

# **APLICAÇÃO DE MODELO BLACK-BOX EM SISTEMA DE REFRIGERAÇÃO**

## **Tumialán J. A.**

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica.

Laboratório de Energia e Sistemas Térmicos

Av. João Naves de Ávila, 2160. Campus Santa Mônica, Bloco 1M.

CEP 38400-089, Uberlândia – MG, Brasil.

e-mail: [jtumialan@mecanica.ufu.br](mailto:jtumialan@mecanica.ufu.br)

## **Hernandez O. S.**

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica.

Laboratório de Energia e Sistemas Térmicos

Av. João Naves de Ávila, 2160. Campus Santa Mônica, Bloco 1M.

CEP 38400-089, Uberlândia – MG, Brasil.

e-mail: [oscarhm@mecanica.ufu.br](mailto:oscarhm@mecanica.ufu.br)

## **Julio D. A.**

Universidade Federal de Uberlândia, Faculdade de Engenharia Mecânica.

Laboratório de Energia e Sistemas Térmicos

Av. João Naves de Ávila, 2160. Campus Santa Mônica, Bloco 1M.

CEP 38400-089, Uberlândia – MG, Brasil.

e-mail: [dorisjulio@mecanica.ufu.br](mailto:dorisjulio@mecanica.ufu.br)

**Resumo.** Este trabalho apresenta a modelagem estática de um sistema de refrigeração de compressão a vapor utilizando modelo Black-box (Redes Neurais Artificiais) com o algoritmo de treinamento “back-propagation”. O modelo é fortemente dependente dos componentes do sistema (compressor, condensador, dispositivo de expansão, evaporador, etc.). Em geral, das características dos componentes do sistema com múltiplas-entradas e múltiplas-saídas (MIMO - multi-input multi-output). Foram usados dados experimentais de um protótipo de sistema de refrigeração montado no laboratório de Energia e Sistemas Térmicos – LEST/FEMEC/UFU. Os resultados do modelo apresentaram-se satisfatórios para obter diferentes variáveis, tais como; potência consumida, vazão mássica; coeficiente de performance do sistema. Esta forma de modelar proporciona informação sobre comportamento de cada um dos parâmetros de cada componente, operando como uma ferramenta que pode ser utilizada para desenvolver modelagem semi-empírica simplificada.

**Palavra-chave:** modelagem, refrigeração, redes neurais.

## **1. INTRODUÇÃO**

Os sistemas de refrigeração tornam-se a cada dia mais imprescindíveis para a vida moderna, e a medida que as necessidades de conforto humano e conservação de produtos ganham maior destaque no mundo contemporâneo nos leva melhorar sistemas já existentes, através de estudos

generalizados para melhorar a eficiência e consumo de energia para este tipo de sistemas de refrigeração.

Encontra-se na literatura diferentes linhas de modelagem de este tipo de sistema, modelos altamente detalhados como o proposto por Rigola et al (1996) são mais úteis na otimização do ‘design’ de compressores e não na predição do comportamento do compressor. Em outra linha de modelagem estão modelos mais simplificados baseados em correlações estatísticas, parâmetros de performance e simplificações fundamentadas em conceitos físicos (Chi, 1982, Yassuda, 1983, MacArthur, 1984, e Braun, 1999). Modelos dessa natureza são úteis em projeto, otimização, investigação de controle e detecção de falhas em sistemas de refrigeração. A principal dificuldade relacionada com estes modelos é a obtenção dos parâmetros que são propostos para descrever o comportamento do compressor, como: eficiências de processos, coeficiente de inércia de válvulas, coeficientes politrópicos, parâmetros geométricos e coeficientes locais de troca térmica, porém, o desenvolvimento de modelos teóricos rigorosos pode não ser praticável para processos complexos se o modelo requer um grande número de equações diferenciais com um número significativo de parâmetros desconhecidos. Uma alternativa é desenvolver uma aproximação empírica do modelo diretamente de dados experimentais. Estes modelos são muitas vezes referenciados como *black box* (modelos tipo caixa preta). O processo a ser modelado é considerado como uma caixa preta onde as entradas e saídas são conhecidas, mas o comportamento interno da ‘caixa preta’ é desconhecido.

## 2. REDES NEURAIS ARTIFICIAIS (ANN)

A arquitetura da ANN utilizada é um perceptron multicamadas (MLP), que consiste de uma camada de entrada, um de saída um ou mais camadas ocultas, e  $n$  neurônios em cada camada, a forma pela qual os neurônios estão interconectados (topologia ou arquitetura da rede) causa um enorme efeito na operação da rede. As camadas de uma rede neural são interconectadas através de parâmetros internos denominados pesos ( $w$ ). O algoritmo de “backpropagation” com a função de ativação sigmóide é usado para treinar a rede, que utiliza o método iterativo do gradiente descendente que minimiza o erro meio quadrático entre a saída desejada e a saída da rede.

O modelo típico do neurônio utilizado no algoritmo de *backpropagation*, é apresentado na Fig. (1), onde as entradas  $x_n$  são conectadas pelos seus respectivos pesos  $w_n$  para o processamento de sua saída por intermédio da função de ativação  $f(I)$ .

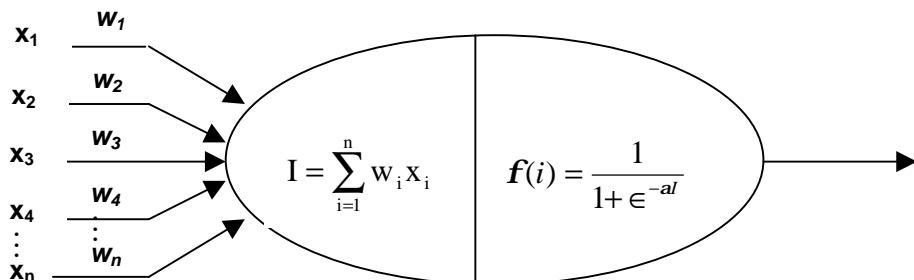


Figura 1. Neurônio de processamento do algoritmo *backpropagation* com função de ativação sigmóide.

Para o melhor entendimento da implementação, suponhamos uma rede neural com uma camada de entrada uma oculta e uma saída para o mapeamento de um problema com  $x_n$  entradas e  $y_n$  saídas como mostra a Fig. (2)

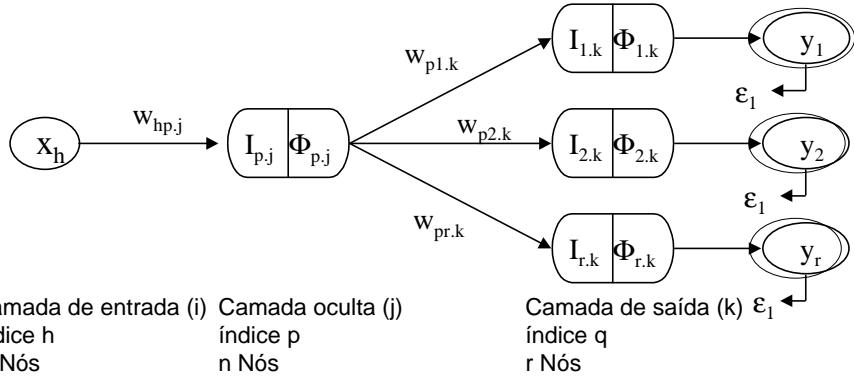


Figura 2. Esquema de rede neural com uma camada oculta, mostrando os símbolos e os índices.

Uma vez propagadas as entradas da rede, define-se o erro médio quadrático:

$$e^2 = [Y_r - \Phi_{rk}]^2 \quad (1)$$

Onde  $Y_r$  são as saídas desejadas e  $\Phi_{rk}$  são as saídas propagadas da rede. A Atualização de pesos na camada de saída. São mudadas em proporção ao erro quadrático médio em relação aos respectivos pesos. A equação (2) é o calculo da derivada para uma rede de duas camadas (oculta e saída).

$$\Delta w_{pq,k} = -h_{p,q} \frac{\frac{d}{d w_{pq,k}} e^2}{\frac{d}{d w_{pq,k}}} \quad (2)$$

Onde  $h_{p,q}$  “learning” é uma constante de proporcionalidade associado a uma taxa de aprendizagem dos pesos  $w_{pq,k}$ .

Para resolver esta derivada parcial utiliza-se a regra da cadeia que resulta na Eq. (3).

$$\Delta w_{pq,k} = -h_{p,q} \cdot \frac{\frac{d}{d \Phi_{q,k}} e^2}{\frac{d}{d \Phi_{q,k}}} \cdot \frac{\frac{d}{d I_{q,k}} \Phi_{q,k}}{\frac{d}{d I_{q,k}}} \cdot \frac{\frac{d}{d w_{pq,k}} I_{q,k}}{\frac{d}{d w_{pq,k}}} \quad (3)$$

Onde:

$$d_{pq,k} = 2[T_q - \Phi_{q,k}] \Phi_{q,k} [1 - \Phi_{q,k}] \quad (4.7e)$$

Logo os pesos são atualizados seguindo a equação (4), de recorrência:

$$w_{pq,k}(N+1) = w_{pq,k}(N) + h_{p,q} \cdot d_{pq,k} \cdot \Phi_{p,j} \quad (4)$$

Note que  $N$  é número de iterações ou épocas.

Para o cálculo dos pesos que estão entre a camada de entrada e a camada oculta utiliza-se as seguintes derivadas.

$$\Delta w_{hp,j} = -h_{h,p} \frac{\frac{d}{d w_{hp,j}} e^2}{\frac{d}{d w_{hp,j}}} \quad (5)$$

Onde  $\mathbf{h}_{hp,p}$  é outra constante proporcional de aprendizagem relativa à atualização dos pesos  $w_{hp,j}$  novamente utilizando a regra da cadeia a equação (5), pode ser escrita;

$$\Delta w_{hp,j} = -\mathbf{h}_{hp,p} \frac{\|\mathbf{e}_q\|^2}{\|\Phi_{q,k}\|} \cdot \frac{\|\Phi_{q,k}\|}{\|I_{q,k}\|} \cdot \frac{\|\Phi_{p,j}\|}{\|I_{p,j}\|} \cdot \frac{\|\Phi_{p,j}\|}{\|I_{p,j}\|} \cdot \frac{\|\Phi_{p,j}\|}{\|w_{hp,j}\|} \quad (6)$$

Onde:

$$\mathbf{d}_{hp,j} = \mathbf{d}_{pq,k} w_{pq,k} \frac{\|\Phi_{p,j}\|}{\|I_{p,j}\|} \quad (7)$$

logo os pesos  $w_{hp,j}$  são atualizados seguindo a equação 8, de recorrência:

$$w_{hp,j}(N+1) = w_{hp,j}(N) + \mathbf{h}_{hp} x_h \mathbf{d}_{hp,j} \quad (8)$$

Nas duas equações aparece o termo  $\mathbf{h}$  referente à taxa de aprendizado, esta variável determina pequenas mudanças nos pesos da rede de uma iteração a outra.

Uma outra maneira de evitar bruscas oscilações sem a necessidade de escolher uma taxa de aprendizado pequena é a inserção do termo *momentum*, a sim as equações ficam rescritas:

$$w_{pq,k}(N+1) = \mathbf{a} \cdot w_{pq,k}(N) + \mathbf{h}_{pq} \cdot \mathbf{d}_{pq,k} \cdot \Phi_{p,j} \quad (9)$$

$$w_{hp,j}(N+1) = \mathbf{a} \cdot w_{hp,j}(N) + \mathbf{h}_{hp} x_h \mathbf{d}_{hp,j} \quad (10)$$

Onde  $\mathbf{a}$  é usualmente um número positivo chamado constante de *momentum*, e controla o ciclo de realimentação da variação do peso.

### 3. MÉTODO DE MODELAGEM DO SISTEMA DE COMPRESSÃO A VAPOR

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.

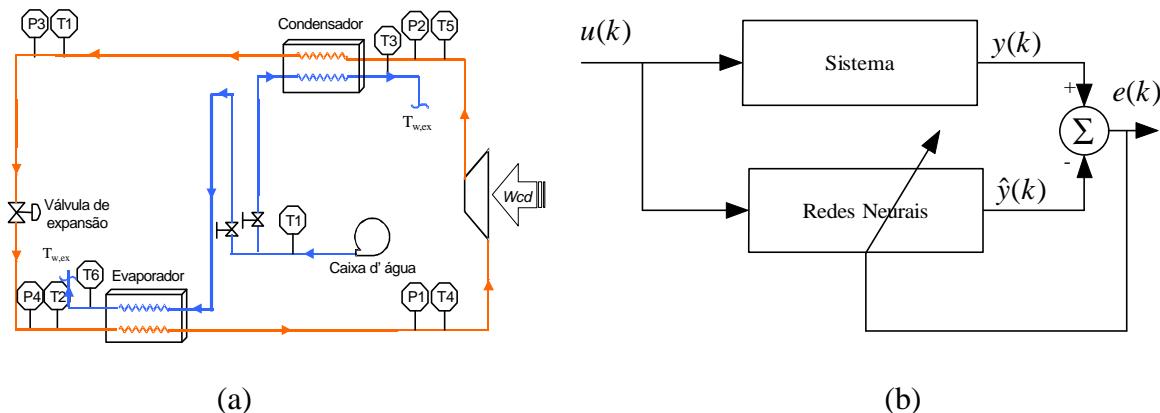


Figura 3. Diagramas da bancada experimental e modelagem do sistema.

A figura (3b) mostra a estrutura da modelagem do sistema utilizando redes neurais artificiais, cada componente do sistema foi modelado separadamente. Uma das grandes vantagens de utilizar este tipo de modelo é que não é exigido um conhecimento a priori da planta para a modelagem dos componentes.

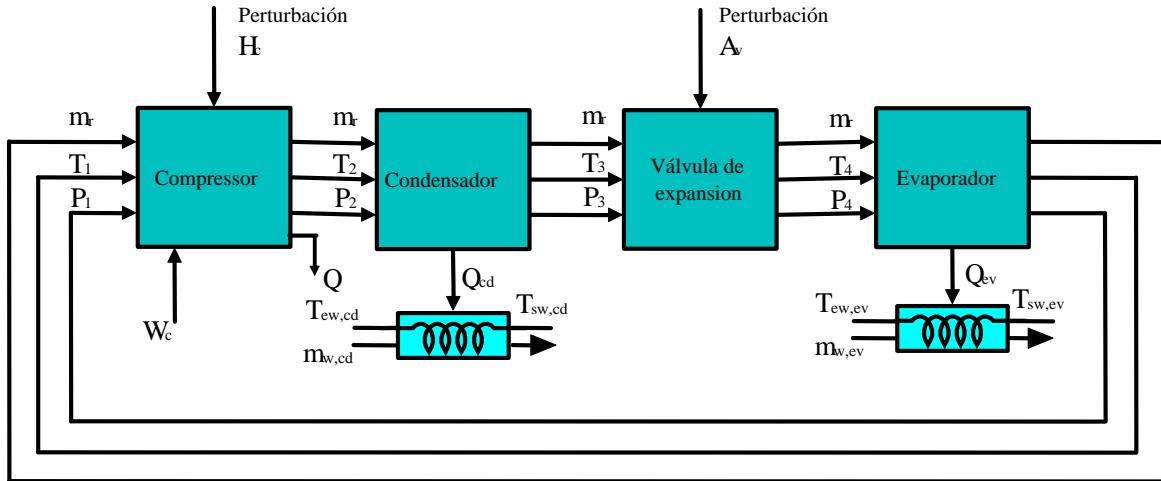


Figura 4. Diagrama de blocos do protótipo de refrigeração

Na figura 4 pode-se observar que cada componente tem suas respectivas estradas e saídas, que facilitam a sua modelagem já que não possuem nenhuma dependência explícita do tempo, por se tratar de uma modelagem estática.

#### 4. ANALISE DE RESULTADOS

A tabela a seguir apresenta os índices de desempenho conseguidos em cada componentes do sistema. O erro mínimo foi atingido no condensador  $I_w = 0.275e-4$ , com uma taxa de aprendizagem de  $h = 0.4$

Tabela 1. Índices de desempenho

Componentes	Erro	Iterações
Compressor	0.3e-3	200
Condensador	0.275e-4	270
Válvula de expansão	0.267e-3	300
Evaporador	0.472e-3	250

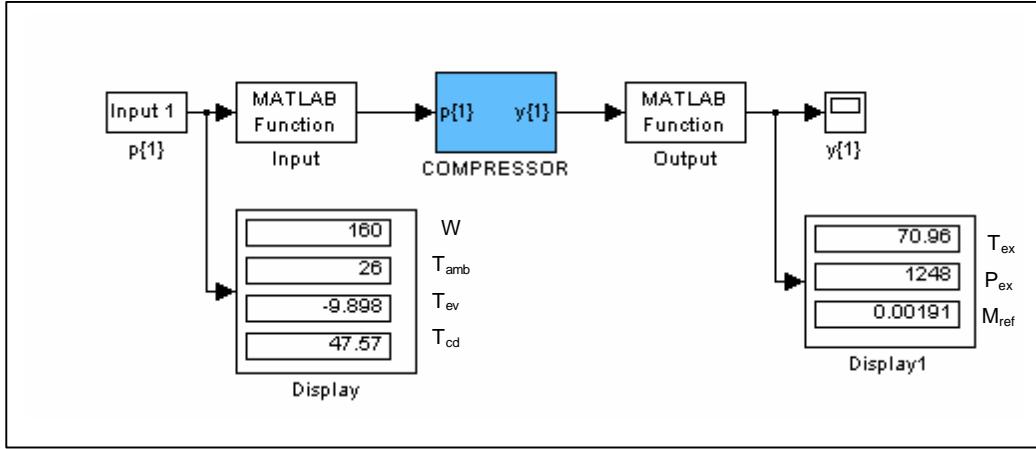


Figura 5. Exemplo da simulação do compressor.

Na figura 5 se observa que a modelagem realizada permite mudar dados de entrada ( $\dot{w}, T_{amb}, T_{ev}, T_{cd}$ ), de forma aleatória o e modelo calcula a resposta do componente ( $T_{ex}, P_{ex}, \dot{m}_{ref}$ ) e os efeitos sobre todo o sistema.

A seguir pode-se observar algumas simulações feitas para validar o modelo caixa preta com dados experimentais, com os ajustes dos pontos experimentais segundo as correlações lineares propostas pelo modelo.

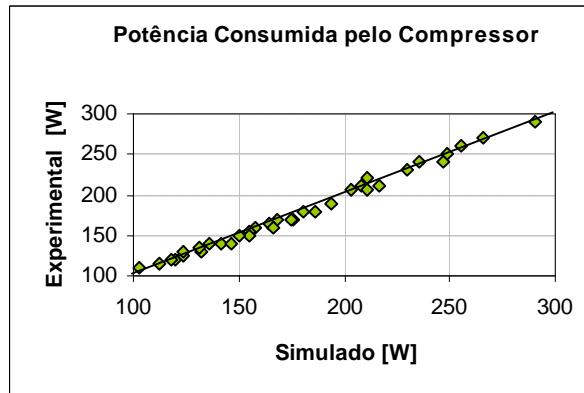


Figura 6. Comparação de potencia consumida simulada e experimental.

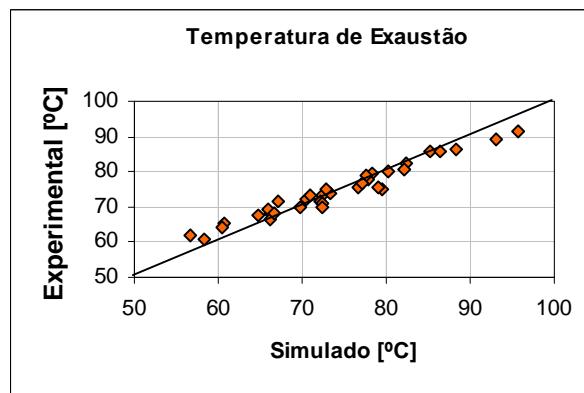


Figura 7. Comparação da temperatura de exaustão do compressor simulada e experimental.

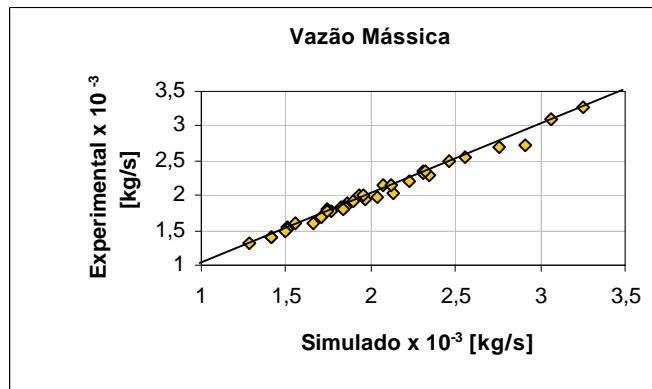


Figura 8. Comparação da vazão mássica simulada e experimental.

## 5.CONCLUSÕES

A utilização de redes neurais artificiais como modelo caixa-preta, apresenta resultados satisfatórios na modelagem do sistema de refrigeração de compressão de vapor. Uma das vantagens desta metodologia consiste na informação obtida sobre o comportamento do sistema o qual permite visualizar quando é possível linearizar os modelos e, portanto fazer modelagens simplificadas, assim como determinar parâmetros semi-empíricos, além de exigir um pequeno esforço computacional, que é característica importante em modelos para a simulação global de sistemas. No futuro pretende-se realizar uma maior quantidade de ensaios, com aquisição em tempo real da potência consumida, para que se possamos avaliar melhor o desempenho do modelo e a influência do transiente do compressor no comportamento do sistema, bem como a dinâmica do sistema onde se terá em consideração a evolução das variáveis no tempo.

## 6. REFERÊNCIAS

- Guanghui SU. Kenji Fukuda. "Applications of Artificial Neural Network for the Prediction of Flow Boiling Curves"
- Braun, J., and Rossi, T., 1999, "A Real - Time Transient Model for Air Conditioners", 20th International Congress of Refrigeration, IIR/IIF, Sydney.
- Chi, J. and Didion, D., 1982, "A Simulation Model of the Transient Performance of a Heat Pump", International Journal of Refrigeration, Vol. 5, p. 176-184.
- MacArthur, J., 1984, "Analytical Representation of the Transient Energy Interactions in Vapor Compression Heat Pumps", ASHRAE Transactions, Vol. 90, Pt. 1b. p. 982-996.
- Rigola, J., Pérez-Segarra, C., Oliva, A., Serra, J., Escribà, M. and Pons, J., 1996, "Parametric Study and Experimental Comparison of Small Hermetic Refrigeration Compressor Using an Advanced Numerical Simulation Model", International Compressor Engineering Conference, Purdue University, pp. 737-742.
- Procel, 1998, <http://www.eletrobras.gov.br/procel/>
- Yassuda, H., Touber, S., and Machielsen, C., 1983, "Simulation Model of a Vapor Compression Refrigeration System", ASHRAE Transactions, Vol. 89, Pt. 2A and B.

## 7. DIREITOS AUTORAIS

Os autores são os únicos responsáveis pelo conteúdo do material impresso incluído no seu trabalho.

# **BLACK-BOX MODEL APPLICATION ON REFRIGERATION SYSTEMS**

## **Tumialán J. A.**

Federal University of Uberlândia . Faculty of Mechanical Engineering  
Laboratory of Energy and Thermal Systems  
Av. João Naves de Ávila, 2.121, Bloco 1M  
CEP 38408-100, Uberlândia . MG, Brazil  
e-mail: [jtumialan@mecanica.ufu.br](mailto:jtumialan@mecanica.ufu.br)

## **Hernandez O. S.**

Federal University of Uberlândia . Faculty of Mechanical Engineering  
Laboratory of Energy and Thermal Systems  
Av. João Naves de Ávila, 2.121, Bloco 1M  
CEP 38408-100, Uberlândia . MG, Brazil  
e-mail: [oscarhm@mecanica.ufu.br](mailto:oscarhm@mecanica.ufu.br)

## **Julio D. A.**

Federal University of Uberlândia . Faculty of Mechanical Engineering  
Laboratory of Energy and Thermal Systems  
Av. João Naves de Ávila, 2.121, Bloco 1M  
CEP 38408-100, Uberlândia . MG, Brazil  
e-mail: [dorisjullio@mecanica.ufu.br](mailto:dorisjullio@mecanica.ufu.br)

**Abstract.** This work presents a static modeling from a steam compression refrigeration system using a black-box (Artificial Neural Network) with a training algorithm “back propagation”. Model is strongly dependant on the components (compressor, condenser, expansion device, evaporator, etc.) features of the MIMO (Multiple Input Multiple Output) system. Experimental data from a refrigeration system prototype, located in the Laboratory of Energy and Thermal Systems LEST/FEMEC/UFU, were used. Results from the model were satisfactory for different system parameters, like: consumed power, massic flow, system performance coefficient. This way of modeling provides information about the behavior of each component parameters, operating like a tool to be used to develop simplified semi-empirical modeling.

**Keyword:** Modeling, Refrigeration, Neural Network