

MODELAGEM DA TEMPERATURA DE MÓDULO FOTOVOLTAICO COM REDE NEURAL ARTIFICIAL

Fábio Alves de Braz Coutinho (UFPE) - fabiocoutinho07@hotmail.com

CHIGUERU TIBA (UFPE) - tiba@ufpe.br

Rinaldo Oliveira de Melo (UFPE) - rinaldoom@hotmail.com

Resumo:

Este trabalho tem como objetivo modelar, com uma rede neural artificial, a temperatura de funcionamento de um arranjo fotovoltaico partindo apenas de variáveis meteorológicas (velocidade do vento, irradiação incidente e temperatura ambiente) que são facilmente obtidas em banco de dados disponíveis em várias localizações ao redor do mundo. Além disso, também compara temperatura obtida pela modelagem com RNA com a temperatura estimada por uma correlação experimental conhecida na literatura como correlação de Skoplaki. Os desvios percentuais e o erros médios quadráticos normalizados são respectivamente -0,42% e 8,90% para a modelagem com RNA e -0,38% e 9,73% para a modelagem com a correlação de Skoplaki, percebe-se assim que a modelagem que utiliza RNA é mais precisa. O arranjo FV experimental que forneceu os dados utilizados (40 dias de medição) para a modelagem com RNA e com a correlação de Skoplaki estava localizada em Recife-PE.

Palavras-chave: *Energia Solar, RNA, Temperatura do módulo FV, correlação de Skoplaki*

Área temática: *Conversão Fotovoltaica*

Subárea temática: *Aspectos técnicos de sistemas fotovoltaicos instalados*

MODELAGEM DA TEMPERATURA DE MÓDULO FOTOVOLTAICO COM REDE NEURAL ARTIFICIAL

Fábio Alves de Braz Coutinho – fabiocoutinho07@hotmail.com

Rinaldo de Oliveira Melo – rinaldoom@hotmail.com

Universidade Federal de Pernambuco, Departamento de Energia Nuclear

Chigueru Tiba – tiba@ufpe.br

Universidade Federal de Pernambuco, Departamento de Energia Nuclear

Resumo. *Este trabalho tem como objetivo modelar, com uma rede neural artificial, a temperatura de funcionamento de um arranjo fotovoltaico partindo apenas de variáveis meteorológicas (velocidade do vento, irradiação incidente e temperatura ambiente) que são facilmente obtidas em banco de dados disponíveis em várias localizações ao redor do mundo. Além disso, também compara temperatura obtida pela modelagem com RNA com a temperatura estimada por uma correlação experimental conhecida na literatura como correlação de Skoplaki. Os desvios percentuais e o erros médios quadráticos normalizados são respectivamente -0,42% e 8,90% para a modelagem com RNA e -0,38% e 9,73% para a modelagem com a correlação de Skoplaki, percebe-se assim que a modelagem que utiliza RNA é mais precisa. O arranjo FV experimental que forneceu os dados utilizados (40 dias de medição) para a modelagem com RNA e com a correlação de Skoplaki estava localizada em Recife-PE.*

Palavras-chave: Energia Solar, RNA, Temperatura do módulo FV, correlação de Skoplaki

1. INTRODUÇÃO

1.1. Caracterização do problema

O uso massivo da energia solar fotovoltaica no Brasil já é uma realidade iminente, seja na modalidade de microgeração ou mesmo com a instalação de grandes centrais geradoras, como o complexo de Pirapora em Minas Gerais que possui mais de 300 MW instalados com previsão de projeto total de 400 MW. Em paralelo à isso os projetistas de sistemas FV devem procurar maneiras de reduzir cada vez mais os custos do kW instalado, um dos meios disponíveis para alcançar tal feito, além do barateamento natural de tecnologia, é aumentar a otimização e a exatidão das características de projeto.

Já é conhecimento consolidado na literatura que o desempenho de uma célula FV (fotovoltaica) é fortemente dependente de sua temperatura e da irradiação solar que a atinge. Enquanto esta é uma variável que depende apenas do clima e da orientação dos módulos, aquela é influenciada pelas propriedades óticas dos componentes dos módulos (células, vidros, encapsulantes, back-sheets), pela eficiência elétrica das células, pela temperatura ambiente, pelo vento, pelas propriedades de transferência de calor por irradiação, pelo albedo e finalmente também pela irradiação incidente. (Koehl et al., 2011 e Dubey, Saraiva e Seshadri, 2013)

O efeito que a temperatura de funcionamento exerce sobre as condições de operação dos módulos varia com o material de construção destes, porém tal efeito já foi exaustivamente estudado e existe um grande número de correlações que modelam, com um bom grau de exatidão, tais efeitos (Wysocki e Palvos, 1960 e Skoplaki e Palyvos, 2009). O efeito da temperatura no funcionamento dos módulos se traduz em modelos que têm como variáveis de entrada: 1- O estado de funcionamento (corrente de curto circuito- I_{sc} , tensão de circuito aberto - V_{oc} e a máxima potência - P_{mp}) sob uma condição muito específica de operação conhecida como NOCT (IEC 61215-2, 2016) (módulo inclinado a 45° graus sul, exposto a uma irradiação de 800 W/m², temperatura ambiente de 20° C, vento com velocidade de 1 m/s e módulo funcionando em circuito aberto), do inglês, Nominal Operating Cell Temperature (temperatura e operação nominal da célula); 2- Os coeficientes de temperaturas que influenciam na corrente, tensão e potência do módulo; 3- Temperatura de funcionamento do módulo. As duas primeiras entradas são disponibilizadas pelos fabricantes dos módulos em suas informações técnicas, sendo assim a maior dificuldade para aplicação desses modelos é a temperatura de funcionamento dos módulos, de como já foi visto anteriormente depende de vários fatores difíceis de quantificar.

Com relação às variáveis climáticas já foi verificado que a temperatura do módulo FV está muito atrelada à velocidade do vento, depende muito pouco da direção deste e praticamente não varia com a temperatura ambiente. (Griffith, Rathod e Paslaski, 1981). Além disso a temperatura possui claramente uma forte dependência em relação à irradiação incidente.

Tendo isso em vista houve um esforço dos pesquisadores para a obtenção de maneiras de realizar essa predição utilizando só fatores de simples obtenção, como por exemplo Skoplaki, Boudouvis e Palyvos, (2008) que desenvolveram uma correlação que foi capaz de prever, com boa exatidão, a temperatura de funcionamento de um módulo solar exposto às mais diversas condições climáticas.

O intuito desse trabalho foi calcular a temperatura de funcionamento dos módulos FV, utilizando as mesmas variáveis utilizadas por Skoplaki e sua equipe (2008), porém, ao invés de correlações semiempíricas foi utilizado uma RNA (Rede

Neural Artificial) para em seguida confrontar os resultados desta com os valores obtidos pela correlação de Skoplaki et al (2008) e os valores obtidos experimentalmente.

1.2 Influência da temperatura no funcionamento do módulo

O efeito da temperatura no módulo pode ser visto na influência desta na corrente, tensão e potência máxima produzida pelo módulo, dada pela Eq. 1:

$$P_m = V_m I_m = (FF) V_{oc} I_{cs} \quad (1)$$

Onde: P_m = potência máxima (W)
 V_m = tensão de potência máxima (V)
 I_m = corrente de máxima potência (A)
 FF = Fator de Forma
 V_{oc} = Tensão de circuito aberto (V)
 I_{cs} = Corrente de curto circuito (A)

O fator de forma é o quão próximo a curva característica é de um retângulo de lado I_{cs} e V_{oc} . É uma medida de quanta resistência em série e quão pouca resistência em paralelo possui uma célula ou módulo solar. O FF afeta a tensão máxima, varia com a irradiação e diminui com a idade do módulo, pois sua resistência interna aumenta com a sua degradação (Buresch, 1983) além disso, o FF, a tensão de circuito aberto, a potência máxima, e consequentemente, a eficiência, diminuem significativamente com o aumento da temperatura (pois a excitação térmica dos elétrons passa a ser dominante em relação à propriedade elétrica do semiconductor), porém a corrente de curto circuito tende a aumentar levemente na mesma situação. (Zondag, 2008)

O efeito da temperatura na potência pode ser visto com clareza na Fig. 1 que ilustra a variação do ponto de potência máxima (P_m) e da tensão de circuito aberto com o a temperatura que varia de 0° C a 75° C.

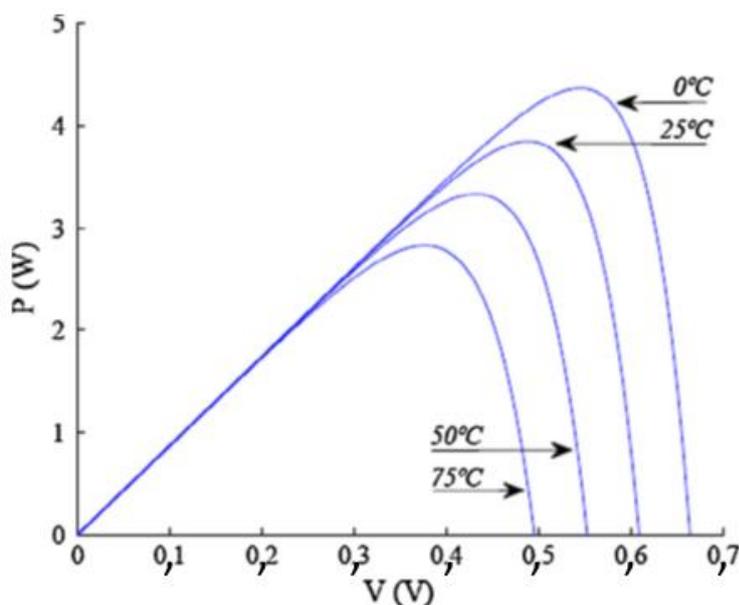


Figura 1: Influência da temperatura de funcionamento na curva característica de uma célula

Fonte: K. A. Moharram, et al., 2013

A equação de Evans (1981) é bem conhecida e utilizada para calcular o efeito da temperatura na eficiência de uma célula FV trabalhando fora das condições padrão de laboratório. A correlação de Evans tem sua forma aproximada na Eq. 2.

$$\eta_c = \eta T_{ref} [1 - \beta_{ref} (T_c - T_{ref})] \quad (2)$$

Onde: η_c = eficiência da célula para uma temperatura qualquer T diferente da T_{ref}

ηT_{ref} = eficiência de referencia (1000W/m² e 25°C), obtida em situação específicas de laboratório

β_{ref} = coeficiente de correção de temperatura °C⁻¹ (valor tabelado)

T_c = temperatura da célula

T_{ref} = 25°C

Essa equação significa que a eficiência da célula em qualquer condição pode ser calculada a partir de seu desempenho funcionando nas condições padrão de laboratório (1000 W/m² e 25°C) e do coeficiente de temperatura que pode ser fornecido pelo fabricante ou aproximado de acordo com o material da célula.

Como dito anteriormente é uma tarefa difícil determinar a temperatura de funcionamento do módulo, pois, dentro do semicondutor, quando exposto a fótons da radiação solar, além da produção de energia, acontece a degradação da radiação na forma de calor; a transferência de calor por convecção (forçada quando há vento com velocidade de pelo menos 1 m/s ou livre quando o vento não alcança tal velocidade) e irradiação (o balanço da irradiação trocada com o ambiente). A condução é desconsiderada porque, no estado estacionário, ela atua apenas transferindo o calor do interior para as superfícies exteriores dos painéis. (Luque e Araujo, 1989)

1.3 Correlação de Skoplaki et al.

Skoplaki et al (2008) realizaram os seguintes cálculos para determinação da temperatura de funcionamento.

Eles partiram do balanço de energia para calcular a temperatura em estado estacionário (funcionamento):

[Potência elétrica produzida] = [potência solar absorvida] – [potência dissipada na forma de calor], que é matematicamente representada por:

$$\eta_c G_T = (\alpha\tau)G_T - U_L(T_c - T_a) \quad (3)$$

Onde: η_c = eficiência da célula/módulo

G_T = Irradiação incidente no plano (W/m²)

τ = transmitância

α = absorvância

U_L = Coeficiente global de troca de calor (W/m²K)

T_c = temperatura da célula/módulo (°C)

T_a = temperatura ambiente(°C)

Aplicando as condições de NOCT e resolvendo para o coeficiente global de troca de calor é possível obtê-lo e então com a sua substituição na Eq. 2 é possível resolve-la em função da temperatura de célula obtendo a Eq. 4.

$$T_c = T_a + \left(\frac{G_t}{G_{NOCT}} \right) (T_{NOCT} - T_{a,NOCT}) \left[\frac{\eta_c}{(\alpha\tau)} \right] \quad (4)$$

Onde: G_{NOCT} = Irradiação na NOCT (800 W/m²)

T_{NOCT} = Temperatura da célula no NOCT (°C)

$T_{a,NOCT}$ = Temperatura ambiente na NOCT (20 °C)

Porém a Eq.4 é apenas uma aproximação, pois o coeficiente global de transferência de calor utilizado é valido apenas na NOCT, reescrevendo a Eq. 3 para as condições de NOCT e realizando o mesmo procedimento já feito obtém-se uma equação semelhante a Eq. 4, porém para condições diferentes da NOCT a Eq. 5.

$$T_c = T_a + \left(\frac{G_t}{G_{NOCT}} \right) \left(\frac{U_{L,NOCT}}{U_L} \right) (T_{NOCT} - T_{a,NOCT}) \left[1 - \frac{\eta_c}{(\alpha\tau)} \right] \quad (5)$$

Onde:

$U_{L,NOCT}$ = Coeficiente global de troca de calor nas condições NOCT

Combinando a Eq.5 com a Eq. 3 é obtido a Eq. 6.

$$T_c = \frac{T_a + \left(\frac{G_t}{G_{NOCT}}\right) \left(\frac{U_{L,NOCT}}{U_L}\right) (T_{NOCT} - T_{a,NOCT}) \left[1 - \frac{\eta_{ref}}{(\alpha\tau)} (1 + \beta_{ref}(T_c - T_{ref}))\right]}{1 - \frac{\eta_{ref}\beta_{ref}}{(\alpha\tau)} \left(\frac{G_t}{G_{NOCT}}\right) \left(\frac{U_{L,NOCT}}{U_L}\right) (T_{NOCT} - T_{a,NOCT})} \quad (6)$$

O coeficiente global de troca de calor é a junção de todos os coeficientes dos modos de troca de calor (convecção livre e forçada e irradiação), porém a perda por irradiação é de 3-4 vezes menor do que perda por convecção forçada. A convecção livre também pode ser desprezada para velocidade de vento superior à 1 m/s. (Eckstein, 1990) Com isso a relação entre os U(s) da Eq. 6 pode ser substituído pela relação entre os coeficientes de convecção forçada.

Existem várias correlações lineares para o cálculo do coeficiente de convecção. (Loveday e Taki, 1996) obtiveram a correlação linear empírica mostrada na Eq. 7.

$$h = 8,91 + 2,0V_f \quad (7)$$

Onde: h= coeficiente de convecção forçada
V_f = velocidade do vento

Substituindo os coeficientes globais pelo coeficiente de convecção da Eq. 7, aplicando as condições de NOCT e as características físicas de módulos de silício à Eq.6 resulta que o segundo termo do denominador pode ser desprezado, uma vez que ele é muito menor do que 1, então a Eq. 6 se reduz à Eq. 8 que é a aqui chamada correlação de Skoplaki.

$$T_c = T_a + \left(\frac{0,32}{8,91+2,0V_f}\right) G_t \quad (8)$$

Segundo Skoplaki et al. (2008) e pelo o que foi reexposto nesse tópico essa correlação só é bem aplicada nas seguintes situações: Módulos em que ambas as suas faces estão expostas às mesmas condições (a troca de calor em ambas as faces são iguais), módulos integrados à construções não são bem modelados; Valores de velocidade do vento maior do que 1 m/s e menores do que 15 m/s, caso contrário a aproximação do coeficiente global de troca de calor pelo coeficiente de convecção forçada é invalidada. Então nesses casos a correlação pode ser aplicada com boa precisão utilizando apenas variáveis climáticas que são obtidas em estações meteorológicas facilmente encontradas pelo mundo. A grande vantagem dessa correlação é que ela utiliza apenas a temperatura ambiente, velocidade do vento e irradiação incidente para calcular a temperatura do módulo.

1.4 Rede Neural

Redes Neurais Artificiais (RNAs) são uma espécie de Inteligência Artificial que serve como uma grande ferramentas para a solução de problemas complexos, elas possuem esse nome devido à semelhança com o funcionamento de um cérebro, tanto na arquitetura quanto no princípio de funcionamento. Uma RNA é um conjunto de pequenas entidades que estão ligadas entre si e essas pequenas entidades transferem informações de uma para outra. Sendo assim, cada unidade dessa tem dois valores associados a ela, o valor de entrada e o seu peso. A saída da unidade é uma função desses respectivos valores.

A RNA imita o processo de aprender do cérebro humano, o conhecimento é adquirido através do processo de aprendizagem e as conexões entres os neurônios são usadas para armazenar o conhecimento, nos formatos dos pesos já citados anteriormente.

Um diagrama da arquitetura do RNA pode ser visto na Fig. 2, as camadas ocultas são assim chamadas porque depois de construída a RNA funciona como uma caixa preta, o número de camadas ocultas e de neurônio por camadas diferem de uma RNA para a outra RNA.

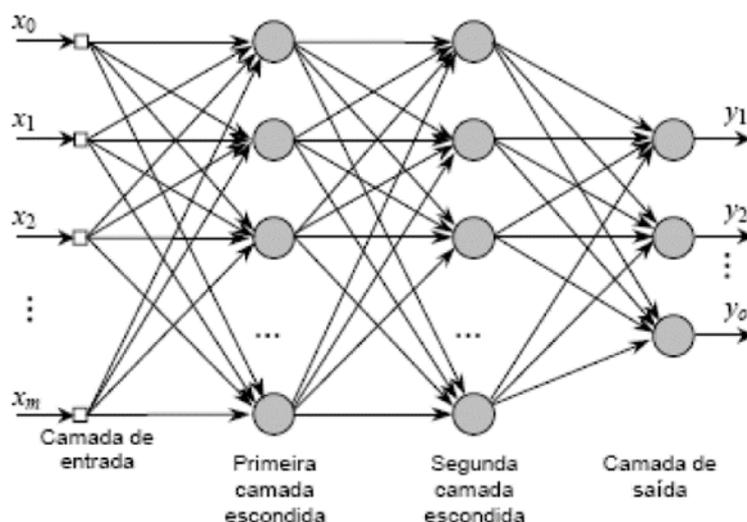


Figura 2: Esquema da arquitetura de uma rede neurais com 2 níveis ocultos

Fonte: Oliveira, et al. 2010

Quando uma excitação é feita na entrada da rede e tem um resultado desejado na saída ao longo das sinapses há o armazenamento de pesos para cada neurônio no caminho e esses pesos são modificados baseado na entrada e na saída. (Soteris, 2001)

O processo de aprendizagem é chamado treinamento, ele consiste em modificar os pesos usando um método cujo a entrada é adicionada à rede juntamente com a saída e dessa forma os pesos são ajustados para que a entrada produza a saída desejada, antes do treinamento todas as saídas produzidas são aleatórias e descartáveis.

Após o treinamento é feita a verificação, nessa etapa a entrada é colocada na RNA, que por sua vez produz a própria saída e então, a saída produzida pela RNA é comparada com a saída medida, calculando-se o erro, se o mesmo for insatisfatório deve-se treinar novamente a rede, mas, com a ressalva de que dependendo da arquitetura a rede tem um número de pontos para o treinamento que ela deixa de aprender e se torna viciada e ela ao invés de calcular as saídas ela apenas associa a entradas anteriores. Mas uma vez treinada corretamente a rede funciona como uma caixa preta que pode ser facilmente utilizada.

2. Materiais Métodos

2.1 Descrição do Arranjo FV de testes

O sistema utilizado nesse trabalho está localizada em Recife-PE (latitude: 08°03'14'' S, longitude 34°52'52'' W). O arranjo é utilizado como força motriz para uma bomba de água, pois, originalmente é uma bancada de estudo de bombeamento fotovoltaico.

2.1.1 Arranjo Fotovoltaico

O arranjo FV foi montado com todos os módulos em série, com uma inclinação de 23° em relação à horizontal e alinhados no sentido N-S (azimute zero). Na Fig. 3 pode ser visto o arranjo; nela constam 17 módulos, mas um deles está desconectado; sendo assim, são utilizados 16 módulos em série, gerando uma potência máxima nominal de 880 Wp e uma tensão de potência máxima nominal de 278,4 Volts. O módulo utilizado é um ISOFOTON I-55 e suas características nominais estão descritas na Tab. 1.

Tabela 1: Características nominais do módulo FV utilizado

Potência máxima	55±10% Wp
Corrente de Curto circuito	3,38 A
Tensão de Circuito aberto	21,6 V
Corrente de máxima potência	3,16 A
Tensão de máxima potência	17,4 V
Dimensões do módulo	0,34 m x 1,3 m



Figura 3: Arranjo FV

Foi extraído a curva de características do arranjo e as principais informações estão expressa na Tab. 2.

Tabela 1: Características nominais do Arranjo

Potência máxima	894,2 W
Corrente de Curto circuito	4,59 A
Tensão de Circuito aberto	293,7 V
Corrente de máxima potência	4,07 A
Tensão de máxima potência	219,8 V
Dimensões do arranjo	7,072 m ²
Irradiação usada	970 W/m ²
Temperatura do módulo	55° C

2.1.2 Inversor de Frequência

O inversor não conta com um seguidor de máxima potência por isso é necessário escolher a tensão de trabalho, então foi escolhida a tensão de máxima potência medida no arranjo, 219,8 V, otimizando assim a energia gerada. As características nominais do fabricante do inversor estão na Tab. 3. O fato do módulo operar fora do ponto de máxima potência acaba por aumentar a temperatura de operação desse, pois, uma parte da energia fornecida pelo sol é desperdiçada deixando de ser convertida em potência elétrica, e assim, inevitavelmente é convertida em calor. Esse efeito é levado em consideração implicitamente na modelagem que utiliza a rede neural, porém, a correlação de Skoplaki foi desenvolvida levando em consideração que os módulos estavam trabalhando no ponto de máxima potência.

Tabela 3: Características do Inversor de frequência

Entrada: 200-240 V \pm 10 %; 14,4 A; 47 a 63 Hz
Saída: 0-entrada V; 7,4 A 0-650 Hz
Potência máxima do motor conectado: 1,5 kW

2.1.3 Variáveis Térmicas do Arranjo PV

As variáveis térmicas medidas no arranjo foram as temperaturas (em graus Célsius) em 3 pontos do arranjo FV, todos na fileira com 9 módulos da Fig. 3, os pontos são mostrados na Fig.4. As medidas de temperaturas foram obtidas a cada segundo por um sensor LM-35 e no final de um minuto eram armazenadas as médias por minuto de cada um dos três pontos. Este sensor possui um erro de $\pm 0,25^{\circ}\text{C}$, que na faixa de medidas do experimento equivale a um erro de 0,5%, possuindo assim um ótimo custo x benefício. A temperatura do arranjo foi tomada como a média entre os três pontos.

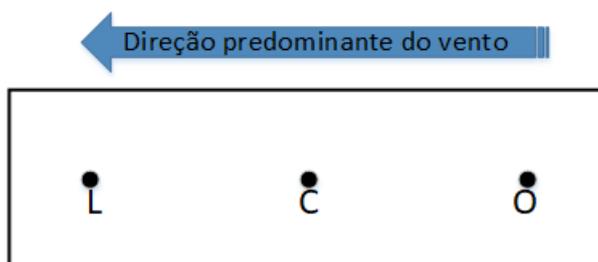


Figura 4 – Disposição dos sensores de temperaturas no arranjo PV

2.1.4 Variáveis meteorológicas

As variáveis meteorológicas medidas foram as mesmas necessárias para a implementação da correlação de Skoplaki: 1-Velocidade do vento medida por um sensor 034B-L da Campbell com erro de 1,1%; 2- Irradiação incidente no plano dos painéis medidas por um sensor LI-COR, modelo LI-200R com erro de 3%; 3- Temperatura ambiente medida por um sensor HMP 155 da Vaisala com erro de 1,8%. Todas essas variáveis foram obtidas no mesmo regime de tempo das variáveis térmicas do arranjo FV.

2.2 Campanha de medição e modelagem

As medidas foram feitas diariamente minuto a minuto das 07:00 da manhã até as 16:00 da tarde por quarenta dias ao longo do ano.

2.3- Modelagem em Rede Neural Artificial

A rede utilizada possui 10 camadas, sem realimentação e, como exposto anteriormente, foi treinada para calcular a temperatura de funcionamento dos módulos a partir da temperatura ambiente, irradiação incidente e velocidade do vento (os mesmos termos da correlação).

Todos os dados obtidos foram distribuídos aleatoriamente em três grupos: o primeiro foi o grupo de treino que continha 50% de todos os dados; o segundo foi o grupo de validação que continha 25% de todos os dados, estes não foram utilizados na correlação de Skoplaki, apenas na validação durante a construção da rede neural; e por último, o grupo de teste que continha os 25% restantes dos dados e foi utilizado para calcular os testes estatísticos e confrontar os resultados de ambas as modelagens. A Fig. 5 ilustra o fluxograma de construção da rede neural suas entradas são: irradiação no plano do arranjo FV, velocidade do vento e a temperatura ambiente e sua saída é a temperatura de funcionamento do arranjo FV.

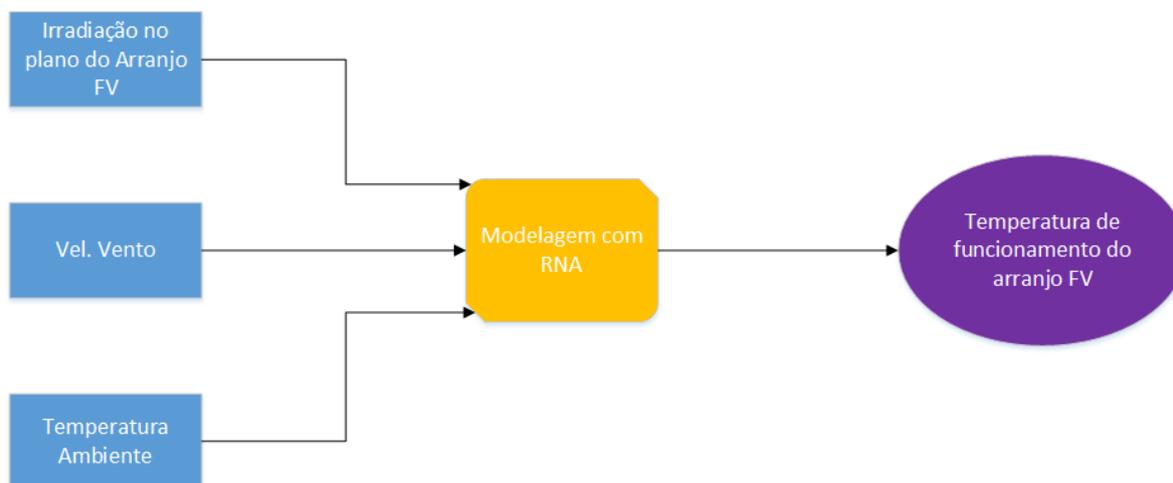


Figura 5: Fluxograma da Rede da Temperatura

2.3 Indicadores Estatísticos

Os indicadores estão expostos nas Eq.(s) 8 e 9.

Desvio percentual – (DP)

$$DP = 100 \frac{\sum_n (V_{calculado} - V_{medido})}{\sum_n V_{medido}} \quad (8)$$

Erro médio quadrático normalizado – (EMQN)

$$EMQN = 100 * \sqrt{\frac{\sum n(V_{calculado} - V_{medido})^2}{n}}{V_{m\u00e9dio}} \quad (9)$$

Onde V significa a grandeza estimada ou medida e N o n\u00famero de medidas.

3. Resultados e Discuss\u00e3o

Ambos os modelos desempenharam de forma semelhante, seus indicadores estat\u00edsticos obtidos pelas Eq.8 e Eq. 9 est\u00e3o expostos na Tab. 4.

Tabela 4: Rede da Temperatura vs Correla\u00e7\u00e3o de E. Skoplaki et al.

	DP (%)	EMQN (%)
Rede das Temperaturas	-0,42	8,90
Correla\u00e7\u00e3o de E. Skoplaki et al.	-0,38	9,73

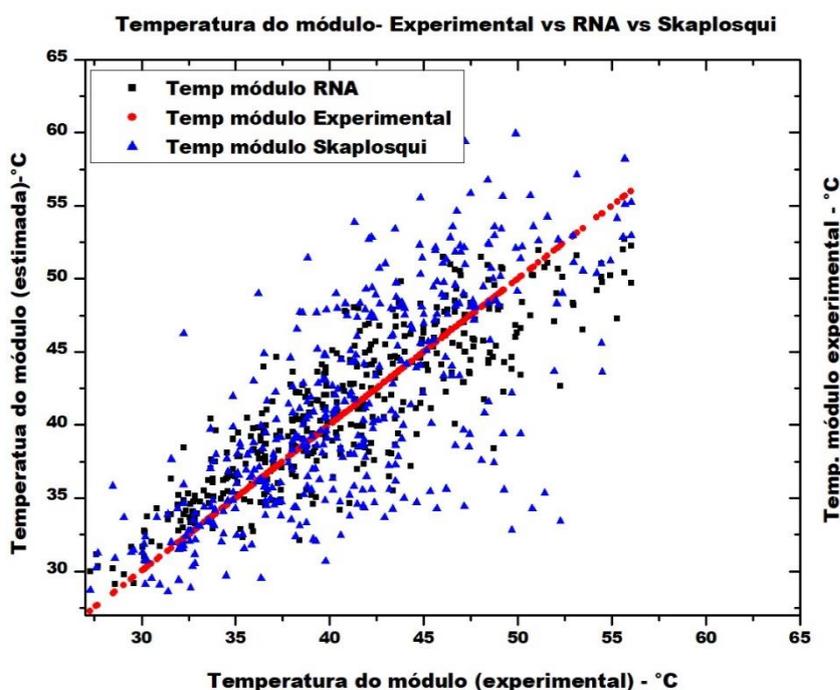


Figura 6: Compara\u00e7\u00e3o do c\u00e1lculo da temperatura: RNA Vs Skoplaki

Os resultados de ambos os modelos tamb\u00e9m podem ser vistos na Fig. 6 e refletem os indicadores estat\u00edsticos. A reta inclinada em 45 graus \u00e9 o alvo para ambas as modelagens, pois ela \u00e9 composta pelos valores experimentais tanto na abcissa quanto na ordenada. Os valores calculados pela correla\u00e7\u00e3o s\u00e3o mais espalhados do que os calculados pela RNA. Ambos os modelos menosprezaram levemente a temperatura experimental, ou seja, ambos em m\u00e9dia calcularam valores abaixo do valor experimental, o que j\u00e1 era esperado pela correla\u00e7\u00e3o de Skoplaki, uma vez que esta desconsidera duas formas de troca calor dos m\u00f3dulos com o ambiente (convec\u00e7\u00e3o livre e irradia\u00e7\u00e3o). Por\u00e9m essa caracter\u00edstica foi suavizada na correla\u00e7\u00e3o, uma vez ela foi desenvolvida para velocidades do vento maior do que 1m/s e nos casos que em que a velocidade do vento diminua abaixo desse limiar, tendendo a zero, o segundo termo da correla\u00e7\u00e3o tende a aumentar, consequentemente aumentando a temperatura de funcionamento calculada por essa.

4. Conclus\u00e3o

O modelo de Skoplaki teve um desempenho ligeiramente inferior ao da modelagem RNA desenvolvida. Em compara\u00e7\u00e3o, os EMQN(s) resultantes foram respectivamente de 8,9% e 9,73% e os DP(s) foram respectivamente -0,42 % e -0,38%. A diferen\u00e7a no erro sistem\u00e1tico (DP) de ambas as modelagens \u00e9 de 0,06 %, nesse caso elas s\u00e3o praticamente id\u00eênticas. J\u00e1 a diferen\u00e7a na dispers\u00e3o (EMQN) tem uma diferen\u00e7a de 0,83 % o que demonstra a superioridade da modelagem com RNA, al\u00e9m disso, a modelagem em RNA pode ser aplicadas em diferentes condi\u00e7\u00f5es onde a correla\u00e7\u00e3o

de Skoplaki não se enquadram (no caso de módulos integrados à construções, por exemplo, onde os lados dos módulos não estão sob as mesmas condições, ou para condições com ventos mais lentos do que 1m/s), porém a rede neural precisa ser treinada nas condições corretas para que assim ela possa calcular corretamente, o que impossibilita a sua aplicação no caso onde esse treinamento não seja possível em tempo hábil.

A precisão da modelagem com RNA pode ser melhorada substancialmente aumentando o tamanho do banco de dados utilizado para o treinamento ou mesmo modificando a sua arquitetura.

O trabalho aqui desenvolvido demonstra que o projetista de sistemas fotovoltaico deve escolher a modelagem RNA se houver tempo e recursos suficientes para realizar o treinamento desta, em caso contrário o profissional ainda pode optar por utilizar correlações, como a de Skoplaki, que calcula com boa precisão utilizando apenas variáveis climáticas de fácil obtenção.

Autorizações e reconhecimentos

Os autores são responsáveis por garantir o direito de publicar todo o conteúdo de seu trabalho. Se for usado material com direitos autorais em sua preparação, pode ser necessário conseguir a autorização do detentor dos direitos para a publicação do material em questão. Os autores irão emitir uma autorização de publicação dos trabalhos em favor da ABENS, assumindo toda a responsabilidade sobre o conteúdo dos mesmos, no momento da inscrição formal do trabalho, acompanhado da taxa de publicação.

Agradecimentos

Agradecemos à CAPES pelo financiamento da pesquisa que resultou, dentre outras, coisas nesse trabalho. Agradecemos ainda ao PROTEN / DEN. Agradeço ainda pessoalmente à orientação precisa e imprescindível do prof. Dr. Chigueru Tiba.

Referências Bibliográficas

- Dubey, S., Sarvaiya, J. N., & Seshadri, B. (2013). Temperature dependent photovoltaic (PV) efficiency and its effect on PV production in the world—a review. *Energy Procedia*, 33, 311-321.
- Eckstein, J. H. (1990). *Detailed modelling of photovoltaic system components* (Doctoral dissertation).
- Evans, D. L. (1981). Simplified method for predicting photovoltaic array output. *Solar energy*, 27(6), 555-560.
- Griffith JS, Rathod NS, Paslaski J. Some tests of flat plate photovoltaic module cell temperatures in simulated field conditions. Proc. 15th IEEE Photovoltaic Specialists Conf., Kissimmee, FL, 1981; p.822-30.
- IEC61215ed.2(Crystalline Silicon Thin-Film Terrestrial Photovoltaic(PV) Modules—Design Qualification and Type Approval) and IEC61646ed. 2(Thin-Film Terrestrial Photovoltaic (PV) Modules —Design Qualification and Type Approval).
- Koehl, M., Heck, M., Wiesmeier, S., & Wirth, J. (2011). Modeling of the nominal operating cell temperature based on outdoor weathering. *Solar Energy Materials and Solar Cells*, 95(7), 1638-1646.
- Loveday, D. L., & Taki, A. H. (1996). Convective heat transfer coefficients at a plane surface on a full-scale building facade. *International Journal of Heat and Mass Transfer*, 39(8), 1729-1742.
- Luque, A., & Araújo, G. L. (1989). *Solar cells and optics for photovoltaic concentration*. A. Hilger.
- M. Buresch, Photovoltaic Energy Systems, McGraw-Hill, 1983. p. 85.
- Moharram, K. A., Abd-Elhady, M. S., Kandil, H. A., & El-Sherif, H. (2013). Enhancing the performance of photovoltaic panels by water cooling. *Ain Shams Engineering Journal*, 4(4), 869-877.
- OLIVEIRA, A. C. S.; SOUZA, A. A.; LACERDA, W. S. e GONÇALVES, L. R. Aplicação de redes neurais artificiais na previsão da produção de álcool. 2010
- Skoplaki, E., Boudouvis, A. G., & Palyvos, J. A. (2008). A simple correlation for the operating temperature of photovoltaic modules of arbitrary mounting. *Solar Energy Materials and Solar Cells*, 92(11), 1393-1402.
- Skoplaki, E., & Palyvos, J. A. (2009). On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations. *Solar energy*, 83(5), 614-624
- Soteris A. Kalogirou. Artificial Neural Networks in renewable energy systems applications: a review. *Renewable & Sustainable Energy Reviews* 2001
- Wysocki, J. J., & Rappaport, P. (1960). Effect of temperature on photovoltaic solar energy conversion. *Journal of Applied Physics*, 31(3), 571-578.
- Zondag, H. A. (2008). Flat-plate PV-Thermal collectors and systems: A review. *Renewable and Sustainable Energy Reviews*, 12(4), 891-959

TEMPERATURE MODELING OF PHOTOVOLTAIC MODULE WITH ARTIFICIAL NEURAL NETWORK

Abstract. *This paper aims to model, with an artificial neural network, the operating temperature of a photovoltaic array base only on meteorological variables (wind speed, incident radiation and temperature ambient) that are easily obtained from database available in various locations around the world. Moreover, it also compares the temperature obtained by modeling by ANN with the temperature estimated by an experimental correlation know in the literature as Skoplaki's correlation. The percentage deviations and RMSE were -0,42 % and 8,90 %, respectively, for modeling with RNA and -0,38 % and 9,73 % for modeling with Skoplaki's correlation, it is evident than the modeling that uses ANN is more accurate. The experimental PV array that provided the data used (40 days) for modeling with ANN and with the Skolpaki's correlation was located in Recife-PE.*

Key words: *Solar Energy, ANN, temperature of PV, Skoplaki's correlation*