

# UTILIZAÇÃO DAS REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE RADIAÇÃO SOLAR

## USE OF ARTIFICIAL NEURAL NETWORKS FOR SOLAR RADIATION FORECAST

**Gleidson Leno Silva Oliveira**

glso@discente.ifpe.edu.br **Márcio Severino da Silva**

marcio.silva@garanhuns.ifpe.edu.br

---

### RESUMO

O aproveitamento da energia solar obtida através de células solares instaladas em locais com boa incidência de radiação solar representa um grande potencial para a geração elétrica. Diante da grande difusão dessa tecnologia no Brasil, investigamos como a energia solar fotovoltaica gerada em uma planta pode ser prognosticada por meio da correlação entre as grandezas físicas: temperatura e radiação. A energia solar exige um investimento relativamente alto por parte do consumidor residencial, comercial ou industrial, mas se apresenta como viável, pois consegue produzir economia na fatura mensal de consumo de energia elétrica após a sua instalação e pleno funcionamento. Essa pesquisa aconteceu no âmbito do Programa de Bolsa de Iniciação Científica (PIBIC) elaborado no IFPE campus Pesqueira, com o objetivo de estudar como a temperatura ambiente influencia no comportamento da incidência de radiação solar durante um período determinado. Considerando que as técnicas de inteligência artificial fornecem ferramentas capazes de estimar dados de sistema complexos, utilizamos redes neurais artificiais (RNA) para a previsão da radiação de energia solar, a partir dos dados disponibilizados pela usina solar do IFPE campus Pesqueira. Desenvolvemos vários experimentos para identificarmos a configuração mais adequada da rede. A rede neural artificial utilizada foi do tipo Multilayer Perceptron e a previsão foi feita utilizando a toolbox neural network do software Matlab. O resultado alcançado foi uma rede capaz de prever a radiação com base nos dados de temperatura com um percentual médio de erro de classificação de 1,21%, ou seja, um percentual de acertos de 98,79%.

Palavras-chave: Energia Solar Fotovoltaica. Rede neural. Previsão da Radiação Solar e Matlab.

## ABSTRACT

The use of solar energy obtained through solar cells installed in places with good incidence of solar radiation represents a great potential for electric generation. Given the great diffusion of this technology in Brazil, we investigated how the photovoltaic solar energy generated in a plant can be predicted through the correlation between the physical quantities: temperature and radiation. Solar energy requires a relatively high investment by the residential, commercial or industrial consumer, but it presents itself as viable, as it can produce savings in the monthly electricity consumption bill after its installation and full operation. This research took place within the scope of the Scientific Initiation Scholarship Program (PIBIC) developed at the IFPE campus Pesqueira, with the objective of studying how the ambient temperature influences the behavior of the incidence of solar radiation during a determined period. Considering that artificial intelligence techniques provide tools capable of estimating complex system data, we use artificial neural networks (ANN) to predict solar energy radiation, based on data provided by the IFPE campus Pesqueira solar plant. We developed several experiments to identify the most suitable configuration of the network. The artificial neural network used was of the Multilayer Perceptron type and the prediction was made using the neural network toolbox of the Matlab software. The result achieved was a network capable of predicting radiation based on temperature data with an average percentage of classification error of 1.21%, that is, a percentage of correct answers of 98.79%.

Keywords: Photovoltaic Solar Energy. neural network. Solar Radiation Prediction and Matlab.

## 1 INTRODUÇÃO

A energia proveniente da irradiação do Sol incidente sobre o planeta Terra é responsável por quase todas as fontes de energia disponíveis. De forma direta, além de utilizada para o aquecimento de fluidos na geração de energia, pode ser convertida em energia elétrica através de materiais fotovoltaicos, sendo uma forma não poluente de gerar eletricidade. O principal empecilho para essa forma de geração em escala comercial é o elevado custo das células solares. Assim, torna-se imprescindível que o local aonde o sistema fotovoltaico venha a ser instalado tenha a maior capacidade de geração por células solares possível, capacidade essa que está diretamente relacionada com a radiação solar na área em questão.

A energia solar, uma das energias que causa menos índices de poluição, é utilizada pelo aquecimento não uniforme da camada terrestre e com o despacho de raios solares que são aplicados nela para que a energia elétrica seja gerada. Ela é considerada uma fonte de energia limpa, pois durante sua geração ela não lança gases poluentes na atmosfera (SOUZA, 2014).

A partir da radiação solar que constitui a força motriz para os movimentos atmosféricos e para outros processos térmicos, dinâmicos e químicos que ocorrem na atmosfera e na superfície terrestre é possível aproveitar a energia solar, onde esta radiação incide nas placas solares fazendo com que a energia solar se converta em energia elétrica.

As redes neurais artificiais são formas de computação não algorítmica embasada por sistemas que lembram um esboço da estrutura de um cérebro humano. São ferramentas capazes de armazenar três conhecimentos a exemplos a serem empregadas na solução de problemas de ajuste funcional, reconhecimento de padrões e diversas outras aplicações. Essas redes artificiais são compostas por unidades de processamento simples, denominadas neurônios, que computam determinadas funções matemáticas, geralmente não-lineares, a partir de entradas recebidas (GUARNIERI, 2006).

As redes neurais podem ser aplicadas em diversos fenômenos no nosso planeta, possibilitando seu uso para a previsão de radiação solar usando um refinamento estatístico para a redução dos erros sistemáticos inerente ao modelo de mesoescala. Nossa pesquisa se propôs a desenvolver uma metodologia para previsão de radiação solar incidente usando como base dados meteorológicos obtidos pela estação de medição e da usina solar fotovoltaica instaladas no IFPE Campus Pesqueira com o uso de Redes Neurais Artificiais (RNA).

Utilizamos o programa *Matlab* com a realização de vários testes com a determinação de valores das radiações reais, e o desenvolvimento de rede neural artificial para previsão da radiação solar. Para ser possível de avaliação dos resultados obtidos foi calculado um índice numérico. O intuito deste índice numérico foi para que fosse utilizado como parâmetro do grau de assertividade da RNA. Um percentual de erro denominado de EC (Erro de Classificação) serviu para a avaliação de quanto a rede foi capaz de acertar ou não a previsão da radiação solar usando por base a temperatura média do ambiente.

A partir dos dados disponibilizados pela usina solar do campus Pesqueira, este trabalho teve como objetivo aplicar uma rede neural artificial perceptron como uma forma de realizar as previsões necessárias de radiação solar e caracterizar as vantagens da adoção de tal método.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 ENERGIA SOLAR

O Sol é a principal fonte de energia para a Terra. A radiação solar constitui-se por uma fonte de energia inesgotável que é o sol, havendo um enorme potencial de sua utilização por meio de sistemas de captação e conversão em outra forma de energia. (SANTOS, 2019).

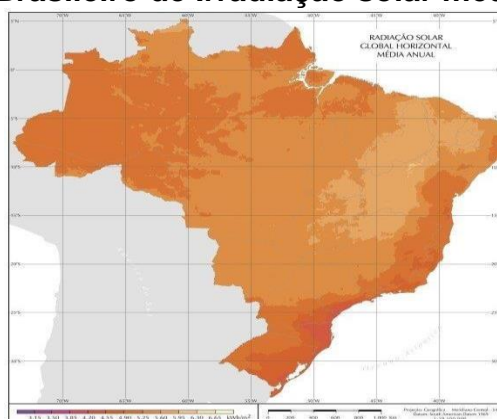
Aproveitar a energia gerada pelo Sol é uma das alternativas energéticas mais promissoras para prover a necessidade do desenvolvimento humano. A energia solar fotovoltaica é energia obtida através da captura da luz do sol e feita a realização da conversão direta para gerar a eletricidade (Efeito Fotovoltaico), sendo a célula fotovoltaica, o principal dispositivo para esse fim. (CEPEL-CRESEB, 2014).

A radiação solar pode ser aproveitada de diversas formas como por exemplo: captura de biomassa, aquecimento de ar e água para fins domésticos e industriais, ciclos termodinâmicos variados e, para o ponto de vista energético gerado por essa radiação a produção de energia elétrica (PEREIRA; VRISMAN; GALVANI, 2002).

O desenvolvimento da energia solar na matriz energética nacional traz benefícios ao país viabilizando as regiões remotas (onde o custo da eletrificação pela rede convencional é demasiadamente alto com relação ao retorno financeiro do investimento), regulando a oferta de energia em períodos de estiagem, diminuindo a dependência do mercado de petróleo e reduzindo as emissões de gases poluentes. Tem-se um grande leque de possibilidades de médio e longo prazo para aproveitamento dessa abundante forma de energia renovável, que vai desde pequenos sistemas fotovoltaicos autônomos até as grandes centrais que empregam energia solar (JHUAN, 2017).

A Figura 1 apresenta o mapa solarimétrico brasileiro onde é possível observar o valor de irradiação solar média diária estimada para cada região do país. Observar-se na mesma que o sul do Brasil possui uma Irradiação (quantidade de energia solar incidente por  $m^2$ ) menor do que comparada a outras regiões como Norte e Nordeste. Isso ocorre pelo distanciamento dos trópicos, onde é mais forte a irradiação solar. Porém, isso não chega a ser um problema para instalação de sistemas fotovoltaicos no Sul do país. Outros países como Alemanha, por exemplo, possuem índices menores de irradiação solar incidentes e mesmo assim possuem uma fração significativa da sua geração de energia elétrica mais fraca pela geração solar (INPE, 2006).

**Figura 1- Mapa Brasileiro de Irradiação solar médio, diário e anual**



Fonte: GAIO; CAMPOS; TIEPOLO (2017)

## 2.2 PREVISÃO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA

Com o aumento no consumo de energia elétrica e o acréscimo de novas fontes de energia renovável na geração distribuída, a geração fotovoltaica vem se destacando mundialmente. Neste cenário, os métodos de previsão de geração ganham maior relevância devido à exigência do aumento da confiabilidade para os sistemas de geração solar, porém a dependência com as condições climáticas, principalmente irradiação solar, criam dificuldades na precisão desta previsão. (YANG; CAO; XIU, 2014). Esta precisão traz vantagens para o sistema de geração melhorando a distribuição, a capacidade e o monitoramento. (GIGONI et al., 2018).

Segundo Majumder, Behera e Nayak (2017) há diferentes horizontes de previsão que podem ser utilizados, sendo eles classificados justamente conforme o período em que a previsão será realizada. Desta forma, cada um destes horizontes tem a sua qualidade em áreas distintas envolvidas na geração de energia fotovoltaica. Os horizontes comumente utilizados para previsão e suas aplicações são descritos abaixo. (MAJUMDER; BEHERA; NAYAK, 2017).

Existe a previsão em Curto Prazo: O período de previsão vai desde poucas horas até um ou dois dias. Também se tem a previsão em Médio Prazo: Com um período de previsão que pode se estender desde poucos dias até semanas. E a previsão em Longo Prazo: Abrange um período ainda mais amplo de previsão que pode variar desde poucos meses até anos.

## 2.3 REDES NEURAIS

McCulloch e Pitts (1943) realizaram o primeiro modelo matemático inspirado no neurônio biológico, resultando assim, na primeira geração de um neurônio artificial. Segundo Silva (2016), o primeiro método de treinamento para redes neurais artificiais foi proposto por Hebb (1949), e se denominou de regra de aprendizado de Hebb, sendo esta baseada em hipóteses e observações de caráter neurofisiológico.

A qualidade da radiação solar está diretamente relacionada ao comportamento da temperatura do ar, já que o ângulo em que a radiação alcança a superfície terrestre é o fator mais importante que afeta o padrão de temperatura na Terra (Wanessa et al, 2021).

As redes neurais artificiais (RNAs) são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios reais e nas características de suas interconexões. As RNAs são formadas por um conjunto de neurônios artificiais que interagem entre si, semelhantes ao funcionamento dos neurônios biológicos. Basicamente, são sistemas paralelos de computação e suas implementações podem ser em hardware (realiza uma determinada tarefa a partir de componentes eletrônicos) ou em software (simulações por programação em um computador digital) (MATSUNAGA, 2012).

O *Matlab* é um software de computação numérica de análise e visualização de dados. Embora seu nome signifique Laboratório de Matrizes, seus propósitos atualmente são bem mais amplos. Ele nasceu como um programa para operações matemáticas sobre matrizes, mas ao longo dos anos transformou-se em um sistema computacional bastante útil e flexível. Assim o *Matlab* é uma ferramenta e uma linguagem de programação de alto nível, e tem como principais funções: a construção de gráficos e compilação de funções, a manipulação de funções específicas de cálculo e variáveis simbólicas. Além disso, o *Matlab* possui uma grande quantidade de bibliotecas auxiliares, denominadas de *Toolboxes*, que otimizam o tempo gasto

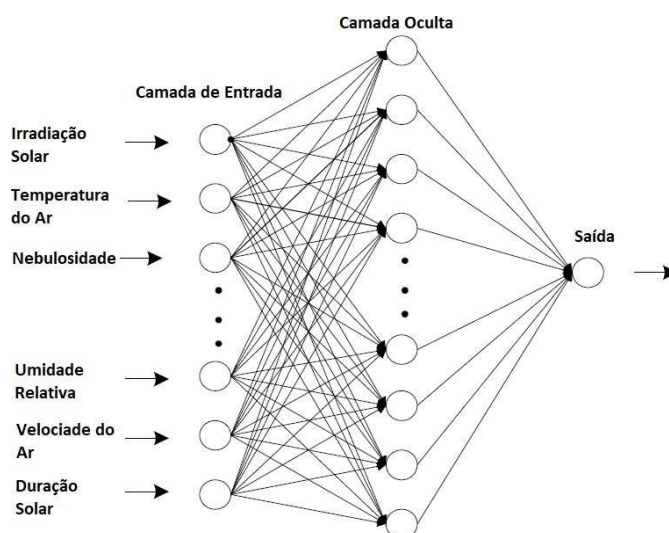
para realizar as tarefas, uma vez que, o usuário poderá utilizar muitas funções já definidas, poupando o tempo de criá-las. Por outro lado, infelizmente, os programas feitos são difíceis de serem executados num ambiente fora do *Matlab*. (BECKER et al, 2010).

## 2.4. Redes Neurais Artificiais

### 2.4.1 Estrutura

O principal elemento de uma rede neural artificial é o neurônio. Os neurônios são combinadores lineares que interagem com os dados de entrada, uma vez que a precaução desses dados é definida pelos seus pesos sinápticos. (ABEDIN et al., 2017). As RNAs são compostas por camadas, sendo que cada uma dessas camadas contém um número de neurônios como mostra a Figura 2. Na primeira camada, conhecida como camada de entrada, são colocados os dados de entrada que serão utilizados para o aprendizado do algoritmo, nesta camada cada neurônio é responsável por um tipo de dado, ou seja, se para uma previsão são utilizados dois tipos de dados, na camada de entrada existirá apenas dois neurônios. Na segunda camada, chamada de camada oculta, acontece o tratamento dos dados, essa camada é composta pelos neurônios ocultos.

**Figura 2 - Diagrama Estrutural uma Rede Neural Artificial**



Fonte: Adaptado de (CHENG; GE; CAO, 2012).

Para se definir a quantidade adequada de neurônios a serem inseridos na camada oculta de uma rede neural artificial, existem diferentes abordagens. Silva (2005) apresenta uma técnica de determinação da quantidade de neurônios ocultos a partir do teorema de Kolmogorov, representada pela Equação 1, que relaciona a quantidade de neurônios ocultos, denotado por  $N_{\text{ocultos}}$ , com o número de neurônios de entradas e de saída, denominado  $N_{\text{entrada}}$ .

$$N_{\text{ocultos}} = 2 * N_{\text{entradas}} + 1 \quad (1)$$

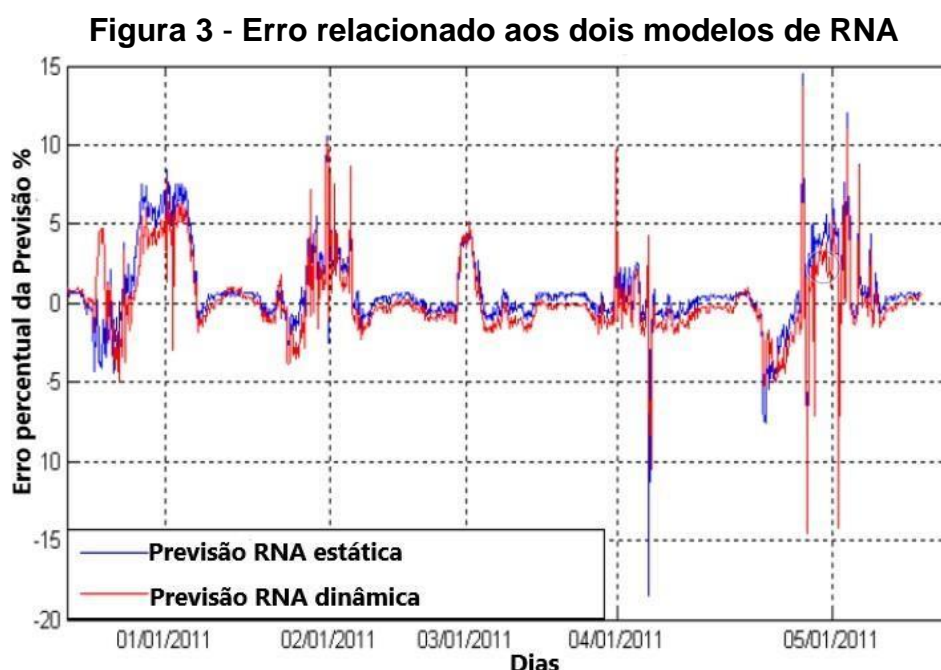
Para Haykin (2001), o número ótimo de neurônios ocultos se dá pela relação entre o erro médio quadrático e a quantidade destes neurônios, sendo que o valor ótimo está no modelo que apresentar menor erro com o menor número de neurônios

ocultos. Experimentos com um número mínimo de 2 neurônios ocultos são realizados, e a cada novo experimento modificava o número de camada oculta, com o objetivo de encontrar a relação ótima entre número de neurônios ocultos e erro médio quadrático (ALZHRANI et al., 2017).

### 2.4.2 Classificação

Segundo Barreto (2002), é possível classificar as redes neurais artificiais em redes neurais diretas e redes neurais com ciclos. Os modelos mais comuns são as redes neurais diretas, representadas por camadas, como mostrado na Figura 3.

Outros modelos existentes são as redes neurais com ciclos, modelo também frequentemente referenciado como redes neurais recorrentes. Estas últimas também são chamadas de redes neurais com repetição, sendo versões dinâmicas do modelo direto, originalmente criadas para representar na saída valores próximo aos utilizados na entrada. Para Alzahrani et al. (2017), as redes neurais diretas não são capazes de trabalhar com sequências aleatórias de entradas por não possuírem resposta à valores de saída. Para essas operações são usadas as redes neurais recorrentes ou com repetição, técnicas que repetem o sistema com o valor de saída anterior.



### 2.4.3 Normalização

Antes da entrada dos dados no sistema e logo após a sua limpeza, é necessário ordenar os mesmos. Para tanto, a normalização dos dados é utilizada para lidar com as diferentes escalas nos dados de entrada. (SINGH et al., 2015). O uso desta técnica diminui o processo de treinamento e diminui as chances de paradas durante o cálculo. Na normalização, os valores de entrada da rede neural são ordenadas sob uma faixa de valores mínimos e máximos (ALZHRANI et al., 2017).

A normalização mantém a proporcionalidade dos valores no conjunto de dados, além de melhorar a precisão das previsões. (SHI et al., 2011). Ainda segundo Singh et al. (2015), a normalização de Ponto Decimal, a Z-Score e a normalização de Instituto Federal de Pernambuco *campus* Pesqueira. Curso de Licenciatura em Física. 17 de fevereiro de 2022.

Mínimos e Máximos são algumas das técnicas empregadas neste tipo de tratamento dos dados. A técnica frequentemente utilizada na normalização de dados relacionados a previsão de geração é a normalização de mínimos e máximos, como em Shi et al. (2011), Singh et al. (2015), Alanazi, Alanazi e Khodaei (2016), Alzahrani et al. (2017). Geralmente os valores são ordenados entre 0 e 1, podendo haver variações nos valores mínimos e máximos. Na Equação 2 está a representação genérica da normalização de mínimos e máximos, onde  $P_n$  representa o valor real não normalizado,  $P_{\min}$  representa o limite da normalização e  $P_{\max}$  representa o limite superior.

$$P_{\text{nor}} = P_n - P_{\min} / P_{\max} - P_{\min} \quad (2)$$

Após a normalização, os dados de entrada a serem utilizados na rede neural estarão em uma mesma escala de referência. (ALANAZI; ALANAZI; KHODAEI, 2016).

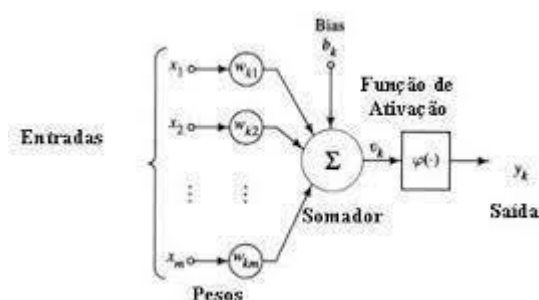
A equação utilizada para fazer o treinamento completo do trabalho foi a equação 3, onde  $V_{\text{exato}}$  denomina o valor exato não normalizado,  $V_{\text{mínimo}}$  denomina o valor mínimo normalizado e  $V_{\text{máximo}}$  representa o valor máximo.

$$X = (((V_{\text{exato}} - V_{\text{mínimo}}) * (1 - 0)) / (V_{\text{máximo}} - V_{\text{mínimo}})) \quad (3)$$

### 2.4.3.1 Função de Treinamento

A rede Neural Network Toolbox do Software Matlab (Matlab, 2017) foi escolhida para fazer as simulações, pois fornece algoritmos, funções e aplicativos para criar, treinar, visualizar e simular redes neurais. A RNA utilizada é do tipo Multilayer Perceptron (MLP), capaz de fazer qualquer mapeamento de entrada-saída desejado, como é apresentado na figura 4, desde que so tenha um significado, e que o número de neurônios na camada intermediária seja satisfatório (Hecht-Nielsen, 1990).

**Figura 4- Ilustração de um neurônio**



Fonte: Adaptado de (Hecht-Nielsen, 1990).

Pode-se destacar na arquitetura de uma MLP três perfis de camadas (Chatfield, 1989). A primeira é a camada de entrada e não é constituída por neurônios, e sim pela junção dos sinais de entrada. A segunda, camada intermediária ou camada escondida, é composta por  $N$  neurônios, e realiza algumas modificações. Por fim, a camada de saída, onde existem tantos neurônios quanto o número de saídas desejadas, cada saída representa uma variável que se deseja realizar a previsão (Chatfield, 1989).

Nesse trabalho foi utilizados essas camadas de entradas e saídas diversas vezes, para selecionar qual seria a entrada e saída mais adequada, para encontrar a melhor inicialização e o menor erro quadrático médio possível.



Foram utilizados materiais e dados já disponíveis na estação de medição meteorologia do Campus, Usina solar fotovoltaica do Campus, laboratório de informática, foi instalado o programa Matlab no computador com uma capacidade de memória adequada para que se pudesse roda perfeitamente e fosse possível realizar os treinamentos e os testes adequados.

Para que se pudesse atingir o objetivo deste trabalho, foi utilizada uma metodologia teórica e uma literatura sobre redes neurais em diversos trabalhos que abordam o tema.

Para a aplicação das metodologias, foram utilizados programas de gerenciamento de banco de dados, planilhas eletrônicas e programas que possuem *toolbox* de redes neurais que permitam aplicar as expressões e critérios de previsão desenvolvidos para a radiação solar.

Os dados que foram utilizados no trabalho foram dados de temperatura e radiação já existente na usina, os dados eram coletados diariamente e de todos os minutos durante o ano de 2017 todo, no total eram 26.3187, mas com as normalizações de dias e meses só foram usados 365 números de radiação e temperatura.

A rede neural Network Toolbox do Software Matlab foi escolhida para as simulações, pois fornecem algoritmos, funções e aplicativos para criar, treinar, visualizar e simular redes neurais. A rede neural utilizada é do tipo multilayer perceptron, capaz de fazer qualquer mapeamento de entrada e saída desejada.

## 2.4 CONTRIBUIÇÃO DAS REDES NEURAIS PARA O ENSINO DE FÍSICA

Redes neurais artificiais (RNAs) são definidas como sistemas paralelos distribuídos compostos de unidades básicas de processamento, os neurônios, que calculam funções matemáticas, por exemplo, funções não lineares. Esses neurônios são distribuídos em uma ou mais camadas, essas camadas podem ser bastante utilizadas no processo de treinamento de experimentos de física e podem ser calculadas por algumas das funções matemáticas.

As redes neurais artificiais têm como inspiração a estrutura biológica do cérebro. Assemelham-se principalmente na capacidade de adquirir conhecimento do ambiente através de um processo de aprendizagem e de armazenar o conhecimento em pesos sinápticos, que processam a informação recebida por cada neurônio de entrada e com os dados já armazenados relacionados a física podem realizar testes referentes a esse processo de armazenamento de aprendizagem e conhecimento da área da física em laboratórios.

A resolução de problemas utilizando RNAs se dá em duas etapas: uma etapa de aprendizagem, em que se alimenta a rede com exemplos e ela é treinada, extraindo características pertinentes à descrição do problema, seguindo um algoritmo de aprendizado adequado; e outra etapa de generalização, na qual a rede usa as características extraídas anteriormente para gerar respostas coerentes ao problema (CUSTÓDIO, 2019).

A contibuição das redes neurais artificiais no ensino de física, só tera um grande avanço se for utilizadas em laboratóriós, em experimentos que tenha o intuito de desenvolver algum tipo de expectativa referente a um experimento já existente.

Em experimentos de laboratórios, terá que ser montado um modelo de rede neural para realizar os experimentos adequados, com dados já existentes de outros experimentos para inserir na rede neural artificial e com a ajuda do matlab fazer com

que nos apresente os erros que podem vir a ocorrer nos experimentos, para que possamos fazer ajustes que nos possibilite a diminuir esses erros e com isso ter um experimento que possa nos dar um resultado mais correto.

Por exemplo, no experimento da velocidade angular, podemos realizar testes para diminuir algum erro apresentado por esse experimento, utilizando dados já existentes desse experimento, podemos ajustar os dados, realizar testes no modelo de rede criado e com a ajuda do matlab tentar diminuir os erros encontrados nesse experimento e com isso encontrar o melhor resultado possível para esse e outros experimentos.

### 3 METODOLOGIA

#### 3.1 MÉTODOS E HORIZONTE DE PREVISÃO A SEREM UTILIZADOS

O horizonte de estudo deste trabalho será de longo prazo, com o objetivo realizar a previsão de geração fotovoltaica na região de Pesqueira, para os próximos 12 meses, com um horizonte de aproximadamente 365 dias a frente. As previsões em longo prazo são caracterizadas por projetar a disponibilidade de geração de energia fotovoltaica em determinada área ao longo de meses e anos. (MAJUMDER; BEHERA; NAYAK, 2017).

O fator inicial para uma implementação confiável está na qualidade dos dados históricos obtidos. O período em que é determinado o princípio é monitorado e também tem influência na previsão, desta forma, o objetivo deste estudo é adquirir dados com o maior período possível de monitoramento. (CHATURVEDI; ISHA, 2016). Devido a quantidade de estudos relacionados a previsão de energia que utilizam redes neurais artificiais para suas previsões, aliada a capacidade das redes neurais de lidar com diferentes tipos de dados e aspectos não lineares, Abedin et al. (2017), este algoritmo será o utilizado nesta previsão.

Em estudos se é mostrado que a precisão de uma previsão com rede neural é incrementada de acordo com a qualidade dos dados. (SINGH et al., 2015). A precisão é aperfeiçoada através do processo de treinamento e pela arquitetura da rede neural construída. (ALANAZI; ALANAZI; KHODAEI, 2016). Desta forma, será necessário realizar diversas etapas de treinamento para encontrar uma arquitetura ótima para esta previsão.

Para a construção da rede neural artificial e para a realização do algoritmo de previsão o *software* utilizado será o Matlab, devido a quantidade de trabalhos na literatura que trabalham com este *software*, pelo suporte disponibilizado pela fabricante para seus recursos e pela confiabilidade e integridade de seu sistema. (ANDERSON; YAKIMENKO, 2018). No Matlab será utilizada a *Deep Learning Toolbox*, uma biblioteca que permite criar, calcular e visualizar redes neurais artificiais. Após a realização da previsão, os valores gerados serão testados, com o objetivo de comparar os valores obtidos com valores atuais de geração. A modelagem de uma rede neural artificial depende dos fatores específicos as características dos dados a serem analisados.

### 4 RESULTADOS E ANÁLISE

Para que se pudessem obter os dados de maneira mais clara e relevante em nosso trabalho, foi realizada varias normalização dos valores da temperatura

ambiente e da radiação, para que depois realizar os experimentos com os algoritmos GDM, LM e RP, para que depois dos experimentos fosse observado qual o algoritmo que nos trazia mais correto o valor do erro médio, mas para isso realizamos vários experimentos como mostra nas tabelas abaixo, até encontrarmos o melhor resultado e o melhor algoritmo.

Utilizando os dados horários de temperatura ambiente e radiação, obtidos da estação meteorológica do Campus Pesqueira, foi possível obter um banco de dados robusto que foi utilizado para treinamento e validação (70% dos dados) e testes (30% dos dados). A partir deste banco de dados, partiu-se para realizar os experimentos.

Para cada experimento, foi necessário analisar a melhor configuração, ou seja, o melhor algoritmo para as camadas. A Tabela 1 apresenta a escolha do melhor algoritmo possível entre os algoritmos GDM, LM e RP. Como parâmetro de avaliação da melhor configuração foi verificado o erro quadrático médio (mean-squared error - MSE).

**Tabela 1 – Valores de MSE para algoritmos previamente**

Inicializações	GDM $\eta = 0,01$ $\mu_c = 0,9; 100000$	LM	RP
1 <sup>a</sup>	0,064564	0,021302	<b>0,015326</b>
2 <sup>a</sup>	0,060531	0,02896	<b>0,016342</b>
3 <sup>a</sup>	0,093765	0,023268	<b>0,019706</b>
4 <sup>a</sup>	0,069106	0,014646	<b>0,025156</b>
5 <sup>a</sup>	0,077665	0,010182	<b>0,049233</b>
6 <sup>a</sup>	0,032803	0,016568	<b>0,02229</b>
7 <sup>a</sup>	0,012515	0,021409	<b>0,01945</b>
8 <sup>a</sup>	0,028896	0,030202	<b>0,017949</b>
9 <sup>a</sup>	0,0617	0,018249	<b>0,019167</b>
10 <sup>a</sup>	0,028054	0,023529	<b>0,021095</b>
<b>Erro médio do MSE</b>	<b>0,139054</b>	<b>0,109847</b>	<b>0,111429</b>

Fonte: Autoria Própria (2019)

Na tabela 1 verificamos qual algoritmo iria dar o menor erro possível para o experimento, então vimos que o melhor algoritmo seria o algoritmo LM.

Depois que escolhido o melhor algoritmo, foram refeitas novas inicializações para que se salvasse a rede com o menor valor do erro quadrático médio, conforme Tabela 2.

**Tabela 2 – Valores de MSE para o algoritmo LM**

Inicializações	LM
1 <sup>a</sup>	<b>0,018143</b>
2 <sup>a</sup>	<b>0,012727</b>
3 <sup>a</sup>	<b>0,029253</b>
4 <sup>a</sup>	<b>0,019323</b>
5 <sup>a</sup>	<b>0,019044</b>
6 <sup>a</sup>	<b>0,016751</b>

<b>7<sup>a</sup></b>	<b>0,017966</b>
<b>8<sup>a</sup></b>	<b>0,012802</b>
<b>9<sup>a</sup></b>	<b>0,020509</b>
<b>10<sup>a</sup></b>	<b>0,022003</b>
<b>Erro médio Do MSE</b>	<b>0,108047</b>

Fonte: Autoria Própria (2019)

Logo na segunda tabela foram realizadas 10 inicializações para encontrar qual seria a melhor inicialização do MSE do algoritmo LM, assim encontramos que a melhor inicialização foi a 2<sup>a</sup>.

O experimento foi realizado 10 vezes para o algoritmo de melhor inicialização com diferentes números de neurônios. A Tabela 3 mostra os valores obtidos pelo melhor algoritmo encontrado com a variação de neurônios.

Tabela 3 – Valores de MSE para o algoritmo LM variando-se o número de neurônios

Inicializações	Neurônios na Camada Oculta – REDE				
	1 neurônio	2 neurônios	3 neurônios	4 neurônios	5 neurônios
1 <sup>a</sup>	0,018143	0,019479	0,013907	0,01768	0,021035
2 <sup>a</sup>	0,012727	0,015601	0,012979	0,016638	0,013685
3 <sup>a</sup>	0,029253	0,015445	0,01963	0,019039	0,02069
4 <sup>a</sup>	0,019323	0,016481	0,018634	0,018873	0,017294
5 <sup>a</sup>	0,019044	0,014792	0,010498	0,020565	0,015357
6 <sup>a</sup>	0,016751	0,018625	0,02293	0,018597	0,016598
7 <sup>a</sup>	0,017966	0,021003	0,018468	0,016623	0,017067
8 <sup>a</sup>	0,012802	0,016216	0,014386	0,015897	0,018681
9 <sup>a</sup>	0,020509	0,017411	0,014859	0,012898	0,021238
10 <sup>a</sup>	0,022003	0,018602	0,013992	0,018337	0,024364
Erro médio	0,108047	0,106696	0,10548	0,106832	0,107819
Inicializações	Neurônios na Camada Oculta – REDE				
	6 neurônios	7 neurônios	8 neurônios	9 neurônios	10 neurônios
1 <sup>a</sup>	0,016896	0,019574	0,015095	0,021747	0,011934
2 <sup>a</sup>	0,016361	0,017759	0,017663	0,016817	0,017731
3 <sup>a</sup>	0,014524	0,015179	0,01937	0,017458	0,013841
4 <sup>a</sup>	0,01017	0,020209	0,022331	0,016485	0,01944
5 <sup>a</sup>	0,017761	0,020579	0,015938	0,016715	0,025534
6 <sup>a</sup>	0,02138	0,014532	0,011207	0,017413	0,016161
7 <sup>a</sup>	0,015863	0,017287	0,017028	0,01359	0,02127
8 <sup>a</sup>	0,018934	0,017893	0,013866	0,020827	0,013988
9 <sup>a</sup>	0,016987	0,019557	0,014923	0,016894	0,020002
10 <sup>a</sup>	0,023262	0,018912	0,024367	0,021044	0,016286
Erro médio	0,106558	0,107407	0,106526	0,107181	0,106926

Fonte: Autoria Própria (2019)

A tabela 3 apresenta os experimentos para encontrar onde seria o menor erro possível variando os números de neurônios no algoritmo LM, onde encontramos a melhor configuração da rede neural com o número de camadas em 10 neurônios, apresentando os menores valores do erro de classificação encontrado como mostra a Tabela 4.

Tabela 4 – Valores de EC para as melhores redes

Inicializações	Neurônios na Camada Oculta – REDE				
	1 neurônio	2 neurônios	3 neurônios	4 neurônios	5 neurônios

EC/	5,87% (8ª)	5,49%(10ª)	7,10% (5ª)	6,00%(10ª)	4,55% (2ª)
Inicializações	Neurônios na Camada Oculta – REDE				
	6 neurônios	7 neurônios	8 neurônios	9 neurônios	10 neurônios

Em resumo, com os algoritmos inicialmente escolhidos foram feitas dez inicializações para em cada um deles, depois foi calculado o erro médio (MSE médio) de cada um, em seguida foi observado qual algoritmo se tinha o menor erro, neste caso o LM. Depois apenas com o algoritmo LM, inicializou-se dez redes que foram salvas e depois alteradas as quantidades de neurônios presentes e verificada qual apresentava o menor MSE. Com o menor MSE de cada caso foi possível escolher a inicialização e número de neurônios mais adequado e calcular o erro de classificação. O melhor resultado alcançado foi para 1ª inicialização com dez neurônios, obtendo-se MSE de 0,011934 e erro de classificação de 1,21%.

## 5 CONSIDERAÇÕES FINAIS

Com o aumento de usinas solares, os responsáveis pelas operações de energia solar e de sistemas elétricos se necessitam de ferramentas capazes de prever a disponibilidade de recursos solares para a previsão de curto prazo. Para isso, é disponibilizado as técnicas de inteligência computacional, em desempenho das redes neurais artificiais.

Neste trabalho foi realizado um tratamento de dados de temperatura ambiente e radiação real obtidos da estação meteorológica do IFPE Campus Pesqueira. Após o tratamento de dados foi possível, utilizando o toolbox de redes neurais do *Matlab*, construir uma RNA que foi sendo refinada a cada novo passo e que obteve resultados promissores, como o melhor cenário de acerto de acertos de 98,79%, considerando que apresentou um erro de apenas 1,21%.

O resultado apresentado nesse trabalho mostra que pode ser útil a aplicação de redes neurais artificiais, o algoritmo mais indicado e o número de neurônios mais adequado para se fazer previsão de radiação solar usando como dado de entrada a temperatura ambiente. Com o uma previsão de temperaturas médias, de acordo com esse trabalho, é viável prever a radiação e conseqüentemente se fazer uma estimativa da quantidade de produção de energia.

O sistema de rede neurais artificiais é capaz de ajustar automaticamente o mapa de curso de cada aluno por meio de uma personalização automática.

A utilização das redes neurais no ensino básico tem inúmeras vantagens no processo de aquisição de habilidades. As RNA tem sido cada vez mais empregadas no ensino médio, sobretudo, já que se trata de um modelo computacional extremamente útil para a resolução de problemas complexos. A utilização de RNA no aprendizado da interpretação geométrica da derivada a partir da taxa média de variação e visão computacional com reconhecimento de imagens são apenas dois exemplos de como esse assunto pode ser inserido e instigar os estudantes a aprofundar seus conhecimentos nas áreas de Matemática e Física. Ela tem efeitos positivos no processo ensino-aprendizado dos discentes, com aumento da capacidade de armazenamento de informações, de análise sistemática dos dados e de criação de novas abordagens para resolver cada problema apresentado.

As RNAs têm cooperação multidisciplinar envolvendo os campos da neurociência, da matemática, da computação científica e da estatística, sua habilidade em reconhecer padrões é amplamente aplicada em reconhecimento de imagens, análise

de espectros, tomada de decisão em problemas complexos-lineares e não lineares.

## REFERÊNCIAS

ABEDIN, Zainal et al. A model for prediction of monthly solar radiation of different meteorological locations of Bangladesh using artificial neural network data mining tool. 2017. Disponível em: <<https://ieeexplore.ieee.org/document/7912993/>>. Acesso em: 03 dez. 2021.

ALANAZI, Mohana; ALANAZI, Abdulaziz; KHODAEI, Amin. **Long-Term Solar Generation Forecasting**. 2016. Disponível em: <<https://ieeexplore.ieee.org/document/7519883/>>. Acesso em: 03 dez. 2021.

ALZHRANI, Ahmad et al. **Solar Irradiance Forecasting Using Deep Recurrent Neural Networks**. 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8191206/>>. Acesso em: 03 dez. 2021.

ANDERSON, William W.; YAKIMENKO, Oleg A. **Using Neural Networks to Model and Forecast Solar PV Power Generation at Isle of Eigg**. 2018. Disponível em: <<https://ieeexplore.ieee.org/document/8372522/>>. Acesso em: 03 dez. 2021.

BARRETO, Jorge M. **Introdução às Redes Neurais Artificiais**. 2002. Disponível em: <<http://www.inf.ufsc.br/~j.barreto/tutoriais/Survey.pdf>>. Acesso em: 03 dez. 2021.

BECKER, Alex Jenaro; SILVA, Daiane Medianeira Ilha da. **Noções básicas de programação em Matlab**. Santa Maria, 2010. Disponível em: <[http://w3.ufsm.br/petmatematica/images/minicursos/Apostilas/Apostila\\_Matlab.pdf](http://w3.ufsm.br/petmatematica/images/minicursos/Apostilas/Apostila_Matlab.pdf)>. Acesso em: 20 jun. 2018.

BROLESE, ROAN. **PREVISÃO DE GERAÇÃO DE ENERGIA FOTOVOLTAICA UTILIZANDO MÉTODO DE APRENDIZADO DE MÁQUINA**, UNIVERSIDADE DE CAXIAS DO SUL, ano 2019, p. 14 - 82, ago. 2019.

CARVALHO, Wanessa *et al.* **Previsão de irradiação solar e temperatura do ar utilizando Redes Neurais Artificiais para a cidade de São Luís-MA**, 9º CONGRESSO LUSO-BRASILEIRO PARA O PLANEJAMENTO URBANO, REGIONAL, INTEGRADO E SUSTENÁVEL (PLURIS 2021 DIGITAL) Pequenas cidades, grandes desafios, múltiplas oportunidades, ano 2021, p. 1 e 13, 7 abr. 2021. Disponível em: <<https://pluris2020.faac.unesp.br/Paper817.pdf>>. Acesso em: 4 nov. 2021.

CEPEL-CRESEB. Manual de Engenharia para Sistemas Fotovoltaicos. [S.l.], 2014. Disponível em: Acesso em: 19 nov. 2021.

CHATURVEDI, D. K.; ISHA. **Solar Power Forecasting: A Review**. 2016. Disponível em: <<https://pdfs.semanticscholar.org/a679/0993e18db1b5d488b161194fa07a3d5c139f.pdf>>. Acesso em: 03 dez. 2021.

Chatfield, C. The Analysis of Time Series—An Introduction. Chapman and Hall, New York, 1989.

CUSTÓDIO, Caio Amaral. **Redes Neurais Artificiais e Teoria do Funcional da Densidade: otimização de funcionais para modelagem de**

**nanomateriais.** Universidade Estadual Paulista – UNESP Campus de Araraquara – Instituto de Química, Araraquara, p. 15 a 48, 6 set. 2019. Acesso em: 03 mar. 2022.

DIENSTMANN, Gustavo. **Energia solar, uma comparação de tecnologias.** Porto Alegre, dez. 2009.

FIORIN, Daniel *et al.* **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**, [s. l.], 18 abr. 2011.

GIGONI, Lorenzo *et al.* Day-Ahead Hourly Forecasting of Power Generation from Photovoltaic Plants. 2018. Acesso em: 19 nov. 2021.

GUARNIERI, Ricardo André. **Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA.** São José dos Campos, 12, 2006.

HAYKIN, Simon. **Redes Neurais - Princípios e práticas.** 2. ed. Porto Alegre: Bookman, 2001. 908 p. Disponível em: <[http://www.ncdd.com.br/livros/redes\\_neurais\\_simon\\_haykin.pdf](http://www.ncdd.com.br/livros/redes_neurais_simon_haykin.pdf)>. Acesso em: 03 dez. 2021.

HEBB, D. O. *The Organization of Behavior: A Neuropsychological Theory.* New York, USA: Wiley, 1949.

Hecht-Nielsen, R. *Neurocomputing.* Addison-Wesley Publishing Company, New York, 1990.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. *Atlas Brasileiro de Energia Solar.* São José dos Campos: INPE, 2006. 64 p.

JUNÍOR, Roberto Hilário Pereira; SANTOS, Leandro Pereira; SANTOS, Vanessa Cristina Lopes. **Geração Distribuída: Sistema de cogeração fotovoltaico conectado à rede elétrica de baixa tensão.** Disponível em: <[https://semanaacademica.org.br/system/files/artigos/artigo\\_9.pdf](https://semanaacademica.org.br/system/files/artigos/artigo_9.pdf)>. Acesso em: 09 de jun. 2017.

MAJUMDER, Irani; BEHERA, Manoj Kumar; NAYAK, Niranjan. *Solar Power Forecasting Using a Hybrid EMD-ELM Method.* 2017. Acesso em: 19 nov. 2021.

MAJUMDER, Irani; BEHERA, Manoj Kumar; NAYAK, Niranjan. **Solar Power Forecasting Using a Hybrid EMD-ELM Method.** 2017. Disponível em: <<https://ieeexplore.ieee.org/document/8074179/>>. Acesso em: 03 set. 2018.

MATLAB, Neural Network Toolbox, disponível em: <[https://www.mathworks.com/programs/trials/trial\\_request.html?prodcode=NN](https://www.mathworks.com/programs/trials/trial_request.html?prodcode=NN)>. Acessado em 1/2017.

MATSUNAGA, Victoria Yukie. **Curso de Redes Neurais utilizando o MATLAB.** 2012. Disponível em: <<http://www.muriloleal.com.br/visao/repositorio/centec/eai/ia//REDES%20NEURAI%20-%20APOSTILA.pdf>>. Acesso em: 03 dez. 2021.

MCCULLOCH, W. S.; PITTS, W. H. *A logical calculus of the ideas immanent in* Instituto Federal de Pernambuco *campus* Pesqueira. Curso de Licenciatura em Física. 17 de fevereiro de 2022.

nervous activity. *Bulletin of Mathematical Biophysics*, v. 5,p. 115-113, 1943.

OLIVEIRA, JHUAN. **DESENVOLVIMENTO E TREINAMENTO DE REDES NEURAIIS ARTIFICIAIS PARA PROCESSAMENTO DE DADOS DE RADIAÇÃO SOLAR**, UNIVERSIDADE FEDERAL DE SANTA CATARINA, p. 04 a 36, 6 jul. 2017.

PEREIRA, ANDRÉ B.; VRISMAN, AUGUSTO L.; GALVANI, EMERSON. Estimativa da radiação solar global diária em função do potencial de energia solar na superfície do solo. 2002.

PEREIRA, E. B; Martins, F. R.; Abreu, S. L.; Rütther, R. 2006. **Atlas brasileiro de energia solar. Instituto Nacional de Pesquisas Espaciais (INPE)**, São José dos Campos, 60p.

SHI, Jie et al. **Forecasting Power Output of Photovoltaic System Based on Weather Classification and Support Vector Machine**. 2011. Disponível em: <<https://ieeexplore.ieee.org/document/6074294/>>. Acesso em: 03 dez. 2021.

SILVA, I. N. da. *Redes neurais artificiais: para engenharia e ciências aplicadas*. 2. ed. São Paulo: Person, 2016.

SILVA, Renato Maia. **Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP**. 2005. 144 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Centro Técnico Científica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2005. Cap. 4. Disponível em: <[https://www.maxwell.vrac.puc-rio.br/7335/7335\\_5.PDF](https://www.maxwell.vrac.puc-rio.br/7335/7335_5.PDF)>. Acesso em: 03 dez.2021.

SINGH, Vikas Pratap et al. **Forecasting of 5MW Solar Photovoltaic Power Plant Generation Using Generalized Neural Network**. 2015. Disponível em: <<https://ieeexplore.ieee.org/document/7489107/>>. Acesso em: 03 dez. 2021.

SOUZA, Ramon Bezerra. **Avaliação de modelos de inteligência artificial para previsão de velocidade de vento em curto prazo**. Recife, 08, 2014.

YANG, Zhengqiu; CAO, Yapei; XIU, Jiapeng. **Power Generation Forecasting Model for Photovoltaic Array Based on Generic Algorithm and Bp Neural Network**. 2014. Disponível em: . Acesso em: 19 nov. 2021.