



Grupo de Estudo de Geração Eólica, Solar e Armazenamento-GES

Tratamento de Dados Solarimétricos - Comparação entre um Método Convencional que usa Correlação com o Uso de Redes Neurais Artificiais

ALCIDES CODECEIRA NETO* (1,2); EDUARDO DE AGUIAR SODRÉ (1,2); JOSÉ BIONE DE MELO FILHO(1,3);
CHESF (1); UPE – POLI (2); IFPE (3);

RESUMO

Os estudos iniciados na CHESF com vistas à elaboração de projetos de energia solar exigem a necessidade de se conduzir medições solarimétricas nas áreas em que esses projetos serão implantados. Os dados de irradiação solar são essenciais para a modelagem e avaliação de desempenho de sistemas solares. Este Informe Técnico tem como objetivo apresentar um método para estimação da irradiação solar, considerando os dados medidos em solo para uma localidade do semiárido nordestino. Será utilizada a aplicação de uma Rede Neural Artificial (RNA), do tipo *Multilayer Perceptron* (MLP), usando a técnica de aprendizado supervisionado conhecida como *back-propagation*.

PALAVRAS-CHAVE

Medição Solarimétrica, Irradiação Solar, Redes Neurais Artificiais.

1.0 - INTRODUÇÃO

O uso das energias renováveis na composição da matriz elétrica Brasileira, tendo em vista os problemas ambientais decorrentes do uso de combustíveis fósseis, e a diversificação da matriz energética utilizando combustíveis renováveis com vistas à segurança no abastecimento e redução das emissões atmosféricas, vêm contribuindo para que o setor elétrico promova os leilões de venda de energia elétrica provenientes de fontes não convencionais de energia limpa, primeiramente a biomassa e a eólica, e recentemente a solar fotovoltaica. O uso crescente dessas fontes renováveis para geração de energia elétrica em todo o mundo contribuirá para mitigar a emissão de gases de efeito estufa e, conseqüentemente, reduzir os efeitos relacionados com as mudanças climáticas.

Os recentes estudos iniciados na Chesf visando à possibilidade de concorrer com projetos de energia solar nos próximos leilões de energia a serem promovidos pelo Governo Federal, bem como o interesse da empresa em participar de Projetos de Pesquisa e Desenvolvimento com foco em energia solar, como aquele decorrente do Projeto Estratégico da Chamada Pública da ANEEL 013/2011 (Energia Solar Fotovoltaica) e do Projeto Estratégico da Chamada Pública da ANEEL 019/2015 (Energia Heliotérmica), levaram à necessidade de se conduzir estudos de medição solarimétrica nas áreas onde os projetos serão instalados. Os dados de irradiação solar direta, difusa e global em superfícies horizontais e inclinadas constituem elementos essenciais para a modelagem e avaliação de desempenho de plantas heliotérmicas e fotovoltaicas.

(*) Rua Delmiro Gouveia, n° 333, Bloco B, Sala 213, San Martin, CEP 50761-901, Recife, PE, – Brasil
Tel: (+55 81) 3229-3547 – email: alcidesc@chesf.gov.br



As Redes Neurais Artificiais (RNA) constituem uma técnica importante para se estimar a radiação solar em uma dada região propícia à instalação de usinas fotovoltaicas e heliotérmicas. Uma Rede Neural Artificial consiste de uma estrutura interconectada de unidades de processamento simples, cuja funcionalidade assemelha-se a um neurônio biológico. Essas unidades de processamento são conectadas em rede, obedecendo a uma dada arquitetura, e observando-se um conjunto de parâmetros definidos para o problema em consideração, quando do treinamento da RNA. Durante as duas últimas décadas as RNA têm sido bastante empregadas como uma técnica importante em várias áreas de pesquisa, como por exemplo, otimização e previsão de dados, de bastante interesse para o estudo das medições solarimétricas.

Devido à natureza estocástica da radiação solar (direta, difusa e global), as técnicas empregadas por meio das RNA mostram-se interessantes na sua determinação. Essas técnicas se aplicam bem quando se considera a incerteza dos vários parâmetros climáticos, espacial e temporal que levam à determinação da radiação global. Dados horários médios mensais de temperatura, umidade relativa do ar, índice pluviométrico e velocidade do vento ao longo de um período de tempo, como um ciclo anual, para uma localidade a uma dada altitude, latitude e longitude, são de fundamental importância para se analisar o índice de radiação solar (direta, difusa e global) dessa localidade. Esses parâmetros são essenciais na análise de desempenho de plantas solares fotovoltaicas e heliotérmicas. Quando das medições solarimétricas em uma dada localidade de interesse, para instalação de uma planta solar, faz-se necessário estimar os dados solarimétricos, o que tem sido feito empregando-se uma técnica convencional comprovada cientificamente, geralmente através de correlações.

Por exemplo, para o desenvolvimento de empreendimentos com tecnologia CSP é necessária uma avaliação do potencial solar a partir da medição da Radiação Solar Direta Normal - DNI (*Direct Normal Irradiance*), ou seja, a radiação normal direta no local de implantação. Um valor aceitável para a implantação de tecnologia heliotérmica é uma radiação DNI superior a 1900 kWh/m² ano (equivalente a 5,3 kWh/m² dia). A região do semiárido nordestino apresenta-se como uma área favorável, seja pelos elevados níveis da radiação, baixa pluviometria, como também pela proximidade da Linha do Equador.

Este Informe Técnico tem como objetivo apresentar um método para estimação da Radiação Solar Normal Direta (DNI) em uma dada localidade, a partir do treinamento de uma Rede Neural Artificial do tipo *Multilayer Perceptron* (MLP). O treinamento da Rede Neural Artificial dar-se-á usando-se a técnica de aprendizado supervisionado conhecida como *backpropagation*. Foram considerados dados da Radiação Solar Normal Direta (DNI), medidos em solo, no distrito de Bom Nome, situado no município de São José do Belmonte, no sertão do Estado de Pernambuco.

2.0 - REDES NEURAIS ARTIFICIAIS

A Rede Neural Artificial (RNA) é uma técnica baseada no funcionamento do cérebro humano. A ideia dos neurônios como constituintes do cérebro foi introduzida por Ramon Cajal em 1911 [2]. A figura 1 mostra a representação de um neurônio biológico.




FIGURA 1 – Representação de um Neurônio Biológico

Neurônios biológicos apresentam características não lineares e formam sistemas de processamento de informações altamente paralelos, os quais são caracterizados por robustez, tolerância à falta e habilidade de aprender pela força das conexões, no que diz respeito a mudanças no ambiente em observação. Nos neurônios biológicos, sinais eletroquímicos conhecidos como estímulos são recebidos pela célula neuronal através das sinapses. Cada sinapse tem seu próprio peso, o qual determina a forma e a extensão do estímulo que chega ao neurônio através daquela sinapse, que também afeta a saída do referido neurônio. A soma dos pesos dos estímulos de entrada alimentam o núcleo do neurônio que, em resposta, envia impulsos elétricos que são transmitidos para outros neurônios, ou são enviados para outras unidades biológicas. Os pesos sinápticos são sempre atualizados durante o processo de aprendizagem. Os neurônios são interconectados com um grande número de outros neurônios através das sinapses. Grupos de neurônios são organizados em subsistemas que são integrados para formar o cérebro [2].

A figura 2 apresenta um modelo simplificado de uma Rede Neural Artificial (RNA). Essa técnica de RNA simula a entrada de estímulos, que alimentam os neurônios de entrada (sinapses). Esses estímulos são alterados pelos pesos sinápticos. O somatório dos produtos de cada estímulo e seu respectivo peso sináptico passa a ser a entrada de uma função de ativação, e cuja saída é alimentada para outros neurônios da rede neural. Todos esses neurônios são interconectados, e os valores de ativação podem constituir a saída final da rede neural ou podem ainda ser alimentados para o próximo modelo. Os pesos de conexão são modificados durante o treinamento da rede de forma a se obter um melhor resultado, quando comparado com a resposta desejada. A definição da arquitetura de rede neural a ser utilizada depende do problema a ser considerado.




FIGURA 2 – Representação de um Neurônio Artificial

2.1 Rede Neural Artificial do Tipo *Multilayer Backpropagation*

A figura 3 apresenta um modelo de RNA com duas camadas. Em uma RNA cada neurônio processa uma soma ponderada de seus sinais de entrada, x_j , para $j = 1, 2, \dots, n$, e cujo resultado é então aplicado uma função de ativação não linear. As equações 1 e 2 apresentam, respectivamente, a função de saída e a função de ativação. Um função de ativação típica é a função sigmóide, apresentada na figura 4.




FIGURA 3 – Rede Neural Artificial com os Neurônios de Entrada e Duas Camadas

$$y = \varphi \left(\sum_{j=1}^n w_{ji} x_j \right) \quad (1)$$

$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

O algoritmo *Backpropagation* é um método de treinamento iterativo supervisionado para redes neurais de alimentação multicamadas, que usa o treinamento de dados consistindo de P pares de vetores entrada-saída que caracteriza o problema [6]. Uma amostra de treinamento de dados é escolhida aleatoriamente e considerando o vetor de entrada da rede, leva ao vetor de saída dessa rede, através do processamento da RNA, camada por camada. A diferença entre a saída da rede neural e a resposta desejada é usada para ajustar os pesos sinápticos, de forma que à medida que a rede neural é treinada, o vetor de saída dessa rede será mais próximo da saída desejada para o problema a ser resolvido. Esse processo é repetido até que a saída da rede neural em treinamento convirja para a resposta desejada. O algoritmo *Backpropagation* minimiza uma função erro definida pela média da diferença do quadrado da soma entre a diferença de cada neurônio na camada de saída e a saída desejada. A função erro é apresentada na equação 3, onde p é o índice dos P pares de vetores, k é o índice dos elementos do vetor de saída Y , d_{pk} é o k -ésimo elemento do vetor resposta desejado, e y_{pk} é o k -ésimo elemento do vetor de saída quando o padrão p se refere à entrada da rede neural.




FIGURA 4 – Função de Ativação Sigmóide

$$E = \frac{1}{P} \sum_P \sum_k (d_{pk} - y_{pk})^2 \quad (3)$$

A minimização da função erro E resulta na regra de atualização dos pesos das conexões entre os neurônios. Esse ajuste do peso da conexão entre o neurônio i , em uma camada m , e o neurônio j , em uma camada $m+1$, é expresso na equação 4, onde i é o índice de unidades na camada m , A constante positiva η é conhecida como taxa de aprendizado da rede neural, y_i é a saída da unidade i na m -ésima camada, e δ_j é o termo do erro delta propagado de volta da j -ésima unidade, na camada $m+1$, definida na equação 5; k é o índice de neurônios na camada $m+2$, à frente da camada que contém o neurônio j .

$$\Delta w_{ji} = \eta \delta_j y_i \quad (4)$$

$$\delta_j = [d_j - y_j] y_j [1 - y_j], \text{ se o neurônio } j \text{ estiver na camada de saída.} \quad (5)$$

$$\delta_j = y_j [1 - y_j] \sum_k \delta_k w_{kj}, \text{ se o neurônio } j \text{ estiver na camada escondida.}$$

Nas equações 4 e 5, a escolha de uma taxa de aprendizado pequena leva a uma taxa de convergência lenta; por outro lado, uma taxa de aprendizado elevada leva a oscilações quando do processo de convergência. Uma solução simples para aumentar a taxa de aprendizado sem oscilação é a inclusão de um termo conhecido como momentum, $\alpha \Delta w_{ji}(n)$, o qual determina o efeito das mudanças dos pesos anteriores na direção do movimento no espaço dos pesos, onde n é o número da iteração e α é uma constante positiva pequena. Assim a regra de atualização dos pesos sinápticos é apresentada na equação 6. Quando da ocorrência da convergência, a rede neural então estará pronta para teste e operação [3, 6].

$$\Delta w_{ji}(n+1) = \eta \delta_j y_i + \alpha \Delta w_{ji}(n) \quad (6)$$

2.2 O Algoritmo *Resilient Propagation* - RPROP

De acordo com Riedmiller e Braun [4, 5], o algoritmo RPROP (*Resilient Propagation*), é um algoritmo de aprendizado extremamente eficiente que executa o cálculo do Δw_{ji} de forma direta, baseado em informações locais do gradiente, e não baseado na “dimensão” do gradiente, sendo as derivadas parciais de cada peso de um neurônio conhecidas; a minimização da função erro E é obtida executando-se o gradiente descendente.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$$

$$\Delta w_{ji} = -\eta \frac{\partial E(t)}{\partial w_{ji}} \quad (7)$$

A escolha da taxa de aprendizado η , que determina o tamanho do passo na direção contrária ao gradiente da função erro tem um importante efeito no tempo despendido até que a convergência seja alcançada (tempo de treinamento). Se a taxa de aprendizado é pequena, são necessários muitos passos até que um valor aceitável da função erro seja alcançado; do contrário, se a taxa de aprendizado é escolhida como sendo muito grande, provavelmente será apresentada uma oscilação da função erro E , não permitindo que seja atingido o valor desejado. Para se obter esse algoritmo, deve-se introduzir a variável Δ_{ji} , que é denominada de “valor atualizado”. Cada peso Δw_{ji} tem sua variável Δ_{ji} , e ela determina, de forma exclusiva, o tamanho da variável Δw_{ji} . A variável segue a seguinte regra de aprendizagem:

$$\Delta_{ji}(t) = \begin{cases} \eta * \Delta_{ji}(t-1) & \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} > 0 \\ \eta * \Delta_{ji}(t-1) & \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} < 0 \end{cases} \quad (8)$$

Toda vez que a derivada parcial do correspondente peso muda de sinal, o que indica que a última atualização foi muito grande e o algoritmo pulou um mínimo local, a variável Δ_{ji} é diminuída por um fator η . Se a derivada mantém seu sinal, a variável é levemente incrementada de modo a acelerar a convergência em regiões de planície.

Então, a atualização da variável Δw_{ji} é realizada de acordo com a seguinte regra bastante simples: Se a derivada parcial é positiva (função erro aumentando de valor), o peso w_{ji} é diminuído pela sua variável Δ_{ji} . Se a derivada é negativa, o Δ_{ji} é adicionado.

$$\Delta w_{ji}(t) = \begin{cases} -\Delta_{ji}(t) & \text{if } \frac{\partial E(t)}{\partial w_{ji}} > 0 \\ +\Delta_{ji}(t) & \text{if } \frac{\partial E(t)}{\partial w_{ji}} < 0 \end{cases} \quad (9)$$

Entretanto, existe uma exceção: se a derivada parcial mudar de sinal, isto é, o passo anterior foi muito grande e o ponto de mínimo foi perdido, a atualização do peso é revertida.

$$\Delta w_{ji}(t) = -\Delta w_{ji}(t-1), \quad \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} < 0 \quad (10)$$

Devido ao "backtracking" acima, a derivada pode mudar de sinal novamente no passo seguinte. Para evitar uma punição dupla da variável Δ_{ji} , deve-se não atualizá-la no passo seguinte. Na prática isto pode ser feito declarando $\frac{\partial E(t-1)}{\partial w_{ji}} = 0$ na regra de adaptação da variável Δ_{ji} . As variáveis Δ_{ji} e os pesos w_{ji} são atualizados uma vez por época (uma época significa que todos os padrões do conjunto de treinamento são apresentados uma vez).

Em relação a todos os outros algoritmos de treinamento rápido para o *Multilayer Perceptron* (MLP), o algoritmo RPROP toma somente o sinal da derivada parcial para executar o aprendizado da RNA. Esta característica conduz a um processo de adaptação transparente e extremamente poderoso, muito eficiente em relação ao tempo de processamento e memória computacional utilizados.

3.0 – O PROCEDIMENTO PARA A ESTIMATIVA DA IRRADIAÇÃO SOLARIMÉTRICA

O controle de qualidade dos dados medidos em estações solarimétricas tem a finalidade de excluir dados medidos incorretamente, pouco prováveis de ocorrer e inexistentes, monitorar o sistema de medição, e garantir a operação e manutenção correta desses dados, obtendo-se dessa forma, uma estimativa de medição aceitável.

Essa técnica de estimativa de irradiação solarimétrica com o uso de Rede Neural Artificial, aplicada aos dados medidos, é realizada após a medição *in loco*, seguida do controle de qualidade dos dados medidos. A figura 5 apresenta os procedimentos a serem considerados quando da aplicação desse método.



FIGURA 5 – Procedimentos para aplicação da técnica com o uso de RNA

4.0 – METODOLOGIA

A metodologia para estimativa da irradiação solar depende da disponibilidade dos três componentes da irradiação solar (GHI, DHI e DNI), e da existência de dados medidos incorretamente ou mesmo não medidos (inexistentes) no período de tempo considerado para o tratamento desses dados.

Levou-se em consideração se um, dois ou os três dados solares (GHI, DHI e DNI) estão ausentes. Em termo do intervalo de tempo para medição, a metodologia diferencia entre intervalos de até uma hora, maior do que uma hora e maiores do que vinte e quatro horas, conforme especificado na Tabela 1. A depender da disponibilidade dos três componentes da irradiação solar e do comprimento dos intervalos de ausência de medições considerados, estes são preenchidos ou pela equação que relaciona os três componentes, ou por outras técnicas citadas na literatura (1), conforme apresentado na figura 6.

Tabela 1. – Metodologia de Estimativa dos Dados

Número de Componentes Ausentes (GHI, DHI, DNI)	Cálculo do componente ausente
Um componente ausente	$GHI = DNI * \cos(SZA) + DHI$
Dois componentes ausentes	Método da Referência (8)
Tres componentes ausentes com Lacuna menor do que 1h	Interpolacao Linear
Tres componentes ausentes com Lacuna maior do que 1h	Redes Neurais Artificiais

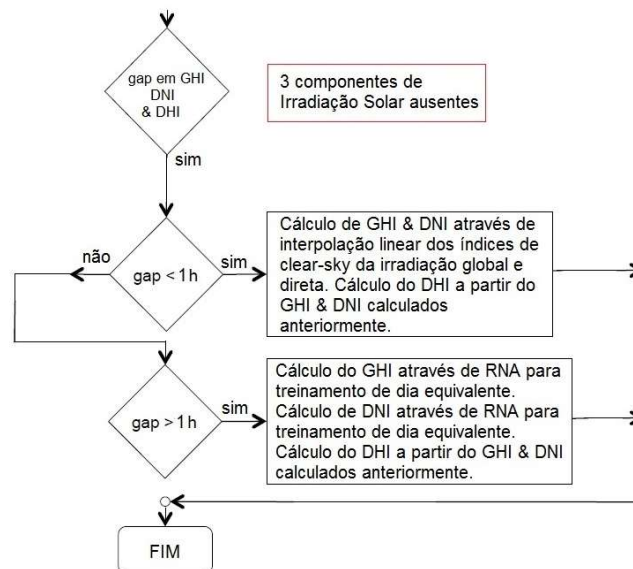


FIGURA 6 – Metodologia para aplicação da Estimativa de Medição Solarimétrica

A Rede Neural considerada foi uma MLP (Multilayer Perceptron) conforme mostrada na figura 7. Essa MLP tem duas camadas escondidas com função sigmóide, e uma camada de saída com função linear. As camadas escondidas têm quarenta neurônios na primeira e dez neurônios na segunda.

Os dados utilizados para treinamento da Rede Neural foram divididos em três classes de dias: bons, médios e ruins. Verificou-se que a divisão dos dias nessas três classes facilitou o desempenho da Rede Neural. O critério utilizado para divisão dos dias nessas três classes é heurístico e é calculado através de um índice de aproximação em relação a um dia que já tenha sido avaliado como bom, ruim ou médio por um analista

especializado. Os valores de DNI foram normalizados para utilização no treinamento das Redes Neurais.

A Figura 8 apresenta a solução da Rede Neural considerada, para a medição da irradiação DNI (W/m^2) para três dias típicos, quais sejam, a classe de dias ruins, a classe de dias bons e a classe de dias médios. Os valores em vermelho são a resposta da Rede Neural e os valores em preto são os dados medidos. A Figura 8a é a classe de dias bons, com boa insolação DNI e sem nuvens. A Figura 8b é a de um dia típico de qualidade de DNI médio e a Figura 8c é a de um dia de irradiação DNI ruim.

Conforme os resultados preliminares, a utilização das Redes Neurais mostrou-se satisfatória para a solução da estimativa solarimétrica pretendida.




FIGURA 7 – Rede Neural MLP utilizada




FIGURA 8 – Aproximação da Rede Neural para Irradiação Normal Direta (DNI) medida em solo

5.0 – CONCLUSÃO

Esse Informe Técnico apresentou um método para estimativa da irradiação solar em uma dada localidade a partir do treinamento de uma Rede Neural Artificial do tipo *Multilayer Perceptron* (MLP), usando a técnica de aprendizado supervisionado conhecida como *back-propagation*. Foi utilizado o algoritmo RPROP (*Resilient Propagation*), que é um algoritmo de aprendizado extremamente eficiente, para tratamento de dados solarimétricos. Esse método apresentou resultados preliminares satisfatórios. Foram considerados dados da Radiação Solar Normal Direta (DNI), medidos em solo, no distrito de Bom Nome, situado no município de São José do Belmonte, no sertão do Estado de Pernambuco.

Recomenda-se que essa técnica seja estudada em maior profundidade e aplicada a outras localidades de interesse da Chesf para aplicação da estimativa de energia solar, considerando outros parâmetros, como a irradiação difusa (Difuse Horizontal Irradiance – DHI) e a irradiação global (Global Horizontal Irradiance – GHI), além de dados pluviométricos, que estão relacionados com a formação de nuvens, e que afetam as medições de dados em estações solarimétricas.

6.0 – REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Schwandt, M.; Chhatbar, K.; Meyer, R.; Fross, K.; Mitra, I.; Vashistha, R.; Giridhar, G.; Gomathinayagam, S.; Kumar, A.; "Development and test of gap filling procedures for radiation data of the Indian SRRA measurement network", Energy Procedia, Elsevier - 2013 ISES Solar World Congress.



- (2) Reddy, K. S.; Ranjan, M.; "Solar resource estimation using artificial neural networks and comparison with other correlation models", Energy Conversion and Management, Pergamon, 2002.
- (3) Mohandes, M.; Rehman, S.; Halawani, T. O.; "Estimation of Global Solar Radiation Using Artificial Neural Networks", Renewable Energy, Vol. 14, Nos. 1 – 4, pp. 179 – 184, Pergamon, 1998.
- (4) Riedmiller, M.; Braun, H.; "A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm", Proceedings of the IEEE International Conference on Neural Networks, San Francisco – USA, 1993.
- (5) Sodr , E. A.; "Avalia o da Estabilidade de Tens o atrav s das T cnicas de Intelig ncia Artificial", Tese de Doutorado, UFCG, 2006.
- (6) Haykin, S.; "Neural Networks and Learning Machines", Third Edition, Pearson – Prentice Hall, 2009.
- (7) Crawford, Mark; "Catching the Sun", Magazine of The American Society of Mechanical Engineers – ASME, Mar o de 2013, p ginas 32 a 37.
- (8) D. G. Erbs, S. A. Klein, J. A. Duffie, "Estimation of the diffuse radiation fraction for hourly, daily and monthly-average global radiation", Solar Energy 28, 293–302, 1982.

7.0 – DADOS BIOGRFICOS

Alcides Codeceira Neto possui MSc e PhD em Engenharia Mec nica pela Cranfield University - Inglaterra, na  rea de Ci ncias T rmicas,   professor da Escola Polit cnica da Universidade de Pernambuco - UPE e Engenheiro da Assessoria de Pesquisa, Desenvolvimento e Inova o (AEP) da Chesf.

Eduardo de Aguiar Sodr  possui DSc em Engenharia El trica pela UFCG,   professor da Escola Polit cnica de Pernambuco - UPE e Engenheiro do Departamento de Engenharia de Gera o E lica (DEGE) da CHESF.

Jos  Bione de Melo Filho possui DSc em Tecnologias Energ ticas Nucleares pela UFPE,   professor do Instituto Federal de Pernambuco – IFPE e Gerente da Assessoria de Pesquisa, Desenvolvimento e Inova o (AEP) da Chesf.