado participam no consumo total de energia nos setores residencial, comercial e industrial de 32 %, 20 % e 6 % respectivamente (Procel, 1998), além disso, esta porcentagem pode ser maior em sistemas que operam com equipamentos defeituosos (Herzog e LaVine 1992). Com o avanço da tecnologia computacional, sistemas de aquisição de dados (A/D) e mecanismos de instrumentação, nos últimos anos é possível utilizar algoritmos de monitoração em tempo real, que permitem a detecção de falhas que podem estar ocorrendo num sistema supervisionado e com isso impedir danos posteriores no sistema. As pesquisas extensivas em detecção e diagnóstico de falhas (FDD) em sistemas de aquecimento, ventilação e ar condicionado (HVAC), são motivados pelo interesse de reduzir o consumo de energia e conseqüentemente seus custos.

Os estudos FDD são extensivos e vários pesquisadores deixaram aportes importantes, a seguir mostraremos alguns dos mais importantes aportes encontrados na literatura. (Braun e Brueker, 1997) utilizaram uma metodologia estatística baseados em regras de controle para as unidades de condicionamento de ar (AHU) do terraço. (Grimmelius, 1995) gero uma matriz

de sintomas para cada tipo de falhas e o efeito causado; os sintomas eram desvios das variáveis selecionadas dos valores previstos usando um modelo estatístico linear. (Dexter e Mok, 1992) utilizaram o modelo de caixa preta (lógica fuzzy) para identificar determinados padrões de falhas utilizando um modelo quantitativo. (Stylianou e Nikapour, 1996) o modelo FDD conteve três módulos básicos, primeiro módulo (ciclo-desligado) trata-se da detecção de falha quando o chiller é desligado a noite (monitorando o desempenho dos sensores), o segundo módulo detecta a falha durante os 15 minutos iniciais (modulo de arranque) analisando as mudanças do fluxo do refrigerante, e o ultimo modulo opera no regime estável e monitora o declínio no desempenho da unidade. (Lee, 1996a) descreve métodos para FDD em unidades de manuseio de ar (AHU) de volume de ar variável (VAV), este estudo define o uso do método residual que e a diferença entre o estado atual e o estado normal do sistema. (Lee, 1996b) descreve o uso de uma rede artificial simples (ANNs) que foi treinada com testes padrões residuais, para diagnosticar as falhas em vários subsistemas de AHU. (Lee, 1997), descreve uma arquitetura de uma ANN de dois-etapas para o diagnóstico dos sistemas (AHU,VAV), usando equações da regressão para a recuperação das falhas dos sensores de temperatura. Neste este último trabalho foram aproveitadas algumas das falhas encontradas nos estudos anteriores, para não ter a necessidade de treinar novamente a ANN. (Lee, 1999) mostra a aplicação de técnicas e classificação rigorosas de FDD em VAV e AHU.

Para este estudo de detecção de falhas foram utilizadas as redes neurais artificiais (ANNs) tipo perceptron multi-camadas (MPL) usando algoritmo "backpropagation" e a função de ativação sigmóide para treinar a rede MPL, seja em operação sem falha do sistema analisado ou com falhas artificialmente introduzidas. Foi utilizado o um protótipo experimental de sistema de refrigeração de compressão de vapor devidamente instrumentado para obter os dados necessários ao treinamento da rede com ou sem falhas, é realizado uma análise de sensibilidade das variáveis necessárias para a identificação das falhas visando fazer o diagnóstico. Descreveremos a seguir a metodologia utilizada e os resultados obtidos no treinamento e na classificação das falhas; o qual permite avaliar a metodologia proposta.

2. PROTÓTIPO DE SISTEMA DE REFRIGERAÇÃO

No nosso estudo foi utilizado um protótipo de sistema de refrigeração de compressão de vapor, tendo como fluido primário o refrigerante R134a e fluido secundário água. O sistema é composto basicamente por: compressor hermético (~300W) de velocidade variável, condensador, evaporador de fluxo cruzado, e uma válvula de expansão eletrônica. O sistema foi totalmente instrumentado com sensores de temperaturas tipo PT-100 e sensores de pressão manométrica piezos-resistivos, a Fig. (1) mostra a localização dos sensores de temperatura T e pressão P utilizados.

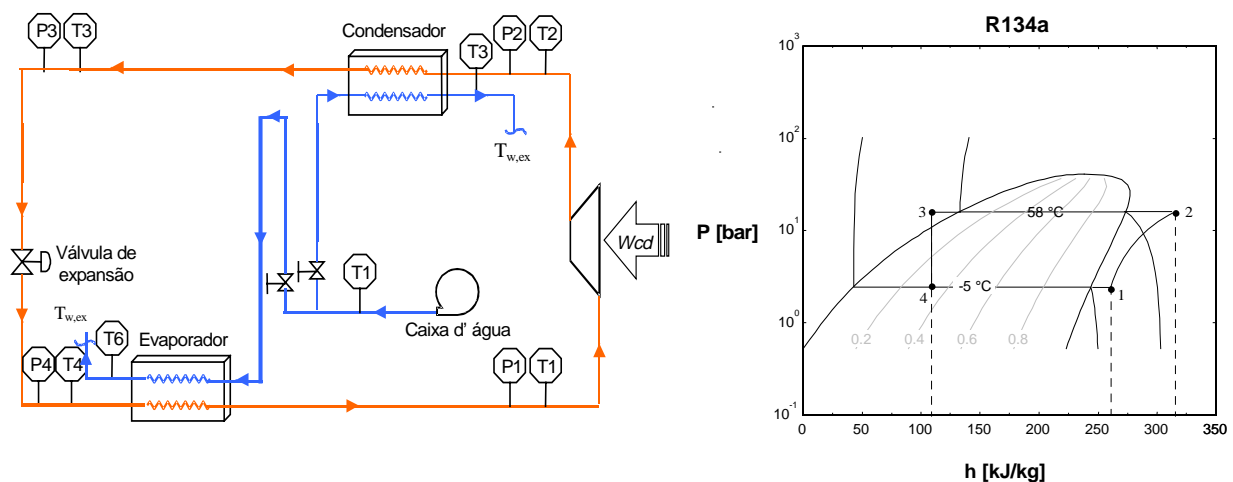


Figura 1. Diagrama esquemático da bancada de ensaios e ciclo de Carnot.

3. MODELO DE DETECÇÃO DE FALHA (FD)

As grandezas medidas (entradas) e as propriedades calculadas (saídas) foram analisadas usando um pré-processador termodinâmico que faz todos os cálculos, mostra a evolução das variáveis no tempo e obtém as propriedades termodinâmicas nas diferentes condições de operação predefinidas para cada ensaio. As propriedades calculadas geram uma base de dados do funcionamento normal do sistema, que servem para treinar a rede neural artificial, após avaliação da rede neural, são introduzidas falhas artificiais no sistema para poder avaliar a robustez do modelo FD, como mostra a Fig. (2).




Figura 2. Diagrama do pré-processador termodinâmico.

3.1. Pré-processador termodinâmico

A aquisição de dados e os cálculos térmicos são realizados em tempo real através de balanços térmicos nos componentes do sistema. Para se obter as propriedades termodinâmicas do gás refrigerante, utiliza-se uma rotina computacional do pacote TRNSYS; a seguir especificamos os balanços térmicos realizados nos diferentes componentes do ciclo.

3.1.1. Avaliação da vazão mássica de refrigerante

A primeira lei da termodinâmica é aplicada por meio de um balanço de energia a um determinado volume de controle (evaporador e condensador), para calcular estimativas de vazão de refrigerante em sistema com múltiplas entradas e saídas, podemos escrever a Eq. (1).

$$\sum_{i=1}^n \dot{Q}_i + \sum_{i=1}^n \dot{m}_{i,su} \left(h_{su,i} + \frac{V_{su,i}^2}{2} \right) + \sum_{i=1}^n W_i = \frac{dU}{d\tau} + \sum_{i=1}^n \dot{m}_{i,ex} \left(h_{ex,i} + \frac{V_{ex,i}^2}{2} \right) \quad (1)$$

A Equação.(1), pode ser simplificada desprezando-se as variações de energia cinética e potencial e assumindo também, condições de regime permanente no volume de controle ou seja: $dU/d\tau = 0$.

Assim a expressão simplificada é dada pela Eq.(2).

$$\sum_{i=1}^n \dot{Q}_i + \sum_{i=1}^n (\dot{m}\Delta h)_i + \sum_{i=1}^n \dot{W}_i = 0 \quad (2)$$

3.1.2. Balanço de energia nos trocadores de calor

Aplicando a conservação de energia nos trocadores obtém-se as equações para o fluxo de calor.

$$\dot{Q} = \dot{m}_w C p_w (T_{w,ex} - T_{w,su}) \quad (3)$$

$$\dot{Q} = \dot{m}_{ref} (h_{ref,ex} - h_{ref,su}) \quad (4)$$

$$\dot{Q} = UA * LMTD \quad (5)$$

As equações para a diferença media logarítmica da temperatura (*LMTD*) são:

$$LMTD_{cd} = \frac{(T_{cd} - T_{w,su}) - (T_{cd} - T_{w,ex})}{\ln\left(\frac{(T_{cd} - T_{w,su})}{(T_{cd} - T_{w,ex})}\right)} \quad (6)$$

$$LMTD_{ev} = \frac{(T_{w,su} - T_{ev}) - (T_{w,ex} - T_{ev})}{\ln\left(\frac{(T_{w,su} - T_{ev})}{(T_{w,ex} - T_{ev})}\right)} \quad (7)$$

Onde:

- \dot{Q} = Fluxo de calor [W]
- $h_{ref,su}; h_{ref,ex}$ = Entalpias do refrigerante (entrada e saída), respectivamente [J/kg]
- Cp_w = Calor específico da água [J/kg-K]
- \dot{m}_w = Vazão mássica da água [kg/s]
- UA = Coeficiente global de troca térmica [W/K]
- \dot{m}_{ref} = Vazão mássica do refrigerante [kg/s]




Figura 3. Estrutura da rede neural e a função de ativação sigmóide.

3.2. Estrutura da rede neural artificial

O modelo de rede neural utilizado neste trabalho é perceptron multi-camadas (MLP), que em geral, consiste de uma camada de entradas, uma ou mais camadas intermediárias (escondidas) e uma camada de saída como mostra a Fig. (3a). O algoritmo “backpropagation” com a função de ativação sigmóide Fig. (3b) é usado para treinar o MLP, que emprega um método iterativo do

gradiente-descendente que minimiza o erro médio quadrático entre a saída desejada e a saída da rede.

$$a_j = \frac{1}{1 + e^{-\infty(input_j - \theta)}} \quad (8)$$

4. SENSIBILIDADE DOS PARÂMETROS

A Figura. (4) define as variáveis mais sensíveis identificadas no pre-processamento térmico, a $APPR_c$ é a diferença entre a temperatura de condensação (T_{cd}) e a temperatura de saída da água do condensador ($T_{w,ex,cd}$), da mesma forma se define um $APPR_e$ para o evaporador que é a diferença entre a temperatura de saída da água ($T_{w,ex,ev}$) e a temperatura de evaporação (T_{ev}); $DTWCD$ e $DTWEV$ como a diferença de temperatura da água de entrada e saída do condensador e evaporador, respectivamente.

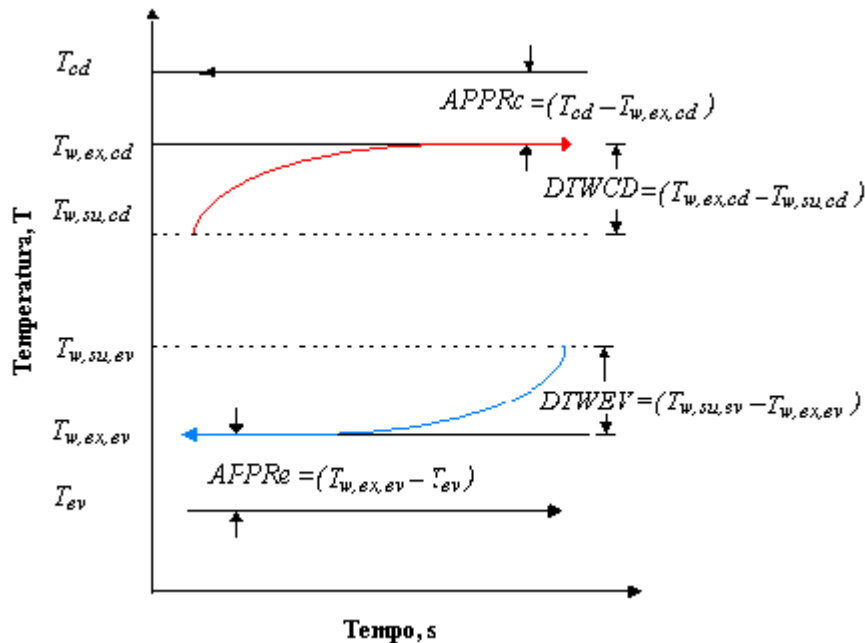


Figura 4. Definição das diferenças de temperaturas

Para modelar o comportamento com falhas do sistema, cada falha experimentalmente implementada foi devidamente registrada, sendo calculados os parâmetros descritos anteriormente para analisar a sensibilidade dos mesmos, com resultado mostrado nas Tab. (1) e (2)

Tabela 1. Parâmetros sensíveis para uma falha específica

Tipo de falha	Parâmetros sensíveis
(1) Redução da vazão de água no evaporador	$UA_e, APPR_e, DTWEV$
(2) Redução da vazão de água no condensador	$UA_c, APPR_c, DTWCD$
(3) Obstrução no tubo do evaporador	UA_e e $APPR_e$
(4) Obstrução no tubo do condensador	UA_c e $APPR_c$
(5) Falha interna no compressor	P, COP e $\eta_{isentrópica}$

Tabela 2. Mudanças observadas em o análise de sensibilidade

Tipo de falha	Evaporador			Condensador			Compressor	
	DTWEV	APPR _e	UA _e	DTWCD	APPR _c	UA _c	$\eta_{isentrópica}$	η_{motor}
(1)	↑	↓	↑	0	0	0	0	0
(2)	0	0	0	↑	↓	↑	0	0
(3)	0	↑	↓	0	0	0	0	0
(4)	0	0	0	0	↑	↓	0	0
(5)	0	0	0	0	0	0	↓	0

5. ESCOLHA E ANÁLISE DE DADOS PARA O TREINAMENTO DA REDE NEURAL

O Treinamento da rede foi realizado, a partir da observação previa do comportamento do sistema para cada tipo de falha, neste caso comparamos o ,fluxo de refrigerante (\dot{m}_{ref}) com o coeficiente global de troca de calor no evaporador (UA_{ev}), e com a temperatura de evaporação (T_{ev}), assim como a relação entre os parâmetros apresentados na Tab.(1). A Figura.(5a), (5b) mostra o comportamento típico dos parâmetros escolhido para o sistema (evaporador) (nosso caso linear) para logo serem implementados no treinamento da rede como descrito a seguir.

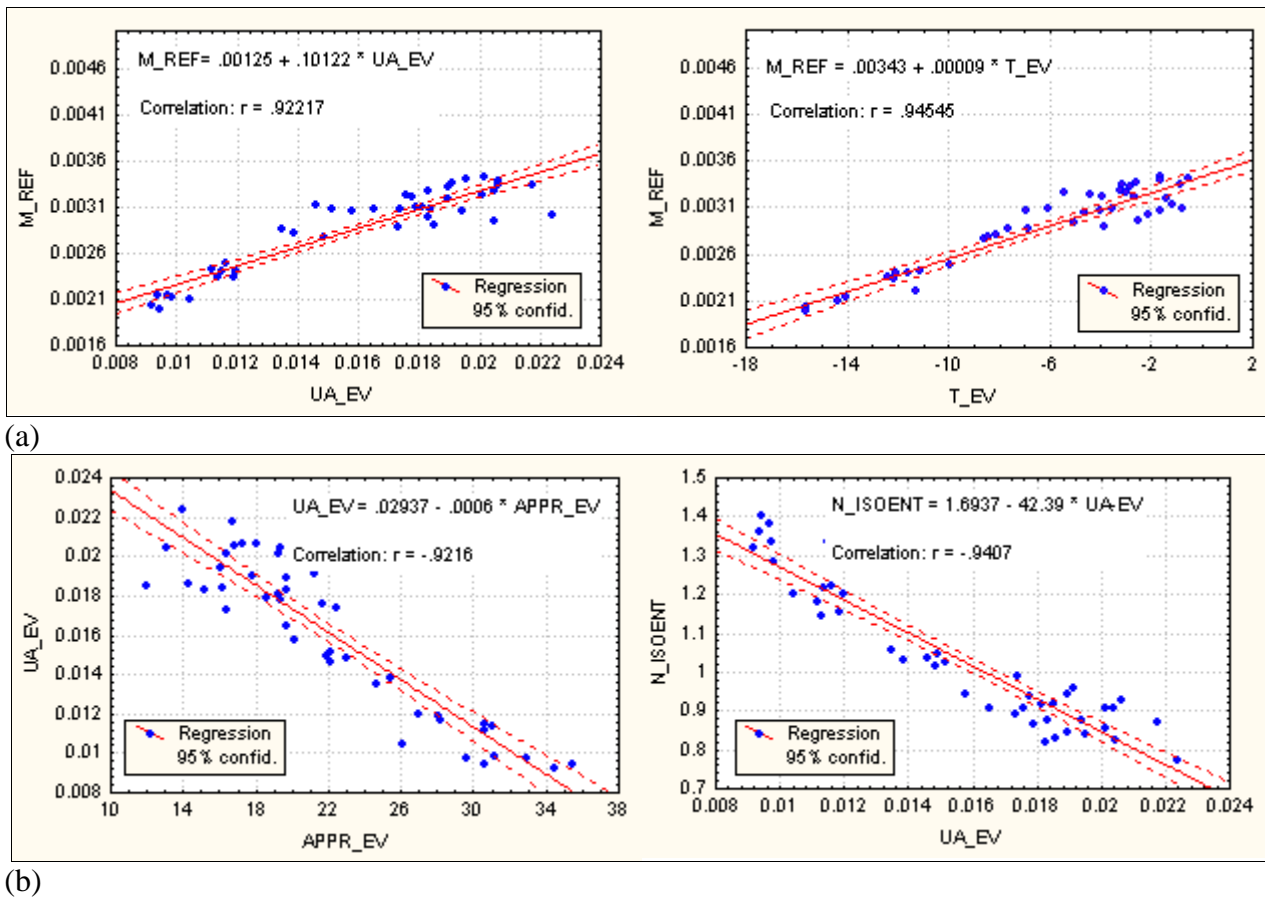


Figura 5. Comportamento normal do protótipo de sistema

A Figura. (6) apresenta o fluxograma do procedimento utilizado no treinamento da rede neural. A escolha da arquitetura da rede neural é feita dependendo do comportamento das variáveis envolvidas, quanto mais complexo o comportamento será necessária escolha de um maior número de épocas de treinamento ou incrementar o número de camadas intermediárias.

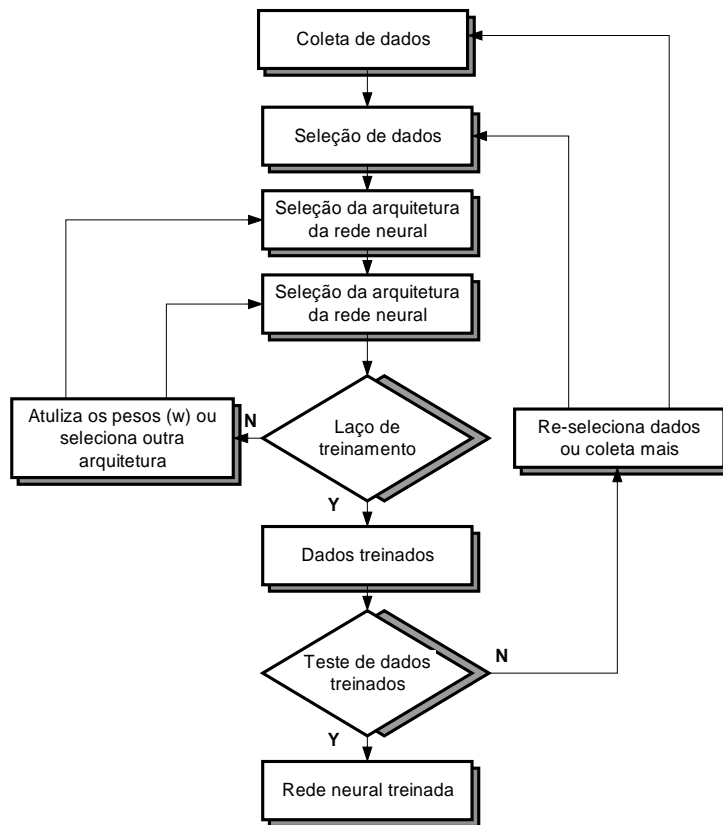


Figura 6. Fluxograma do algoritmo de treinamento.

A Figura.(8) mostra o comportamento das variáveis mais sensíveis quando foi introduzida a falha artificial no evaporador. O procedimento de introdução de falhas, realizado experimentalmente parte da operação do sistema de refrigeração estável, a seguir foi mudada subitamente a vazão de água no evaporador, reduzindo o fluxo em 54%. Observamos uma redução de 12°C no $APPR_e$ e um aumento de 9°C no $DTWEV$, com mudança de 0.013 para 0.042 $\text{kJ}/^\circ\text{C}$ do UA_{ev} , como mostra a Fig.(7).

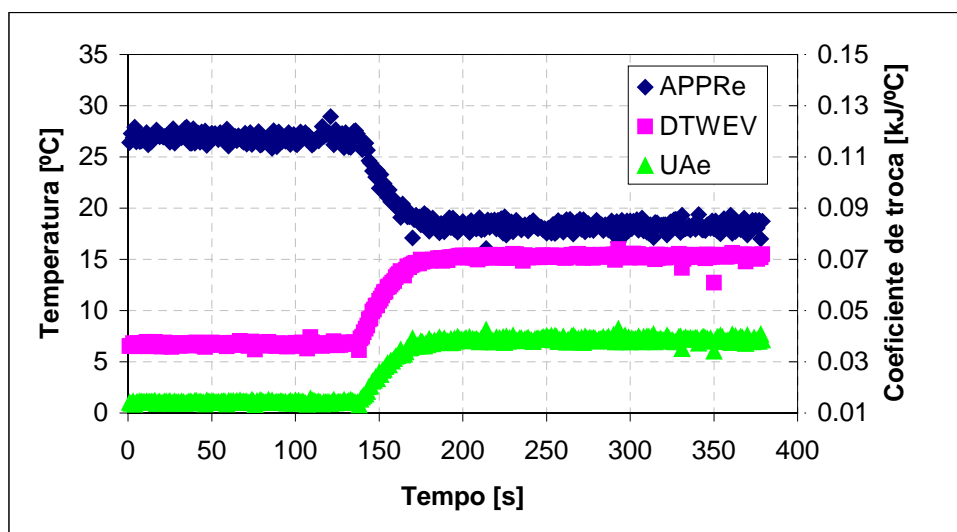


Figura 7. Apresenta o comportamento das variáveis mais sensíveis.

A Figuras. (8) e (9) mostram o comportamento das variáveis envolvidas na análise da falha com comportamento normal e com falhas, para duas reduções da vazão de água do evaporador (54 e

90%). A partir da operação normal e estável do sistema (pontos antes de 140s na Fig. (7)), após a falha ser introduzida a operação do sistema diverge da operação normal como mostra a Fig.(8) de forma uniforme caracterizando claramente a falha o qual facilita o posterior diagnóstico. A Figura.(9) mostra os efeitos da falha sobre o fluxo de refrigerante, mostrando a sensibilidade deste parâmetro.

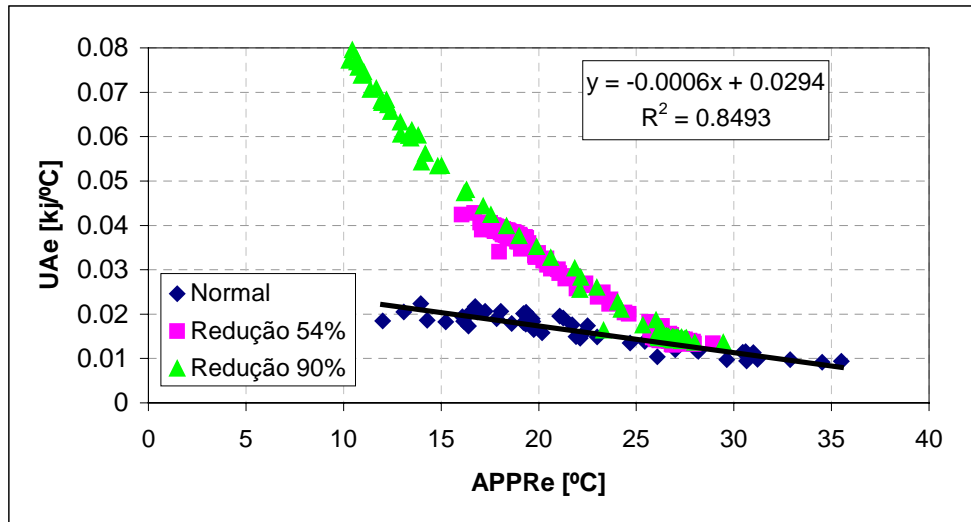


Figura 8. Gráfico do comportamento normal e com falha.

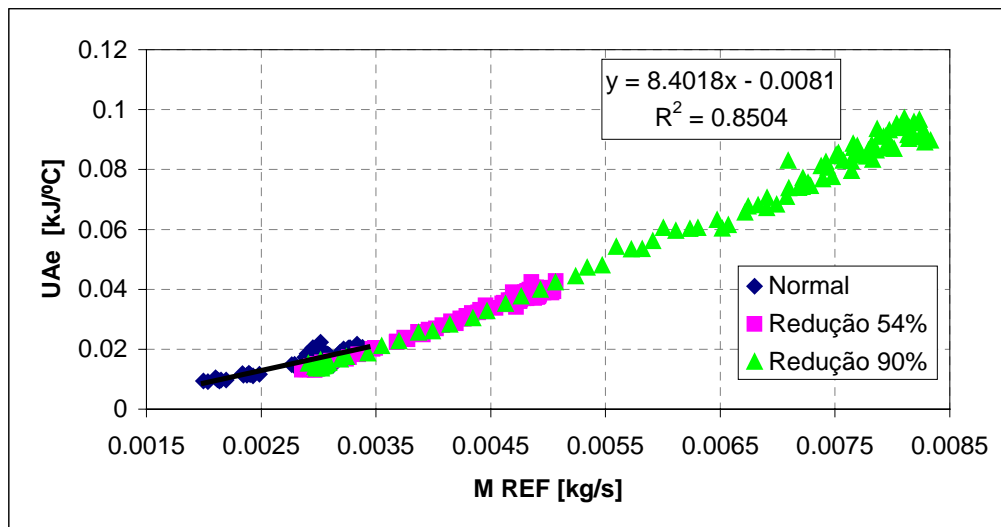


Figura 9. Gráfico do comportamento normal e com falha.

6. CONCLUSÃO

Este trabalho apresenta uma metodologia de detecção de falhas (FD) em sistemas de aquecimento, ventilação e ar condicionado (HVAC) usando redes neurais artificiais (ANNs). Durante este estudo, uma base de dados experimentais em regime permanente do sistema foi gerada, as escolhas dos pontos ótimos do funcionamento do sistema para o treinamento da rede neural foi feita após os cálculos das propriedades térmicas. A arquitetura da rede neural escolhida foi composta por duas camadas de entrada, duas intermediárias e uma de saída. O algoritmo de treinamento utilizado é backpropagation utilizando a função de ativação sigmóide.

Neste trabalho foi mostrada a metodologia de detecção e diagnóstico, para uma falha específica (falha do evaporador) sendo observado bons resultados para detecção e diagnóstico.

A metodologia proposta, embora simples, conseguiu atingir as necessidades do modelo de detecção de falhas. Vale a pena destacar que as variáveis envolvidas no modelo da rede possuem comportamento linear, facilitando desta maneira o treinamento da rede neural. Outra característica importante que observo-se que a falha introduzida no modelo tem comportamento uniforme, facilitando desta maneira a sua caracterização. Especificamos porém que a análise apresentada por enquanto é útil para este tipo de sistema, sendo que posteriormente os estados serão conduzidos no sentido de generalizar a metodologia proposta.

7. AGRADECIMENTO

Os autores gostariam de agradecer a CAPES, que proporcionam o suporte financeiro para desenvolvimento da pesquisa, e ao técnico do Laboratório Energia e Sistemas Térmicos (LEST) Cláudio Gomes do Nascimento pela montagem da bancada experimental

8. BIBLIOGRAFIA

- Braun, J.E. and M.S. Breuker. 1997. "Demonstration of a Statistical, Rule-Based Fault Detection and Diagnostic Method on a Rooftop Air-Conditioning Unit." *CLIMA 2000 Conference Proceedings*: CD-ROM.
- Braun, J.E. and T.M. Rossi. 1997. "A Statistical, Rule-Based Fault Detection and Diagnostic Method for Vapor Compression Air Conditioners." *HVAC&R Research*, Vol.3, No.1, pp.19-37.
- Dexter A. L. and M. Benouarets. 1996a. "Transient Detection." *IEA Annex Final Report*.
- Grimmelius, H.T., J.K. Woud, and G. Been. 1995. "On-line Failure Diagnosis for Compression Refrigeration Plants." *Rev. Int. Froid* 18(1): pp. 31-41.
- Harunori Yoshida, Tatsuhiro Iwami, Hideki Yuzawa, Masami Suzuki., 1996 "Typical Faults of Air-Conditioning Systems and Fault Detection by ARX Model and Extended Kalman Filter", ASHRAE AT-96-3-5.
- Henk C. Peitsman, Vicent E. Bakker., 1996 "Application of Black-Box Models to HVAC Systems for Fault Detection", ASHRAE AT-96-6-3.
- Ian B. D. McIntosh., 1999, "A Model-Based Fault Detection and Diagnosis Methodology for HVAC Subsystems" University of Wisconsin – Madison.
- João. M. Pimenta, Oscar. H. Mendoza., 1999 "Overview of Fault Detection and Diagnosis Methods Applied to HVAC Systems", COBEM 99, Universidade Federal de Uberlândia.
- L. K. Norford., 1998 "Fault Detection and Load Monitoring in Ventilation Systems", Massachusetts Institute of Technology. ASHRAE Transactions.
- Mcdowell Tim, 1992 "Routine Modified, Prepared for inclusion in Trnsys 14.1 - jwt -- 7/93"
- N. Maruyama, M. Benouarets, A. L. Dexter.,1993, "Fuzzy Model-Based Fault Detection", Department of Engineering Science, University of Oxford.
- Philip Haves, Timothy I. Salisbury, J. A. Wright., 1996 "Condition Monitoring in HVAC Subsystems Using First Principles Models", ASHRAE AT-96-3-1.
- Won-Yong Lee, John M. House, Cheol Park, George E. Kelly.,1996, "Fault Diagnosis of an Air-Handling Unit Using Artificial Neural Networks" ASHRAE V. 102 Pt. 1, pp 540-549.
- Won-Yong Lee, Cheol Park, George E. Kelly.,1996, "Fault Detection in an Air-Handling Unit Using Residual and Recursive Parameter Identification Methods" ASHRAE V. 102 Pt. 1.
- Lee, W.Y., J.M. House, and D.R. Shin. 1997. "Fault Diagnosis and Temperature Sensor Recovery for an Air-Handling Unit." *ASHRAE Transactions*, 103(1).
- Won-Yong Lee, John M. House, Cheol Park, Dong Ryul Shin.,1999, "Classification Techniques for fault Detection and Diagnosis of an Air-Handling Unit Using" ASHRAE CH-99-18-5.

9. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material incluído neste trabalho.

FAULT DETECTION IN REFRIGERATION SYSTEMS, METHODOLOGY PROPOSAL

Tumialán, J. A.

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica
Laboratório de Energia e Sistemas Térmicos
Av. João Naves de Ávila, 2.121. Campus Santa Mônica, Bloco 1M
CEP 38400-902, Uberlândia – MG, Brasil
e-mail: jtumialan@mecanica.ufu.br

Oliveira, J. E.; Hernandez, O. S.; Pico, C. E.; Martins, G

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica
Laboratório de Energia e Sistemas Térmicos
Av. João Naves de Ávila, 2.121. Campus Santa Mônica, Bloco 1M
CEP 38400-902, Uberlândia – MG, Brasil
e-mail: {jeolivei; oscarhm; capico; gmartins}@mecanica.ufu.br

Abstract. This work uses Artificial Neural Networks (ANNs), with the backpropagation algorithm as expert model of fault detection. It presents the training outline accomplished with experimental data picked from a prototype of a refrigeration system by vapor compression, operating in normal conditions as recommended by the manufacturers. Once trained the neural network some artificial faults are introduced in the system, and by the method of residual errors, and using statistical analysis identify and diagnoses fault. The work presents the results of the training, accomplished diagnoses and makes considerations about the potentialities of the used methodology

Keywords: *Fault detection, Refrigeration, Air-condition, Neural networks.*