

## APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA MODELAGEM DO COMPORTAMENTO TÉRMICO DE CONDENSADORES EVAPORATIVOS

### Felipe Roman Centeno

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmento Leite, 425, sala 314, 3º andar, 90050-170, Porto Alegre, RS, Brasil, tel.: +55 51 3316-3776 fax.: +55 51 3316-4001  
frccenteno@yahoo.com.br

### Herbert Martins Gomes

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmento Leite, 425, sala 314, 3º andar, 90050-170, Porto Alegre, RS, Brasil, tel.: +55 51 3316-3541 fax.: +55 51 3316-3681  
herbert@mecanica.ufrgs.br

### Paulo Otto Beyer

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmento Leite, 425, sala 314, 3º andar, 90050-170, Porto Alegre, RS, Brasil, tel.: +55 51 3316-3360 fax.: +55 51 3316-4001  
pob@mecanica.ufrgs.br

### Paulo Smith Schneider

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmento Leite, 425, sala 311, 3º andar, 90050-170, Porto Alegre, RS, Brasil, tel.: +55 51 3316-3931 fax.: +55 51 3316-4001  
pss@mecanica.ufrgs.br

*Resumo: Este trabalho descreve uma aplicação de redes neurais artificiais (RNAs) para prever o comportamento de um condensador evaporativo empregado em sistemas de refrigeração por compressão de amônia. A fim de obter dados para treinamento e validação da RNA proposta, usam-se as informações divulgadas pelo fabricante do condensador, presentes em seus catálogos. Parte desses dados são utilizados na montagem da RNA modelo para o equipamento, com treinamento baseado no algoritmo de Levenberg Marquardt, e com ela determina-se a taxa de rejeição de calor para diferentes entradas de temperatura de condensação da amônia e de temperatura de bulbo úmido do ar. As previsões obtidas com a RNA concordam bem com os valores do catálogo do fabricante, com erro médio relativo de 1.86%, com confiança de 95.45%. Utilizando a RNA modelada, é feita a simulação de parâmetros interpolados, obtendo desvios na faixa de 0.27- 3.25%, e extrapolados, os quais se mostram coerentes com as curvas de comportamento do equipamento. Os resultados mostram que condensadores evaporativos, apesar de envolverem transferência simultânea de calor e massa, podem alternativamente ser modelados usando RNAs com bom grau de acerto.*

*Palavras chave: Redes neurais artificiais, Condensador evaporativo, Refrigeração, Amônia*

### 1. Introdução

Condensadores evaporativos (CE's) rejeitam calor para o ambiente externo, resultante da condensação do fluido de trabalho do equipamento. No caso do equipamento em estudo, vapor de amônia (NH<sub>3</sub>) superaquecido proveniente da descarga do compressor é admitido no conjunto de serpentinas do condensador. Pelo lado externo, uma corrente de ar forçado é misturada com outra corrente de água, escoando em sentidos opostos. A água admitida sofre evaporação, até o limite de saturação do ar que escoar em contracorrente, provocando assim o rebaixamento de sua temperatura e intensificando a transferência de calor, como é mostrado esquematicamente na Fig. 1.

Tanto o ar como a água atuam em conjunto para promover sua retirada do calor proveniente da condensação da amônia, sendo que a evaporação da água na corrente de ar é o mecanismo mais importante. A massa de água evaporada é pequena em relação ao total que circula no sistema, e sua reposição e recirculação são feitas a partir de uma bacia, localizada na parte inferior no condensador. Assim, fica claro que se tem uma combinação das características dos condensadores resfriados a água e a ar.

CE's são largamente empregados na refrigeração industrial, pois consomem menos energia do que os modelos que operam apenas com ar ambiente, promovem trocas de calor maiores por unidade de área do equipamento e permitem a operação com temperaturas de descarga reduzidas (Stoecker e Jabardo, 2002).

A montagem de uma RNA depende de dados do comportamento dos equipamentos. O fabricante dos mesmos está desenvolvendo paralelamente a esse trabalho a montagem de um laboratório de ensaios para esse fim, mas para a primeira abordagem dessa técnica, recorreu-se aos dados disponíveis em catálogo. Nela, o calor rejeitado pelo CE é obtido a partir do conhecimento da temperatura de bulbo úmido do ar na entrada,  $T_{wbl}$ , e da temperatura de condensação do fluido refrigerante,  $T_C$ .




Figura 1. Representação esquemática de um condensador evaporativo (Flores, 2005).

Para um sistema de refrigeração com condensador evaporativo, Ertunc et al.,2005, aplicou RNA para prever o seu desempenho. A fim de obter dados para treinar e testar a RNA proposta, foi montado um sistema de refrigeração experimental, sendo realizados 60 testes em diferentes condições de operação, todos em regime permanente, variando a carga no evaporador, vazão de água e de ar e temperaturas de bulbo seco e de bulbo úmido do ar na entrada do equipamento. Utilizando alguns dos dados experimentais, uma modelagem em RNA foi desenvolvida para o sistema, baseada no algoritmo de Levenberg-Marquardt, sendo a sua arquitetura composta por 5 neurônios na camada de entrada, uma camada oculta com 4 neurônios, e 5 neurônios na camada de saída, e usando função de ativação tipo tangente sigmóide. A RNA foi usada para prever a taxa de rejeição de calor no condensador, a vazão mássica de refrigerante, a potência do compressor, a potência elétrica do motor do compressor, e o coeficiente de desempenho. As previsões desta RNA concordaram com os valores experimentais, com erros médios relativos na faixa de 1.90- 4.18%.

No presente estudo, a aproximação por RNA foi aplicada na modelagem do comportamento térmico de um condensador evaporativo. Utilizando dados fornecidos pelo fabricante do equipamento, uma RNA modelo para este tipo de comportamento foi desenvolvida, sendo esta usada para prever a capacidade de rejeição de calor no condensador evaporativo.

## 2. Redes Neurais Artificiais

Uma RNA tenta representar as funções cerebrais de forma computacional recorrendo ao mecanismo de aprendizado com base no comportamento humano. Suas habilidades de aprendizado por exemplos tornam as RNAs mais flexíveis e poderosas do que aproximações paramétricas com ajustes de funções (Hagan et al, 1996).

RNAs consistem em massivos nós de processamento interconectados, conhecidos como neurônios. O neurônio, visto na Fig. 2, é a unidade básica de uma RNA e, como uma unidade de processamento, deve receber estímulos ( $x_i$ ) pelas conexões dos axônios.




Figura 2. Neurônio: unidade básica de processamento ([www.cerebromente.org.br](http://www.cerebromente.org.br)).

Para se obter a saída desejada, deve-se haver transformações nestes estímulos, a qual ocorre em duas etapas. Primeiramente ocorre uma transformação do tipo linear nesses estímulos, obtendo um escalar, conhecido como *NET*, dado pela Eq. (1). Os coeficientes desta transformação linear são conhecidos como “pesos” e são representados por  $w_i$ .

$$NET = \left( \sum_{i=0}^P w_i x_i \right) \quad (1)$$

onde  $P$  é o número de estímulos. Na segunda etapa é aplicada uma transformação neste escalar  $NET$ , a qual pode ser linear ou não-linear, denominando-se por “função de ativação”, representada por  $f$ . Assim como no comportamento do neurônio humano, a função de ativação decidirá quando e como a saída ( $y$ ) do neurônio ocorrer. Como indicado na Fig. 2, há uma entrada com valor constante ( $x_0 = +1$ ) e seu respectivo peso ( $w_0$ ), a qual é um parâmetro relacionado na função de ativação chamado *bias*, sendo este considerado como desconhecido na Eq. (1), apenas por conveniência, o que fornece uma respectiva saída. Este processo pode ser escrito como: (Haykin, 2001)

$$y = f(NET) = f\left[\left(\sum_{i=0}^P w_i x_i\right)\right] \quad (2)$$

Há muitas maneiras de definir a função de ativação, como função linear, função sigmóide, função tangente hiperbólica, etc. Estas unidades básicas de processamento podem ser conectadas de diferentes formas entre si, e podem operar de diversas maneiras, formando assim uma grande variedade de redes neurais.

RNAs podem ser treinadas para simular uma determinada função pelo ajuste dos pesos sinápticos das conexões entre os neurônios, partindo de dados de entrada e de saída, comparando estes com os obtidos pela simulação da rede, sendo então ajustados os pesos até que a resposta simulada seja igual a resposta requerida, dentro de um intervalo de incerteza. O erro entre a saída da rede e a saída desejada é minimizado pela modificação dos pesos. Quando o erro atinge um certo valor ou o número máximo de iterações é excedido, o processo de treinamento é cessado. Então, esta rede treinada pode ser usada para simular as saídas do sistema devido a novos estímulos.

A arquitetura de uma RNA é usualmente dividida em três partes: um camada de entrada, camada(s) oculta(s), e uma camada de saída. A informação contida na camada de entrada é mapeada para a camada de saída através da(s) camada(s) oculta(s). Cada unidade pode enviar sua saída somente para unidades de camadas superiores e receber suas entradas de camadas inferiores. Para um dado problema de modelagem, o número de nós nas camadas de entrada e de saída é determinado pela física do problema, sendo igual ao número de parâmetros de entradas e de saída, respectivamente.

O desempenho de uma RNA é avaliado pela análise de regressão entre as saídas da rede, i.e., parâmetros encontrados, e correspondentes alvos, i.e., valores experimentais (reais). Usualmente as saídas  $y_i$  da RNA devido a uma entrada  $x_i$  não serão os valores desejados de saída  $d_i$  usados durante o processo de treinamento. Para cada conjunto de entradas e saídas, o Erro Momentâneo,  $\varepsilon_i$ , pode ser escrito como:

$$\varepsilon_i(t) = d_i - y_i(t) \quad (3)$$

onde  $i$  é o número de neurônios na camada de saída e  $t$  refere-se a iteração em que a simulação está. O Erro Quadrático Médio,  $E_{rms}$ , é dado por:

$$E_{rms} = \frac{1}{P} \sum_P [d_i - y_i(t)]^2 \quad (4)$$

onde  $P$  é o número de conjunto de dados usados no treinamento. Empregando qualquer algoritmo para minimizar a função erro (por exemplo Levenberg-Marquardt), os pesos podem ser calculados e uma função de aproximação pode ser obtida. Um parâmetro comum utilizado em qualquer algoritmo básico usado no treinamento de redes (como retro-propagação) é a “taxa de aprendizagem” a qual define a taxa na qual o aprendizado é alcançado. Tal parâmetro deve ser cuidadosamente escolhido para evitar instabilidades numéricas ou problemas com divergência. A capacidade de generalização e acerto do ajuste pode ser estimada pelo Erro Médio Quadrático avaliado com alguns conjuntos de dados não utilizados no treinamento (Kovacs, 1996).

### 3. Modelagem com RNA

Na solução do problema do condensador evaporativo a variável desejada é a taxa de rejeição de calor  $Q_C$ , expressa em kcal/h nos catálogos do fabricante, o que expressa sua potência ou capacidade. Essa potência depende da temperatura de bulbo úmido do ar na entrada do equipamento  $T_{wbl}$  e da temperatura de condensação do refrigerante  $T_C$ , ambas expressas em °C, e servem como parâmetros de entrada de uma tabela de fatores de correção de capacidades. Nela, o valor unitário corresponde ao valor nominal do equipamento, marcado em vermelho na tabela apresentada no Anexo 1. Assim, adota-se um comportamento padrão relativo à variável  $Q_C$ , o qual segue curvas conhecidas como função das variáveis  $T_{wbl}$  e  $T_C$ , conforme pode ser visto na Fig. 3, para que possa ser realizada a modelagem por RNA.

Uma parte dos dados da Fig. 3 serão usados como entradas para o treinamento da RNA, através do algoritmo de Levenberg-Marquardt, também utilizado por Ertunc et al, 2005. Outra parte será usada para validação do processo de ajuste, com os critérios definidos pelas Eqs. (3) e (4).

Pode-se imaginar não somente um, mas alguns conjuntos de dados para treinar a rede neural. Isto leva a uma

situação onde maior o número de conjunto de dados, menor a limitação de uso da RNA. Isto tende a melhorar a representação do problema real, onde vários dados podem ser usados.

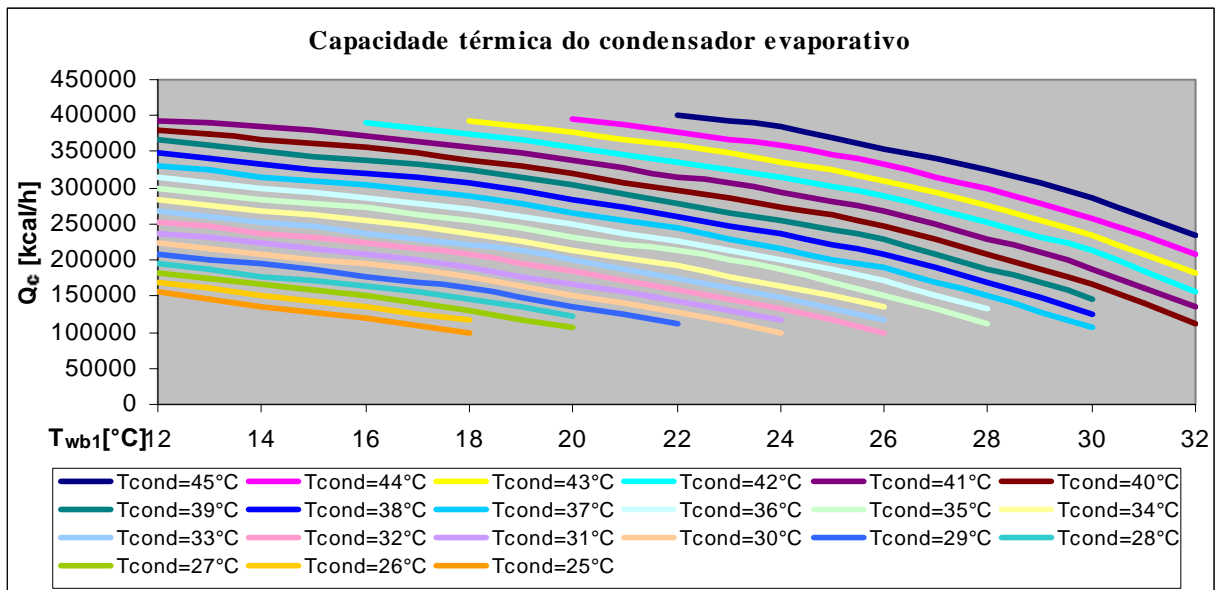


Figura 3. Capacidade térmica do condensador evaporativo  $Q_c$ , kcal/h.

A arquitetura da RNA utilizada para a modelagem do comportamento térmico do condensador evaporativo, com os nomes dos parâmetros de entrada e saída, está ilustrado esquematicamente na Fig. 4.




Figura 4. Estrutura da RNA para o estudo do condensador evaporativo.

O código computacional utilizado para resolver o algoritmo de Levenberg-Marquardt foi desenvolvido usando MATLAB<sup>®</sup> 6 (*The MathWorks, Inc., 2001*), o qual usa função de ativação tangente sigmóide nas camadas escondidas e linear na camada de saída.

#### 4. Resultados e discussões

A melhor arquitetura encontrada (Fig. 4) para a RNA foi (2:10:10:1), a qual significa dois vetores de entrada, seguido por duas camadas escondidas com dez neurônios cada e uma camada de saída com um neurônio, taxa de aprendizagem de 0,10 e critério de convergência de  $10^{-4}$ , conforme Eq. (4).

Do total de 319 amostras, presentes no Anexo 1, 52 foram utilizadas no treinamento e outras 170 utilizadas na validação da RNA. A Fig. 5 mostra a curva do Erro Quadrático Médio,  $E_{rms}$ , dado pela Eq. (4), em relação às épocas durante a fase de treinamento da RNA, observando que para este caso foram necessárias 11 épocas para que o  $E_{rms}$  atingisse o critério de convergência previamente especificado. Na Fig. 6, a curva do comportamento do condensador obtida a partir de dados do catálogo (+) é mostrada com os dados de validação obtidos usando a RNA treinada previamente (X). Nota-se que cada família de pontos refere-se a uma temperatura de condensação  $T_c$ , conforme pode

ser visto também na Fig. 3. Na Fig. 6, os pontos de validação seguem a mesma tendência, sempre muito próximos das curvas de comportamento, com Erro Médio Relativo de 1.86%, para confiança de 95.45%, valor este abaixo dos presentes em Ertunc et al., 2005, mostrando que o treinamento mesmo com poucos pontos foi suficiente para capturar o comportamento completo do fenômeno.

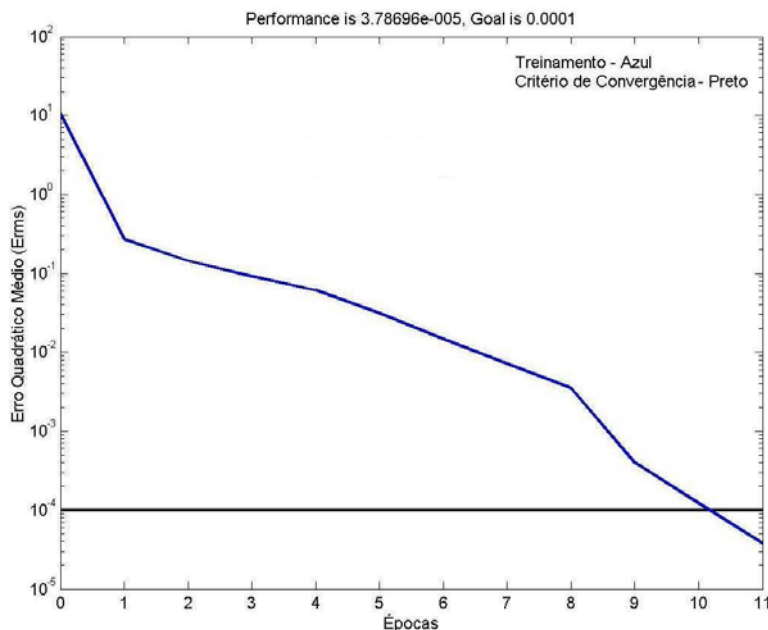


Figura 5. Erro Quadrático Médio (Eq. 4) em função da época de treinamento da RNA.




Figura 6. Capacidade Térmica do Condensador Evaporativo, kcal/h.  
(+) para dados de Catálogo e (X) para saída da RNA

Com a finalidade de conhecer a capacidade da RNA, proposta acima, em simular situações variadas de operação do CE, empregam-se novos valores, obtidos pela interpolação e extrapolação daqueles divulgados no catálogo do fabricante.

Observando-se a Tab. 1, em que os valores da 3ª coluna correspondem aos valores de  $Q_C$  encontrados pela RNA, e os da 4ª coluna correspondem à tais potências mais próximas ao valor calculado para a *interpolação*, para diferentes temperaturas de bulbo úmido do ar e temperaturas de condensação da amônia, presentes nas duas primeiras colunas, respectivamente. Para este caso de simulação do CE através da RNA, os valores de  $Q_C$  apresentam desvios percentuais

que variam de 0.27 a 3.25%, em relação aqueles obtidos pela interpolação algébrica de dados catalogados, conforme se observa pela 6ª coluna da Tab. 1.

Tabela 1. Capacidade Térmica do Condensador Evaporativo [kcal/h] – Resultados da Interpolação com a RNA.

$T_{bu}$ [°C]	$T_C$ [°C]	$Q$ [kcal/h] (1)	$Q$ [kcal/h] (2)	Desvio [kcal/h]	Erro [%]
14,7	28,3	182500	176560	5940	3.25
19,4	28,3	134500	138170	3670	2.65
12,6	34,4	287500	284260	3240	1.12
17,5	34,7	283000	285520	2520	0.88
23,4	35,8	200500	206330	5830	2.82
31,7	40,6	137000	131950	5050	3.69
28,6	44,5	301500	302320	820	0.27

(1) valores resultantes da simulação da RNA; (2) valores interpolados daqueles presentes no Anexo 1

O emprego da simulação com a RNA para valores *extrapolados* levou aos resultados apresentados na Fig. 7, na qual nota-se que tais resultados seguem a mesma tendência do comportamento térmico do CE.




Figura 7. Capacidade Térmica do Condensador Evaporativo, kcal/h (X) para dados de Catálogo e (+) para saída da RNA.

Conforme mostrado na Tab. 1 e na Fig. 7, a RNA proposta possui a capacidade de simular o comportamento do CE mesmo em faixas de operação distintas das apresentadas pelo seu fabricante, sendo assim, quaisquer que sejam os dados de entrada fornecidas para a RNA, esta trará como resposta valores coerentes para  $Q_C$ . Por exemplo, pode-se citar o caso da cidade de Caxias do Sul, RS – Brasil, onde, no inverno, a  $T_{bu}$  normalmente fica abaixo de 12°C, valor este não disponível em catálogo, sendo assim, é possível a determinação do  $Q_C$  para esta aplicação através do uso da RNA apresentada acima a qual está devidamente treinada e validada.

## 5. Conclusões

A técnica de redes neurais artificiais (RNA) para modelar o comportamento térmico do condensador evaporativo (CE) pode ser recomendada de acordo com os resultados mostrados neste trabalho.

O comportamento de sistemas não lineares é bem representado por RNA's, e os resultados encontrados são adequados do ponto de vista de engenharia e tem potencial para serem aplicadas em casos reais.

Sugere-se que um estudo mais aprofundado deva ser conduzido para identificar a importância de outros parâmetros intervenientes, tais como vazão mássica de ar, água e amônia. O modelo pode levar a melhores resultados e menos esforços para treinamento desde que números adimensionais sejam usados.

Espera-se avançar na qualidade dos resultados da simulação com RNA a partir de ensaios que vem sendo desenvolvidos atualmente na bancada experimental de condensadores evaporativos montada na empresa FrostFrio. A bancada deverá auxiliar no desenvolvimento de novas soluções para os equipamentos, ao mesmo tempo que servirá para fornecer dados para o emprego de RNA's como ferramenta de seleção de equipamentos para os usuários dos sistemas.

## 6. Agradecimentos

Ao CNPq pelo apoio financeiro ao primeiro autor do trabalho na forma de bolsa de mestrado e ao corpo técnico da empresa Frost Frio Refrigeração Industrial pelos dados concedidos.

## 7. Referências

- Ertunc, H. M., Hosoz, M., “Artificial neural network analysis of a refrigeration system with an evaporative condenser”, Applied Thermal Engineering, *In Press*, (2005).
- Flores, F. S., 2005, “Modelamento matemático de condensadores evaporativos pelo método e-NUT”, Monografia (Trabalho de Conclusão de Curso de Engenharia Mecânica), Departamento de Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS.
- Frost Frio Refrigeração Industrial, 2004, “Catálogo de condensadores evaporativos”, Caxias do Sul, RS.
- Hagan, M. T., Demuth H. B., Beale, M., 1996, “Neural Network Design”, PWS Publishing Company, Boston, MA.
- Haykin, S., 1994, “Neural Networks: A Comprehensive Foundation”, Mc Millan, NJ.
- Kovacs, Z. L., 1996, “Redes Neurais Artificiais: Fundamentos e Aplicações”, Edição Acadêmica São Paulo, Escola Politécnica da Universidade de São Paulo, São Paulo.
- Looney, C. G., 1997, “Pattern Recognition Using Neural Networks: Theory and Algorithms for Engineers and Scientists”, Oxford University Press, NY.
- Stoecker, W. F., Jabardo, J. M., 2002, “Refrigeração Industrial”, 2.ed., Edgard Blücher, São Paulo, SP.

## 8. Responsabilidade

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

## 9. Anexos

Anexo 1. Fatores de correção de capacidades para condensador evaporativo\* (Fonte: Catálogo Frost Frio, 2004).

FATORES DE CORREÇÃO DE CAPACIDADES - REFRIGERANTE NH3																						
TEMP. COND. (°C)	PRESSÃO COND. - MAN. (kgf/cm <sup>2</sup> )	TEMPERATURA DE BULBO ÚMIDO (°C)																				
		12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32
45	17,16										2	1,96	1,92	1,85	1,77	1,7	1,62	1,53	1,43	1,3	1,17	
44	16,68									1,98	1,94	1,89	1,84	1,79	1,73	1,66	1,58	1,49	1,39	1,29	1,17	1,04
43	16,21							1,97	1,93	1,88	1,84	1,79	1,74	1,68	1,62	1,55	1,47	1,38	1,28	1,17	1,04	0,91
42	15,74					1,95	1,91	1,87	1,83	1,78	1,73	1,68	1,63	1,57	1,51	1,44	1,35	1,26	1,16	1,06	0,92	0,78
41	15,29	1,97	1,95	1,93	1,9	1,86	1,82	1,78	1,74	1,69	1,64	1,58	1,53	1,47	1,41	1,34	1,25	1,15	1,05	0,94	0,81	0,67
40	14,85	1,9	1,87	1,84	1,81	1,78	1,74	1,69	1,65	1,6	1,54	1,48	1,43	1,37	1,31	1,24	1,14	1,04	0,94	0,83	0,7	0,56
39	14,41	1,83	1,79	1,75	1,72	1,69	1,66	1,62	1,57	1,52	1,46	1,39	1,33	1,27	1,21	1,14	1,04	0,94	0,84	0,73		
38	13,99	1,74	1,7	1,66	1,63	1,6	1,57	1,53	1,48	1,42	1,36	1,3	1,24	1,18	1,11	1,04	0,95	0,85	0,74	0,62		
37	13,57	1,65	1,62	1,58	1,55	1,52	1,48	1,44	1,39	1,33	1,28	1,22	1,15	1,08	1	0,95	0,85	0,75	0,64	0,53		
36	13,16	1,57	1,54	1,5	1,47	1,43	1,39	1,35	1,3	1,25	1,19	1,13	1,07	1	0,93	0,86	0,76	0,66	0,56			
35	12,76	1,49	1,46	1,42	1,39	1,36	1,32	1,27	1,22	1,16	1,11	1,06	1	0,94	0,85	0,76	0,66	0,56	0,46			
34	12,37	1,42	1,38	1,34	1,31	1,28	1,24	1,19	1,13	1,07	1,02	0,96	0,89	0,82	0,75	0,67	0,6	0,53				
33	11,99	1,34	1,3	1,26	1,23	1,19	1,15	1,11	1,06	1	0,94	0,87	0,81	0,74	0,66	0,58	0,5	0,42				
32	11,61	1,26	1,23	1,19	1,16	1,12	1,08	1,04	0,98	0,92	0,86	0,79	0,73	0,66	0,58	0,5	0,42	0,34				
31	11,25	1,19	1,16	1,12	1,08	1,04	1	0,95	0,89	0,83	0,78	0,72	0,65	0,58	0,51	0,44	0,37	0,3				
30	10,89	1,12	1,08	1,04	1	0,97	0,93	0,88	0,82	0,76	0,7	0,64	0,57	0,5	0,44	0,38	0,32	0,26				
29	10,54	1,04	1	0,97	0,93	0,89	0,85	0,8	0,74	0,67	0,62	0,56										
28	10,2	0,97	0,93	0,89	0,86	0,82	0,78	0,73	0,67	0,61												
27	9,87	0,91	0,87	0,83	0,79	0,75	0,7	0,65	0,59	0,53												
26	9,54	0,84	0,8	0,76	0,72	0,67	0,63	0,58														
25	9,22	0,78	0,73	0,68	0,64	0,6	0,55	0,5														

FATORES DE CORREÇÃO PARA REFRIGERANTES R-12, R-22, R-502 MULTIPLICAR POR 0,9

\*Valores da tabela devem ser multiplicados por 200000 kcal/h para obter-se  $Q_c$

**APPLICATION OF NEURAL NETWORK FOR THE MODELING OF THE THERMAL BEHAVIOR OF EVAPORATIVE CONDENSERS**

**Felipe Roman Centeno**

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmiento Leite, 425, sala 314, 90050-170, Porto Alegre, RS, Brasil, tel.:+55 51 3316-3776 fax.: +55 51 3316-4001  
frcenteno@yahoo.com.br

**Herbert Martins Gomes**

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmiento Leite, 425, sala 314, 90050-170, Porto Alegre, RS, Brasil, tel.:+55 51 3316-3541 fax.: +55 51 3316-4001  
herbert@mecanica.ufrgs.br

**Paulo Otto Beyer**

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmiento Leite, 425, sala 314, 90050-170, Porto Alegre, RS, Brasil, tel.:+55 51 3316-3360 fax.: +55 51 3316-4001  
pob@mecanica.ufrgs.br

**Paulo Smith Schneider**

Universidade Federal do Rio Grande do Sul, PROMEC, Programa de Pós Graduação em Engenharia Mecânica, Av. Sarmiento Leite, 425, sala 314, 90050-170, Porto Alegre, RS, Brasil, tel.:+55 51 3316-3931 fax.: +55 51 3316-4001  
pss@mecanica.ufrgs.br

**Abstract**

This paper describes an application of artificial neural networks (ANNs) to predict the main behaviour of an evaporative condenser of the ammonia type. In order to gather the data for training and testing the proposed ANN, it was used the equipment manufacturer's catalogue. An ANN model for the evaporative condenser based on Levenberg Marquardt training algorithm was developed using some of the data. The ANN was used for predicting the unknown heat rejection rate to a known condensation temperature of the refrigerant and a known wet bulb temperature of the air entering in the condenser. The ANN predictions usually agrees with the catalogued values, with mean relative errors of 1.86%, with trust of 95.45%. Using modeled RNA, interpolated parameters are simulated, obtaining deviations in the range of 0.27 – 3.25%, and also extrapolated parameters, which are shown coherent with the curves of behavior of the equipment. Results show that evaporative condensers, despite of the simultaneously heat and mass transfer involved, could be modeled alternatively using ANNs within a high degree of accuracy.

**Keywords:** Artificial neural network, Evaporative condenser, Refrigeration, Ammonia