

GAP FILLING DE DADOS SOLARIMÉTRICOS UTILIZANDO REDES NEURAS ARTIFICIAIS

Alcides Codeceira Neto – alcidesc@chesf.gov.br

Eduardo de Aguiar Sodré – easodre@chesf.gov.br

CHESF / UPE

Pedro Bezerra de Carvalho Neto – pbezerra@chesf.gov.br

CHESF

José Bione de Melo Filho – jbione@chesf.gov.br

CHESF / IFPE

Nicolaj Röttinger – n.roettinger@googlemail.com

GIZ

Resumo. 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. Devido à natureza estocástica da irradiação 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 irradiação 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 irradiação solar 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 usina solar, pode-se deparar com determinadas situações onde alguns desses parâmetros, por motivos operacionais, deixaram de ser medidos e armazenados pelo conjunto de equipamentos instalados localmente, gerando algumas lacunas no banco de dados técnicos a ser construído. Dessa forma, faz-se necessário estimar aqueles dados faltantes, aqui denominados de gap filling, usando uma técnica comprovada cientificamente. Este artigo técnico tem como objetivo apresentar um método para estimação 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. São considerados dados medidos em solo para a localidade em análise, e a existência de lacunas no banco de dados solarimétricos, o que evidencia o uso de uma técnica de Gap Filling, como o uso de uma RNA.

Palavras-chave: Gap Filling, Irradiação Direta Normal (DNI), Redes Neurais Artificiais.

1. INTRODUÇÃO

O aproveitamento da energia solar para a produção de energia elétrica pode ser efetuado por meio da transformação da irradiação solar diretamente em energia elétrica pelo processo fotovoltaico, ou pelo aproveitamento da energia solar térmica proveniente da tecnologia de concentração da irradiação solar direta, produzindo vapor e integrando um ciclo termodinâmico convencional turbo-gerador para produção de eletricidade. Essa tecnologia é mundialmente denominada *Concentrating Solar Power (CSP)*.

A Chesf, por meio da Cooperação para o Desenvolvimento Sustentável entre o Brasil e a Alemanha, está participando do programa “Energia Heliotérmica”, que tem como objetivo fornecer recursos para medidas de mitigação das mudanças climáticas no marco da modalidade de financiamento para promover tecnologias favoráveis à proteção do clima global (*Deutsche Klima- und Technologieinitiative - DKTI*). No âmbito do DKTI-CSP, O Banco de Desenvolvimento Alemão - KfW e a Chesf assinaram um termo de cooperação a fim de acordar medidas concretas para a preparação de um eventual investimento em uma usina piloto usando a tecnologia Heliotérmica CSP (*Concentrated Solar Thermal Power*) em escala industrial (30 – 50 MWe) no Nordeste do Brasil. A disponibilização de recursos financeiros à Chesf, pelo KfW, resultou em serviços de consultoria com o objetivo de otimizar o processo de medições solarimétricas e seleção de localidades para instalação de estações solarimétricas em quinze subestações da Chesf. O governo Alemão também está contribuindo financeiramente por meio da Agência Internacional de Cooperação Alemã (*Deutsche Gesellschaft für Internationale Zusammenarbeit - GIZ*), na modalidade de cooperação técnica, em coordenação conjunta com o Ministério da Ciência, Tecnologia e Inovação.

Com base nos resultados dos estudos e nos critérios previstos pelo KfW, a Chesf identificou cinco locais no entorno das estações de medição, adequados para uma eventual instalação de uma usina CSP. Essa Cooperação Técnica inclui um estudo de pré-viabilidade, focando tanto na tecnologia CSP como na tecnologia fotovoltaica, devendo esse

estudo ser seguido por um estudo de viabilidade, os quais deverão fornecer à Chesf informações necessárias para um eventual desenvolvimento de uma usina comercial de energia solar de dimensão industrial.

A técnica de medição da energia solar é conhecida como aquela que mais apresenta lacunas (*gaps*) quando da elaboração de dados de séries temporais medidas. Lacunas podem ocorrer devido à perda de potência, desalinhamento dos instrumentos de medição, falta de limpeza na superfície desses instrumentos de medição, dentre outros fatores. Procedimentos de rotina com a finalidade de avaliar a qualidade dos dados medidos visam identificar o mau funcionamento desses instrumentos. Mesmo equipando-se as estações solarimétricas com bons equipamentos de medição, usualmente as séries temporais dos dados medidos apresentam a existência de lacunas, as quais podem ter uma faixa de duração que vai de alguns minutos até vários dias. A depender da duração desse intervalo sem ocorrência de medição e do tipo de parâmetros não registrados, vários procedimentos podem ser usados para preenchimento dos intervalos cujas medições não foram registradas (*gaps*). Muitas aplicações tais como as simulações para estudos de desempenho de energia solar necessitam da preparação de dados a serem organizados em séries temporais. Dessa forma, torna-se de grande importância o preenchimento das lacunas com inexistência de parâmetros medidos com valores que apresentem certo grau de confiabilidade, de forma a serem utilizados nos estudos de desempenho de energia solar (Schwandt *et al.*, 2013).

Devido à natureza estocástica da irradiação solar (direta, difusa e global), as técnicas empregadas por meio das RNA mostram-se interessantes na sua determinação. Por exemplo, para o desenvolvimento de empreendimentos com tecnologia CSP é necessária uma avaliação do potencial solar a partir da medição da Irradiação Solar Direta Normal - DNI (*Direct Normal Irradiance*), ou seja, a irradiação normal direta no local de implantação. Um valor aceitável para a implantação de tecnologia heliotérmica é uma irradiação DNI superior a 1900 kWh/m² ano (equivalente a 5,3 kWh/m² dia). A região do semi-árido nordestino apresenta-se como uma área favorável, seja pelos elevados níveis da irradiação, baixa pluviometria, como também pela proximidade da Linha do Equador. Conforme as referências pesquisadas não há um procedimento padrão para o preenchimento de lacunas (*gaps*) de dados de irradiação solar. Algumas pesquisas aplicadas têm sido realizadas nessa linha pela Agência Internacional de Energia (*International Energy Agency – IEA*), *IEA Task 46* e *IEA SolarPACES*, e pelo Projeto de Pesquisa da União Europeia denominado ENDORSE. Entretanto, os procedimentos de *Gap Filling* e cheque de qualidade desses dados ainda não são aplicados a dados de redes de qualidade de alta pesquisa (Schwandt *et al.*, 2013).

Este artigo técnico tem como objetivo apresentar um método para estimação da Irradiação 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 Irradiação 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. Para essa localidade os dados medidos foram analisados, sendo constatada a existência de lacunas no banco de dados solarimétrico, o que evidencia a técnica de *Gap Filling* usando a RNA.

2. REDES NEURAIS ARTIFICIAIS

A Rede Neural Artificial (RNA) é uma técnica baseada em alguns fatos importantes do sistema nervoso que têm sido estudado por neurocientistas e outros profissionais da área de saúde. Apesar dos significantes avanços na área, muitos estudos e pesquisas ainda precisam ser realizados. A ideia dos neurônios como constituintes do cérebro foi introduzida por Ramon Cajal em 1911 (Reddy and Ranjan, 2002). A Fig. 1 mostra a representação de um neurônio biológico.

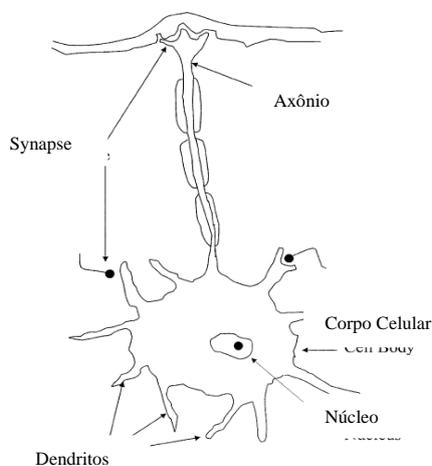


Figura 1 – Representação de um Neurônio Biológico

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 (Reddy and Ranjan, 2002).

A Fig. 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.

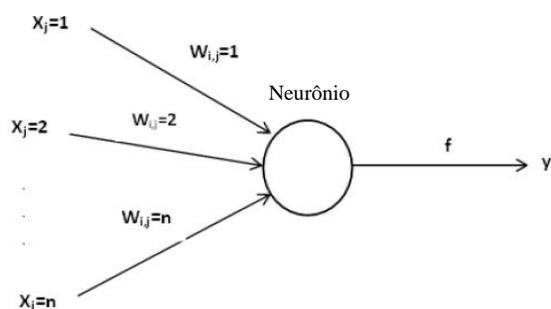


Figura 2 – Representação de um Neurônio Artificial

No caso do uso de Redes Neurais Artificiais (RNA) com o propósito do preenchimento de lacunas (*Gap Filling*) em séries de dados de medições solarimétricas, ressaltam-se as dificuldades inerentes às incertezas da irradiação solar, no que diz respeito aos parâmetros climáticos, espaciais e temporais dos valores da irradiação solar. Levando-se em consideração essas incertezas, têm-se buscado a aplicação das técnicas de RNA para resolução desses problemas.

2.1 Rede Neural Artificial do Tipo Multilayer Perceptron

A Fig. 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 Eqs. 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 Fig. 4.

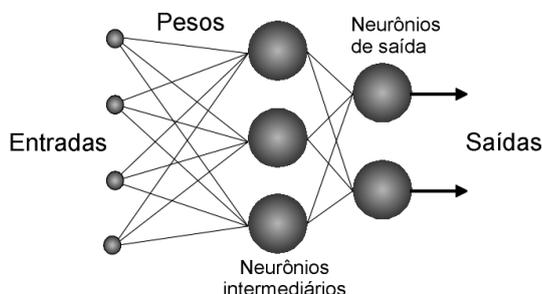


Figura 3 – Rede Neural Artificial com os Neurônios de Entrada e Duas Camadas

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

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

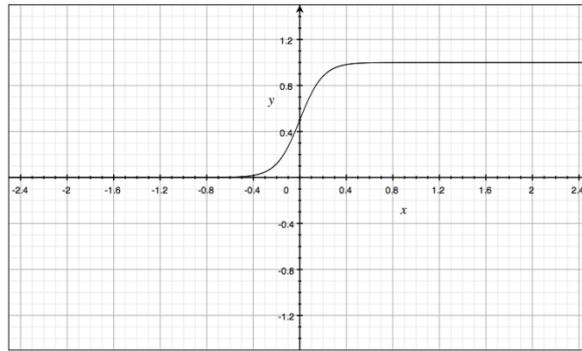


Figura 4 – Função de Ativação Sigmóide

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 (Haykin, 2009). 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 Eq. (3), onde p é o índice dos P pares de vetores, k é o índice dos elementos do vetor de saída \mathbf{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.

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

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 Eq. (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 Eq. (5); k é o índice de neurônios na camada $m+2$, à frente da camada que contém o neurônio j .

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

$$\begin{aligned} \delta_j &= [d_j - y_j] y_j [1 - y_j], \text{ se o neurônio } j \text{ estiver na camada de saída.} \\ \delta_j &= y_j [1 - y_j] \sum_k \delta_k w_{kj}, \text{ se o neurônio } j \text{ estiver na camada escondida.} \end{aligned} \quad (5)$$

Nas Eq. (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 Eq. (6). Quando da ocorrência da convergência, a rede neural então estará pronta para teste e operação (Mohandes, *et al.*, 1998), (Haykin, 2009).

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

2.2 O Algoritmo Resilient Propagation - RPROP

De acordo com (Riedmiller and Braun, 1993) e (Sodré, 2006), 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.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t) \quad (7)$$

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

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 w_{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:

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

onde $0 < \eta^- < 1 < \eta^+$

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 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.

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

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

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 fazendo que a derivada $\partial E(t-1)/\partial w_{ji} = 0$ 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. O PROCEDIMENTO DE GAP FILLING

O controle de qualidade dos dados medidos em estações solarimétricas tem a finalidade de excluir dados

medidos incorretamente ou pouco prováveis de ocorrer, monitorar o sistema de medição, e garantir a operação e manutenção correta desses dados, obtendo-se dessa forma, dados meteorológicos de alta precisão.

Em sendo assim, visando obter dados meteorológicos com alta precisão e sem lacunas, o método de *Gap Filling* visa preencher as lacunas de dados que foram excluídos, ou aqueles que estão incorretos.

A técnica de *Gap Filling* com o uso de RNA, aplicada aos dados solarimétricos medidos, é realizada após a medição solarimétrica realizada in loco, seguida do controle de qualidade dos dados medidos. A Fig. 5 apresenta os procedimentos a serem considerados quando da aplicação desse método.

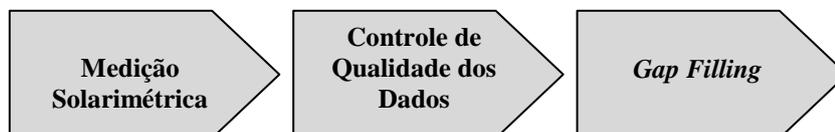


Figura 5 – Procedimentos para aplicação da técnica de *Gap Filling*

4. METODOLOGIA

Para o *Gap Filling* dos dados solarimétricos, a metodologia aplicada depende de:

- disponibilidade dos três componentes da irradiação solar sendo medidos, isto é, GHI, DHI e DNI; e
- duração no tempo do gap (dados ausentes).

A metodologia do *Gap Filling* leva em consideração se um, dois ou todos os três dados solarimétricos estão ausentes (gaps). Em termo do comprimento dos gaps, a metodologia diferencia entre gaps até 1 hora, maior do que 1 hora e gaps maiores do que 24 horas, conforme mostrado na Tab. 1, a seguir. Dependendo da disponibilidade dos três componentes da irradiação solar e da duração (comprimento) dos gaps, estes são preenchidos ou pela equação que relaciona os três componentes, ou por outras técnicas citadas na literatura (Schwandt *et al.*, 2013), conforme apresentado na Fig. 6.

Tabela 1 – Metodologia do Gap Filling

Número de Componentes Ausentes (GHI, DHI, DNI)	Cálculo do componente ausente
Um componente ausente	$GHI = DNI * \cos(SZA) + DHI$
Dois componentes ausentes	Método (Erbs, <i>et al.</i> , 1982)
Tres componentes ausentes com Lacuna menor do que 1h	Interpolacao Linear
Tres componentes ausentes com Lacuna maior do que 1h	Redes Neurais Artificiais

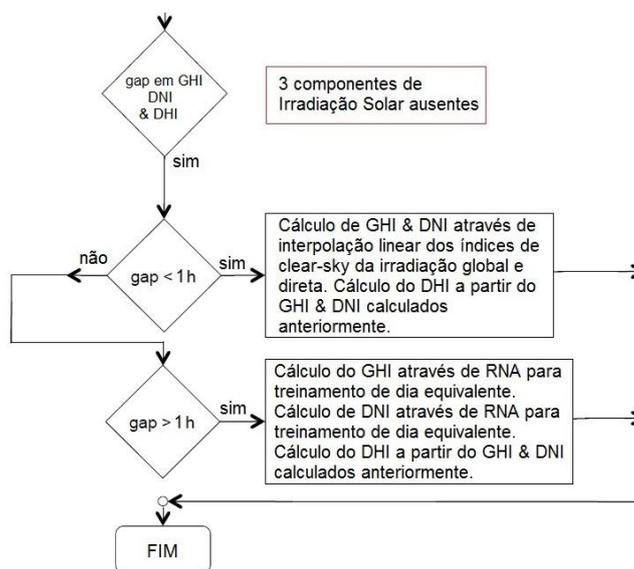


Figura 6 – Metodologia para aplicação da técnica de *Gap Filling*

A Rede Neural considerada foi uma MLP (Multilayer Perceptron) conforme apresentado na Fig. 7. Essa MLP tem 2 (duas) camadas escondidas com função Sigmóide, e uma camada de saída com função linear. As camadas escondidas têm 40 (quarenta) neurônios na primeira e 10 (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 facilita a 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 Fig. 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 de irradiação considerados são somente os valores normalizados e agregados em média de 10 minutos das 12 horas diurnas (das 06h00 às 18h00), totalizando 72 pontos de irradiação. Os valores em vermelho representam a resposta da Rede Neural e os valores em preto representam os dados medidos. A Fig. 8(a) é a classe de dias bons, com boa insolação DNI e sem nuvens. A Fig. 8(b) é um dia típico de qualidade de DNI médio e a Fig. 8(c) é um dia de irradiação DNI ruim.

A Fig. 9 apresenta os resultados dos Erros Quadráticos Médios (Mean Squared Error) para cada época de treinamento da Rede Neural.

Conforme os resultados preliminares estão sendo obtidos, a utilização das Redes Neurais tem-se mostrado promissora para a solução do *Gap Filling*.

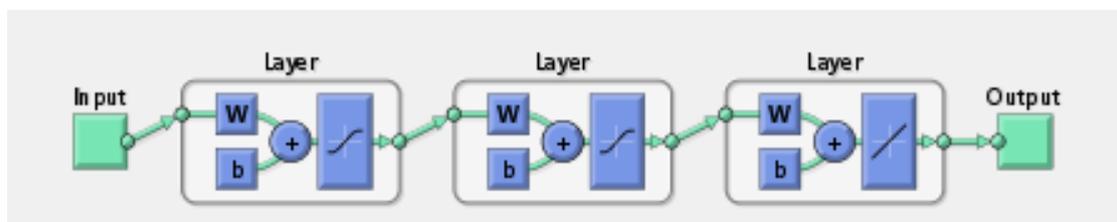


Figura 7 – Rede Neural MLP utilizada

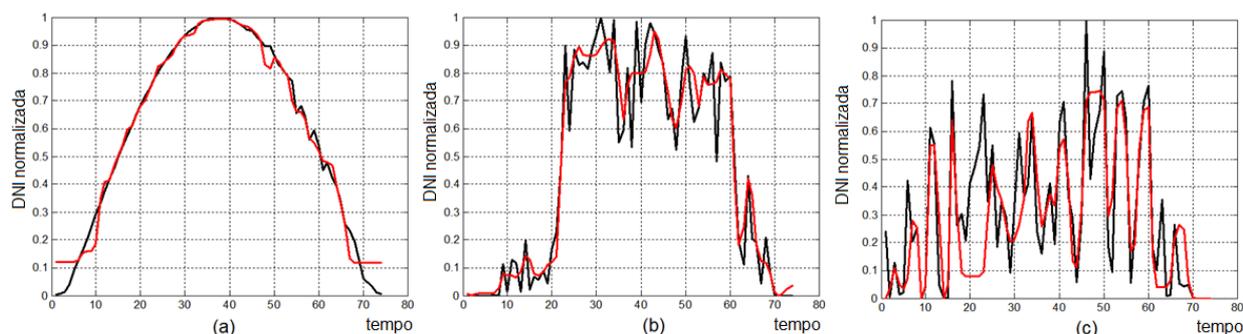


Figura 8 – Aproximação da Rede Neural para Irradiação Normal Direta (DNI) medida em solo

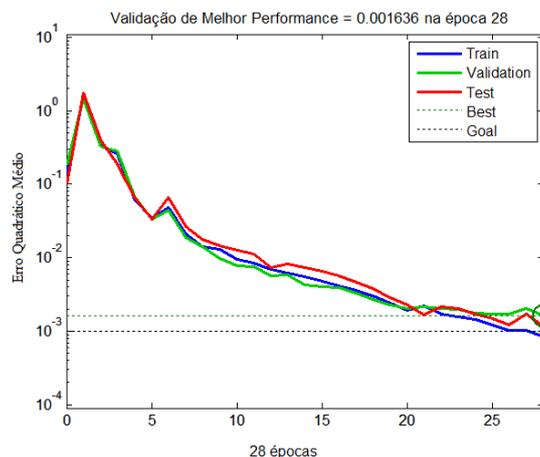


Figura 9 – Erros Quadráticos Médios

5. CONCLUSÃO

Este artigo 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 preenchimento de lacunas (*Gap Filling*) existentes quando da medição solarimétrica dos dados considerados.

Pode-se afirmar que as empresas que trabalham nessa área não chegaram num consenso quanto aos procedimentos padrões para o preenchimento de lacunas (*gaps*) de dados de irradiação solar. Algumas pesquisas aplicadas têm sido realizadas nessa linha pela Agência Internacional de Energia (*International Energy Agency – IEA*). Entretanto, os procedimentos de *Gap Filling* e cheque de qualidade desses dados ainda não são aplicados a dados de redes de qualidade de alta pesquisa (Schwandt *et al.*, 2013). Foram considerados dados da Irradiação 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.

Como resultado da técnica de *Gap Filling* para preenchimento das lacunas existentes com o uso de RNA em medições solarimétricas, constatou-se que o método em referência apresentou resultados preliminares que podem ser quantificados através da Fig. 9.

Recomenda-se que as RNS sejam estudadas em maior profundidade e aplicadas a outras localidades de interesse da Chesf, 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 sobremaneira as medições de dados em estações solarimétricas.

REFERÊNCIAS

- Schwandt, M., Chhatbar, K., Meyer, R., Fross, K., Mitra, I., Vashistha, R., Giridhar, G., Gomathinayagam, S., Kumar, A., 2013. Development and test of gap filling procedures for radiation data of the Indian SRRA measurement network, Energy Procedia, Elsevier - ISES Solar World Congress.
- Reddy, K. S., Ranjan, M., 2002. Solar resource estimation using artificial neural networks and comparison with other correlation models, Energy Conversion and Management, Pergamon.
- Mohandes, M., Rehman, S., Halawani, T. O., 1998. Estimation of Global Solar Radiation Using Artificial Neural Networks, Renewable Energy, Vol. 14, n. 1 – 4, pp. 179 – 184, Pergamon.
- Riedmiller, M., Braun, H., 1993. A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm, Proceedings of the IEEE International Conference on Neural Networks, San Francisco – USA.
- Sodré, E., 2006. Avaliação da Estabilidade de Tensão através das Técnicas de Inteligência Artificial, Tese de Doutorado, Eng. Elétrica, UFCG, 2006.
- Haykin, S., 2009. Neural Networks and Learning Machines, Third Edition, Pearson – Prentice Hall.
- Erbs, D. G., Klein, S. A., Duffie, J. A., 1982. Estimation of the diffuse radiation fraction for hourly, daily and monthly-average global radiation, Solar Energy 28, pgs 293–302.

GAP FILLING OF SOLAR RADIATION MEASUREMENTS USING ARTIFICIAL NEURAL NETWORK

Abstract. *Regarding solar radiation measurements within a given area, it is common to get gaps in the parameters which have been measured and stored in a technical data base. In order to avoid such a situation, it is of relevance to fill these gaps by estimating parameters with the use of a technique that applies a computational interconnected structure of processing units – the Artificial Neural Network (ANN). The technical paper presents a method to estimate the solar radiation in a site by using an Artificial Neural Network technique with Multilayer Perceptron (MLP). The method considers the supervised learning technique known as back-propagation. It has been analyzed ground data measurements in an area sited in São José do Belmonte, in the semiarid region of the State of Pernambuco, Brazil. The use of the model presented good preliminary results and will be improved and tested in other sites which have been chosen as candidates for installing solar power plants in the near future.*

Key Words: *Gap Filling, Direct Normal Irradiation (DNI), Artificial Neural Networks*