

REPRESENTAÇÃO E ANÁLISE DA SENSIBILIDADE DE COLETORES SOLARES VIA REDES NEURAS ARTIFICIAIS¹

Luis Enrique Zárate – zarate@pucminas.br
Laboratório de Inteligência Aplicada LICAP (PUC Minas)
Elizabeth Marques Duarte Pereira – green@pucminas.br
Grupo de Estudos em Energia (GREEN/ PUC Minas)
Jorge Moisés Assis – jorge.moises.assis@gmail.com
Laboratório de Inteligência Aplicada LICAP (PUC Minas)
Wagner Ribeiro Bitencourt Coelho – wagnerrbc@gmail.com
Laboratório de Inteligência Aplicada LICAP (PUC Minas)
Victor de Paula Gil – victorgil_mg@yahoo.com.br
Laboratório de Inteligência Aplicada LICAP (PUC Minas)

2.2 Equipamentos e sistemas de aquecimento de água

Resumo. Desde a apresentação dos coletores solares como um meio alternativo de produção de energia, muitas pesquisas vêm trabalhando com esses sistemas. Os coletores solares são extremamente influenciados pelos parâmetros de operação: temperatura ambiente (T_{amb}), temperatura de entrada da água (T_e), radiação solar (R_{ad}) e, principalmente, pelo seu processo de fabricação. Esses parâmetros são importantes para se conhecer a qualidade e a eficiência de um coletor solar específico. A eficiência desses sistemas pode ser modificada pelo seu modo de fabricação e essa condição não é considerada em modelos matemáticos de coletores. Na classificação dos coletores solares, é importante saber como T_{amb} , T_e e R_{ad} influenciam na temperatura final de saída da água (T_s) (extremamente associada à eficiência do sistema) de cada um dos coletores considerados. Essas influências podem ser obtidas através da análise da sensibilidade dos parâmetros com relação à T_s . Por outro lado, devido à sua facilidade em resolver problemas não lineares, baseados em dados reais, neste artigo, Redes Neurais Artificiais (RNA) são propostas como um meio alternativo de representar e comparar coletores solares. Logo, através de diferenciações de uma rede neural previamente treinada, os fatores de sensibilidade podem ser obtidos. Os fatores de sensibilidade mostram o quanto os parâmetros de entrada influenciam nas variáveis de saída. Neste artigo, análise de sensibilidade através de RNA, a comparação e a classificação de coletores solares são aplicadas e discutidas.

Palavras-chave: Redes Neurais Artificiais, Análise de Sensibilidade, Energia Solar, Coletores Solares.

1. INTRODUÇÃO

Devido à diminuição das bacias hidrográficas ao redor do mundo, bem como ao constante crescimento populacional, constata-se que, nessa nova realidade, o tradicional caminho de produção de energia (pelo sistema hidroelétrico) pode não ser suficiente para atender à demanda por esse bem. Desde então surgiu a necessidade de criação de novas formas de produção de energia, razão pela qual muitas alternativas vêm sendo apresentadas. Sistemas de energia solar, especialmente

¹ O projeto que deu origem ao presente trabalho foi apoiado e financiado pela Companhia de Energia de Minas Gerais (CEMIG), Grupo de Estudos em Energia (GREEN) e Pontifícia Universidade Católica de Minas Gerais (PUC Minas).

aquecedores de água, estão incluídos nessas alternativas. O sistema de aquecimento de água por meio da energia solar mais utilizado é o termossifão, no qual a parte principal é o coletor solar.

Um coletor solar é influenciado pelos parâmetros operacionais – temperatura ambiente (T_{amb}), temperatura de entrada da água (T_e), radiação solar (R_{ad}) – e, principalmente, pelo seu processo de fabricação. Esses parâmetros são importantes para se descobrir a eficiência e a qualidade de um coletor solar específico.

Existem muitas pesquisas investigando a eficiência e modelando coletores solares (Morrison e Ranatunga, 1980; Huang, 1984; Kudish, 1998; Kalougirou, 1999; Kalougirou, 2000 e Zárate, 2003). A eficiência desse tipo de sistema pode ser calculada por meio da Eq.(1), a seguir,

$$\eta = \frac{\dot{m}c_p(T_s - T_e)}{RadA_{extern}} \quad (1)$$

onde: η é a eficiência térmica, \dot{m} é a vazão, c_p é a capacidade de aquecimento da água, T_s é a temperatura de saída da água, T_e é a temperatura de entrada da água, R_{ad} é a radiação solar e A_{extern} é a área do coletor solar.

Nos últimos anos, as RNAs (Redes Neurais Artificiais) foram propostas como uma poderosa ferramenta computacional. A RNA apresenta várias vantagens sobre outras técnicas, incluindo seu bom desempenho quando trabalha com problemas não lineares, sua capacidade de generalização e o baixo tempo de processamento que pode ser alcançado quando a rede treinada estiver em operação.

Os dados dos parâmetros operacionais são coletados, geralmente, através de experimentos (conforme International Standards ASHRAE 93-86 RA 91), que dependem do lugar – condições ambientes – de onde foram coletados. Depois de levantados os dados, é importante descobrir como T_{amb} , T_e e R_{ad} influenciam na temperatura de saída da água para classificar e entender o comportamento do coletor solar diante cada material utilizado na fabricação. As atuais normas de classificação não consideram a sensibilidade do coletor a cada parâmetro de entrada; dessa forma é possível haver dois coletores com as mesmas características (materiais e geométricas), mas com diferentes eficiências, classificados no mesmo nível de qualidade. Essa diferença não é detectada pelos modelos matemáticos, podendo, contudo, ser observada através da análise de sensibilidade.

O objetivo deste trabalho é propor uma nova técnica que verifique a influência dos parâmetros de entrada em relação à temperatura de saída da água, utilizando análise de sensibilidade para determinar uma classificação mais fidedigna aos coletores solares e que além disso permita prever os impactos das decisões de projeto na eficiência. Como os modelos matemáticos mais conhecidos não conseguem representar características intrínsecas de um sistema (aspectos de fabricação), a técnica de RNA foi escolhida, em razão de permitir capacidade de generalização e aprendizado das informações do sistema presentes, de forma implícita e explícita, através dos dados coletados.

O trabalho é organizado em cinco sessões. Após a seção introdutória, apresenta-se, na segunda seção, a representação neural do coletor considerada. A expressão para calcular-se a sensibilidade será deduzida na terceira. Na quarta seção, realiza-se a análise de sensibilidade dos parâmetros dos coletores solares e finalmente, na quinta seção, são trazidas as considerações de fecho do trabalho.

2. REPRESENTAÇÃO NEURAL DO COLETOR SOLAR

Para representar coletores solares uma Rede Neural Artificial Multicamadas foi utilizada neste trabalho. Baseadas em teorias cognitivas, as redes neurais tentam trabalhar similarmente ao cérebro humano onde os neurônios de processamento estão presentes em todas as camadas da RNA. A camada de entrada recebe as entradas externas (denominada por diversos autores como camada oculta) enquanto a camada de saída é responsável por produzir uma resposta para o problema representado. Escolhendo os melhores valores para os diversos parâmetros da RNA, como o número de seus neurônios (problema ainda não resolvido), alguns autores sugeriram que o número de neurônios da camada oculta poderia ser $2n+1$, em que n é o número de entradas da rede (Zárate,

2004). Por outro lado, o número determinado de neurônios na camada de saída é igual ao número de saídas desejadas da rede.

A temperatura ambiente (T_{amb}), a temperatura de entrada da água (T_e) e a radiação solar (R_{ad}) são as variáveis usadas como entradas da RNA. A temperatura de saída da água (T_s) é a saída desejada da rede. Neste trabalho, a RNA representa o coletor solar de acordo com a Eq.(2):

$$f(T_{amb}, T_e, R_{ad}) \xrightarrow{RNA} T_s \quad (2)$$

A estrutura da rede neste trabalho pode ser esquematicamente representada como mostra a Fig. 1, a seguir. A rede contém sete neurônios ocultos (2 x entradas + 1) e um neurônio de saída.

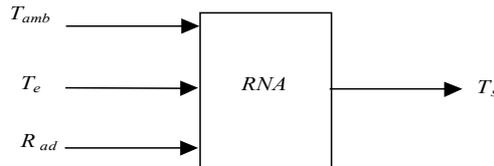


Figura 1. Diagrama esquemático da RNA

A função sigmóide não linear, Eq.(3), exibida abaixo, foi escolhida neste trabalho como função de transferência do axônio, devido ao fato de ser mais consistente em relação à biofísica de um neurônio biológico. Um dos parâmetros dessa função é a soma ponderada dos produtos das entradas e pesos associados à conexão dos neurônios.

$$f = \frac{1}{1 + \exp^{-\sum \text{Entradas} \times \text{Pesos}}} \quad (3)$$

Por outro lado, foi aplicado aprendizado supervisionado no treinamento da RNA, especificamente o mais utilizado algoritmo conhecido como retro-propagação do erro. Esse algoritmo utiliza um conjunto de dados de treinamento para o processo de aprendizagem da RNA do qual as entradas e as saídas desejadas podem ser extraídas. Para cada parâmetro do conjunto de dados de treinamento escolhido, os pesos da rede são ajustados a fim de minimizar os erros obtidos nos valores de saída. Técnica de gradiente e um fator de convergência denominado “taxa de aprendizado” são utilizados no processo de minimização de erros na saída (Zárate, 2004).

2.1 Seleção do conjunto de dados de treinamento

Os dados coletados referem-se a três coletores de alumínio feitos por fabricantes distintos. Todos os coletores foram classificados pelo INMETRO (Instituto Nacional de Metrologia) como tipo A - segue em anexo a especificação de cada coletor. Através de experimentos em diferentes situações ambientais satisfazendo as recomendações ASHRAE Standards foram coletados 728, 772 e 698 dados, para cada coletor respectivamente.

Existem inúmeras pesquisas para determinar o tamanho do conjunto de treinamento. Neste trabalho, o tamanho do conjunto foi calculado por meio de análise estatística, de acordo com a Eq.(4):

$$\eta = \left(\frac{z}{e} \right)^2 (f(1-f)) \quad (4)$$

onde n é o tamanho do conjunto de treinamento, z é o nível de confiança, e é o erro em torno da média e f é a proporção da população, cujo valor padrão é 0.5.

A fim de se obter o tamanho do conjunto, o menor erro em torno da média foi usado ($e=0,04$), com nível de confiança igual a 90% ($z=1,645$) e proporção da população em 0.5 ($f=0.5$). Nessas condições, o tamanho do conjunto de treinamento assumido foi de 423 dados. O restante dos dados foi utilizado no processo de validação.

Com o tamanho do conjunto calculado, o método escolhido para selecionar os 423 dados foi apresentado em (Zárate, 2004). O método proposto possui três etapas:

1. para cada variável da rede, os valores máximos e mínimos são encontrados no conjunto e selecionados;
2. o valor mais representativo do conjunto (ponto de operação nominal do sistema) é adicionado ao conjunto de treinamento;
3. os elementos restantes são selecionados aleatoriamente, com o propósito de se alcançar o tamanho do conjunto definido.

2.2 Preparando os dados para treinamento

Geralmente, o maior esforço para se obter uma rede treinada está na coleta e no pré-processamento dos dados de entrada. A operação de pré-processamento consiste na normalização de dados; os valores de entrada e saída ficaram na faixa de 0 a 1.

O seguinte procedimento foi adotado para normalizar os dados antes que fossem utilizados na estrutura da rede:

1. para melhorar a convergência do processo de treinamento da RNA, o intervalo de normalização [0,1] foi reduzido para [0.2 , 0.8];
2. os dados foram normalizados utilizando-se as seguintes equações:

$$f^a(L_o) = L_n = (L_o - L_{mín}) / (L_{max} - L_{mín}) \quad (5a)$$

$$f^b(L_n) = L_o = L_n L_{max} + (1 - L_n) L_{mín} \quad (5b)$$

As fórmulas acima devem ser aplicadas em cada variável do conjunto de treinamento, normalizando todos os seus valores.

3. L_{min} e L_{max} foram computados da seguinte forma:

$$L_{min} = L_{sup} - (N_s / (N_i - N_s))(L_{inf} - L_{sup}) \quad (6a)$$

$$L_{max} = ((L_{inf} - L_{sup}) / (N_i - N_s)) + L_{min} \quad (6b)$$

onde L_{sup} é o máximo valor dessa variável, L_{inf} é o mínimo valor, N_i e N_s são os limites da normalização (nesse caso, $N_i = 0.2$ e $N_s = 0.8$).

2.3 Processo de treinamento

Para o processo de treinamento, valores aleatórios (entre -1 a 1) foram atribuídos aos pesos de conexão, que são valores atribuídos a cada dado, utilizando-se os dados de treinamento. A taxa de aprendizagem foi estabelecida em 0,08 e o erro normalizado equivalente a 1°C considerando o desvio máximo aceitável recomendado pelo INMETRO. A Tab. 1 contém o erro mínimo, o erro máximo, o erro médio e o desvio do erro, obtidos durante o processo de treinamento para os três coletores considerados. O erro médio e o desvio padrão mostram resultados satisfatórios na representação neural do sistema coletor solar. A validação é o verdadeiro teste para a RNA, estando abaixo do valor esperado significa que o aprendizado foi satisfatório.

Tabela 1. Erros dos treinamentos

Coletor	Erro Min. (°C)	Erro Max. (°C)	Erro Médio (°C)	Desvio Padrão (°C)
1	2,57E-04	0,99738	0,3288357	0,573874
2	0,00106442	0,998561531	0,37303256	0,5970447
3	1,35E-04	0,9576713	0,26400324	0,34671847

2.4 Processo de validação

Para o processo de validação, foram utilizados os dados não vistos pela rede durante o aprendizado. A Tab. 2 contém o erro mínimo, o erro máximo, o erro médio e o desvio do erro, obtidos durante a validação. Os resultados mostram o bom desempenho das RNA para condições não vistas durante seu treinamento.

Tabela 2. Erros das validações

Coletor	Erro Min. (°C)	Erro Max. (°C)	Erro Médio (°C)	Desvio Padrão (°C)
1	0,0018589	0,9842099	0,3240393	0,55788422
2	0,0011116	1,084761595	0,382135966	0,61433762
3	0,00303432	0,98601165	0,265734788	0,336027404

3. OBTENDO FATORES DE SENSIBILIDADE

Antes de apresentar os fatores de sensibilidade, algumas variáveis usadas serão abordadas:

U_i , $i = 0, \dots, N$ são as entradas da rede e $U_0 = 1$ é uma entrada de polarização;

$f_i^a(.)$ $i = 0, \dots, N$ são as entradas das funções de normalização e $f_0^a(.) = 1$;

X_i , $i = 0, \dots, N$ são as entradas normalizadas $X_0 = U_0$;

W_{ij}^h $i = 1, \dots, L$ e $j = 0, \dots, N$ é o peso correspondente ao neurônio i e a entrada j ;

$net_j^h = \sum_{i=0}^N W_{ji}^h X_i$ $j = 1, \dots, L$ é o produto dos pesos pelas entradas;

$f_j^h(net_j^h)$ $j = 0, \dots, L$ com $f_0^h(net_0^h) = 1$ é a função sigmoideal da camada oculta;

I_j , $j = 0, \dots, L$ são os valores correspondentes à função sigmoideal $I_0 = 1$;

W_{ij}^o $i = 1, \dots, M$ e $j = 0, \dots, L$ é o peso do neurônio i e a entrada j para a camada oculta;

$net_j^o = \sum_{i=0}^L W_{ji}^o I_i$ $j = 1, \dots, M$ é o produto dos pesos pelas entradas da camada oculta;

$f_j^o(net_j^o)$ $j = 1, \dots, M$ é o valor da função sigmoideal da camada de saída;

Y_j , $j = 1, \dots, M$ são as saídas normalizadas da rede, obtidas através da função sigmoideal;

$f_i^b(.)$ $i = 1, \dots, M$ são as funções de desnormalização das saídas;

Z_i , $i = 1, \dots, M$ são os valores de saída da rede;

e_{\max_k}, e_{\min_k} $k = 1, \dots, N$ são os máximo e mínimo valores das entradas;

$s_{\max_k}, s_{\min_k} \quad k = 1, \dots, M$ são os máximo e mínimo valores das saídas.

3.1 Equações de sensibilidade

Neste trabalho, uma RNA multicamadas com uma camada oculta foi usada. A RNA tem N entradas, M saídas e L neurônios na camada oculta. A diferenciação de redes neurais é genérica e só depende de N, M, L e dos pesos da camada oculta e de saída, obtidas durante o processo de treinamento. O conjunto de equações para obtenção da sensibilidade da rede é:

$$\begin{aligned} Z_1 &= f_1^b(Y_1) \\ Z_2 &= f_2^b(Y_2) \\ &\vdots \\ Z_M &= f_M^b(Y_M) \end{aligned} \quad (7)$$

Substituindo as variáveis Y por seus respectivos valores, a Eq.(8), que correlaciona as entradas com as saídas normalizadas das redes, é obtida:

$$\begin{aligned} Z_1 &= f_1^b(f_1^o(\sum_{j=0}^L W_{1j}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)))) \\ Z_2 &= f_2^b(f_2^o(\sum_{j=0}^L W_{2j}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)))) \\ &\vdots \\ Z_M &= f_M^b(f_M^o(\sum_{j=0}^L W_{Mj}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)))) \end{aligned} \quad (8)$$

Por meio da substituição dos valores correspondentes para as funções $f^a(\cdot), f^b(\cdot), f^o(\cdot), f^h(\cdot)$, a Eq.(9) é obtida:

$$\begin{aligned} Z_1 &= \frac{1}{1 + \exp^{-V_1}} [s_{\max_1} - s_{\min_1}] + s_{\min_1} \\ Z_2 &= \frac{1}{1 + \exp^{-V_2}} [s_{\max_2} - s_{\min_2}] + s_{\min_2} \\ &\vdots \\ Z_M &= \frac{1}{1 + \exp^{-V_M}} [s_{\max_M} - s_{\min_M}] + s_{\min_M} \end{aligned} \quad (9)$$

Onde:

$$V_k = \sum_{j=0}^L W_{kj}^o f_j^h(\sum_{i=0}^N W_{ji}^h f_i^a(U_i)) \quad \text{para } k = 1, \dots, M \quad (10)$$

Na forma reduzida, a Eq.(9) torna-se:

$$Z_k = \frac{1}{1 + \exp^{-V_k}} [\text{smax}_k - \text{smin}_k] + \text{smin}_k \quad \text{para } k = 1, \dots, M \quad (11)$$

Os fatores de sensibilidade serão calculados através da Eq.(12):

$$\frac{\partial Z}{\partial U} = \begin{bmatrix} \frac{\partial Z_1}{\partial U_1} & \frac{\partial Z_1}{\partial U_2} & \dots & \frac{\partial Z_1}{\partial U_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial Z_M}{\partial U_1} & \frac{\partial Z_M}{\partial U_2} & \dots & \frac{\partial Z_M}{\partial U_N} \end{bmatrix} \quad (12)$$

Na qual cada termo da matriz de sensibilidade é calculado na forma:

$$\frac{\partial Z_k}{\partial U_i} = [\text{smax}_k - \text{smin}_k] \frac{\exp^{-V_k}}{(1 + \exp^{-V_k})^2} \frac{\partial V_k}{\partial U_i} \quad (13)$$

Manipulando-se a derivada da Eq.(13) e levando-se em conta a Eq.(9), a expressão seguinte é obtida:

$$\frac{\partial V_k}{\partial U_i} = \frac{\partial}{\partial U_i} (W_{k0}^o + \sum_{j=1}^L W_{kj}^o f_j^h (\sum_{i=0}^N W_{ji}^h f_i^a(U_i))) \quad (14)$$

Pela diferenciação da Eq. (14) e substituição da expressão na Eq.(13), a Eq.(15) é encontrada, o que permite o cálculo dos fatores de sensibilidade da rede:

$$\frac{\partial Z_k}{\partial U_i} = \begin{bmatrix} R_1 W_{11}^o & R_1 W_{12}^o & \dots & R_1 W_{1L}^o \\ R_2 W_{21}^o & R_2 W_{22}^o & \dots & R_2 W_{2L}^o \\ \vdots & \vdots & \vdots & \vdots \\ R_M W_{M1}^o & R_M W_{M2}^o & \dots & R_M W_{ML}^o \end{bmatrix} \begin{bmatrix} \frac{Q_1 W_{11}^h}{\text{emax}_1 - \text{emin}_1} & \frac{Q_1 W_{12}^h}{\text{emax}_2 - \text{emin}_2} & \dots & \frac{Q_1 W_{1N}^h}{\text{emax}_N - \text{emin}_N} \\ \frac{Q_2 W_{21}^h}{\text{emax}_1 - \text{emin}_1} & \frac{Q_2 W_{22}^h}{\text{emax}_2 - \text{emin}_2} & \dots & \frac{Q_2 W_{2N}^h}{\text{emax}_N - \text{emin}_N} \\ \vdots & \vdots & \dots & \vdots \\ \frac{Q_L W_{L1}^h}{\text{emax}_1 - \text{emin}_1} & \frac{Q_L W_{L2}^h}{\text{emax}_2 - \text{emin}_2} & \dots & \frac{Q_L W_{LN}^h}{\text{emax}_N - \text{emin}_N} \end{bmatrix} \quad (15)$$

4. ANÁLISE DE SENSIBILIDADE DOS COLETORES SOLARES

Diferenciando a RNA representada pela Eq.(2), os fatores de sensibilidade podem ser determinados através da Eq.(15). Considerando M = 1 e N = 3, a Eq.(12) pode ser representada por:

$$\frac{\partial Z}{\partial U} = \frac{\partial Tout}{\partial U} = \begin{bmatrix} \frac{\partial Z_1}{\partial U_1} & \frac{\partial Z_1}{\partial U_2} & \frac{\partial Z_1}{\partial U_3} \end{bmatrix} = \begin{bmatrix} \frac{\partial Tout}{\partial Tamb} & \frac{\partial Tout}{\partial Tin} & \frac{\partial Tout}{\partial G} \end{bmatrix} \quad (16)$$

Aplicando-se a Eq.(15) apresentada na seção 4, os fatores de sensibilidade para diferentes condições de operação foram determinados. Na Tab. 3, exemplos dos fatores de sensibilidade, para o coletor 1, são apresentados.

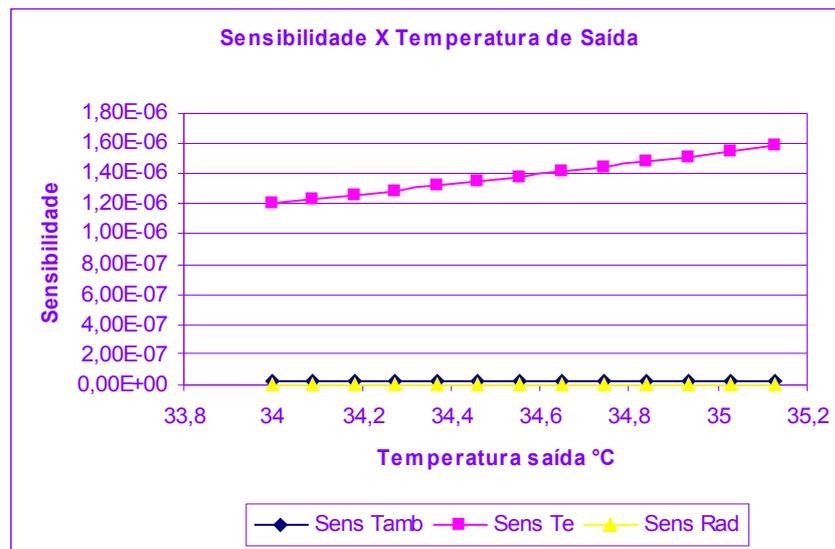
Tabela 3. Conjunto de dados e suas sensibilidades

T _{amb}	T _e	R _{ad}	Sens T _{amb}	Sens T _e	Sens R _{ad}	T _s
------------------	----------------	-----------------	-----------------------	---------------------	----------------------	----------------

26,38	27,49	779,04	2,36E-08	1,20E-06	3,94E-09	34,00035
26,38	27,49	789,14	2,41E-08	1,23E-06	4,03E-09	34,09115
26,38	27,49	799,24	2,47E-08	1,26E-06	4,13E-09	34,18253
26,38	27,49	809,34	2,53E-08	1,29E-06	4,22E-09	34,2745
26,38	27,49	819,44	2,59E-08	1,32E-06	4,32E-09	34,36705

Observando os dados da análise de sensibilidade da Tab. 3, percebe-se que a temperatura de entrada da água (T_e) é a variável que mais influencia a temperatura de saída da água (T_s) e que a radiação (R_{ad}) é a variável que menos influencia. A Fig. 2 permite melhor visualização da influência de cada parâmetro de entrada para o conjunto de dados da Tab. 3.

Figura 2. Sensibilidade dos parâmetros em função da temperatura de saída



As Fig. 3, Fig. 4 e Fig. 5 permitem analisar a sensibilidade de T_{amb} para cada coletor, enquanto que as Fig. 6, Fig. 7 e Fig. 8 permitem analisar a sensibilidade de R_{ad} . Para construir os gráficos, T_{amb} foi fixada em 26,38°C e R_{ad} foi fixada em três valores distintos: 779,04°C (Radiação Mínima), 853,51 °C (Radiação Média) e 981,06 °C (Radiação Máxima). Já T_e , por ser a variável que mais influencia na saída dos coletores solares, foi variada de 27,49°C a 47,86°C. Quanto maior o valor numérico da sensibilidade, mais sensível a saída é ao parâmetro.

Figura 3. Coletor 1

Figura 4. Coletor 2

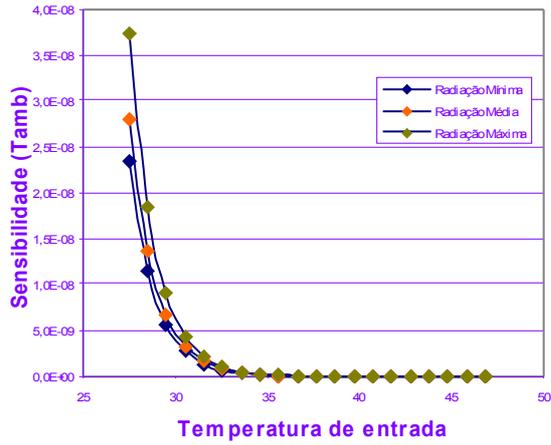


Figura 5. Coletor 3

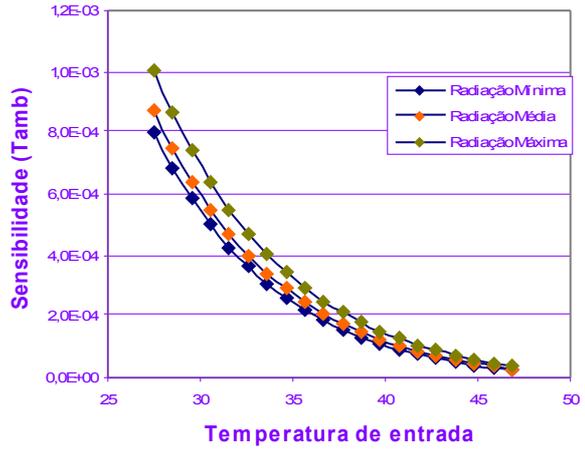


Figura 6. Coletor 1

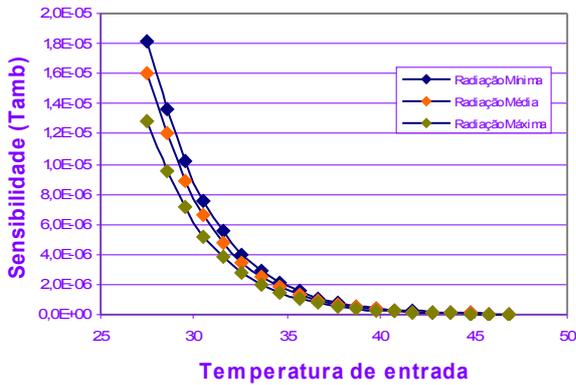


Figura 7. Coletor 2

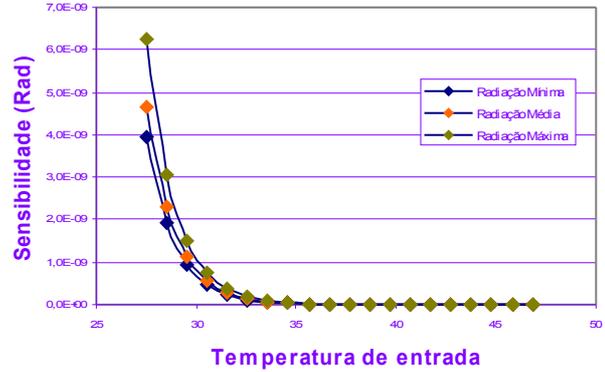
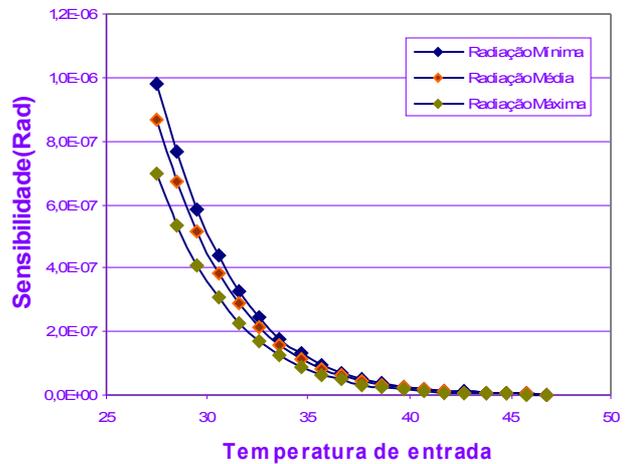
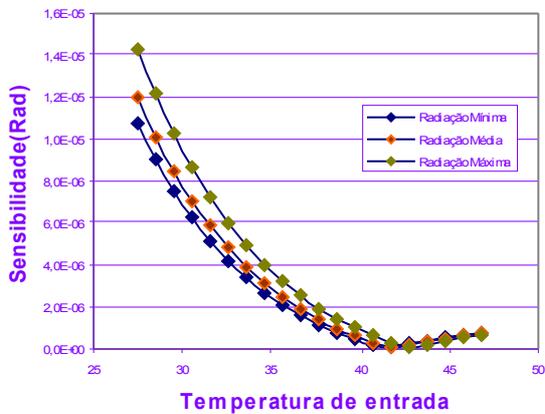


Figura 8. Coletor 3



5. CONCLUSÕES

Dos gráficos pode-se concluir que, para o coletor 1, quando a temperatura de entrada atinge aproximadamente 35°C, os parâmetros ambientais (T_{amb} e R_{ad}) exercem mínima influência na temperatura de saída. A temperatura de saída do coletor 2 é a que sofre maior influência dos parâmetros de entrada e, mesmo com o aumento da temperatura de entrada, as variáveis continuam exercendo considerável impacto. A Fig. 7 tem uma peculiaridade com relação às demais figuras, pois depois de uma determinada temperatura de entrada os parâmetros ambientais voltam a exercer influência sobre a temperatura de saída da água.

Os principais parâmetros de análise de sensibilidade em coletores solares foram discutidos neste trabalho. A análise de sensibilidade permite verificar a influência dos parâmetros de entrada na produção da saída. Para realizar a análise, os fatores de sensibilidade foram calculados por meios de diferenciação de três redes neurais previamente treinadas.

Pela análise dos fatores de sensibilidade, pôde-se observar que a temperatura de saída da água é mais influenciada pela temperatura de entrada da mesma. Em outras palavras, isso significa que a eficiência do coletor solar não é tão influenciada pelos parâmetros ambientais (T_{amb} , R_{ad}). Entretanto, verificou-se que o coletor solar é mais influenciado pela temperatura ambiente do que pela radiação.

O trabalho mostra uma nova maneira de classificar coletores solares que permitirá ao fabricante analisar o impacto das decisões do projeto na eficiência do coletor. Entende-se por decisões do projeto definir: material de isolamento, espessura de isolamento, área do coletor, maneira de fabricação (industrial/artesanal), entre outros aspectos.

Em trabalhos futuros, o método proposto será utilizado para avaliar sistemas de energia solar similares em suas especificações para determinar o impacto de cada aspecto na eficiência dos coletores solares.

REFERÊNCIAS

- HUANG, B.J. (1984) Similarity theory of solar water heater with natural circulation. *Solar Energy*, 25(105).
- KALOGIROU, S. (2000) Thermo-siphon solar domestic water heating systems: long term performance prediction using ann. *Solar Energy*, 69(2): p. 167-174.
- KALOGIROU, S.; PANTELIOU, S.; DENTSORAS, A. (1999) Modeling solar domestic water heating systems using ann. *Solar Energy*, 68(6): p. 335-342.
- KUDISH, A.I.; SANTAURA, P.; BEAUFORT, P. (1998) Direct measurement and analysis of thermo-siphon flow. *Solar Energy*, 35(2): p.167-173.
- MORRISON, G.L.; RANATUNGA, D.B.J. (1980). Transient response of thermo-siphon solar collectors. *Solar Energy*, 24(191).
- ZÁRATE, L. E. *et al.* (2003) Representation of a solar collector via artificial neural networks. In M.H. Hamza, editor, *International Conference on Artificial Intelligence and Applications*, p. 517-522, Benalmádena, Spain, September. IASTED, ACTA Press.
- ZÁRATE, L. E. *et al.* (2004). Neural representation of a solar collector with optimization of training sets. In *Proceedings of 17th International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems*, Ottawa, Canada, May, IEA/AIE.

REPRESENTATION AND SENSITIVITY ANALYSIS OF SOLAR COLLECTORS VIA ARTIFICIAL NEURAL NETWORKS

Abstract. *Since solar collectors have been presented as an alternative way of energy producing, many researches have been working with these systems. The solar collectors are greatly influenced*

by the operation parameters: ambient temperature (T_{amb}), input water temperature (T_e), solar irradiance (G) and mainly by manufacture process. Those parameters are important in order to know the quality and the efficiency of a specific solar collector. The efficiency of those systems can be influenced by manufacture process and this condition is not considered in mathematical models of collectors. By other hand, due its facility in solving nonlinear problems, experimental data based, in this paper, Artificial Neural Networks (ANN) have been proposed as alternative to represent and to compare solar collectors. In the classification of solar collectors, is important to know how T_{amb} , T_{in} , G influence the output water temperature (T_s) (strongly associated to the system efficiency) for each collector considered. These influences may be obtained through the sensitivity analysis of the parameters in relation to T_{out} . So, through differentiation of a previously trained net, the sensitivity factors can be obtained. The sensitivity factors show how much the input variables influence the output variables. In this paper, the sensitivity analysis via ANN, to compare and classify solar collectors is applied and discussed.

Key-words: Artificial Neural Networks, Sensitivity Analysis, Solar Energy, Solar Collectors.

ANEXO

Coletor Solar	Área externa (m ²)	Produção Específica Mensal de Energia (kWh/mês/m ²)	Eficiência Térmica (%)	Nº Tubos	Isolamento BASE Material	Isolamento BASE Espessura (mm)	Isolamento LATERAL Material	Isolamento LATERAL Espessura (mm)
01	1,00	82,4	59,5	9	Lã de vidro	25,0	NA	NA
02	1,06	83,1	58,4	9	Lã de vidro	35,0	NA	NA
03	1,19	87,2	58,4	9	Lã de vidro	25,4	Lã de vidro	25,4