

# Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares

(Forecast of solar energy resource by using neural network methods)

Daniel V. Fiorin<sup>1</sup>, Fernando R. Martins<sup>2</sup>, Nelson J. Schuch<sup>1</sup> e Enio B. Pereira<sup>2</sup>

<sup>1</sup>Centro Regional Sul de Pesquisas Espaciais, Instituto Nacional de Pesquisas Espaciais, Santa Maria, RS, Brasil

<sup>2</sup>Centro de Ciência do Sistema Terrestre, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, Brasil

Recebido em 7/1/2010; Aceito em 15/3/2011; Publicado em 28/3/2011

Este trabalho tem como objetivo discutir de forma sucinta a ferramenta matemática conhecida como redes neurais artificiais e algumas aplicações na área de energias renováveis. Inicialmente, o trabalho descreve a relevância desta ferramenta estatística nas diversas áreas do conhecimento e, posteriormente, conceitua e descreve as principais configurações possíveis de uma rede neural artificial. Por fim, o trabalho demonstra a aplicação da ferramenta para o levantamento de disponibilidade de recursos de energia solar no Brasil a partir de dados de superfície coletados em estações da rede SONDA operada pelo Centro de Ciência do Sistema Terrestre do Instituto Nacional de Pesquisas Espaciais. Os resultados obtidos até o momento mostram que as redes neurais podem fornecer estimativas com a confiabilidade necessária para avaliação da disponibilidade de energia solar e com melhor desempenho que outras técnicas estatísticas utilizadas na literatura.

**Palavras-chave:** energia solar, redes neurais artificiais, modelagem atmosférica, modelos de mesoescala.

This work aims at discussing the artificial neural networks (ANN) and some applications in renewable energy assessment. First, the paper describes the statistical relevance of this tool in different areas of knowledge and the main ANN concepts and configurations. Finally, the paper presents and discusses the use of ANN for the solar energy assessment in Brazil by using data collected in SONDA sites operated by the Center for Earth System Science of the Brazilian Institute for Space Research. The results show that ANN can provide reliable estimates with better performance than other statistical tools.

**Keywords:** solar energy, artificial neural networks, atmospheric modeling, numeric mesoscale models.

## 1. Introdução

A principal preocupação ambiental nos dias atuais diz respeito ao aquecimento global e mudanças climáticas decorrentes do aumento de temperatura do nosso planeta. Já é de amplo conhecimento o papel desempenhado pelo consumo de energia nos processos físicos associados não só ao aquecimento global como também à fenômenos relacionados à poluição atmosférica. No entanto, a disponibilidade e uso de energia está intrinsicamente ligada ao desenvolvimento da sociedade e da nação [1]. Na atualidade, os países desenvolvidos são considerados os principais responsáveis pelo aumento da concentração do monóxido de carbono e outros gases de efeito estufa na atmosfera em decorrência do elevado consumo de combustíveis fósseis necessário para a manutenção do padrão de vida de suas populações. Todavia, países como Brasil, Índia, China e Rússia estão partilhando cada vez mais esta responsabilidade em

razão da demanda crescente por energia para apoiar o desenvolvimento econômico. A preocupação com os danos ambientais, o compromisso de reduzir as emissões de gases de efeito de estufa e as perspectivas de esgotamento do petróleo nas próximas décadas [2-4] são os fatores que vem impulsionando o desenvolvimento de pesquisas e novas tecnologias para viabilizar a adoção de fontes renováveis de energia.

Pode-se acrescentar a esses fatores, a necessidade de diversificação da matriz energética com o intuito de aumentar a confiabilidade e a segurança o setor energético de uma nação. Para exemplificar este aspecto, pode-se citar as instabilidades na geração hidroeétrica em razão da ocorrência de períodos prolongados de seca como o ocorrido no Brasil no início desta década.

No Brasil, a energia solar é uma das mais promissoras opções energéticas uma vez que a maior parte do seu território está localizado na região inter-tropical e recebe elevada irradiação solar durante todo o ano [5].

<sup>2</sup>E-mail: fernando.martins@inpe.br.

Os principais obstáculos para a exploração comercial dos recursos de energia solar são custo ainda elevado quando comparado às fontes convencionais de energia, sua forte dependência das condições climáticas e a reduzida quantidade de informações de cunho científico sobre a disponibilidade e variabilidade temporal e espacial dos seus recursos.

As preocupações ambientais e de segurança energética mencionados acima têm propiciado um crescimento da demanda por informações que vem impulsionando o desenvolvimento de pesquisas científicas nas principais instituições de pesquisa do país com o intuito de desenvolvimento de novas tecnologias para aproveitamento dos recursos de energia solar a um custo comparável ao apresentado por outras fontes de energia; e de aprimorar a base de dados científicos disponíveis para o desenvolvimento de novos projetos e instalações de plantas para aproveitamento da energia solar.

Atualmente, a previsão da incidência de radiação solar na superfície do planeta também apresenta importância no gerenciamento de sistemas de geração e distribuição de eletricidade [6-8]. Diversas metodologias foram desenvolvidas com o intuito de produzir estimativas e previsões de irradiação solar em alta resolução temporal e espacial [9, 10].

Modelos numéricos utilizados em previsão meteorológica possuem códigos computacionais para parametrização dos processos radiativos na atmosfera e podem ser utilizados para previsão da irradiação solar na superfície. No entanto, as previsões fornecidas por esses modelos, para um ou dois dias de antecedência, apresentam desvios elevados em relação a valores medidos em superfície [8]. Estudos anteriores apontam como causa principal desses desvios elevados a dependência da irradiação solar em relação à cobertura de nuvens e às condições meteorológicas que envolvem intrinsecamente processos físicos não-lineares de difícil parametrização [11-13].

Nos últimos anos, metodologias aplicando redes neurais artificiais (RNA) estão sendo desenvolvidas e utilizadas para previsão e avaliação da disponibilidade de recursos de energia solar [14-17]. Este trabalho tem como foco descrever e discutir os modelos de redes neurais desenvolvidos e aplicados para a previsão de parâmetros associados à irradiação solar utilizando dados coletados na rede SONDA operada pelo Instituto Nacional de Pesquisas Espaciais. Para isso, apresenta, inicialmente, uma revisão sucinta dos conceitos físicos associados aos processos radiativos na atmosfera e do conhecimento sobre as redes neurais artificiais e sua aplicação na previsão e estimativa da irradiação solar incidente na superfície.

## 2. Processos radiativos na atmosfera

O Sol é a principal fonte de energia de nosso planeta, e a radiação solar constitui a força motriz para os movi-

mentos atmosféricos e para outros processos térmicos, dinâmicos e químicos que ocorrem na atmosfera e camadas superficiais da crosta terrestre [18]. A radiação solar que atinge a Terra exibe uma faixa contínua de comprimentos de onda ( $\lambda$ ) entre 0 e  $4 \mu\text{m}$ . A temperatura do Sol ( $\sim 5900 \text{ K}$ ) é significativamente superior a temperatura da atmosfera e superfície terrestre. Considerando que ambos seguem aproximadamente a lei de Planck, as emissões de radiação pela superfície terrestre ocorrem em comprimentos de onda maiores ( $4$  a  $100 \mu\text{m}$  com picos de  $10$  a  $12 \mu\text{m}$ ) [19]. A Fig. 1 mostra uma representação comparativa do espectro eletromagnético da radiação emitida pelo Sol e pela Terra. Costuma-se utilizar o termo “radiação de onda curta” para a radiação eletromagnética emitida pelo Sol, isto é, radiação com comprimentos de onda inferior a  $4 \mu\text{m}$ . Em contrapartida é utilizada a expressão “radiação de onda longa” para a radiação emitida pela Terra uma vez que está possui comprimentos de onda superiores a  $4 \mu\text{m}$  [20].




Figura 1 - Representação gráfica comparativa dos espectros da radiação eletromagnética emitida pelo Sol (5900 K) e pela nosso planeta Terra (290 K).

As regiões do espectro eletromagnético podem ser classificadas em intervalos de comprimento de onda como base nas características e mecanismos específicos de interação com os constituintes atmosféricos que não fazem parte do escopo deste trabalho. A Tabela 1 apresenta a classificação para a radiação de onda curta comumente encontrada em publicações científicas.

A porção mais significativa do espectro, associada com transferência de energia radiativa na atmosfera, é compreendida entre a faixa de comprimentos de onda da radiação ultravioleta e infravermelha-próximo [21]. A radiação visível corresponde a aproximadamente 43% do total emitido de energia emitida pelo Sol. Aproximadamente 49% da radiação emitida estão na região do infravermelho-próximo, e apenas cerca de 7% apresentam comprimentos de onda no ultravioleta. Menos de 1% da radiação solar é emitida como raios X, raios gama e ondas de rádio.

Tabela 1 - Subdivisões do espectro eletromagnético nas regiões da radiação ultravioleta, visível e infravermelho.

Região	Comprimento de onda	Subdivisão	Comprimento de onda
Ultravioleta (UV)	10-400 nm	UV-C	10-280 nm
		UV-B	280-320 nm
		UV-A	320-400 nm
Visível (VIS)	400-700 nm	Violeta	400-430 nm
		Índigo	430-450 nm
		Azul	450-500 nm
		Verde	500-570 nm
		Amarelo	570-590 nm
		Alaranjado	590-610 nm
		Vermelho	610-700 nm
Infravermelho (IV)	700 nm-1000 $\mu\text{m}$	IV Próximo (NIR)	0,7-1,5 $\mu\text{m}$
		IV de onda curta	1,5-3,0 $\mu\text{m}$
		IV Médio	3,0-8,0 $\mu\text{m}$
		IV de onda longa	8,0-15 $\mu\text{m}$
		IV Distante	> 15 $\mu\text{m}$

Fonte: <http://www.geotec-rs.com.br/espectro.html>.

A radiação solar, após atingir o topo da atmosfera, sofre processos de absorção e espalhamento ao longo do seu percurso [22]. Cerca de 25% da radiação solar incide na superfície da Terra sem nenhuma interferência da atmosfera, o restante é absorvido, ou espalhado em direção à superfície da Terra ou em direção ao espaço. Estes processos estão ilustrados quantitativamente na Fig. 2, e dependem do comprimento de onda da radiação, além da dimensão e natureza do material que interage com a radiação solar.




Figura 2 - Representação gráfica dos processos radiativos que ocorrem na atmosfera.

O espalhamento é um processo físico no qual um particulado ou molécula de gás no percurso da onda eletromagnética continuamente remove energia da onda incidente, em todos os comprimentos de onda, e dispersa essa energia em todas as direções. As características do espalhamento dependem do tamanho das moléculas de gás ou aerossóis. No espalhamento Rayleigh, a radiação é espalhada por partículas de dimensões muito menores do que o comprimento de onda da radiação. Neste caso, o espalhamento é inversamente proporcional à 4ª potência do comprimento de

onda ( $E_{\lambda_s} \sim 1/\lambda^4$ ). Este é o caso do espalhamento da luz visível por gases atmosféricos e responsável pela cor azul do céu.

No espalhamento Mie, a radiação é espalhada por partículas de dimensões muito próximas ou superiores em até 8 vezes o comprimento de onda da radiação. Neste caso, o espalhamento não depende do comprimento de onda. O espalhamento Mie ocorre nas gotículas de nuvens e aerossóis atmosféricos. As características deste espalhamento explicam a tonalidade branca das nuvens, nevoeiros e atmosfera com elevada carga de particulados em grandes centros urbanos.

Na absorção da radiação solar, as moléculas de gases adquirem a energia incidente, que é transformada em movimento molecular interno resultando em aquecimento da atmosfera. Esse processo é preponderantemente na presença dos gases absorvedores como o O<sub>3</sub>, CO<sub>2</sub> entre outros. Alguns particulados como o *black carbon* emitido na queima de biomassa também apresentam elevado coeficiente de absorção da radiação solar. A radiação solar também é responsável pela ocorrência de diversas reações fotoquímicas na atmosfera terrestre. Um exemplo bastante importante está relacionado ao ciclo do O<sub>3</sub> na estratosfera que utiliza parte da radiação solar na faixa do ultravioleta. A Fig. 3 permite a comparação entre os espectros de radiação solar emitido por um corpo negro a 5900 K (linha pontilhada), o espectro de radiação que atinge o topo da atmosfera e superfície ao nível do mar. Pode-se observar que os constituintes atmosféricos absorvem diferentemente os diversos comprimentos de onda da radiação solar e da radiação terrestre alterando o espectro da radiação à medida que se propaga na atmosfera. As diferenças entre as curvas ao nível do mar e no topo da atmosfera representam a atenuação da radiação ao percorrer a atmosfera. A área sombreada representa a contribuição devida à absorção da radiação por moléculas do ar, principalmente por H<sub>2</sub>O, CO<sub>3</sub>, O<sub>3</sub>, O<sub>2</sub> [23].




Figura 3 - Comparação entre os espectros de radiação eletromagnética emitidos por um corpo negro a 6000 K, no topo da atmosfera e ao nível do mar.

Define-se fluxo radiante como taxa de transferência de energia por radiação eletromagnética, expresso em unidades de energia por unidade de tempo: Joules por segundo ( $J.s^{-1}$ ) ou Watts (W). A densidade de fluxo radiante (irradiância), expressa em Watts por metro quadrado ( $W.m^{-2}$ ), representa o fluxo radiante através de uma unidade de área.

A média anual da irradiância solar total incidente no topo da atmosfera (TDA) em um plano perpendicular a direção da radiação solar é conhecida como constante solar ( $I_{SC}$ ). O valor de  $I_{SC}$  é de aproximadamente  $1368 W.m^{-2}$ , no entanto, este valor varia ao longo do ano como função da distância Terra-Sol e do ângulo zenital solar ( $\theta_z$ ). O ângulo zenital solar é definido como ângulo formado entre o zênite local e uma linha imaginária que une a superfície horizontal ao Sol. O zênite local é o ponto no espaço que forma um ângulo de  $90^\circ$  com a superfície terrestre.

Os valores instantâneos da irradiação solar no topo da atmosfera ( $I_0$ ) são calculados por métodos numéricos descritos em [20]

$$I_0 = I_{SC} \cdot E_0 \cdot \cos \theta_z, \quad (1)$$

onde  $E_0$  é fator de correção da excentricidade da Terra. O total diário da irradiação solar no topo da atmosfera ( $H_0$ ) pode ser determinado a partir de

$$H_0 = \frac{I_{SC}}{\pi} E_0 [h_0 \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(h_0)], \quad (2)$$

onde ( $\varphi$ ) é a latitude do local na superfície da Terra e ( $\delta$ ) é a declinação solar.

A radiação solar (onda curta) que incide na superfície costuma ser classificada com base nos processos radiativos em que estiveram envolvidos ao longo do percurso pela atmosfera. Dessa forma, deve-se ter em mente algumas definições e termos técnicos bastante usuais na literatura científica:

- **Irradiância direta:** consiste na irradiância incidente numa superfície horizontal que não sofreu nenhum processo radiativo na atmosfera (compõe o feixe de radiação proveniente do Sol – nenhum espalhamento por constituinte atmosférico);

- **Irradiância difusa:** consiste na irradiância incidente numa superfície horizontal decorrente do espalhamento por constituintes atmosféricos (moléculas, material particulado, nuvens, etc.) – responsável pela iluminação de áreas que não recebem iluminação direta do Sol;

- **Irradiância global:** consiste na totalidade da irradiância incidente numa superfície horizontal, isto é, a somatória das irradiâncias direta e difusa;

- **Irradiância direta normal:** consiste na fração da irradiância solar proveniente diretamente do Sol com incidência normal à superfície e, portanto, está intrinsecamente associada ao ângulo zenital solar e a inclinação da superfície em relação à horizontal;

- **Irradiância atmosférica:** consiste na irradiância de onda longa emitida por camadas da atmosfera situadas acima do plano de observação e que incide em superfície horizontal.

- **Índice de transparência atmosférica ( $K_t$ ):** é definido como a razão da irradiação solar global incidente na superfície ( $I$ ) e a irradiância solar no topo da atmosfera ( $I_0$ )

$$K_t = \frac{I}{I_0}. \quad (3)$$

## 2.1. Interações entre radiação solar e nebulosidade

As nuvens possuem um papel importante no balanço radioativo da atmosfera. A sua influência na transmitância da radiação solar é complexa, e varia com as características das nuvens tais como profundidade óptica, forma, quantidade, tipo e altura e ainda com o ângulo zenital solar. Define-se albedo como a fração da radiação solar incidente que é refletida por uma superfície. Os topos das nuvens são os mais importantes refletores da atmosfera, tendo o seu albedo variando entre 40% para nuvens finas com menos de 50 m, a 80% para nuvens espessas, com mais de 5000 m. De maneira geral, quanto maior a quantidade de água (gotículas ou gelo), maior ocorrência de espalhamento Mie (maior albedo) e menor a incidência de irradiação solar direta na superfície.

Outro fator importante no papel desempenhado pelas nuvens no balanço radiativo da atmosfera está relacionado com a sua altitude. Nuvens mais altas apresentam menores temperaturas, emitem menos energia ao espaço, absorvem mais efetivamente o calor emitido pela superfície, refletem menos a radiação solar incidente, e, portanto, atuam no sentido de aquecer a atmosfera. Por outro lado, nuvens de baixas altitudes

estão mais aquecidas, refletem mais efetivamente a radiação solar incidente, e ainda possuem pouca absorvidade da energia emitida pela superfície do planeta, agindo, desta forma, para resfriar a atmosfera.

A nebulosidade é o principal fator de modulação da irradiação solar que incide na superfície do planeta, e ainda, a principal fonte de erro nas estimativas obtidas com o uso de modelos numéricos de transferência radiativa em razão da complexidade dos processos radiativos em que está envolvida [6].

## 2.2. Modelos computacionais para estimativa da radiação solar incidente

O conhecimento da disponibilidade de energia solar na superfície de nosso planeta tem aplicações importantes em diversas áreas das atividades humanas como, por exemplo, a agricultura, a arquitetura, a saúde, a indústria e lazer. A demanda por estimativas e previsões da incidência de radiação solar vem crescendo a cada dia e são essenciais para o planejamento e gerenciamento de diversos setores da economia entre os quais podemos destacar o setor energético. A avaliação da disponibilidade de energia solar e sua variabilidade temporal e espacial pode ser realizada com uso de dados coletados por uma rede de radiômetros (sensores de radiação solar) aliados a técnicas de interpolação. No entanto, para regiões de grande extensão, a implementação e manutenção de uma rede de sensores necessária para gerar dados com a precisão necessária para as diversas aplicações torna-se proibitivo [24, 25].

A adoção de modelos computacionais para obtenção de estimativas da radiação solar com uso de relações empíricas ou pela solução da equação de transferência radiativa (ETR) constitui-se uma alternativa à metodologia anterior. Para mapear a disponibilidade de energia solar no território brasileiro, a adoção de modelos computacionais que utilizam dados de satélite tem-se mostrado a melhor alternativa [6]. Os modelos computacionais podem ser classificados em modelos estatísticos e modelos físicos. Os modelos físicos caracterizam-se por utilizar métodos matemáticos que visam simular os processos físicos atmosféricos e solucionar a equação de transferência radioativa. Apesar de não apresentarem restrição espacial, eles necessitam de informações confiáveis sobre as condições atmosféricas, sendo que nem sempre tais informações são disponíveis ou apresentam a confiabilidade esperada. O modelo BRASIL-SR, desenvolvido e atualmente em uso no INPE, utiliza dados de satélite e medidas de superfície para solucionar a ETR para determinar estimativas da irradiação solar incidente na superfície [6].

Os modelos estatísticos caracterizam-se por utilizar expressões empíricas para estimativa da radiação incidente em função de alguma propriedade do sistema Terra-Atmosfera medida por satélite ou por instrumentos de superfície, ficando com sua validade restrita à

região para a qual suas expressões empíricas foram desenvolvidas. Os modelos de redes neurais artificiais e regressões lineares múltiplas desenvolvidos neste trabalho podem ser considerados modelos estatísticos, utilizando dados solarimétricos, eólicos e meteorológicos, para estimar a radiação solar incidente para a região específica de onde são provenientes as informações de entrada dos modelos.

## 3. Redes neurais

Redes Neurais Artificiais (RNAs) são sistemas paralelos e distribuídos constituídos de unidades simples, os nodos ou *neurônios*, que computam funções matemáticas (especialmente não-lineares). As RNAs apresentam-se como ferramentas estatísticas capazes de armazenar conhecimentos a partir de exemplos, e vem sendo aplicadas em problemas de ajuste de funções, reconhecimento de padrões, modelos de previsão e outras aplicações em diversas áreas do conhecimento humano. A principal razão para sua ampla gama de aplicações reside na capacidade de generalização, auto-organização, e processamento temporal que possibilita a resolução de diferentes problemas complexidades.

De maneira análoga ao sistema nervoso de um ser humano, os nodos são dispostos em uma ou mais camadas e interligadas por inúmeras conexões, geralmente unidirecionais, denominadas *sinapses*. A estas conexões associam-se valores, denominados pesos sinápticos, responsáveis pela ponderação das entradas de cada nodo como forma de armazenamento do conhecimento de um determinado modelo [26, 27].

### 3.1. Breve histórico do desenvolvimento das RNAs

Na década de 40, o psiquiatra e neuro-anatomista Warren McCulloch e o jovem matemático Walter Pitts publicam, em 1943, o primeiro trabalho a propor um modelo artificial de um neurônio biológico. Neste modelo simples, ilustrado na Fig. 4, o nodo possui  $n$  terminais de entrada ( $x_1, x_2, \dots, x_n$ ), por onde é alimentado com sinais provenientes das saídas de outros neurônios ou por informações de entrada da rede. Esses sinais ou informações são ponderados por pesos fixos ( $w_1, w_2, \dots, w_n$ ) das sinapses. Caso o somatório ( $\Sigma$ ) dos produtos  $x_i w_i$ , apresente valor igual ou superior a um limiar  $\theta$  (*threshold*), o sinal de saída ( $y$ ) do nodo recebe o valor igual a 1 (nodo excitado). Por outro lado, se o somatório apresenta resultado inferior ao limiar, a saída do nodo é zero [28].

Donald Hebb (1949) [29] discutiu o aprendizado de redes biológicas e artificiais, propondo que a plasticidade da aprendizagem de redes neurais artificiais seria decorrente das variações dos pesos de entrada dos nodos enquanto o aprendizado de nodos biológicos dava-se pelo reforço das ligações sinápticas entre no-



dos excitados. Em 1958, Frank Rosenblat apresentou seu modelo de RNA, o *perceptron* de uma camada, demonstrando que nodos de McCulloch e Pitts dotadas de sinapses ajustáveis conforme saídas desejáveis poderiam ser treinadas para classificar certos tipos de padrões. Ele descreveu a tipologia da RNA, a estrutura das ligações, e o mais importante, propôs um algoritmo de treinamento para seu modelo executar algumas funções [30].

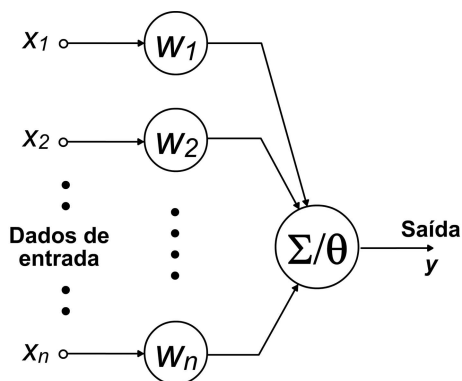


Figura 4 - Representação de um neurônio artificial (Nodo) de acordo com a proposta apresentada por McCulloch e Pitts [28].

Em 1960, Widroff e Hoff apresentaram o seu modelo denominado Adaline (*ADaptive LInear NEuron*) que diferenciava-se do *perceptron* por possuir saídas binárias bipolares (-1 ou 1) ao invés das saídas unipolares (0 ou 1). O ajuste dos pesos era feito com uso do método do gradiente para minimização do erro em função dos erros de suas saídas analógicas através do, que ficou conhecida como *regra delta* ou *regra de Widrow-Hoff* [31].

Nos anos 70, a pesquisa e desenvolvimento de métodos e aplicações das RNAs sofreram um grande redução em consequência do trabalho de Minsky e Papert, que alertava para o fato dos *perceptrons* estarem limitados somente a problemas linearmente separáveis. Minsky e Papert (1970) [32] também afirmavam que o processo de aprendizagem não garantia a convergência para RNAs com mais de uma camada, e questionavam o aumento significativo das necessidades computacionais para a solução de problemas mais complexos. A retomada das pesquisas aconteceu na década de 80, após Hopfield (1982) [33] demonstrar as propriedades associativas das RNAs com problemas físicos, e a descrição do algoritmo de treinamento *back-propagation* (1986) que possibilitou às redes de múltiplas camadas solucionarem problemas com alta complexidade [33, 34]. A partir daí, houve uma nova explosão de interesse científico pelas RNAs baseado nos avanços da tecnologia, especialmente microeletrônica, e na estagnação nas pesquisas da linha simbolista de inteligência artificial.

### 3.2. Arquiteturas das RNAs

A escolha da arquitetura de uma RNA está relacionada com o tipo de problemas a ser abordado e é definida por

4 parâmetros principais: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre nodos, e a topologia da rede.

Em relação ao número de camadas, existem redes de camada única, que possuem somente um nodo entre as camadas de entrada e saída da rede, sendo restritas a resolver problemas linearmente separáveis. As redes neurais de múltiplas camadas possuem mais de um neurônio entre uma entrada e uma saída da rede.

As conexões entre os nodos podem ser do tipo *feed-forward* (ou acíclica), quando a saída de um nodo só poderá servir de entrada para nodos de uma camada posterior, ou do tipo *feedback* (cíclica), na qual a saída de um nodo pode servir de entrada para um nodo de uma mesma camada ou de uma camada inferior. Quando ocorre a realimentação da saída nas camadas de entrada a RNA é dita recorrente. Entre as principais classes de RNAs, podemos destacar as redes *Perceptron* e *Adaline*, já mencionadas neste texto, as *Perceptrons de Múltiplas Camadas (MLP)*, *Memórias Matriciais*, *Self-Organizing*, *Processamento Temporal*, entre outras. Maiores detalhes sobre as diversas topologias podem ser encontradas em diversos textos de referência sobre o tema [35, 36].

### 3.3. Perceptrons de múltiplas camadas

As RNAs do tipo *Perceptrons de Múltiplas Camadas (Multilayer Perceptron – MLP)* são redes que apresentam uma ou mais camadas de nodos intermediários ou escondidos. As redes MLP são muito utilizadas por apresentarem maior simplicidade e facilidade de implementação. Na Fig. 5 temos um exemplo de MLP com três entradas, duas camadas intermediárias com quatro neurônios e uma camada de saída com um neurônio, produzindo uma única informação de saída.




Figura 5 - Representação gráfica de uma RNA-MLP com duas camadas intermediárias.

A camada de entrada é muitas vezes ignorada por diversos autores por que apenas recebe e distribuem dados, não realizando nenhuma operação matemática. As redes MLP apresentam maior poder computacional, atribuído às suas camadas internas, podendo trabalhar

com dados não linearmente separáveis. As redes com uma camada intermediária podem representar qualquer função contínua enquanto as redes que possuem duas ou mais camadas intermediárias podem, teoricamente, implementar qualquer função, linearmente separável ou não, sendo que a precisão dos resultados gerados pela RNA está relacionada com o número de nodos nas camadas intermediárias [37].

Os neurônios (nodos) em redes MLP diferem-se do modelo de McCulloch e Pitts [28], por permitirem a saída de um valor qualquer ao invés de ter o somatório ponderado das entradas comparado a um limiar gerando um sinal de saída binário (0 ou 1). Para isso, desenvolveram-se novos modelos de neurônios artificiais aos quais se aplicam funções de ativação aos valores ponderados da entrada. Essas funções são geralmente não-lineares, para que possam representar problemas não lineares e diferenciáveis. O neurônio apresentado na Fig. 6 pode ser visto como um neurônio genérico dentro da estrutura de uma rede MLP.

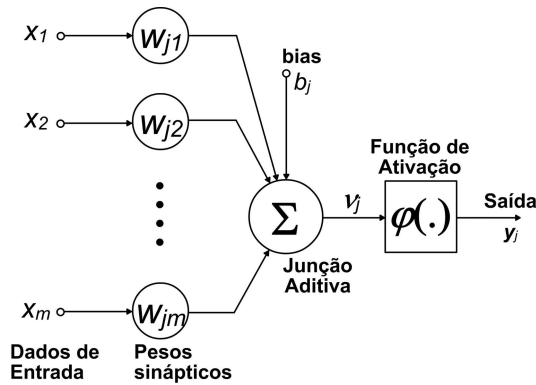


Figura 6 - Modelo de um neurônio artificial de uma rede MLP. Fonte: Adaptado de Haykin [27].

Na MLP, o somatório ponderado dos valores das entradas é combinado com outro valor ajustável, denominado *bias* ( $b_j$ ), que tem a função de expandir ou reduzir a entrada líquida da função de ativação para ajustar o chamado *nível de atividade interna* do neurônio ( $v_j$ ). A saída do neurônio ( $y_j$ ) é produzida pela aplicação da *função de ativação* ( $\phi$ ) ao nível de atividade interna do neurônio. Estas relações são descritas por

$$v_j = \sum_{i=1}^m w_{ji}x_i + b_j \quad (4)$$

$$y_j = \phi(v_j) \quad (5)$$

As funções de ativação mais comumente utilizadas são a função limiar (degrau), a função linear e as funções sigmóides logística e tangente hiperbólica. Estas funções são representadas respectivamente pelas Eqs. (6) a (9) e possuem o comportamento de seus sinais de saída esboçados na Fig. 7.




Figura 7 - Representação gráfica de diferentes funções de ativação: (a) função degrau; (b) função linear; (c) função logística; (d) função tangente hiperbólica.

Função limiar

$$\varphi(v_j) = \begin{cases} +\gamma & \text{se } v_j \geq 0 \\ -\gamma & \text{se } v_j < 0 \end{cases} \quad (6)$$

Função linear

$$\varphi(V_j) = \alpha \cdot V_j \quad (7)$$

Sigmóide logística

$$\varphi(v_j) = \frac{1}{1 + \exp(-\alpha \cdot v_j)} \quad (8)$$

Sigmóide Tg.hip.:

$$\varphi(v_j) = \operatorname{tgh} \frac{v_j}{2} = \frac{1 - \exp(-v_j)}{1 + \exp(-v_j)} \quad (9)$$

As funções de ativação são definidas para uma pequena faixa de valores. A função limiar geralmente possui valor  $\gamma = 1$ , trabalhando no intervalo entre -1 e 1, o mesmo intervalo da função tangente hiperbólica, enquanto que a função logística é aplicada no intervalo entre 0 e 1.

As funções sigmóides são as funções mais empregadas nas camadas internas de uma MLP por serem contínuas, crescentes, diferenciáveis e não-lineares. Muitos autores sugerem o emprego da função linear, definida com  $\alpha = 1$ , na camada de saída da rede de forma que a sua saída seja igual ao nível de atividade interna.

### 3.4. Escolha da topologia de uma rede MLP

O número de camadas e nodos a serem utilizados em uma MLP deve ser determinado de forma empírica, pois depende de alguns fatores tais como complexidade do problema em estudo, número de exemplos de treinamento, quantidade de ruído presente nos exemplos, e distribuição estatística dos dados de treinamento.

Apesar de haver métodos propostos para definir a topologia da RNA para uma aplicação sabe-se que o melhor caminho é construir diferentes modelos, com diferentes funções de ativação, diferentes métodos de treinamento, diferentes números de camadas e nodos com o intuito de avaliar a combinação que melhor atende aos requisitos estabelecidos para a aplicação. Na verdade, busca-se encontrar um equilíbrio entre a rigidez e a flexibilidade da rede. Ela não deve ser rígida a ponto de não modelar fielmente os dados e nem flexível em demasia a ponto de modelar até para determinação do número de nodos da rede, o ruído nos dados. Normalmente, é aconselhável a adoção de técnicas de *pruning* para otimização da topologia. Tais técnicas consistem em começar o treinamento com um número superdimensionado de nodos e ir eliminando os nodos que apresentarem as ligações sinápticas mais fracas (menores pesos). Outra técnica importante é o processo de regularização utilizado para redução dos pesos e consequente indicação quais nodos devem ser “eliminados” da rede. Outra forma de reduzir o tamanho da rede é avaliar estatisticamente quais as informações e variáveis relacionadas ao problema em estudo que são realmente importantes para alimentar a RNA de modo a excluir aquelas que não influem significativamente nos resultados. O método dos fatores de contribuição para redução do número de variáveis de entrada utiliza a soma dos valores absolutos dos pesos das ligações sinápticas entre o nodo de entrada e os nodos da primeira camada interna para avaliar quais parâmetros são os mais importantes para a rede. Quanto maior for o somatório dos pesos, maior é a importância daquele parâmetro para a rede [35].

### 3.5. Treinamento e aprendizagem das RNAs

Na fase de aprendizagem ou treinamento, um conjunto de exemplos é apresentado para a rede, que ajusta os seus pesos sinápticos de forma iterativa até que ela extraia as características para representar as informações fornecidas. Posteriormente, estes pesos são fixados e utilizados para gerar soluções para novos valores fornecidos como entrada.

Para o treinamento das RNAs podem ser utilizados diferentes algoritmos de treinamento que diferem basicamente pelo modo como é realizado o ajuste dos pesos. Os algoritmos de treinamento dividem-se em dois paradigmas: Aprendizado Supervisionado e Aprendizado Não-Supervisionado. No aprendizado não-supervisionado é fornecido à rede somente valores de entrada que são organizados em diferentes classes de acordo com a semelhança de suas propriedades através do ajuste de seus pesos da rede. No treinamento supervisionado existe um supervisor externo que fornece a rede tanto os valores de entrada disponíveis quanto os valores de saída esperados. O aprendizado supervisionado, ilustrado na Fig. 8, é o método mais comum

para treinamento das RNAs.




Figura 8 - Mecanismo do aprendizado supervisionado.

O aprendizado supervisionado pode ser classificado em treinamento dinâmico e treinamento estático. No primeiro ocorrem alterações na estrutura de rede (redução ou aumento do número de camadas, número de nodos em cada camada e número de conexões). Por outro lado, no treinamento estático, empregado neste trabalho, somente os valores dos pesos sofrem alterações e a topologia da rede é mantida inalterada.

Em resumo, no treinamento supervisionado estático, a RNA compara o valor de saída calculado com o valor esperado, e avalia o erro decorrente das diferenças entre ambos. Assim, com a discrepância conhecida, os pesos sinápticos são modificados de forma a minimizar o erro e encontrar a melhor relação entre os informações de entrada e saída. Algebricamente, o termo  $e(t)$  relativo ao erro é escrito como a diferença entre o valor  $y(t)$  calculado pela RNA no instante  $t$  e o valor da saída esperado  $d(t)$

$$e_j(t) = d_j(t) - y_j(t). \quad (10)$$

A cada etapa de treinamento são feitas pequenas modificações nos pesos, provocando uma minimização incremental dos erros, convergindo em direção do valor esperado. A forma genérica de alteração dos pesos é dada por:

$$w_{j,i}(t+1) = w_{j,i}(t) + \eta e(t) x_i(t), \quad (11)$$

onde  $\eta$  é a taxa de aprendizado que determina a velocidade com que os pesos serão ajustados em direção ao menor erro e  $x_i(t)$  é a entrada para o nodo  $i$  no tempo  $t$ .

Nos algoritmos em que se mantém a taxa de aprendizado constante, a determinação deste parâmetro é um importante fator no seu desempenho, visto que altas taxas podem fazer a algoritmos oscilar e tornar-se instável enquanto baixas taxas requerem um maior tempo computacional para atingir o fim do treinamento. Nos algoritmos que possuem taxas de aprendizado variáveis, elas se adaptam as condições da superfície de erro buscando proporcionar a maior taxa de aprendizado possível enquanto houver estabilidade, e no decorrer do treinamento, a taxa de aprendizado é reduzida.

Na prática adota-se a soma dos erros quadráticos de todas as saídas como parâmetro de desempenho da rede, e também como função de custo  $E(t)$ , descrita na



Eq. (12), a ser minimizada pelo algoritmo de treinamento. Este é o princípio da regra delta de Widrow e Hoff [31] utilizada no treinamento de RNAs.

$$E(t) = \frac{1}{2} \sum_j e_j^2(t). \quad (12)$$

A função de custo pode ser visualizada como uma *superfície de erro*, com os parâmetros livres do sistema (pesos e bias) como coordenadas. Ela pode apresentar um único ponto de mínimo, quando possui somente funções de ativação lineares, ou pode apresentar vários mínimos locais além do mínimo global, se houverem nodos não-lineares [26]. O objetivo é que, ao longo do treinamento, o erro parta de um ponto arbitrário da superfície e se desloque até o mínimo global. No entanto, quando temos saídas não lineares, o treinamento da RNA pode se estabilizar em uma região de mínimo local, porém com erro maior que o seu mínimo global. Para garantir que a rede irá encontrar o seu mínimo global.

O algoritmo *backpropagation* (retropropagação) é o mais comumente empregado no treinamento supervisionado de redes MLP [34]. Em uma primeira fase ocorre a propagação do sinal funcional (*feedforward*) mantendo-se os pesos fixos de modo a gerar um valor de saída a partir das entradas fornecidas à RNA. Na segunda fase, as saídas são comparadas com os valores desejados, gerando um sinal de erro, que se propaga da saída para a entrada, ajustando-se os pesos de forma a minimizar o erro (retropropagação do erro – *backpropagation*).

O ajuste dos pesos é baseado no método do gradiente para minimização do erro, isto é, a correção aplicada a cada peso do neurônio é dada pelo produto da taxa de aprendizado adotada e a derivada parcial da função custo em relação ao peso em questão. Ao aplicar a regra da cadeia, sem aprofundarmos nos aspectos matemáticos, podemos dizer que os ajustes nos pesos, ( $\Delta w_{ji}$ ), tornam-se dependentes do valor do gradiente local  $\delta_j(t)$ , definido na Eq. (13), onde o termo  $\varphi_j(v_j(t))$  é a derivada da função de ativação aplicada ao nível de atividade interna do neurônio.

$$\delta_j(t) = e_j \cdot \varphi_j(v_j(t)), \quad (13)$$

$$\Delta w_{ji}(t) = \eta \cdot \delta_j(t) \cdot x_i(t). \quad (14)$$

Este algoritmo possibilita também o ajuste dos pesos das camadas internas da rede.

O ajuste dos pesos sinápticos pode ser realizado a cada iteração (*treinamento sequencial*) ou após a apresentação à rede de todos os exemplos do conjunto de dados de treinamento (*treinamento por lote*). Segundo Braga e cols. [26], o treinamento sequencial é geralmente mais rápido e requer menor demanda computacional (tempo e memória física), porém é mais instável.

No treinamento por lote, a apresentação de todos os exemplos de treinamento à RNA é denominada época. Durante cada época, os pesos mantêm-se constantes e define-se uma nova função de custo como a média das funções de custo para cada exemplo. Devido ao cálculo de diferentes gradientes da nova função de custo para cada exemplo, ao final da época ajusta-se os pesos, de acordo com a média dos ajustes calculados para cada exemplo [27].

Existem diversos algoritmos para implementar o treinamento por retropropagação. Diversos deles foram avaliados neste trabalho e serão brevemente descritos a seguir com foco nas suas principais características.

O algoritmo de redução do gradiente por lote (*Batch Gradient Descent*) ajusta os pesos e desvios em direção ao gradiente negativo da função custo. O algoritmo *Batch Gradient Descent with Momentum* apresenta frequentemente melhores resultados ao introduzir o conceito de momento, que leva em conta os ajustes anteriores nos pesos, observando a recente tendência de mudanças na superfície de erro, desprezando pequenas sinuosidades na superfície de erro. Tal comportamento evita que o algoritmo fique preso a um pequeno mínimo local da superfície de erro, podendo mais facilmente chegar ao mínimo global [38].

São ditos “algoritmos de alto desempenho” aqueles que usam técnicas heurísticas baseadas na redução do gradiente (*variable learning rate backpropagation* e RProp) ou baseadas em padrões de otimização numérica – Gradiente Conjugado, Quase-Newton, e *Levenberg-Marquardt*.

O algoritmo Rprop (*Resilient Backpropagation*) foi desenvolvido com o intuito de reduzir a influência da magnitude dos gradientes nos ajustes de pesos, visto que a derivada de funções sigmóides utilizadas em MLP é pequena para pontos afastados de zero devido ao comportamento assintótico da função. Esse fato gera pequenos gradientes locais que acarreta pequenas modificações nos pesos, e conseqüente lentidão na minimização da função custo. O algoritmo Rprop utiliza somente o sinal do gradiente, sendo a magnitude do ajuste variável conforme a permanência ou mudança do sinal do gradiente nas sucessivas iterações. Segue-se a lógica que se a derivada parcial manteve o sinal, o ajuste foi insuficiente e deve ser ampliado, e do contrário, se houve alteração do sinal da derivada, o ajuste foi superior e deve ser reduzido.

O algoritmo de *Levenberg-Marquardt* é considerado o algoritmo mais rápido para redes de tamanho moderado (até algumas centenas de pesos). Nele, o gradiente é computado pela transposta da matriz Jacobiana que possui as derivadas primeiras da função custo em função dos erros.

### 3.6. Generalização

Algumas vezes, embora tenha sido atingido um erro mínimo para a RNA durante o treinamento, quando ela é aplicada a um novo grupo de dados o erro encontrado é elevado. Costuma-se afirmar que a rede não adquiriu a capacidade de generalização, pois houve um excesso de treinamento (*overfitting*) que acontece, geralmente, quando é empregado um número grande de nodos nas camadas internas da rede. De forma simples, podemos entender que, neste caso, a RNA “decora” os dados ao invés de apreender seus padrões. A generalização indica a capacidade da RNA em aprender através de um pequeno número de exemplos e, posteriormente, simular valores coerentes para um grupo desconhecido de dados [26].

Com o intuito de garantir a capacidade de generalização RNA, alguns métodos numéricos podem ser aplicados, entre os quais se destacam a regularização e o treinamento com parada antecipada. No método de regularização, a função custo é modificada com o intuito de minimizar não somente o erro,  $e(t)$ , como também os valores dos pesos ao longo do treinamento, visto que pesos elevados estão relacionados com a ocorrência de *overfitting* [38]. A nova função custo,  $J$ , é descrita pela Eq. (15) onde  $k$  é o número de nodos na saída,  $d_i$  representa a saída esperada do nodo  $i$ ,  $y_i$  é a saída gerada pelo nodo  $i$ ,  $w$  é o vetor de pesos e  $\lambda$  o parâmetro de regularização que deve ser ajustado de forma empírica, tornando o processo de treinamento bastante complexo.

$$J = \frac{1}{2} \sum_{i=1}^k (d_i - y_i)^2 + \frac{1}{2} \lambda \|w\|^2 \quad (15)$$

No treinamento com parada antecipada, os dados disponíveis são divididos em um conjunto de aprendizagem e um conjunto de supervisão. Os pesos são ajustados empregando somente o conjunto de aprendizagem, porém o conjunto de supervisão é utilizado para avaliar a capacidade de generalização da RNA através da medida do erro que a RNA apresenta para esse conjunto ao longo do treinamento. A etapa de treinamento é interrompida quando o erro para o conjunto de supervisão começa a crescer, embora o erro do conjunto de aprendizagem pudesse ser reduzido ainda mais se o treinamento tivesse continuidade. [35].

### 3.7. Aplicações das redes neurais artificiais na estimativa de recursos de energia solar

As RNAs são ferramentas aptas a resolverem vários problemas de cunho geral, tais como, aproximação, classificação, categorização, predição, modelamento, controle, processamento de sinais e imagens, otimização, etc., nas diversas áreas do conhecimento humano como saúde, economia, energia, desenvolvimento tecnológico e produção industrial entre outras

[26,38]. Na última década, as RNAs tem tido uma crescente aplicação na estimativa e previsão de disponibilidade de recursos energéticos renováveis [11, 39-41].

Apesar de tratar-se de uma ferramenta estatística que considera relações empíricas entre as variáveis meteorológicas, as RNAs tem-se apresentado como um método alternativo com boa destreza frente a problemas não-lineares ou de natureza estocástica como os complexos processos físicos que influenciam na disponibilidade de energia solar e eólica [14]. Diversos estudos publicados descrevem aplicações da RNAs com o intuito de previsão ou determinação de estimativas de radiação solar incidente na superfície. Soares e cols. [17] utilizaram redes MLP de 3 camadas, treinadas com o algoritmo padrão *backpropagation* com momento, para modelar a radiação solar difusa horária na cidade de São Paulo. Os autores constataram que valores medidos de irradiação solar global na superfície, a irradiação solar no topo da atmosfera (TDA), valores de umidade relativa e da irradiação de onda longa são informações relevantes para esta aplicação de RNA. Neste estudo, os autores verificaram que a temperatura do ar e a pressão atmosférica não influenciavam na precisão e confiabilidade das estimativas produzidas e enfatizaram que medidas de irradiação de onda longa podem substituir dados de nebulosidade quando estes não estão disponíveis.

Al-Alawi e Al-Hinai [42] empregaram uma rede MLP com 15 nodos na camada oculta para estimativa de valores médios mensais de radiação solar global, utilizando como dados de entrada os valores diários de pressão, temperatura, umidade relativa, velocidade do vento, duração de brilho do Sol e latitude da estação. O modelo desenvolvido apresentou boa capacidade de generalização, estimando a irradiação solar global para sítios não utilizados no treinamento com precisão da ordem de 95%.

Mohandes e cols. [43] realizaram estimativas de valores médios mensais da irradiação solar global diária com RNAs do tipo MLP alimentadas somente por dados da duração de brilho do Sol, latitude, longitude e altitude de 41 estações na Arábia Saudita, sendo que 31 delas foram empregadas no treinamento da RNA. Os dados coletados nas estações restantes foram empregados na validação das estimativas fornecidas pela RNA obtendo-se uma boa concordância entre os valores previstos e medidos. Mohandes e cols. [44] repetem o estudo empregando uma RNA com topologia diferente: *Radial Basis Function* – RBF e observaram que esta topologia de RNA também é viável para obtenção de estimativas da energia solar incidente na superfície, mesmo quando a técnica é comparada com estimativas produzidas por modelos clássicos de regressão.

Mellit e cols. [16], também, empregaram RNAs do tipo *Radial Basis Function* obtendo bons resultados para a previsão de séries temporais de radiação solar global diária a partir de medidas da irradiação solar global durante um ano de referência em conjunto com

valores de temperatura do ar e duração do brilho do Sol.

Elminir e cols. [15] utilizaram RNAs do tipo MLP, treinadas com o algoritmo de *Levenberg-Marquardt*, para previsão de valores diários de irradiação solar global, irradiação de onda longa e irradiação ultravioleta utilizando dados de temperatura ambiente, umidade do ar, cobertura de nuvens, direção e velocidade do vento. Os resultados obtidos apresentaram boa correlação entre os valores previstos e medidos, tanto para a estação onde a rede foi treinada, quanto para uma segunda estação, demonstrando a capacidade de generalização do modelo desenvolvido. Stetsos and Coonick [45] testaram diferentes tipos de RNAs, tais como redes MLP, RBF, ANFIS, recorrentes de Elman, além de regressão linear, para a previsão da irradiação solar horária utilizando séries temporais de temperatura, pressão, velocidade e direção do vento. Os melhores resultados foram obtidos empregando a rede do tipo MLP treinada pelo algoritmo de *Levenberg-Marquardt*.

Guarnieri [14] empregou redes MLP, treinadas pelo algoritmo Rprop, no refinamento das previsões de radiação solar global do modelo de mesoescala Eta adotado operacionalmente para a previsão climática no CPTEC/INPE. Ele selecionou 8 entre 36 variáveis meteorológicas fornecidas pelo modelo Eta/CPTEC para alimentar a RNA e gerar uma previsão de curto prazo da irradiação solar. O objetivo de seu estudo foi produzir previsão com maior confiabilidade de irradiação solar na superfície do que as fornecidas pelo modelo de mesoescala. Neste trabalho, o emprego de RNAs não mostrou superioridade em relação às regressões lineares múltiplas quando aplicadas com o mesmo intuito.

### 3.8. Notação para descrição das RNAs

Este item tem por objetivo estabelecer uma notação para representar as redes do tipo MLP que serão discutidas neste trabalho, simplificando e facilitando a discussão e compreensão da metodologia e resultados apresentados mais adiante.

As redes com uma camada interna serão escritas como “ $n - X - 1$ ”, onde  $n$  é o número de nodos na camada de entrada. Neste estudo estabelecemos que  $n$  será sempre igual ao número de variáveis de entrada das RNA propostas. Assim, a primeira camada serviu apenas para alimentar a rede com os dados de entrada, não realizando nenhuma ponderação. O índice  $X$  representa o número de nodos na camada interna (oculta) da rede. Apenas um nodo será utilizado na camada de saída, pois teremos apenas uma variável de saída. As redes com duas camadas internas serão escritas no formato “ $n - X - Y - 1$ ”, onde  $Y$  representa o número de nodos na segunda camada interna.

Adota-se a seguinte abreviatura para as funções de ativação das camadas das redes: função Linear (LIN), função Logística (LOG) e função Tangente Hiperbólica

(TAN). A primeira sigla representará a função de ativação das camadas internas, enquanto a segunda sigla representará a função de ativação da camada de saída. Como exemplo, a RNA descrita por “2-12-6-1 TAN LOG”, terá dois nodos na camada de entrada, 12 nodos na primeira camada interna, 6 nodos na segunda camada interna, 1 nodo na camada de saída, com funções de ativação tangente hiperbólica nas camadas internas e função linear na camada de saída.

## 4. Aplicação de redes neurais para estimativa de disponibilidade de energia solar

Neste trabalho será discutido o desenvolvimento de uma aplicação para estimativa do índice  $K_t$  e do total diário de irradiação solar global ( $H$ ) utilizando a metodologia de RNA's e dados de irradiação solar coletados na estação de superfície pertencentes à rede SONDA localizada em São Martinho da Serra (SMS) no Rio Grande do Sul. Inicialmente, será apresentada uma descrição sucinta da aquisição de dados de superfície em SMS e, posteriormente, a metodologia desenvolvida e os resultados alcançados.

### 4.1. Rede SONDA - estação de São Martinho da Serra (SMS)

A rede SONDA - Sistema de Organização Nacional de Dados Ambientais – foi implantada em 2004 com o objetivo de estabelecer uma infra-estrutura física e de recursos humanos destinada a gerar uma base de dados de superfície para atender a demanda de informações para a pesquisa, desenvolvimento e operação da área de energia renováveis no Brasil. Atualmente, a rede vem sendo aperfeiçoada e ampliada com financiamento da FINEP e PETROBRAS. A rede SONDA tem propiciado o desenvolvimento de diversos estudos sobre a disponibilidade de recursos energéticos renováveis, dos quais podemos citar o “Atlas Brasileiro de Energia Solar” [5], as publicações sobre cenários de energia solar no Brasil [6,46] e o relatório com as informações sobre a disponibilidade de energia solar e eólica no território brasileiro “Solar and Wind Energy Resources Assessment in Brazil – SWERA Report” [47]. Todas estão disponíveis em <http://sonda.ccst.inpe.br/publicacoes/index.html>.

A Fig. 9 apresenta a distribuição atual das estações ao longo de todo o território brasileiro para aquisição de dados das diversas componentes da irradiação solar, e variáveis meteorológicas (pressão atmosférica, velocidade e direção do vento em diferentes altitudes, umidade relativa, precipitação). Em algumas das estações estão instalados fotômetros solares para aquisição de dados de espessura ótica de aerossóis atmosféricos. As estações SONDA estão classificadas de acordo com a

instrumentação instalada e o tipo de dados coletados em: *Referência*, *Eólicas*, *Solares Básicas* e *Solares Avançadas*.



Figura 9 - Distribuição das estações de dados de superfície da rede SONDA no território brasileiro. Estações identificadas com forma quadrangular são estações de referência com equipamentos para aquisição de dados de energia solar e eólica. Maiores detalhes sobre a Rede SONDA podem ser obtidas em [www.sonda.ccst.inpe.br](http://www.sonda.ccst.inpe.br).

A estação localizada em São Martinho da Serra (RS) é uma das cinco estações de *Referência* da rede SONDA e está instalada no campus do Observatório Espacial do Sul do Centro Regional Sul (OES/CRS/INPE) – (29°26' S; 53°49' W). As estações de *Referência* são as estações mais completas do Projeto SONDA e realizam as seguintes medidas:

- *Medidas Solares* – radiação global horizontal, radiação direta-normal, radiação difusa horizontal, radiação de onda longa descendente, radiação fotossinteticamente ativa (PAR), iluminância (LUX), espessura óptica de aerossóis (AOT);

- *Medidas Meteorológicas* – temperatura, umidade relativa e pressão do ar atmosférico à superfície, e precipitação;

- *Medidas Eólicas* – velocidade e direção do vento nas alturas de 10, 25 e 50 metros a partir da superfície, e temperatura nas alturas de 25 e 50 metros.

Os principais sensores instalados nas estações de Referência SONDA para aquisição de dados das variáveis relacionadas a irradiação solar são:

- **Piranômetro CM 21 com sistema de ventilação CV 2** (Kipp & Zonen) – aquisição de dados de irradiação solar global na faixa de 300 nm a 2800 nm;

- **Piranômetro CM 22 com sistema de ventilação CV 2** (Kipp & Zonen) – efetua medidas de radiação solar difusa com alta precisão na faixa de 200 a 3600 nm;

- **Tracker Two-Axis Positioner 2AP** (Kipp & Zonen) – posicionador de dois eixos que rastreia com

precisão o caminho solar para controle do ocultador utilizado na aquisição de irradiação difusa e o posicionamento do pirheliômetro para aquisição de irradiação direta normal;

- **Pireliômetro NIP** (Eppley Laboratory, Inc) – efetua medidas de radiação solar direta-normal;

- **Pirgeômetro PIR** (Eppley Laboratory, Inc) – radiômetro de infravermelho para aquisição de dados de radiação de onda longa na faixa de 3500 nm a 5000 nm;

- **LUX Lite** (Kipp & Zonen) – aquisição de dados na faixa de radiação visível com uso de filtro óptico aliado a um fotodiodo que simula a resposta espectral do olho humano;

- **PAR Lite** (Kipp & Zonen) – efetua medidas da radiação fotossinteticamente ativa (PAR – “Photosynthetically Active Radiation”) durante o dia no intervalo de radiação solar visível de 400 a 700 nm;

- **Anemômetro Modelo 05106** (R.M. Young) – aquisição de dados de velocidade horizontal e direção do vento nas alturas de 10 m, 25 m e 50 m;

- **Barômetro Vaisala PTB 101** – efetua medidas da pressão atmosférica na faixa de 600 a 1060 mbar através de um sensor capacitivo;

- **Sensor de Temperatura do ar Modelo 41342** (R.M. Young) – efetua medidas da temperatura do ar através de um sensor de temperatura de platina e equipado com um protetor da radiação solar “Gill Multi-Plate Radiation Shield Model 41002”.

- **Sensor de Temperatura/Umidade Modelo 41372** (R.M. Young) – engloba sensor de umidade relativa do ar de alta precisão acoplado com sensor de temperatura utilizando passagem forçada de ar com uso do protetor “Gill Aspirated Radiation Shield model 43408” para evitar erros causados pela chuva e pela radiação solar;

- **Total Sky Imager TSI-440** (YES) – imageador do céu que utiliza câmera CCD invertida apontada para o centro de um espelho hemisférico convexo que reflete a imagem do céu e fornece a fração do céu coberta por nuvens em fração opaca e fina com uso do *TSI Manager Software*.

Os dados coletados são submetidos à um programa de garantia de qualidade com o intuito de validar os dados coletados e colocados a disposição da comunidade de interesse [48]. Toda a base de dados coletados com avaliação da qualidade está disponibilizada para acesso público e gratuito em [www.sonda.ccst.inpe.br/](http://www.sonda.ccst.inpe.br/). Os dados das componentes de irradiação solar coletados nas estações de Referência também podem ser acessados no website da Baseline Solar Radiation Network (BSRN) (<http://www.bsrn.awi.de/>) administrada pela World Meteorological Organization (WMO).

Os dados de AOT são coletados apenas nas estações de referência com uso de equipamentos estabelecidos pela AERONET e estão disponibilizados em website próprio ([http://aeronet.gsfc.nasa.gov/data\\_](http://aeronet.gsfc.nasa.gov/data_)



menu.html).

#### 4.2. Definições parâmetros estatísticos utilizados

Dois estudos de casos estão apresentados neste artigo. No primeiro estudo foi desenvolvido modelos de RNA com o intuito de obter estimativas para o total diário de irradiação solar global incidente na superfície. Como variáveis preditoras (dados de entrada da RNA's) foram utilizados variáveis meteorológicas medidas na estação SMS ou na plataforma de coleta de dados meteorológicos localizada vizinha à estação SONDA SMS. No segundo estudo, RNA's foram desenvolvidas para estimar o índice de transparência atmosférica (ou *clearness index*) também utilizando dados meteorológicos coletados na mesma estação SMS.

Em ambos os casos, a avaliação do desempenho das RNA desenvolvidas para estimativa dos parâmetros desejados foi realizada utilizando os seguintes parâmetros estatísticos na validação e comparação das estimativas fornecidas pelas diversas RNA's propostas e os dados coletados em superfície:

- **Coefficiente de Correlação ( $R$ ):** medida de associação linear entre observações e previsões definido por

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \cdot \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}}, \quad (16)$$

onde  $y_i$  são os valores previstos pelas RNA's e  $x_i$  são os valores medidos em superfície. Por ser independente da escala e por não levar em conta o viés da previsão, é possível encontrar uma correlação elevada para uma previsão com erros grandes (viés).

- **Viés ou Erro Sistemático Médio ( $MBE$  – *Mean Bias Error*):** valor que permite verificar se a previsão é sistematicamente subestimada (valores negativos) ou superestimada (valores positivos). Possui a mesma unidade das previsões e observações ou pode ser expresso em % do valor médio das observações.

$$MBE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i), \quad (17)$$

onde  $N$  é o número de dados.

- **Raiz do Erro Quadrático Médio ( $RMSE$  – *Root Mean Squared Error*):** valor que representa a magnitude média dos erros de previsão. O RMSE é expresso no quadrado das unidades das previsões ou, de forma similar ao MBE, % do valor médio das observações.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2}. \quad (18)$$

- **Erro Quadrático Médio ( $MSE$  – *Mean Square Error*):** trata-se do valor do RMSE elevado ao quadrado. Considerando a definição da função custo de uma RNA apresentada na Eq. (12) é fácil constatar que se este desvio deve ser minimizado durante o treinamento da rede. Neste estudo, será utilizado para comparar o desempenho de duas RNAs de tipologia semelhantes. O melhor treinamento será aquele que conseguir minimizar ao máximo o valor do MSE do subgrupo de testes do treinamento.

- **Skill:** índice utilizado para comparar dois modelos, quantificando o ganho (ou aperfeiçoamento) obtido pelo uso de um modelo em relação ao outro adotado como referência.

$$Skill(\acute{I}ND, ref) = \frac{\acute{I}ND - \acute{I}ND_{ref}}{\acute{I}ND_{perf} - \acute{I}ND_{ref}}, \quad (19)$$

onde  $\acute{I}ND$  pode ser qualquer dos índices de avaliação apresentados anteriormente (MBE, RMSE, etc.), calculado para uma previsão fornecida pelo modelo a ser avaliado,  $\acute{I}ND_{perf}$  é o valor para previsão perfeita desse índice (0 para MBE ou RMSE; e 1 para R), e  $\acute{I}ND_{ref}$  é o valor do mesmo índice obtido para a previsão fornecida por um modelo adotado como referência. Valores de  $Skill = 1$  representa que a previsão perfeita foi atingida e  $Skill = 0$  significa que não houve ganho em relação à previsão de referência. Valores negativos significam que a previsão avaliada é pior do que a previsão de referência

#### 4.3. Modelagem da estimativa do índice de transparência $K_t$

Para a modelagem do índice de transparência foram utilizados os dados de fração de nuvens finas e opacas observadas pelo TSI-440 na estação SMS como preditoras para alimentar as RNA's desenvolvidas. Para o treinamento, supervisão e validação das redes foram utilizados os dados de irradiação solar global coletados na mesma estação no período compreendido entre Março/2005 a Maio/2008.

Como os dados de fração de nuvens possuem uma resolução temporal de quinze minutos e os dados de irradiação solar são coletados a cada minuto, optou-se por utilizar valores médios da irradiação solar de um período de quinze minutos em torno do horário de aquisição das frações de nuvens.

Dessa forma, as RNA's desenvolvidas geram estimativas da irradiância solar média no intervalo de quinze minutos ao redor do horário de aquisição dos dados de fração de cobertura de nuvens. Por exemplo, as RNA's fornecem a estimativa da irradiação solar média no período de 11 h 53 min até 12 h 07 min quando alimentada com as frações de cobertura de nuvens observadas pelo equipamento no horário de 12 h.



#### 4.4. Modelagem da integral diária de radiação solar

A Tabela 2 apresenta as variáveis escolhidas como preditoras para alimentar as RNA que forneceram estimativas do total diário de irradiação global incidente na superfície. A seleção teve como base os dados meteorológicos coletados na estação SMS e informações publicadas na literatura científica. Ao todo foram selecionadas nove variáveis de entrada, incluindo a irradiação solar no topo da atmosfera ( $H_0$ ) definida no tópico 2 deste artigo. A Tabela 2 apresenta também o fator de correlação entre estas variáveis preditoras e o total diário da irradiação solar incidente na superfície.

O conjunto de dados disponível para o estudo apresentou distribuição sazonal irregular, de forma que divisão para constituir os diferentes grupos no treinamento, supervisão e validação das RNA's foi realizada de forma a garantir que não ocorresse concentração de dados de uma mesma estação sazonal em qualquer um dos grupos. Para o estudo estavam disponíveis 401 dias no período entre Março/2005 a Maio/2008. As médias diárias e desvio-padrões das estimativas das frações de nuvens opacas ( $FN_{op}$ ) e finas ( $FN_f$ ) foram calculadas a partir dos dados fornecidos pelo equipamento TSI a cada 15 minutos. As médias diárias dos dados de pressão, temperatura e umidade provenientes coletados na estação SONDA – SMS foram calculadas para todos os 401 dias disponíveis.

Os dados velocidade de vento a 10 m foram coletados na Plataforma de Coleta de Dados – PCD do CPTEC/INPE – MCT instalada no Observatório Espacial do Sul próxima a estação SONDA – SMS uma vez que o anemômetro de 10 m na torre anemométrica da estação SONDA – SMS somente entrou em operação em 2006. A literatura científica recomenda o uso de medidas de vento a 10 m e não nas alturas de 25 e 50 m, por este apresentar maior relação com o clima local.

Os dados apresentados na Tabela 2 mostram que o total diário da irradiação global em SMS apresenta maior correlação com as informações relacionadas às

frações de nuvens e a umidade relativa do ar. Mesmo assim, todas as variáveis foram utilizadas nos estudos e avaliações realizadas neste estudo. Após separação e tratamento do conjunto de dados, diferentes topologias de RNAs foram treinadas seguindo a metodologia descrita mais adiante no tópico 4.5.

#### 4.5. Treinamento e regularização das RNA's

A metodologia adotada no treinamento das RNAs é a mesma para as duas aplicações discutidas neste trabalho. Apenas o tipo da RNA empregada foi mantido fixo nas análises realizadas para as duas aplicações – tipo *feed-forward* (MLP). Todas as combinações das demais opções (número de camadas, número de nodos em cada camada, funções de ativação e o algoritmo de treinamento) foram alvo de intensivos testes que serão discutidos nos resultados deste trabalho.

Antes do início do treinamento, a base de dados foi normalizada em relação aos valores máximos e mínimos de cada variável, Eq. (16). Assim, tanto as variáveis de entrada quanto as variáveis de saída passam a assumir valores de 0 a 1.

$$valor\ normalizado = \frac{valor-m\u00ednimo}{m\u00e1ximo - m\u00ednimo} \quad (20)$$

Os dados normalizados são posteriormente divididos aleatoriamente na seguinte forma:

- 50% para o grupo de treinamento;
- 25% para o grupo de supervisão;
- 25% para o grupo de validação.

Uma vez selecionadas as opções relativas à configuração da topologia da RNA, a rede é treinada utilizando os grupos de treinamento e supervisão da base de dados. Durante o treinamento, os erros de ambos os grupos estarão sendo reduzidos, porém, somente o grupo de treinamento estará sendo fornecido como exemplo para o aprendizado da rede. Quando acontecer uma inflexão positiva na função erro do grupo de supervisão, o treinamento será interrompido imediatamente.

Tabela 2 - Variáveis selecionadas para alimentar as RNA's desenvolvidas para estimativa do total diário da irradiação global incidente na superfície. A segunda coluna apresenta os valores de correlação observados entre os dados coletados para cada variável preditora e total diário da irradiação global.

Variável preditora	Correlação
Média diária da fração de nuvens opacas ( $FC_{op-AVG}$ )	-0,898
Média diária da fração de nuvens finas ( $FC_f-AVG$ )	-0,561
Desvio padrão da fração de nuvens opacas ( $FC_{op-STD}$ )	-0,533
Desvio padrão da fração de nuvens finas ( $FC_f-STD$ )	-0,687
Média diária da pressão atmosférica (P)	0,300
Média diária da velocidade do vento a 10 m (W)	0,048
Média diária da umidade relativa (RH)	-0,674
Média diária da temperatura (T)	0,090
Total diário de irradiação solar no topo da atmosfera ( $H_0$ )	0,162

O treinamento de cada topologia de RNA foi repetido 10 vezes. Ou seja, pelo menos 9 vezes ao término do treinamento, os pesos e os valores dos desvios (*bias*) da rede foram inicializados a valores aleatórios e o treinamento foi recomeçado. Esta inicialização é necessária no sentido de que, dependendo dos valores iniciais dos pesos e *bias*, o treinamento começará numa região diferente da superfície de erro da RNA, podendo se encaminhar a diferentes mínimos locais, ou ao próprio mínimo global. A literatura sugere que uma topologia de rede seja testada com bem mais do que 10 treinamentos, mas neste trabalho foi adotada esta metodologia visto a grande quantidade de topologias testadas em cada análise. Após a série de treinamentos, adota-se a configuração de pesos que apresentou o melhor resultado do treinamento (menor erro para o grupo de supervisão) [26].

Após a conclusão do treinamento para determinada topologia de RNA, a rede é utilizada para estimar o parâmetro de saída alimentada pelo grupo de dados de validação. As estimativas fornecidas para esse conjunto de dados será utilizada para avaliar e comparar o de-

sempenho de cada uma das topologias utilizadas para as RNA's.

## 5. Resultados obtidos

### 5.1. Parâmetro $K_t$

Para o parâmetro  $K_t$ , foram inicialmente treinadas várias topologias de redes, com uma e duas camadas internas com função de ativação tangente hiperbólica, e função de ativação linear na camada de saída. Por tratar-se de redes com poucos pesos a serem ajustados foi empregado o algoritmo de *Levenberg-Marquardt* para treinamento.

Observa-se nos resultados apresentados nas Tabelas 3 e 4 que o número de nodos em uma camada interna não influenciou no desempenho da RNA, assim como o número de camadas internas. Na prática, não compensa investir em redes com maior número de camadas e de nodos para obter desempenhos muito semelhantes visto que o aumento do número de nodos acarreta aumento do custo computacional no treinamento e no processamento da RNA.

Tabela 3 - Resultados do treinamento de diferentes topologias de redes MLP com uma camada interna empregadas para modelar o parâmetro  $K_t$ .

Topologias	Treino		Supervisão		Validação			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
2-2-1	0,84	0,018	0,84	0,017	0,85	0,017	-0,01	24,1
2-4-1	0,85	0,017	0,85	0,017	0,86	0,016	0,02	23,6
2-6-1	0,85	0,017	0,85	0,017	0,85	0,017	0,01	24,0
2-8-1	0,85	0,017	0,85	0,017	0,85	0,017	0,07	24,1
2-12-1	0,86	0,016	0,86	0,016	0,86	0,016	-0,21	23,3
<b>2-14-1</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,06</b>	<b>23,4</b>
<b>2-16-1</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,03</b>	<b>23,4</b>
2-20-1	0,86	0,016	0,86	0,016	0,86	0,016	-0,07	23,4
2-24-1	0,86	0,016	0,86	0,016	0,86	0,016	-0,03	23,5

Tabela 4 - Resultados do treinamento de diferentes topologias de redes MLP com duas camadas internas empregadas para modelar o parâmetro  $K_t$ .

Topologias	Treino		Supervisão		Validação			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
2-14-1 TAN LIN	0,86	0,016	0,86	0,016	0,86	0,016	0,06	23,4
2-14-1 LOG LOG	0,86	0,016	0,86	0,016	0,86	0,016	0,08	23,4
2-14-1 LOG-LIN	0,86	0,016	0,86	0,016	0,86	0,016	0,02	23,4
2-14-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	0,13	23,5
2-14-1 LIN LIN	0,82	0,020	0,82	0,020	0,83	0,019	-0,07	25,8
2-16-1 TAN LIN	0,86	0,015	0,86	0,016	0,86	0,016	-0,03	23,4
<b>2-16-1 LOG LOG</b>	<b>0,86</b>	<b>0,015</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,02</b>	<b>23,3</b>
2-16-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	-0,08	23,5
2-16-1 LOG LIN	0,86	0,016	0,86	0,016	0,86	0,016	0,26	23,4
2-10-5-1 TAN LIN	0,86	0,016	0,86	0,016	0,86	0,016	-0,10	23,4
2-10-5-1 LOG LOG	0,86	0,016	0,86	0,016	0,86	0,016	-0,18	23,4
2-10-5-1 LOG LIN	0,86	0,016	0,86	0,016	0,86	0,016	-0,06	23,4
2-10-5-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	-0,05	23,4
2-12-6-1 TAN LIN	0,86	0,016	0,86	0,016	0,86	0,016	-0,14	23,4
<b>2-12-6-1 LOG LOG</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,03</b>	<b>23,3</b>
<b>2-12-6-1 LOG LIN</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,02</b>	<b>23,4</b>
2-12-6-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	-0,12	23,3
RLM	0,82	0,020	0,82	0,020	0,83	0,019	-0,08	25,8

Nas Figs. 10 e 11 observa-se o comportamento gráfico do MSE do grupo de supervisão em relação ao número de nodos das camadas internas. Observa-se que, de modo geral, o erro MSE é maior para RNA's com menos nodos e, que a partir de certo número de nodos, o desvio volta a crescer. Isso ocorre pro que o treinamento é interrompido cada vez mais cedo com o objetivo de evitar o *overfitting* que é mais provável de ocorrer para redes maiores.




Figura 10 - Variação do erro quadrático médio obtido para diferentes números de nodos na única camada interna de uma rede MLP durante a modelagem do parâmetro  $K_T$ .




Figura 11 - Variação do erro MSE obtido para diferentes números totais de nodos nas duas camadas internas de uma rede MLP durante a modelagem do parâmetro  $K_T$ .

A partir das análises iniciais, selecionaram-se as duas topologias de redes com uma camada interna (2-14-1 e 2-16-1) e as duas topologias de redes com duas camadas internas (2-10-5-1 e 2-12-6-1) que apresentaram os melhores resultados, para que fosse avaliado o emprego de outras funções de ativação. Os resultados destas análises estão descritos na Tabela 4. Pode-se constatar que o emprego da função de ativação sigmóide

logística, tanto para as camadas internas quanto para a camada de saída proporcionou os melhores desempenhos.

A Tabela 4 apresenta também os resultados obtidos com o uso de Regressão Linear Múltipla (RLM) utilizando as mesmas variáveis preditoras para a obtenção de estimativas. Verificou-se ainda que emprego de funções de ativação lineares em todas as camadas da RNA é equivalente ao resultado obtido empregando RLM demonstrando que o uso de funções de ativação não lineares permite o modelamento das não-linearidades presentes nos processos radiativos que ocorrem na atmosfera.

Os melhores desempenhos foram apresentados pela RNA's configuradas com a função de ativação sigmóide logística nas camadas internas, com destaque para as topologias "2-16-1 LOG LOG", "2-12-6-1 LOG LOG" e "2-12-6-1 LOG LIN". Essas três topologia apresentaram desempenhos muito próximos sendo que os MBE apresentado por essas RNA's para os dados do grupo de validação indicaram uma sub-estimativa da ordem de -0,025%.

A Fig. 12 apresenta os valores de  $K_t$  previstos por este modelo plotados em função dos valores medidos. A Tabela 5 apresenta a comparação entre o desempenho das metodologias RLM e RNA com a topologia "1-12-6-1 LOG LOG". Pode-se notar um ganho da ordem de 20% nos coeficientes de correlação e desvios das estimativas fornecidas pelas duas metodologias. A RNA apresentou uma redução de aproximadamente 57% do desvio MBE e 9,6% do RMSE.




Figura 12 - Valores dos parâmetros  $K_t$  obtidos pela rede MLP em função dos valores medidos.

Tabela 5 - Resultados do treinamento de diferentes topologias de redes MLP empregadas para modelar o parâmetro  $K_T$ , testando diferentes funções de ativação.

Topologias	Treino		Supervisão		Validação			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
2-14-1 TAN LIN	0,86	0,016	0,86	0,016	0,86	0,016	0,06	23,4
2-14-1 LOG LOG	0,86	0,016	0,86	0,016	0,86	0,016	0,08	23,4
2-14-1 LOG-LIN	0,86	0,016	0,86	0,016	0,86	0,016	0,02	23,4
2-14-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	0,13	23,5
2-14-1 LIN LIN	0,82	0,020	0,82	0,020	0,83	0,019	-0,07	25,8
2-16-1 TAN LIN	0,86	0,015	0,86	0,016	0,86	0,016	-0,03	23,4
<b>2-16-1 LOG LOG</b>	<b>0,86</b>	<b>0,015</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,02</b>	<b>23,3</b>
2-16-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	-0,08	23,5
2-16-1 LOG LIN	0,86	0,016	0,86	0,016	0,86	0,016	0,26	23,4
2-10-5-1 TAN LIN	0,86	0,016	0,86	0,016	0,86	0,016	-0,10	23,4
2-10-5-1 LOG LOG	0,86	0,016	0,86	0,016	0,86	0,016	-0,18	23,4
2-10-5-1 LOG LIN	0,86	0,016	0,86	0,016	0,86	0,016	-0,06	23,4
2-10-5-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	-0,05	23,4
2-12-6-1 TAN LIN	0,86	0,016	0,86	0,016	0,86	0,016	-0,14	23,4
<b>2-12-6-1 LOG LOG</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,03</b>	<b>23,3</b>
<b>2-12-6-1 LOG LIN</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>0,86</b>	<b>0,016</b>	<b>-0,02</b>	<b>23,4</b>
2-12-6-1 TAN TAN	0,86	0,016	0,86	0,016	0,86	0,016	-0,12	23,3
RLM	0,82	0,020	0,82	0,020	0,83	0,019	-0,08	25,8

Tomando como ponto de partida a topologia “2-12-6-1 LOG LOG” realizou-se um teste adicional, no qual esta rede foi treinada empregando diferentes algoritmos utilizados no treinamento de redes MLP. A Tabela 6 compara os desvios obtidos nas estimativas fornecidas pela RNA com os resultados apresentados pela Regressão Linear Múltipla (RLM). A Tabela 7 apresenta os desvios observados, o número de épocas, e o tempo médio de processamento computacional necessário para a conclusão do treinamento. Embora

tenha apresentado o maior tempo de processamento, o algoritmo *Levenberg-Marquardt* confirmou ser o algoritmo que leva aos menores erros durante o treinamento, e será mantido em todas as análises deste trabalho.

Tabela 6 - Comparação entre os modelos desenvolvidos por RLM e por redes MLP para previsão do parâmetro de radiação  $K_T$ .

Modelo	Validação			
	R	MSE	MBE%	RMSE%
RLM	0,83	0,020	-0,08	25,8
2-12-6-1 LOG LOG	0,86	0,016	-0,03	23,3
Skill	0,20	0,18	0,57	0,096

Tabela 7 - Comparação do desempenho de diferentes algoritmos de treinamento na análise do parâmetro de radiação solar  $K_t$ .

Algoritmo	Épocas	Tempo computacional (s)	Supervisão	
			R	MSE
<i>Levenberg-Marquardt</i>	86	54	0,86	0,016
<i>Resilient Backpropagation</i>	89	16	0,85	0,017
Gradiente conjugado escalar	131	40	0,85	0,017
Taxa de aprendizagem variável	180	33	0,83	0,019
Tx. de aprendizagem variável com momento	196	41	0,84	0,019

## 5.2. Total diário de irradiação solar global

Todas as RNA's configuradas para fornecer estimativas do total diário de irradiação solar incidente na superfície foram treinadas com o emprego do algoritmo

de *Levenberger-Marquardt*. A função sigmóide logística foi mantida como função de ativação dos nodos nas camadas internas e de saída. Os resultados do treinamento e validação das RNA's estão apresentados respectivamente nas Tabelas 8 e 9.

Tabela 8 - Resultados do treinamento de diferentes topologias de redes MLP com uma camada interna na modelagem da integral diária de radiação solar.

Topologias	Treino		Supervisão		Validação			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
RLM					0,91	0,006	-1,09	13,8
9-3-1	0,96	0,003	0,97	0,003	0,91	0,006	1,35	13,5
9-5-1	0,96	0,003	0,97	0,003	0,92	0,005	0,51	12,7
<b>9-6-1</b>	<b>0,97</b>	<b>0,002</b>	<b>0,97</b>	<b>0,003</b>	<b>0,92</b>	<b>0,005</b>	<b>0,56</b>	<b>13,4</b>
9-9-1	0,97	0,002	0,96	0,002	0,90	0,006	2,03	14,7
9-12-1	0,95	0,004	0,96	0,003	0,90	0,006	1,25	14,6
9-18-1	0,97	0,002	0,96	0,003	0,91	0,006	2,53	13,7

Tabela 9 - Resultados do treinamento de diferentes topologias de redes MLP com duas camadas internas na modelagem da integral diária de radiação solar.

Topologias	Treino		Supervisão		Validação			
	R	MSE	R	MSE	R	MSE	MBE%	RMSE%
RLM					0,91	0,006	-1,09	13,8
9-3-1-1	0,95	0,004	0,96	0,003	0,906	0,006	0,38	14,0
9-3-3-1	0,95	0,004	0,96	0,003	0,908	0,006	0,61	13,9
9-9-5-1	0,97	0,003	0,96	0,003	0,912	0,006	0,67	13,7
9-9-9-1	0,95	0,004	0,96	0,003	0,909	0,006	0,54	14,0
9-12-12-1	0,97	0,002	0,96	0,003	0,912	0,006	0,60	13,8
9-18-9-1	0,97	0,003	0,96	0,003	0,899	0,006	1,93	14,6
9-18-12-1	0,98	0,002	0,97	0,003	0,906	0,006	1,09	14,1
9-18-15-1	0,97	0,003	0,96	0,004	0,899	0,006	0,97	14,5
9-18-18-1	0,98	0,001	0,96	0,003	0,913	0,006	0,28	13,7

As informações estatísticas relativas ao modelo que utiliza a regressão linear múltipla – RLM também estão apresentadas nas Tabelas 8 e 9 com o intuito de permitir a comparação dos desvios observados para as estimativas produzidas pela diferentes metodologias. Pode-se verificar que apesar de a RLM ter apresentado valores de MSE da mesma ordem de grandeza que as RNA's, ela gera estimativas com os maiores desvios MBE.

A topologia “9-6-1 LOG LOG” apresentou os menores erros MSE no grupo de supervisão. Quando comparado ao modelo RLM, na Tabela 10, pode-se notar que houve um ganho aproximadamente 50% no desempenho no que se refere ao desvio MBE das estimativas de total diário de irradiação solar. No entanto, não houve ganho significativo no fator de correlação e RMSE. A Fig. 13 ilustra a dispersão dos valores previstos e medidos na estação SMS da rede SONDA. Os valores aparecem no intervalo de 0 a 1 por estarem normalizados.

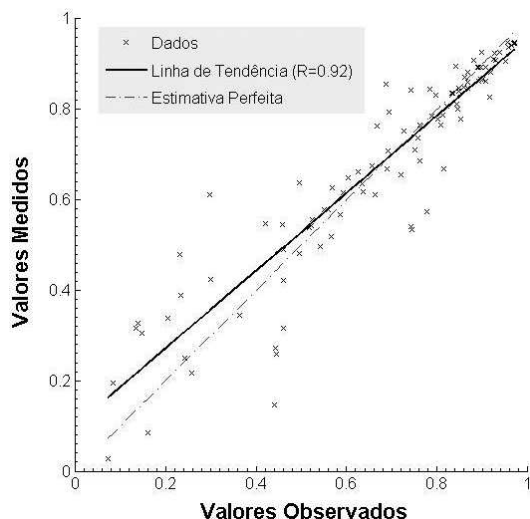


Figura 13 - Dispersão dos valores previstos para o total diário de irradiação solar pela MLP “9-6-1 LOG LOG” em função dos valores calculados a partir de medidas de radiação global solar.

Este comportamento sugere que para uma base de dados pequena (401 dias), as RNAs não conseguiram apresentar uma boa capacidade de generalização, pois

poucos padrões de dados teriam sido apresentados a elas. Outra hipótese está ligada à linearização dos processos físicos em razão de estar trabalhando com integrais diárias e não valores instantâneos.

Tabela 10 - Comparação entre os modelos desenvolvidos por RLM e por redes MLP para previsão da integral diária de radiação solar.

Modelos	Validação			
	R	MSE	MBE%	RMSE%
RLM	0,91	0,006	-1,087	13,8
9-6-1	0,92	0,005	0,561	13,4
SKILL	0,06	0,06	0,484	0,03

## 6. Conclusões

Este estudo discute o uso de redes neurais artificiais para obtenção de estimativas de parâmetros associados a incidência de irradiação solar na superfície. Verificou-se que é possível utilizar redes do tipo *multilayer perceptron* (MLP) com sucesso para a modelagem de parâmetros instantâneos de radiação solar a partir de apenas informações sobre a cobertura de nuvens, enquanto o seu emprego na modelagem da integral diária da radiação solar empregando um conjunto de variáveis climatológicas deve ser melhor estudada. A aplicação de modelos empíricos empregando as redes MLP representaram ganhos significativos na previsão de parâmetros de radiação solar em relação aos modelos desenvolvidos a partir de regressão linear múltipla pois as RNAs apresentaram a capacidade de explorar as não-linearidades presentes nas análises realizadas e tirar informações dos diferentes parâmetros de entrada que eram fornecidos a ela. Ganhos menores foram observados no caso em que a RNA foi aplicada para estimar que a integral diária da irradiação solar na superfície. A primeira hipótese levantada diz respeito ao fato de que a integral diária apresente maior linearidade com as médias das variáveis meteorológicas utilizadas no estudo.

Observou-se também que dentre as topologias aplicadas e avaliadas neste trabalho, as RNA's que empregam a função sigmóide logística como função de



ativação nas camadas internas, e treinadas pelo algoritmo de *Levenberger-Marquardt* mostraram ser as topologias mais viáveis nas análises realizadas. O trabalho deve ter continuidade com a avaliação mais detalhada de quais variáveis meteorológicas desempenham um papel significativo no desempenho das RNA's e a expansão do trabalho para outras regiões brasileiras. O desenvolvimento e compreensão das aplicações de RNA na avaliação dos recursos.

## Referências

- [1] J. Goldemberg and O. Lucon, *Energia, Meio Ambiente & Desenvolvimento* (Editora da Universidade de São Paulo, São Paulo, 2008), 3<sup>a</sup> ed. ampliada e revista, 394 p.
- [2] R.W. Bentley, *Energy Policy* **30**, 189 (2002).
- [3] H.S. Geller, *Revolução Energetica: Políticas para um Futuro Sustentável* (Relume Dumará, Rio de Janeiro, 2003).
- [4] I. Yucel, W.J. Shuttleworth, X. Gao and S. Sorooshian, *Mon. Wea. Rev.* **131**, 1797 (2003).
- [5] E.B. Pereira, F.R. Martins, S.L. Abreu and R. Ruther, *Atlas Brasileiro de Energia Solar* (Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006), 70 pp.
- [6] F.R. Martins, E.B. Pereira, S.A.B. Silva, S.L. Abreu and S. Colle, *Energy Policy* **36**, 2843 (2008).
- [7] A. Hammer, D. Heinemann, C. Hoyer, R. Kuhlemann, E. Lorenz, R. Muller and H.G. Beyer, *Remote Sensing of Environment* **86**, 423 (2003).
- [8] D. Heinemann, E. Lorenz and M. Girodo, in: *Proc. International Workshop on Solar Resource from the Local Level to Global Scale in Support to the Resource Management of Renewable Electricity Generation*. Institute for Environment and Sustainability, Joint Research Center, Ispra (2004).
- [9] G. Reikard, *Solar Energy* **83**, 342 (2008).
- [10] A. Hammer, D. Heinemann, C. Hoyer and E. Lorenz, in: *Proceedings of the EUMETSAT Meteorological Satellite Data Users' Conference*, Antalya, Turkey, (2001); S. Haykin, *Redes Neurais: Princípios e Prática* (Bookman Companhia Editora, Porto Alegre, 2001), 2<sup>a</sup> ed., 900 p.
- [11] L.M. Hinkelman, T.P. Ackerman and R.T. Marchand, *J. Geophys. Res.* **104(D16)**, 19535 (1999).
- [12] S.C. Chou, C.A.S. Tanajura Y. Xue and C.A. Nobre, *J. Geophys. Res.* **107(D20)**, 56 (2002).
- [13] F. Mesinger, in: *Proceedings of ICTP Regional Weather Predictability and Modeling Workshop*, CPTEC/INPE, São José dos Campos (2005). Disponível em <ftp://ftp1.cptec.inpe.br/etamd1/Download/model/EtaGuide.2008.8.pdf>.
- [14] R.A. Guarnieri, *Emprego de Redes Neurais Artificiais e Regressão Linear Múltipla no Refinamento das Previsões de Radiação Solar do Modelo Eta*. Dissertação de Mestrado, INPE, São José dos Campos (2006), 120 p.
- [15] H.K. Elminir, F.F. Areed and T.S. Elsayed, *Solar Energy* **79**, 270 (2005).
- [16] A. Mellit, M. Benganem and M. Bendekhis, *Artificial Neural Network Model for Prediction Solar Radiation Data: Application for Sizing Stand-alone Photovoltaic Power System*. IEEE Power Engineering Society General Meeting (2005).
- [17] J. Soares, A.P. Oliveira, M.Z. Boznar, P. Mlakar, J.F. Escobedo and A.J. Machado, *Applied Energy* **79**, 201 (2004).
- [18] G. Brasseur and S. Solomon, *Aeronomy of the Middle Atmosphere* (ED. Reidel Publishing Company, Dordrecht, 1986), 452 p.
- [19] K.L. Coulson, *Solar and Terrestrial Radiation: Methods and Measurements* (Academic Press, New York, 1975), 322 p.
- [20] M. Iqbal, *An Introduction to Solar Radiation* (Academic Press Canada, Toronto, 1983), 390 p.
- [21] J.P. Peixoto and A.H. Oort, *Physics of climate* (American Institute of Physics Press, New York, 1992), 520 p.
- [22] K.N. Liou, *An Introduction to Atmospheric Radiation* (Academic Press Inc., New York, 1980), 392 p.
- [23] N. Robinson, (ed.) *Solar Radiation* (Elsevier Publishing Company, Amsterdam, 1966), 347 p.
- [24] R. Perez, R. Seals and A. Zelenka, *Solar Energy* **60**, 89 (1997).
- [25] R.A. Guarnieri, F.R. Martins, E.B. Pereira e S.A.B. Silva, in: *Anais do XIV Congresso Brasileiro de Meteorologia*, Florianópolis (2006).
- [26] A.P. Braga, A.C.P.F. Carvalho e T.B. Ludermir, in: *11<sup>a</sup> Escola de Computação*, Universidade Federal do Rio de Janeiro, Rio de Janeiro (1998), 246 p.
- [27] S. Haykin, *Redes Neurais: Princípios e Prática* (Bookman Companhia Editora, Porto Alegre, 2001), 2<sup>a</sup> ed., 900 p.
- [28] W.S. McCulloch and W. Pitts, *Bulletin of Mathematical Biophysics* **5**, 115 (1943).
- [29] D.O. Hebb, *The Organization of Behavior* (Wiley, New York, 1949).
- [30] F. Rosenblatt, *Psychological Review* **65**, 386 (1958).
- [31] B. Widrow and M.E. Hoff, in: *Proceedings of IRE WESCON Convention Record*, Institute of Radio Engineers, Los Angeles, v. 4, p. 96-104 (1960).
- [32] M. Minsky and S. Papert, *Artificial Intelligence Progress Report. Technical Report. UMI Order Number: AIM-252* (Massachusetts Institute of Technology Press, Massachusetts, 1972).
- [33] J.J. Hopfield, *Proceedings of the National Academy of Sciences of the United States of America* **79**, 2554 (1982).
- [34] D.E. Rumelhart, G.E. Hinton and R.J. Williams, *Nature* **323**, 533 (1986), doi:10.1038/323533a0.
- [35] A.P. Braga, A.C.P.F. Carvalho e T.B. Ludermir, *Redes Neurais Artificiais* (Editora LTC, São Paulo, 2007), 283 p.
- [36] R. Beale and T. Jackson, *Neural Computing* (Institute of Physics Publishing, Bristol, 1992), 240 p.

- [37] G. Cybenko, *Continuous Valued Neural Networks with Two Hidden Layers Are Sufficient. Technical Report* (Tufts University, Medford, 1988).
- [38] H. Demuth, M. Beale and M. Hagan, *Neural Network Toolbox User's Guide - Version 6 - for use with MATLAB®. The MathWorks Inc.* Disponível em [http://www.mathworks.com/access/helpdesk/help/pdf\\_doc/nnet/nnet.pdf](http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf). Acesso em 10/2008.
- [39] H.M.J. Barbosa, T.A. Tarasova and I.F.A. Cavalcanti, *Journal of Applied Meteorology and Climatology* **47**, 1377 (2008).
- [40] R.J. Zamora, S. Solomon, E.G. Dutton, J.W. Bao, M. Trainer, R.W. Portmann, A.B.White, D.W. Nelson and R.T. Mc Nider, *Journal of Geophysical Research* **108(D2)**, 4050 (2003).
- [41] M.A. Armstrong, *Comparison of MM5 Forecast Short-wave Radiation with Data Obtained from the Atmospheric Radiation Measurement Program*. Master of Science Scholarly Paper, University of Maryland (2000).
- [42] S.M. Al-Alawi and H.A. Al-Hinai, *Renewable Energy* **14**, 199 (1998).
- [43] M. Mohandes, S. Rehman and T.O. Halawani, *Renewable Energy* **14**, 179 (1998).
- [44] M. Mohandes, A. Balghonain, M. Kassas, S. Rehman and T.O. Halawani, *Solar Energy* **68**, 161 (2000).
- [45] A. Sfetsos and A.H. Coonick, *Solar Energy* **68**, 169 (2000).
- [46] F.R. Martins, R. Ruther, E.B. Pereira and S.L. Abreu, *Energy Policy* **36**, 2855 (2008).
- [47] E.B. Pereira, J.H.G. Lima, F.R. Martins, S.L. Abreu, R. Ruther and O. Amarante, *Solar and Wind Energy Resource Assessment in Brazil* (INPE, São José dos Campos, 2008).
- [48] R.C. Chagas, F.R. Martins, R.A. Guarnieri, E.B. Pereira, S. Mantelli Neto, E.S. Andrade, S. Garcia, A. Bonfim Jr. e J.L.M. Nogueira, in: *Anais do XIV Congresso Brasileiro de Meteorologia*, Florianópolis (2006).