

# ESTIMATIVA DE IRRADIÂNCIA SOLAR UTILIZANDO REDES NEURAIS ARTIFICIAIS E IMAGENS DO CÉU

ESTIMATION OF SOLAR IRRADIATION USING ARTIFICIAL NEURAL NETWORKS AND SKY IMAGES

**Tony Márcio Pereira da Silva**

tonymarcio21@gmail.com

**Prof. Dr. Ygo Neto Batista**

ygo@pesqueira.ifpe.edu.br

---

## RESUMO

A crescente demanda mundial por energia elétrica proveniente de fontes renováveis, estimula cada vez mais a adoção de usinas solares. No entanto, devido à natureza variante da irradiância solar, ocasionada por fenômenos atmosféricos, usinas solares não são capazes de gerar energia de maneira contínua. A estimativa de irradiância solar a curto prazo torna-se uma tarefa fundamental para o planejamento adequado de tais usinas, bem como de sistemas conectados a redes domésticas. Comercialmente há aparelhos capazes de realizar leituras periódicas de irradiância solar, entretanto, a adoção de tais aparelhos em escala torna-se proibitiva devido ao alto custo de aquisição e manutenção. Neste cenário, estudos apresentam abordagens para estimativa de irradiância solar, com destaque para o uso de redes neurais artificiais. Este trabalho revisa de maneira subjetiva alguns destes estudos e se propõe a apresentar um modelo de redes neurais artificiais para estimativa de irradiância solar a partir de imagens do céu. A metodologia proposta inicia-se com a coleta e preparação dos dados, estabelecendo quais informações contribuiriam mais significativamente para aprendizagem da rede. Na sequência, foram projetadas e testadas um total de 10 configurações, contendo um número variado de camadas e neurônios. A precisão destas configurações é verificada a partir do erro médio quadrático e comparação direta com os valores medidos por um luxímetro. A configuração de rede que apresentou resultados mais precisos foi o modelo contendo 30 neurônios em 1 camada interna. O conjunto de dados e o número de entradas estabelecido para a rede neural se mostrou satisfatório.

Palavras-chave: Redes neurais artificiais. Irradiância. Energia. Geração fotovoltaica.

## ABSTRACT

The growing global demand for electricity from renewable sources is increasingly encouraging the adoption of solar plants. However, due to the variant nature of solar irradiance, brought about by atmospheric phenomena, solar plants are not able to generate energy continuously. The short-term estimation of solar irradiance becomes a fundamental task for the proper planning of such plants, as well as systems connected to domestic networks. Commercially, devices capable of periodically performing readings of solar irradiance are available, however, the adoption of such devices becomes prohibitive due to the high cost for acquisition and maintenance. In this scenario, studies present different approaches to estimate solar irradiance, with emphasis on the use of artificial neural networks. This work subjectively reviews some of these studies and proposes to present a model of artificial neural networks to estimate solar irradiance from images of the sky. The proposed methodology begins with data collection and preparation, establishing which information would contribute more significantly to the network learning. Following, a total of 10 configurations were designed and tested, containing a varied number of layers and neurons. The accuracy of these settings is verified from the mean quadratic error and direct comparison with the values measured by a luximeter. The network configuration that presented more accurate results was the model with 30 neurons in 1 inner layer. The data set and the number of entries established for the neural network were satisfactory.

Keywords: Artificial neural networks. Irradiance. Energy. Photovoltaic generation.

---

## 1 INTRODUÇÃO

Com a crescente demanda mundial por energia elétrica proveniente de fontes renováveis, visando eliminar o uso excessivo de fontes poluentes e de disponibilidade limitada, estimula-se cada vez mais a adoção de usinas eólicas e solares. Estudos recentes preveem um futuro promissor para a energia solar, destacando o seu maior crescimento em relação às demais fontes de energia (TOGAWA, André, 2014; BEZERRA, Francisco, 2020). Além disso, tais estudos também apontam que à medida que as tecnologias envolvidas nos processos de geração fotovoltaica avançam, aprimorando e viabilizando cada vez mais sua adoção, a participação desta fonte na matriz energética tendem a crescer.

Entretanto usinas solares não são capazes de gerar energia de maneira constante o tempo todo, pois dependem diretamente da irradiância solar, a qual varia continuamente devido a fenômenos atmosféricos, causados pelo espalhamento das ondas eletromagnéticas ao interagirem com partículas presentes na atmosfera (SANTOS, Cícero, 2012). Outra parcela responsável pela natureza variante da irradiância está diretamente ligada às condições meteorológicas, em especial a cobertura de nuvens, capaz de absorver e refletir radiação em diferentes níveis e direções (GUARNIERI, Ricardo et al, 2007). A aleatoriedade de sua composição e diversidade (forma, tamanho e densidade), fazem das nuvens a maior fonte de incertezas na determinação da irradiância local. Dentro deste contexto, a intermitência e a não controlabilidade da geração fotovoltaica, devido a tais fatores, trazem uma

série de desafios, tais como flutuação de tensão, variação da potência gerada e, conseqüentemente, instabilidade do sistema fotovoltaico como um todo.

Como o desempenho do sistema fotovoltaico possui forte correlação com os níveis de irradiância solar, a estimativa de tais valores torna-se uma tarefa fundamental para o planejamento adequado de usinas solares, bem como de sistemas conectados a redes domésticas, comumente denominados de sistemas híbridos. Comercialmente são oferecidos diferentes aparelhos, cuja finalidade é medir diariamente os níveis de irradiância local. Dentre estes aparelhos, podemos citar o piranômetro e o pireliômetro. Estes aparelhos são frequentemente encontrados em estações (meteorológicas ou solarimétricas) de superfície. Contudo, a utilização de tais aparelhos implica em um alto custo de aquisição, juntamente com gastos em manutenção e da necessidade de realização de calibrações ocasionais. Além disso, se faz necessário o uso de outros equipamentos para leitura, armazenamento e pós processamento dos dados coletados diariamente, o que implica ainda em mais gastos para o funcionamento completo do sistema.

Na literatura da área, a estimativa de irradiância solar aplicada na geração fotovoltaica tem sido realizada utilizando-se de abordagens distintas, tais como aprendizagem de máquina, em especial redes neurais artificiais; utilização de dados previstos a partir de um banco de dados histórico, em geral, fornecidos por agências meteorológicas ou obtidos a partir de estações solarimétricas de superfície (rede SONDA); sensoriamento remoto, entre outras soluções.

Técnicas envolvendo Redes Neurais Artificiais (RNAs) vêm sendo cada vez mais aplicadas em problemas relacionados à previsão de recursos energéticos, tendo em vista sua grande capacidade em lidar com problemas não lineares e de diferentes níveis de complexidade (BENEDITO, Raphael et al, 2019). Desta forma, o presente trabalho se dedica a desenvolver um modelo de RNAs para estimativa de irradiância solar a partir de imagens do céu.

Realizamos uma revisão da literatura científica a fim de analisarmos subjetivamente outras metodologias aplicadas na resolução do problema tratado neste artigo (estimar irradiância solar). Além disso, o presente trabalho aborda assuntos oriundos do campo da física e que podem contribuir para o ensino e aprendizagem de física óptica, como por exemplo: fenômenos relacionados à absorção, reflexão e refração de ondas eletromagnéticas pertencentes a diferentes regiões do espectro.

Na Seção 2 é apresentada a revisão bibliográfica, onde serão discutidas as técnicas aplicadas para busca e seleção de artigos de maior relevância para este trabalho, bem como a análise e discussão das diferentes metodologias aplicadas em outros trabalhos. A Seção 3 apresenta conceitos relacionados a fenômenos radiativos ocorrentes na atmosfera, devido à forte presença de partículas de água, aerossóis e da cobertura de nuvens. Em seguida, a Seção 4 descreve de maneira sucinta conceitos fundamentais acerca da composição estrutural e do funcionamento das RNAs. Na sequência, é apresentada na Seção 5 a metodologia desenvolvida e aplicada neste trabalho, expondo com detalhes as ferramentas utilizadas para coleta e preparação dos dados. Por fim, as Seções 6 e 7 destinam-se a apresentar os resultados e as considerações finais, expondo os testes e análises conclusivas, respectivamente.

## 2 FUNDAMENTAÇÃO TEÓRICA

Esta Seção destina-se a apresentar inicialmente a revisão bibliográfica desenvolvida no presente trabalho, expondo as técnicas aplicadas para busca e seleção de artigos de maior relevância, bem como a análise e discussão das diferentes metodologias aplicadas em outros trabalhos. Em seguida, são discutidos conceitos relacionados a fenômenos radiativos ocorrentes na atmosfera, descrevendo os processos de espalhamento sofridos pela irradiância solar durante o seu trajeto até a superfície terrestre. Por fim, são apresentados de maneira sucinta conceitos fundamentais acerca da composição estrutural e do funcionamento das RNAs.

### 2.1 Revisão Bibliográfica

Neste trabalho, o processo de busca e seleção de referências bibliográficas iniciou-se pela consulta na base de dados do próprio “google acadêmico”. Nesta, inclui um amplo número de materiais acadêmicos disponíveis para consulta pública, oferecendo a possibilidade de pesquisas a partir de termos como palavras-chave, autores, títulos e entre outros. Além disso, é possível realizar uma pesquisa ainda mais específica por meio da opção “pesquisa avançada”, em que é possível filtrar por um determinado autor ou até mesmo um periódico em específico.

A fim de selecionar artigos mais relevantes para o nosso trabalho, o processo de busca foi realizado em três etapas. Na primeira etapa, realizamos uma rápida seleção de artigos pertinentes com o nosso trabalho. Na segunda etapa, empregamos o uso do VOSviewer para mapeamento de palavras-chave de maior recorrência em outros trabalhos acadêmicos. Por fim, foi realizada uma nova busca utilizando-se das palavras-chave mais recorrentes. Os processos realizados em cada etapa serão detalhados a seguir.

O sumário de busca resultante da primeira etapa pode ser consultado na Tabela 1. Para a seleção de artigos mais relevantes, devido ao grande número de resultados retornado pela busca, foi realizada uma análise subjetiva de seus títulos e resumos, avaliando a pertinência do assunto tratado no artigo com este trabalho acadêmico. Adicionalmente, foram desconsiderados resultados duplicados.

**Tabela 1 – Palavras-chave utilizadas na primeira etapa de buscas.**

Palavras-chave	Ano de publicação	Total de resultados	Artigos selecionados
Imagens do céu; Redes neurais; Estimção de irradiância solar.	... - 2015	69	10
Imagens do céu; Redes neurais; Estimção de irradiância solar.	2016 - 2020	56	5
Energia solar; Redes neurais; Irradiância.	... - 2015	308	8
Energia solar; Redes neurais; Irradiância.	2016 - 2020	404	8
Total		837	31

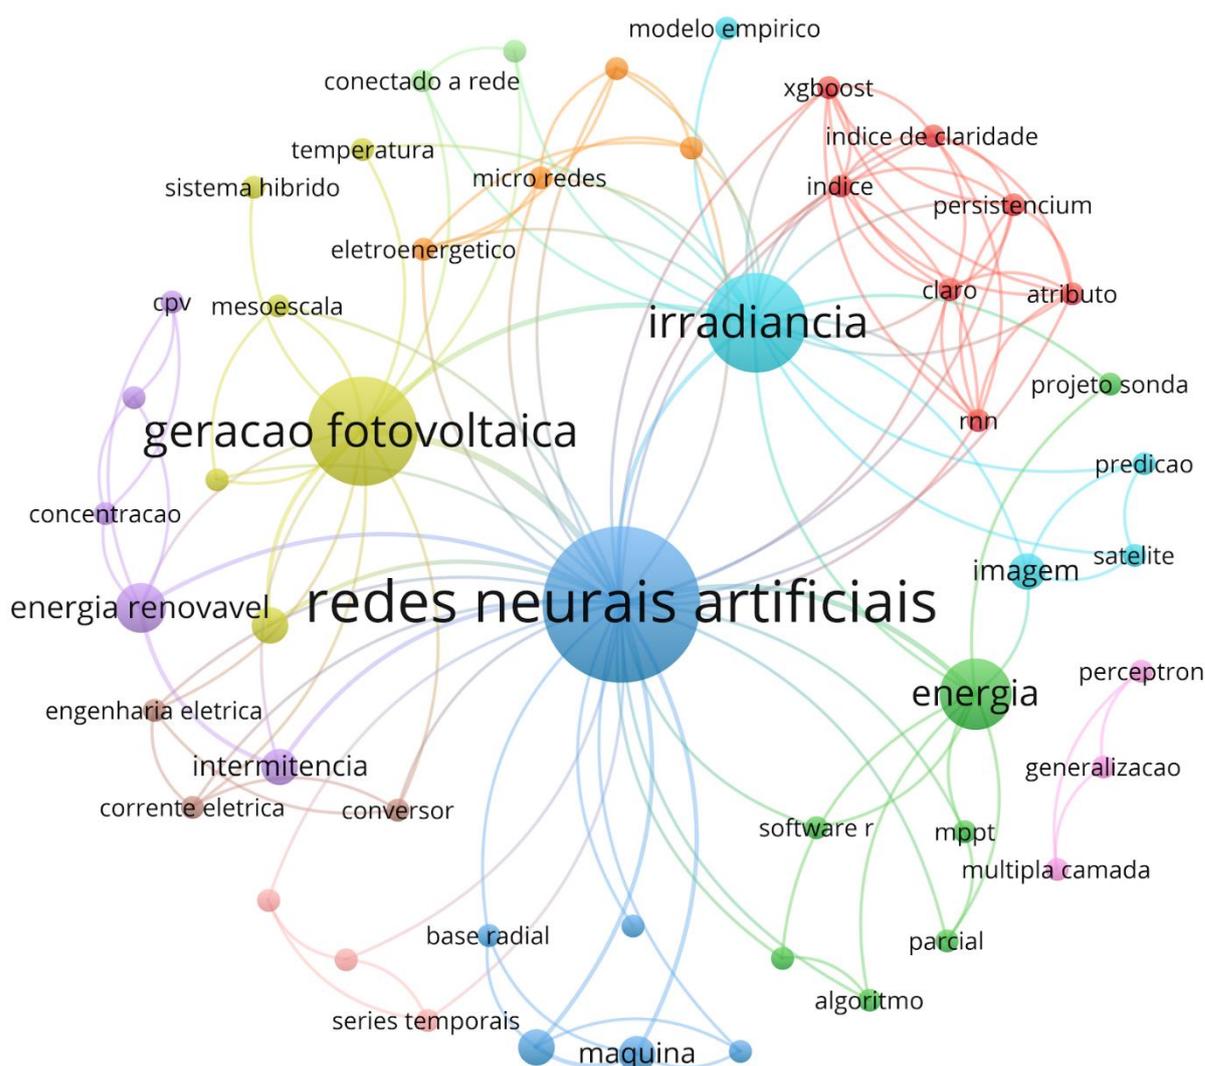
Fonte: Elaborado pelo autor.

Para a segunda etapa, foi empregado o uso da ferramenta computacional VOSviewer, sendo esta, uma ferramenta para elaboração e visualização de redes

bibliométricas a qual possibilita destacar e analisar um conjunto de dados incluindo autores, palavras-chave, ano de publicação, número de citações, revistas e entre outros. Neste trabalho, a ferramenta VOSviewer foi utilizada especificamente para mapeamento de palavras-chave em formato de rede. Este tipo de análise nos auxiliou na exclusão de termos que não correspondem ao âmbito desta pesquisa, como por exemplo agricultura, energia eólica e entre outros. Bem como tornando possível destacarmos termos de maior recorrência em outros trabalhos acadêmicos, a fim de utilizarmos para uma próxima busca que será descrita na terceira etapa.

A partir dos 31 artigos selecionados, foram copiadas e agrupadas as palavras-chave de cada artigo. Em seguida, tais termos foram inseridos na ferramenta VOSviewer para mapeamento, que, por sua vez, revelou a existência predominante dos termos “redes neurais artificiais”, com 15 ocorrências, “geração fotovoltaica”, com 9 ocorrências, “irradiância” com 8 e “energia”, com 5 ocorrências, os quais estão em destaque na Figura 1. O tamanho das esferas representa a recorrência do termo e as conexões indicam os termos que foram utilizados em conjunto em um mesmo artigo.

**Figura 1 – Mapeamento em rede de palavras-chave destacando os termos mais recorrentes.**



Fonte: Elaborado pelo autor.

Por fim, visando encontrar referências bibliográficas de maior pertinência com o nosso trabalho e após refinarmos os termos de consulta, demos início a terceira e última etapa do processo de busca e seleção. Utilizando-se dos termos de maior recorrência, foi possível analisar um novo conjunto de artigos, em que, mais uma vez, novos artigos foram analisados e selecionados. O sumário de busca da terceira etapa é apresentado na Tabela 2. É importante ressaltar que não foi possível obter alguns documentos devido a restrição ao acesso a algumas bases de dados relevantes, por exemplo do IEEE Xplore e do Elsevier.

Priorizamos a escolha de artigos que descrevessem metodologias utilizando redes neurais artificiais para estimar a irradiância solar. Foram selecionados 5 artigos visando a viabilidade da execução deste trabalho visto que, para esses artigos selecionados, seria realizada uma análise aprofundada. O sumário da busca pode ser visto na Tabela 2, enquanto os artigos selecionados estão listados na Tabela 3.

**Tabela 2 – Palavras-chave utilizadas na terceira etapa de busca.**

Palavras-chave	Ano de publicação	Total de resultados	Artigos selecionados
Redes neurais artificiais; Irradiância; Energia; Geração fotovoltaica.	... - 2015	156	2
Redes neurais artificiais; Irradiância; Energia; Geração fotovoltaica.	2016 - 2020	203	3
Total		359	5

Fonte: Elaborado pelo autor.

**Tabela 3 – Artigos selecionados na terceira etapa.**

#	Títulos
01	Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares (FIORIN, Daniel et al. 2011).
02	Modelagem e predição de flutuações da irradiação solar de curta duração (CAMPOS FILHO, Manoel Henriques. 2019).
03	Previsão de irradiância solar por rastreamento de nuvens utilizando imagens (TOGAWA, André. 2014).
04	Redes neurais artificiais aplicadas ao rastreamento de pontos de máxima potência de painéis fotovoltaicos com sombreamento parcial (GASPERACCO, Wellington. 2018).
05	Redes neurais recorrentes e XGBoost aplicados à previsão de radiação solar no horizonte de curto prazo (HEINEN, Eduarth. 2018).

Fonte: Elaborado pelo autor.

## 2.2 Modelos de previsão de irradiância solar

Motivados por uma maior eficiência na operação de sistemas fotovoltaicos, grupos de pesquisa têm se dedicado a desenvolver estudos sobre irradiância solar ou produção fotovoltaica, para isso, exploram técnicas envolvendo a aplicação de redes neurais artificiais, imagens do céu e XGBoost. Esta seção será dedicada a uma breve descrição dos estudos realizados por cada artigo selecionado.

### 2.2.1 Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares (FIORIN, Daniel et al. 2011)

As redes neurais artificiais apresentam-se como um método alternativo para lidar com problemas não lineares, como por exemplo fatores físicos que influenciam diretamente na disponibilidade de recursos energéticos. Fiorin (2011) utiliza redes neurais artificiais do tipo MLP (Multilayer Perceptron) para estimativa do índice  $K_t$  (índice de transmissividade) e do total diário de irradiação solar global. Fiorin (2011), ainda ressalta que redes MLP são amplamente utilizadas devido a sua simplicidade e facilidade de implementação.

O conjunto de dados utilizados para treinamento e validação da rede MLP, coletados no período compreendido entre março de 2005 e maio de 2008, foram fornecidos por uma estação de superfície pertencente à rede SONDA, localizada em São Martinho da Serra no Rio Grande do Sul. Dentre eles, encontram-se valores referentes a medidas solares, meteorológicas e eólicas, presentes na Tabela 4.

**Tabela 4 – Conjunto de dados utilizados como entrada da rede MLP.**

#	Variáveis predictoras
01	Média diária de fração de nuvens opacas
02	Média diária de fração de nuvens finas
03	Desvio padrão da fração de nuvens opacas
04	Desvio padrão da fração de nuvens finas
05	Média diária da pressão atmosférica
06	Média diária da velocidade do vento a 10 m
07	Média diária da umidade relativa
08	Média diária da temperatura
09	Total diário de irradiância solar no topo da atmosfera

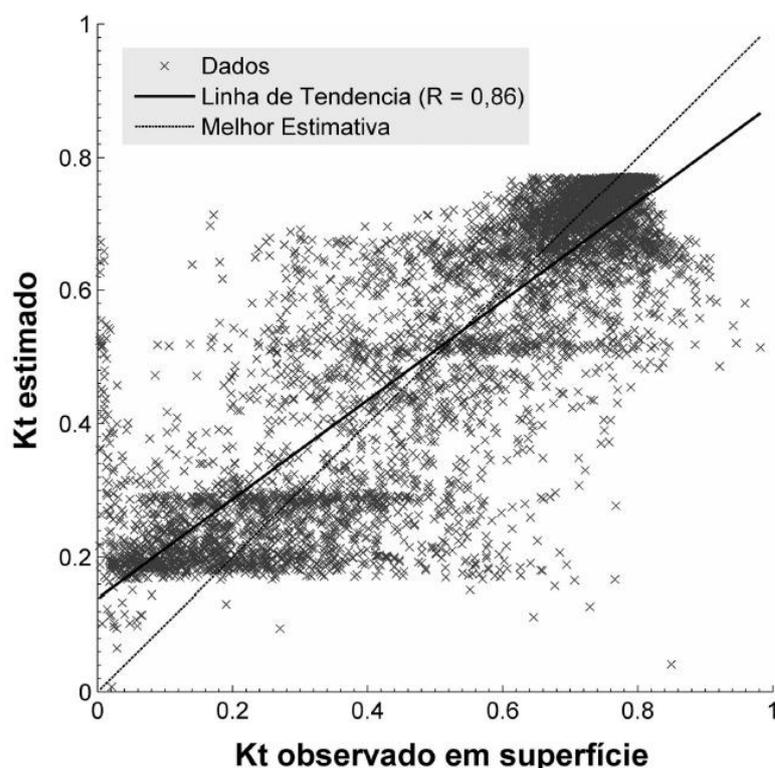
Fonte: Elaborado pelo autor.

Após uma série de testes, foram feitos ajustes referentes ao tipo de função de ativação, número de camadas e de neurônios para cada caso. Para o treinamento de cada configuração de rede, foi realizado um total de 10 repetições. Fiorin (2011) destaca que a literatura sugere que uma topologia de rede seja testada bem mais do que 10 vezes, mas tendo em vista o número de configurações testadas, foi utilizado justamente este valor. Ao finalizar a série de treinamentos, adotou-se a configuração que apresentou o melhor desempenho, frente aos dados de validação fornecidos pela rede SONDA.

As Figura 2 e 3 apresentam os resultados obtidos para o parâmetro  $K_t$  e para o total de irradiação solar global respectivamente, plotados juntamente com os valores previstos. Nos resultados obtidos, é possível notar que o número de neurônios em uma camada interna, a partir de 16 neurônios, não influenciou no desempenho da rede, assim como o número de camadas, a partir de quatro. Esse resultado, no qual um grande número de neurônios reduz o desempenho da rede, é esperado em RNA. O autor, ainda ressalta que, na prática, não compensa investir em configurações com maiores números de camadas e de neurônios para obter desempenhos que sejam

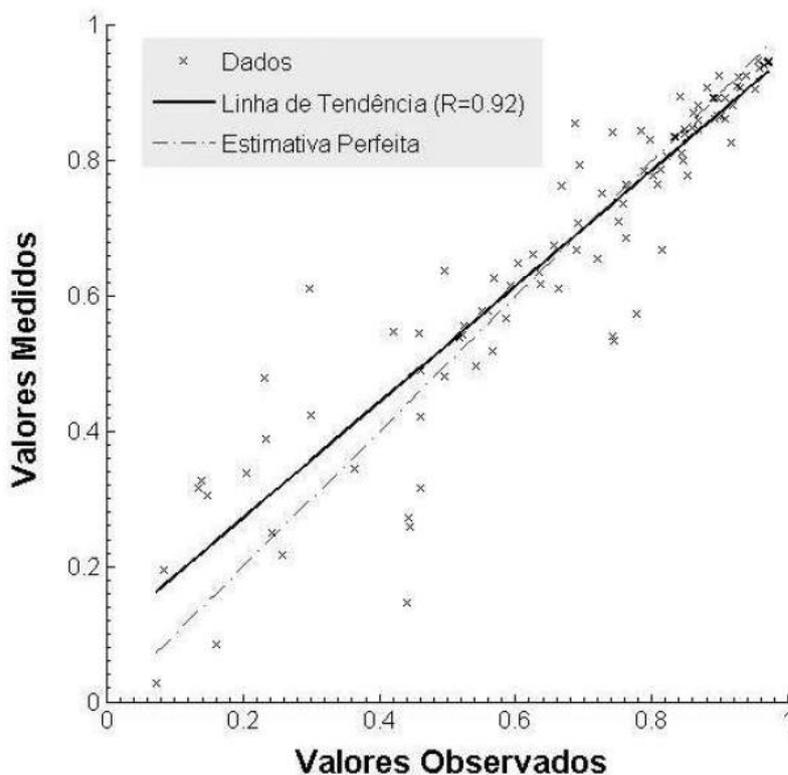
semelhantes a configurações mais simples, considerando que, configurações mais complexas acarretam em exigências computacionais maiores.

**Figura 2 – Valores obtidos para  $K_t$  a partir da rede MLP.**



Fonte: FIORIN, Daniel et al (2011)

**Figura 3 – Valores obtidos para o total diário de irradiância solar global.**



Fonte: FIORIN, Daniel et al (2011)

Apesar da aplicação ser em geração fotovoltaica, este artigo trata da estimativa do índice  $K_t$  e do total diário de irradiação solar global, aplicações que diferem do objeto deste trabalho, que é a estimativa da irradiação solar de curto prazo. Portanto, a estrutura da rede neural utilizada pelo autor pode não ser a mais adequada para a aplicação proposta neste trabalho, visto que o comportamento dos dados de entrada será diferente.

### **2.2.2 Modelagem e predição de flutuações da irradiação solar de curta duração (FILHO, Manoel. 2019)**

Buscando desenvolver uma metodologia que permitisse realizar previsões sobre a incidência de irradiação solar para curtos horizontes temporais, Campos (2019) utiliza-se (i) da ferramenta SVM, presente na biblioteca de *softwares* LIBSVM (*Library for Support Vector Machines*); (ii) imagens do céu e (iii) de dados coletados a partir de uma estação solarimétrica.

Classificada como aprendizado de máquina, a ferramenta SVM (*Support Vector Machine*) constitui uma técnica de aprendizado supervisionado, sendo amplamente utilizada, e com sucesso, em problemas que exigem classificação ou regressão (CAMPOS FILHO, Manoel Henriques. 2019). Em seu texto, Campos (2019) ainda destaca que as técnicas utilizando SVM, apresentam resultados comparáveis aos obtidos por outros algoritmos de aprendizagem, como por exemplo, as redes neurais artificiais. Para maiores detalhes sobre SVM, sugiro ao leitor que consulte a seção 3.7, presente no artigo original.

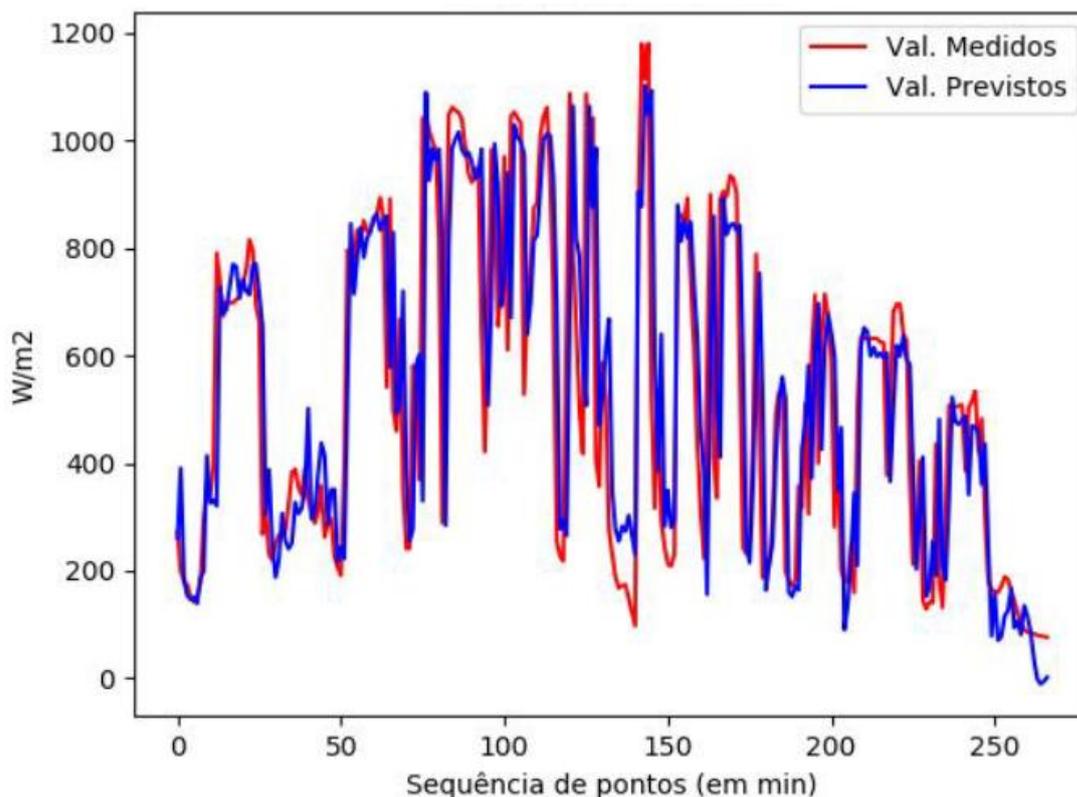
A partir da estação solarimétrica, foram coletados dados fornecidos por um piranômetro e um pireliômetro, ambos conectados a um datalogger responsável por armazenar e em seguida enviar os dados para um servidor. Para aquisição de imagens, foi utilizado uma câmera *Vivotek fisheye* (com uma lente olho de peixe), na qual, foram registradas imagens do céu durante um período de 10 horas por dia, começando de 06:30 da manhã e indo até as 16:30 da tarde, capturadas a cada 5 minutos. Posteriormente, todas as imagens eram enviadas para o mesmo servidor contendo os dados enviados pelo *datalogger*. Adicionalmente, foram coletados dados referentes à velocidade das nuvens, já que estes estão diretamente ligados a variação de irradiação solar. Para isso, foi empregado o uso da biblioteca de *softwares* OpenCV (Biblioteca de código aberto de Visão Computacional), contendo algoritmos responsáveis por calcular o sentido e velocidade do deslocamento das nuvens, assim como realizar a remoção da distorção inserida pela lente olho de peixe.

Segundo Campos (2019), segmentar as nuvens em uma imagem é um processo de extrema importância, visto que a oclusão (ou não) do sol em relação a fração de nuvens, pode impactar significativamente no valor de radiação que chega até o solo. Sendo assim, após analisar um leque de possibilidades para tal tarefa, é escolhido o algoritmo SVC (máquina de vetores de suporte voltada para problemas de classificação), tendo em consideração o suporte e material disponível em diferentes sites. Este algoritmo, também está presente na biblioteca de *softwares* LIBSVM.

Após a análise de modelos de previsão de irradiação, o modelo escolhido foi do tipo SVR (SVM aplicado a problemas de regressão), existente na linguagem *Python*. Neste, foram realizados alguns ajustes para melhor tratamento de séries temporais contendo dados numéricos relativos a fotografias e dados de irradiação. Para as

previsões, foram utilizados um conjunto de dados coletados durante um período de 8 dias, contendo 2939 amostras para treinamento e 267 amostras para validação do modelo. Por fim, para avaliação dos resultados, realizou-se uma comparação entre os valores medidos (fornecidos pela estação solarimétrica) e valores previstos para a irradiância, representados graficamente na Figura 4.

**Figura 4 – Comparativo entre os valores medidos e os valores esperados de irradiância.**



De modo complementar em relação ao artigo analisado anteriormente (Fiorin, 2011), neste caso o autor tem uma aplicação similar a esta em desenvolvimento, neste trabalho de TCC, com a previsão de curto prazo da irradiância solar. Adicionalmente, o autor também utiliza a imagem do céu para realizar tal previsão. Porém, a ferramenta computacional utilizada não foi a rede neural artificial e o hardware utilizado para a aquisição da imagem e para o processamento dos dados não estão em sistema embarcado de baixo custo, como previsto no projeto em desenvolvimento no IFPE Campus Pesqueira. A técnica e os resultados obtidos pelo autor serão analisados durante a implementação deste trabalho de TCC.

### **2.2.3 Previsão de irradiância solar por rastreamento de nuvens utilizando imagens (TOGAWA, André. 2014).**

Com o objetivo de adaptar o método de previsão de irradiância solar por rastreamento de nuvens desenvolvido por Marques e Coimbra (2013), no qual utiliza-se de um equipamento *Total Sky Imager* (TSI), Togawa (2014) aplica uma metodologia que substitui o TSI por uma câmera de segurança *Vivotek*. É importante ressaltar que não foram utilizadas redes neurais artificiais para cumprimento deste

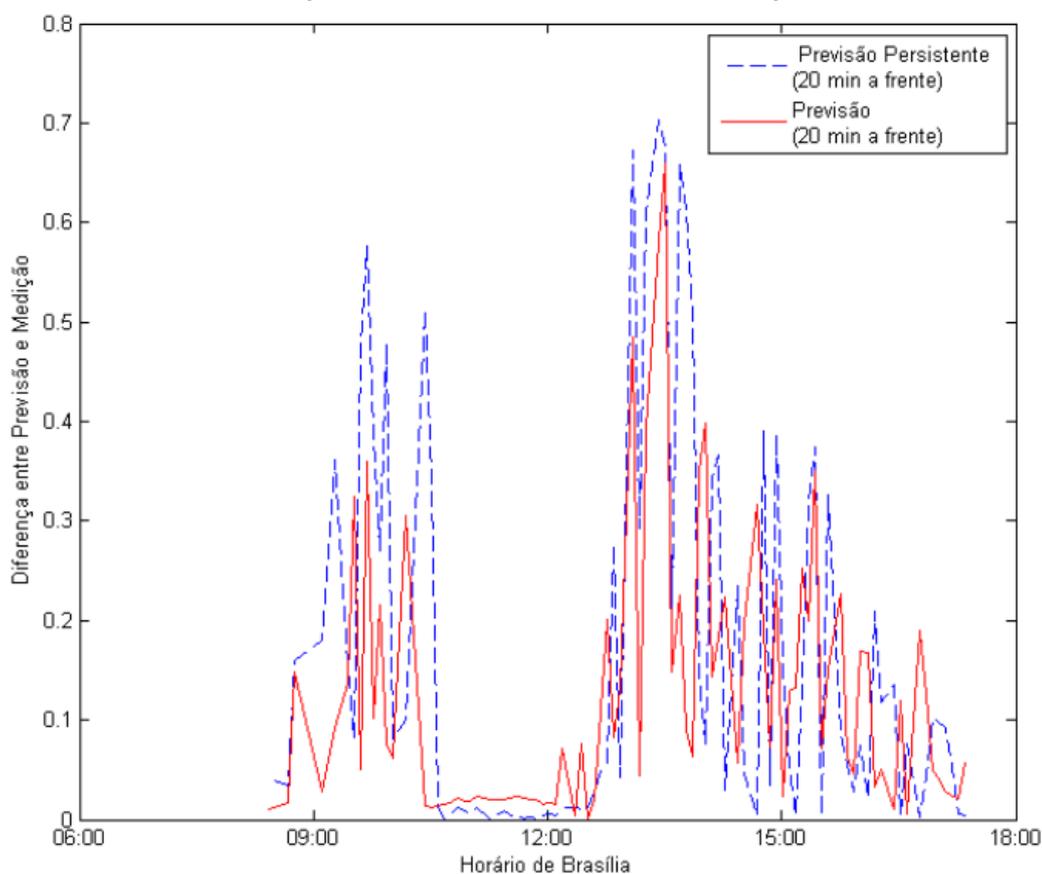
objetivo, mas, um conjunto de softwares desenvolvidos e distribuídos pelo grupo de pesquisa *Coimbra Energy Group* (CEG), os quais oferecem funções como: controle de aquisição de imagem por minuto, detecção da direção em que as nuvens estão se movendo, binarização de imagens, determinação da posição do sol, cálculo da fração de nuvens e previsão de irradiância global horizontal.

A princípio, foram realizadas algumas adaptações, a fim de alcançar uma maior compatibilidade com a câmera *Vivotek*. Tendo em vista que os softwares foram desenvolvidos originalmente na ferramenta *MatLab*, para as adaptações, foi necessário o uso da mesma.

O processo de coleta de dados aconteceu da seguinte forma: (i) após configurada para capturar imagens a cada minuto, durante um período de 5 dias entre 6h e 18h, a câmera *Vivotek* enviava todas as imagens para um servidor; (ii) em seguida, para efeitos de comparação com os dados previstos, Togawa (2014) utiliza-se de um piranômetro conectado a um datalogger, o qual é responsável por armazenar a diferença de potencial medida pelo piranômetro. Adicionalmente, esta diferença de potencial foi convertida em irradiância utilizando-se a constante de calibração fornecida pelo próprio fabricante.

A coleta de dados ocorreu precisamente durante os dias 10, 11, 12, 14 e 15 de maio de 2014. As previsões de irradiância eram realizadas a cada 5 minutos, em que, as previsões realizadas no dia 10, foram as de melhor resultado. A comparação entre os valores gerados pela previsão e os valores medidos, estão representados na Figura 5.

**Figura 5 – Comparação entre a previsão e a mediação de irradiância.**



Fonte: TOGAWA, André (2014)

Durante a análise dos resultados, Togawa (2014) observou que a presença de nuvens finas prejudica as previsões, já que, ao passar na frente do sol, não causam uma grande queda na irradiância, sendo este, um fator considerado pelo piranômetro, mas não pelo *software* de previsão. O fator responsável por causar as maiores distorções nos resultados, diz respeito ao fato de que, em dias de céu limpo, o intenso brilho do sol é considerado como nuvem pelo *software*. Em contrapartida, os dias que apresentaram os melhores resultados, foram os dias parcialmente nublados, com destaque para o dia 10.

Ao analisar este trabalho, verificamos que o hardware para a aquisição da imagem é similar ao apresentado no artigo anterior (CAMPOS FILHO, Manoel Henriques. 2019), com a câmera *Vivotek*, contudo, a falta de um sistema eletromecânico para bloquear a incidência direta da radiação solar sobre o sensor causa saturação no sensor e reduz a precisão do sistema, inclusive prejudicando na segmentação e identificação das nuvens. Adicionalmente, e de forma similar ao artigo anterior, este sistema não é processado em plataforma embarcada, assim como desejado no projeto desenvolvido no IFPE Campus Pesqueira.

#### ***2.2.4 Redes neurais artificiais aplicadas ao rastreamento de pontos de máxima potência de painéis fotovoltaicos com sombreamento parcial (GASPERACCO, Wellington. 2018).***

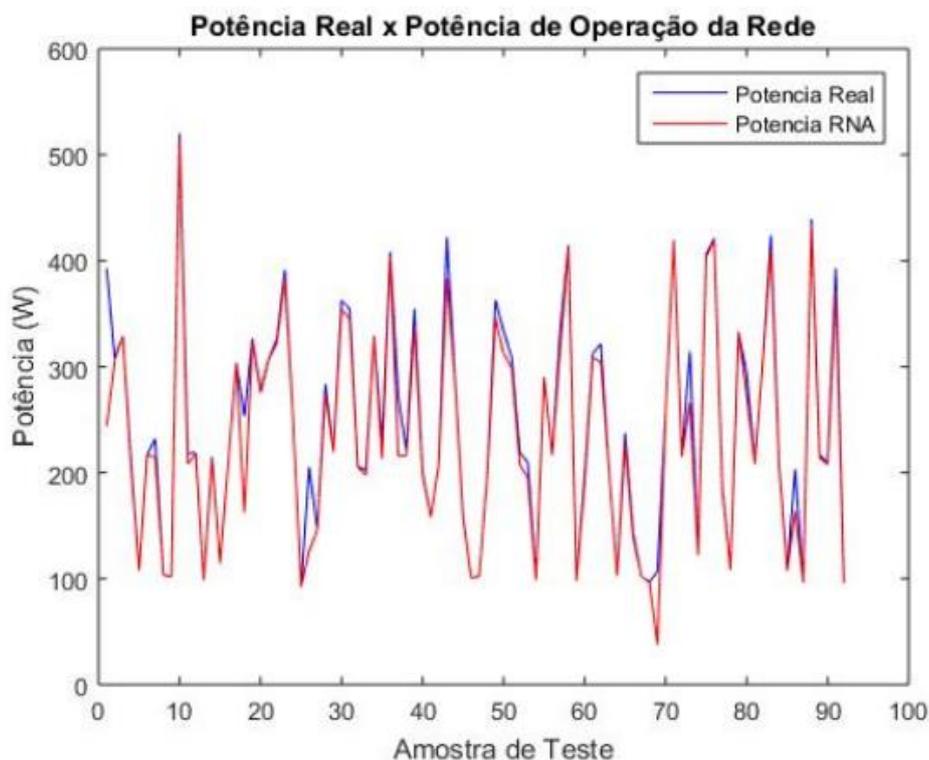
A fim de identificar o ponto de operação de máxima potência em painéis fotovoltaicos em diferentes condições de sombreamento, sendo ele total ou parcial, Gasperacco (2018), também utiliza-se de redes neurais artificiais do tipo MLP. Neste estudo, foram utilizados dados de simulação, gerados a partir de uma plataforma desenvolvida pela ferramenta MatLab.

A configuração adotada para a rede MLP, consiste em 3 entradas, 3 saídas e apenas 2 camadas ocultas contendo 13 neurônios cada. Para aperfeiçoamento da rede, o conjunto de dados utilizado, era composto por um total de 554 amostras para treinamento e 92 para validação, contendo valores referentes a irradiância solar, temperatura e a tensão de circuito aberto do painel, sendo esta, a variável utilizada para determinar o nível de sombreamento naquele instante. A plataforma desenvolvida para aquisição de dados, era composta por apenas dois painéis solares ligados em série e gerando uma potência máxima de 500W.

Gasperacco (2018) destaca que, o número de amostras utilizado se mostrou suficiente para um bom treinamento e desempenho da rede MLP. É importante ressaltar, que o conjunto de dados destinados à validação da rede (92 amostras), não foram usados em nenhum momento durante os treinamentos, apenas para validação.

Para analisar a eficiência da rede, realizou-se uma comparação entre os gráficos plotados a partir dos valores de potência máxima conhecida e dos valores de potência que o sistema entregaria. O erro quadrático médio foi de 0,0037, o que representa um erro médio de 6%. A comparação entre os gráficos, é apresentada na Figura 6.

**Figura 6 – Comparativo entre a potência máxima conhecida e a potência proveniente da rede MLP.**



Fonte: GASPERACCO, Wellington et al (2018)

Neste artigo, o autor utilizou de simulações para aumentar o conjunto de dados para treinamento e testes. Utilizar simulações para gerar dados é uma importante ferramenta visando reduzir o erro da RNA. Observamos resultados nitidamente superiores em relação aos demais artigos já analisados neste trabalho. Para este TCC, será considerada a possibilidade de gerar dados via simulação para o treinamento da RNA.

### **2.2.5 Redes neurais recorrentes e XGBoost aplicados à previsão de radiação solar no horizonte de curto prazo (HEINEN, Eduarth. 2018)**

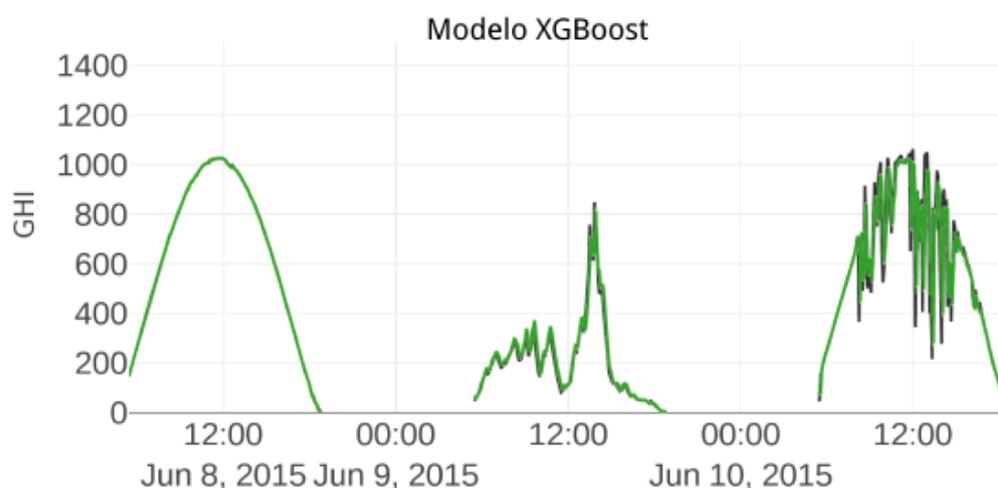
Por fim, o estudo realizado por Heinen (2018) examina o desempenho de modelos baseados em redes neurais recorrentes (RNN) e *Extreme Gradient Boosting* (XGBoost), ambos, quando aplicados em previsões de irradiância solar. As redes RNN, se diferenciam de outras arquiteturas pela sua capacidade de armazenar informações de exemplos anteriores e reproduzir as correlações entre os dados ao longo do tempo. Já o modelo XGBoost, trata-se de um algoritmo de aprendizagem, baseado em árvore de decisão.

Os modelos foram treinados e testados utilizando dados provenientes das cidades de Denver e Las Vegas, publicados pelo *National Renewable Energy Laboratory* (NREL) em 2015. Em seguida, foi empregada a ferramenta Weka, a qual foi responsável por indicar os atributos de maior relevância para a previsão da irradiância solar. Adicionalmente, foram examinados os efeitos da seleção de tais atributos. Como método de avaliação, os resultados obtidos por estes modelos, foram

comparados aos resultados gerados por modelos de persistência dos índices de céu claro e de claridade, desenvolvidos em outras literaturas.

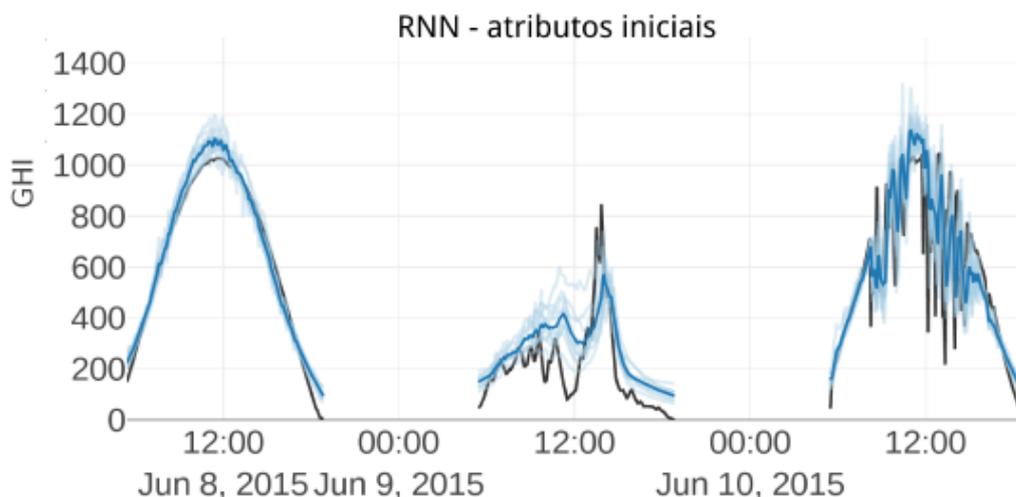
O processo de treinamento ocorreu em duas etapas. Na primeira, foram realizados os treinamentos dos modelos RNN e XGBoost, bem como, suas respectivas validações. Para a segunda, os atributos eleitos como sendo de maior relevância para cumprimento do objetivo, foram separados em um subconjunto e apresentados a um novo modelo RNN-rfe (recursive feature elimination). Este processo não foi aplicado ao XGBoost, pois o mesmo realiza esta tarefa naturalmente. A seguir, os resultados obtidos por cada modelo são comparados aos valores observados (em preto) nas figuras 7, 8 e 9.

**Figura 7 – Estimativa do modelo XGBoost entre os dias 8 e 10 de junho de 2015, comparada à irradiância observada.**



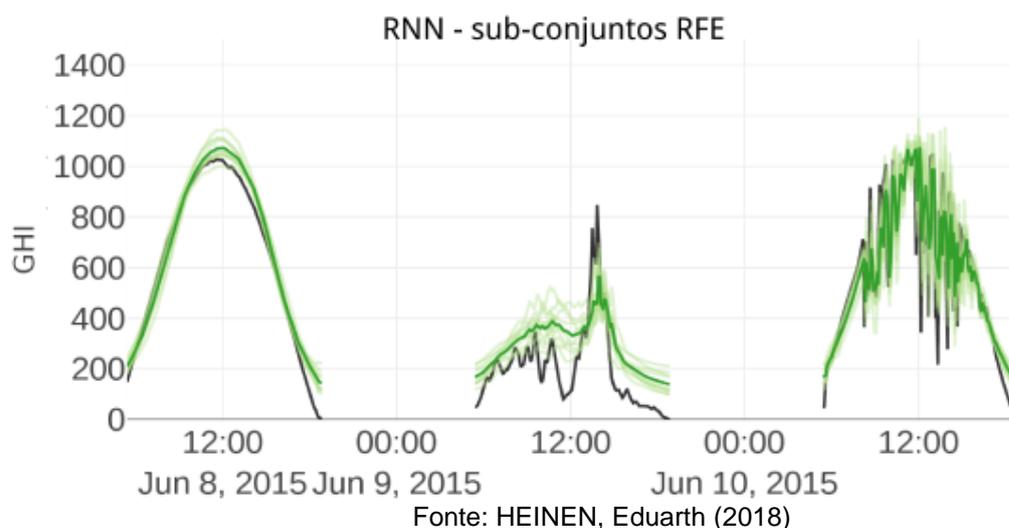
Fonte: HEINEN, Eduarth (2018)

**Figura 8 – Estimativas do modelo RNN entre os dias 8 e 10 de junho de 2015, comparadas à irradiância observada.**



Fonte: HEINEN, Eduarth (2018)

**Figura 9 – Estimativas do modelo RNN-rfe entre os dias 8 e 10 de junho de 2015, comparadas à irradiância observada.**



O autor utilizou RNN, a qual é frequentemente utilizada em análise de dados temporais, apesar dos artigos analisados anteriormente não utilizarem esta técnica. O uso da RNN será considerado neste trabalho de TCC. Já o XGBoost, é um classificador assim como o SVM, utilizado por Campos Filho (2019), contudo, o XGBoost apresentou-se mais adequado para situações não-lineares, como o caso da previsão da irradiância a curto prazo.

### 2.3 Conclusões

Após uma análise criteriosa da bibliografia selecionada, é possível notar o uso predominante de técnicas que exploram a aplicação de redes neurais artificiais para estimativas ou previsão de recursos energéticos, voltados à geração fotovoltaica. Nos estudos realizados por Fiorin (2011) e Gasperacco (2018), são utilizadas RNAs do tipo MLP, em que, mesmo sendo aplicadas em geração fotovoltaica, os estudos descrevem metodologias e aplicações diferentes. No primeiro estudo, a partir de dados provenientes de uma estação solarimétrica, RNAs são treinadas e em seguida aplicadas para estimativa do índice  $K_t$  e do total de irradiância solar global, que por sua vez, apresentou resultados com erros significativos em relação aos valores medidos, sendo assim, a estrutura de rede utilizada pelo autor pode não ser a mais adequada para este trabalho de TCC. Já no segundo estudo, o autor utiliza dados provenientes de simulações para aumentar o conjunto de dados para treinamento e testes, tendo em vista diminuir o erro da RNA e conseqüentemente aumentar sua eficiência. Ao analisar os resultados de ambas as metodologias, a segunda se mostrou nitidamente superior a primeira. Portanto, neste TCC, será considerada a possibilidade de utilizar dados gerados via simulação para treinamento da RNA.

Em contrapartida, ao invés de utilizar RNAs, Campos (2019) e Togawa (2014) utilizam outras ferramentas. No primeiro caso, além de utilizar uma câmera *Vivotek* para captura de imagens do céu, o autor optou por empregar um conjunto de ferramentas desenvolvidas e distribuídas pelo grupo de pesquisa CEG, que por sua vez, alcançou resultados satisfatórios. Já para o segundo, empregou-se a ferramenta SVM, presente na biblioteca de *softwares* LIBSVM, a qual, mesmo utilizando imagens

capturadas a partir de um hardware semelhante ao descrito no estudo anterior (câmera *Vivotek*), não obteve bons resultados em comparação aos valores de irradiação previstos, isto se dá devido ao fato de que não foi considerado o uso de um sistema eletromecânico para bloquear a incidência direta de radiação no sensor, causando sua saturação. Sendo assim, tendo em vista que neste TCC serão utilizadas imagens do céu, será considerado o uso de um aparador durante este processo de aquisição de imagens. Quanto às bibliotecas públicas, o uso destas se mostraram importantes ferramentas que agilizaram e reduziram custos no processo de desenvolvimento dos *softwares*. O uso de bibliotecas será considerado durante o desenvolvimento deste TCC.

Finalmente, o estudo realizado por Heinen (2018), além de utilizar redes neurais do tipo RNN, também explorou o potencial do algoritmo XGBoost, este que, além de ser um classificador como o SVM, também faz parte do conceito de aprendizado de máquina, semelhante às RNAs. Ao analisar os resultados fornecidos pela RNN (Figuras 8 e 9), bem como os resultados gerados pelo XGBoost (Figura 7), é possível notar a superioridade em eficiência do XGBoost, o qual, segundo o autor, além de se apresentar como sendo mais adequado para situações não lineares, também se mostrou mais rápido durante a etapa de treinamento, devido ao seu processo de seleção de atributos de maior relevância para cumprimento do objetivo. Tendo em vista que as RNN são utilizadas frequentemente em análise de dados temporais em outras literaturas, sua aplicação será considerada neste TCC no caso de aplicações em séries temporais.

## 2.4 Fenômenos radiativos na atmosfera terrestre

Considerada como uma das principais fontes de energia do nosso planeta, a radiação eletromagnética proveniente do sol é responsável por diversos fenômenos físicos e químicos, estes que ocorrem tanto na superfície como também na atmosfera da terra. Por menores que sejam as alterações no fluxo de radiação, sendo estas causadas por mudanças climáticas, resultará em mudanças que afetam diretamente as leituras meteorológicas e climáticas realizadas em superfície terrestre (YAMASOE e CORRÊA, 2016). A cobertura de nuvens, por exemplo, desempenha um papel de extrema relevância, quando associada a este fluxo de radiação, tendo em vista sua capacidade de bloquear parcialmente a passagem de luz até a superfície. Segundo DANTAS, CARVALHO e NETO (2010), a radiação solar que atinge a terra, consiste em uma faixa contínua de comprimento de onda ( $\lambda$ ) com valores acima de  $0,15 \mu\text{m}$ , sendo que 99% dessa energia é emitida no intervalo compreendido entre  $0,15$  a  $4,0 \mu\text{m}$ . É comumente utilizado o termo “radiação de onda curta” para se referir a radiação proveniente do sol, isto é, radiação com comprimento de onda inferior a  $4 \mu\text{m}$ . Por outro lado, para a radiação com comprimento de onda superior a  $4 \mu\text{m}$  utiliza-se o termo “radiação de onda longa”.

Todo corpo com temperatura superior ao zero absoluto ( $0 K$ ) emite radiação em diferentes comprimentos de onda possíveis (YAMASOE e CORRÊA, 2016). O termo radiação é definido comumente em livros de física como sendo a propagação ou emissão de energia na forma de ondas eletromagnéticas, ocorrendo por meio de unidades discretas denominadas quanta ou fótons. A energia ( $E$ ) de um fóton pode ser relacionada ao comprimento de onda ( $\lambda$ ) ou com a frequência de oscilação ( $f$ ), por meio da equação:

$$E = hc/\lambda = hf, \quad (1)$$

sendo “ $E$ ” expresso em joules ( $J$ ), “ $h$ ” é a constante de Planck ( $= 6,626 \times 10^{-34} Js$ ) e “ $c$ ” representa a velocidade da luz ( $\cong 2,998 \times 10^8 m/s$  no vácuo). Estas grandezas são indicadas no Sistema Internacional de Unidades (SI).

As regiões que compõem o espectro eletromagnético, podem ser classificadas a partir de seus respectivos intervalos de comprimento de onda. O Quadro 1 apresenta esta classificação para a radiação de onda curta. Considerando o número de processos de transferência de energia radiativa que ocorrem na atmosfera, a região do espectro que corresponde com a maior quantidade de radiação encontra-se na região do ultravioleta ao infravermelho (PEIXOTO e OORT, 1992). A região do espectro que representa a maior quantidade de energia emitida, pertence a região do infravermelho-próximo com 49%, seguido da radiação visível com 43%, o ultravioleta correspondendo com apenas 7% e que menos de 1% da radiação solar é emitida na forma de raios X, raios gama e ondas de rádio (FIORIN, Daniel et al., 2011).

**Quadro 1 – Divisão do espectro eletromagnético em função 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
		Laranja	590 - 610 nm
		Vermelho	610 - 700 nm
Infravermelho (IV)	700 nm - 1000 $\mu m$	IV Próximo (NIR)	0,7 - 1,5 $\mu m$
		IV de onda curta	1,5 - 3,0 $\mu m$

		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: Adaptado de FIORIN, Daniel et al (2011)

Ao atingir a atmosfera terrestre, parte da radiação incidente sofre processos de absorção e espalhamento em seu percurso, no entanto, aproximadamente 25% dessa radiação chega até a superfície sem nenhuma interferência (K. N. Liou, 2002). A radiação restante, como já mencionado, pode ser absorvida ou espalhada para a superfície ou em direção ao espaço. Este processo está ilustrado quantitativamente na Figura 10. Segundo LATORRE et al. (2002) o processo de espalhamento trata-se de um fenômeno físico, o qual um particulado ou molécula de gás, estando no mesmo percurso da onda eletromagnética, absorve de maneira contínua a energia da onda e em seguida a dispersa em todas as direções. O autor ainda destaca que, um dos fatores que exerce influência nas características do espalhamento, está proporcionalmente ligado ao tamanho das moléculas de gás. Portanto, considerando este fator, a seguir, iremos descrever resumidamente dois tipos de espalhamento, o espalhamento Rayleigh e o Mie (segundo a teoria de Lorenz-Mie-Debye).

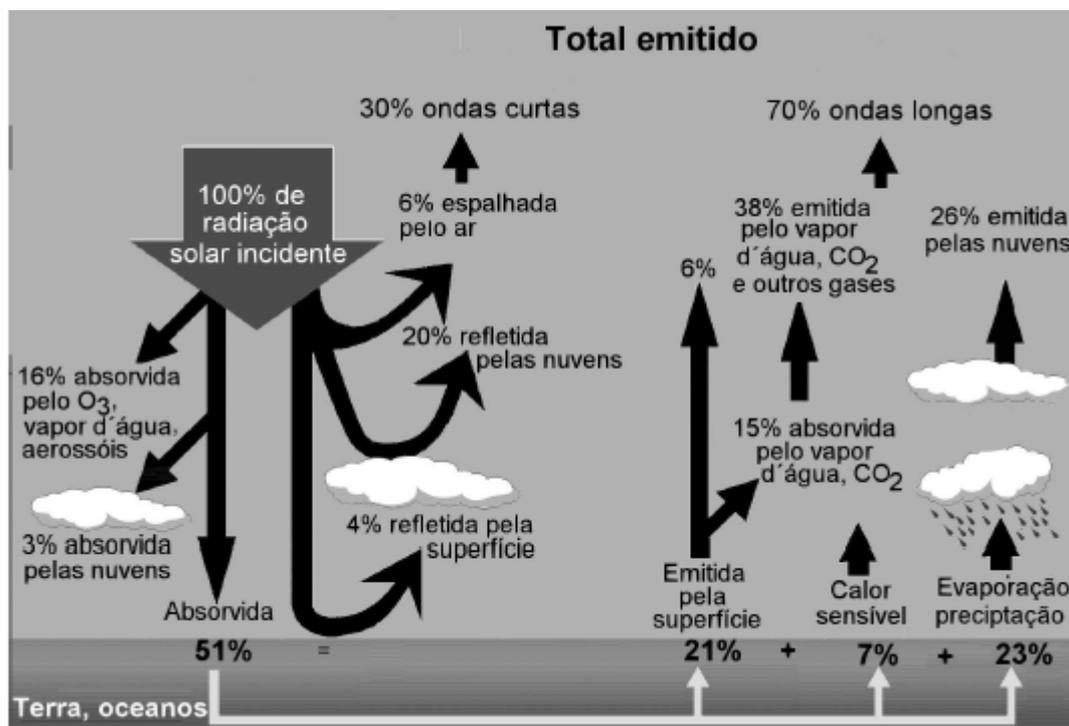
Sendo considerado como uma das primeiras tentativas de descrever com sucesso o espalhamento da luz por pequenas partículas, o espalhamento Rayleigh trata-se de um estudo realizado em 1871 por Lord Rayleigh, o qual descreve uma lei geral para a intensidade da luz espalhada podendo ser aplicável a qualquer partícula com índice de refração diferente daquele do meio o qual a partícula se encontra. Um dos resultados mais relevantes obtido por meio deste estudo trata da descoberta da dependência da intensidade do espalhamento em função do comprimento de onda e do tamanho das moléculas.

No espalhamento Rayleigh, a radiação solar é espalhada por moléculas de dimensões menores do que o seu comprimento de onda e o espalhamento é inversamente proporcional à 4ª potência do comprimento de onda ( $\lambda^4$ ) de acordo com a Equação 2, a qual é responsável por indicar a intensidade ( $I$ ) da luz espalhada (KRAPAS e SANTOS, 2002). Este caso, o qual diz respeito ao espalhamento que ocorre para a luz visível, também é um dos responsáveis pela cor azul do céu.

$$I = k \frac{1}{\lambda^4}, \quad (2)$$

onde ( $k$ ) é uma constante de proporcionalidade.

**Figura 10 – Representação ilustrativa dos processos que ocorrem na atmosfera.**



Fonte: FIORIN, Daniel et al (2011)

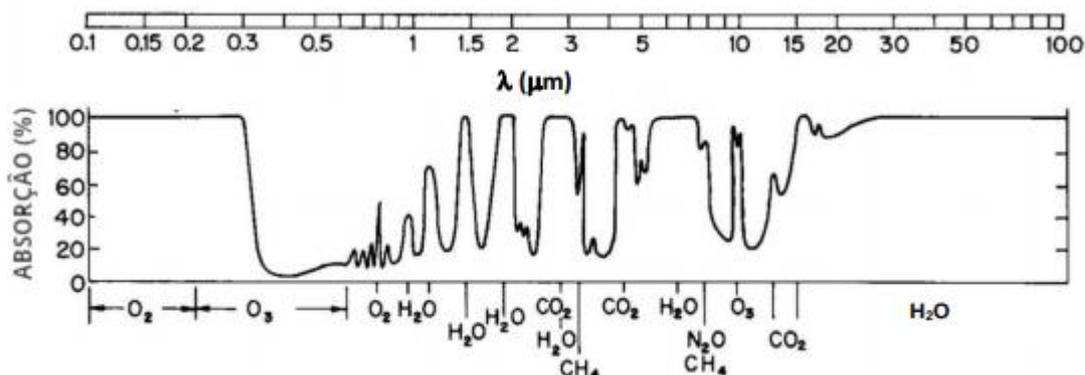
Já o espalhamento Mie, este que foi descrito analiticamente pelo físico Gustav Mie em 1908, trata de um estudo que explica como as ondas eletromagnéticas, provenientes do sol, interagem com partículas de dimensões muito próximas ou superiores ao comprimento de onda da radiação incidente (YAMASOE e CORRÊA, 2016). Em geral, esta interação ocorre com maior frequência em partículas de aerossol, água e nuvens. Por meio do espalhamento Mie, é possível entender as características e processos responsáveis pela tonalidade branca das nuvens e nevoeiros.

Conforme discutido anteriormente, em ambos os tipos de espalhamento existe uma forte dependência espectral em termos de comprimento de onda para a intensidade do espalhamento. Dito isto, para o espalhamento Mie esta dependência acaba sendo cada vez menor à medida que este fenômeno ocorre em partículas de dimensões maiores em relação ao comprimento de onda da radiação incidente. Desta forma, o espalhamento passa a ter uma maior dependência da capacidade de absorção e emissão da partícula.

Ao comparar o espectro solar presente no topo da atmosfera com o espectro solar na superfície terrestre, Amorim (2015) afirma que é possível notar uma diminuição da energia incidente na superfície em alguns comprimentos de onda, devido a presença de constituintes atmosféricos responsáveis pela absorção da radiação em seu caminho. Este processo é mais frequente na presença de determinados gases, estes classificados como absorvedores. O oxigênio ( $O_2$ ) e o ozônio ( $O_3$ ) por exemplo, são capazes de absorver praticamente toda a radiação solar de comprimento de onda inferior a  $3 \mu m$ , porém o ozônio também é capaz de absorver na região do espectro visível. Por outro lado, o dióxido de carbono ( $CO_2$ ) e o vapor de água ( $H_2O$ ) afetam principalmente a radiação na região do infravermelho.

Define-se como sendo “janelas atmosféricas”, as regiões do espectro onde não há processos de absorção por parte dos constituintes atmosféricos. A Figura 11 ilustra graficamente os níveis de absorção em função do comprimento de onda de cada componente citado anteriormente, com destaque para o intervalo compreendido entre 0,3 a 0,8  $\mu\text{m}$  no qual quase toda a radiação não é absorvida. Estes valores correspondem a uma altitude compreendida entre o topo da atmosfera indo até o nível do mar.

**Figura 11 – Percentual de absorção atmosférica de radiação para comprimentos de onda entre 0,1 a 100  $\mu\text{m}$ .**



Fonte: Adaptado de AMORIM, Bruna (2015)

Como já mencionado neste texto, o termo “fluxo radiante” é comumente definido na literatura científica como sendo a taxa de transferência de energia, podendo ser expresso em Joules por segundo ( $J/s$ ) ou Watts ( $W$ ). Já a “densidade de fluxo radiante” (irradiância), que representa o fluxo radiante por unidade de área, pode ser expresso em Watts por metro quadrado ( $W/m^2$ ).

O valor referente a média anual de irradiância total incidente no topo da atmosfera em um plano perpendicular a direção da radiação, pode ser denominado como constante solar ( $I_{CS}$ ). Este valor é aproximadamente  $1360 W/m^2$ , porém, devido aos movimentos de rotação realizados pela terra, este valor sofre várias alterações ao longo do ano em função da distância terra-sol e do ângulo zenital solar ( $z$ ) (TOGAWA, André, 2014). Podemos definir o ângulo zenital solar, como sendo o ângulo formado entre o zênite local e uma linha imaginária, traçada a partir da superfície horizontal até o sol. Define-se como zênite local, o ponto no espaço no qual forma-se um ângulo de  $90^\circ$  com a superfície terrestre.

Os valores instantâneos da irradiação solar incidente no topo da atmosfera ( $I_0$ ), podem ser calculados por métodos matemáticos, como indicado na Equação 3 (FIORIN, Daniel et al, 2011).

$$I_0 = I_{CS} \cdot E_0 \cdot \cos \theta_z \quad (3)$$

Em que ( $E_0$ ) é o fator de correção da excentricidade da órbita da terra, responsável pela correção da distância terra-sol, que varia ao longo do ano. O valor total diário da irradiância solar incidente no topo da atmosfera ( $H_0$ ) pode ser determinado a partir da equação 4.

$$H_0 = \frac{I_{CS}}{\pi} E_0 [h_0 \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(h_0)] \quad (4)$$

Sendo ( $\varphi$ ) a latitude do local na superfície terrestre, ( $\delta$ ) a declinação solar, ou seja, corresponde ao ângulo formado entre o equador terrestre e a linha imaginária traçada até o astro de interesse e ( $h_0$ ) corresponde ao ângulo horário, obtido a partir de:

$$h_0 = (\text{hora} - 12) \cdot 15. \quad (5)$$

A seguir, para maior compreensão do leitor, serão definidos alguns termos técnicos bastante utilizados na literatura e que podem complementar o entendimento deste trabalho:

- **Irradiância direta:** consiste na irradiância incidente em um local com elemento de superfície perpendicular ao raio incidente e que não sofreu nenhum processo radiativo na atmosfera, ou seja, que não sofreu espalhamento.
- **Irradiância difusa:** refere-se a irradiância proveniente do espalhamento por nuvens ou moléculas presentes na atmosfera.
- **Irradiância global:** refere-se ao total de irradiância incidente em uma determinada superfície, isto é, representa a soma entre a irradiância direta e difusa. Este valor total é comumente utilizado para geração fotovoltaica.
- **Irradiância direta normal:** refere-se a parcela de irradiância solar proveniente diretamente do sol com uma incidência que seja normal à superfície e, portanto, está diretamente ligada ao ângulo zenital e inclinação da superfície horizontal.
- **Irradiância atmosférica:** consiste na irradiância de onda longa emitida a partir de camadas atmosféricas que estão acima do plano de observação.
- **Índice de transmissividade ( $K_t$ ):** este valor, pode ser definido como sendo a razão entre a irradiância solar global incidente na superfície ( $I$ ) e a irradiância solar no topo da atmosfera ( $I_0$ ), como indicado na Equação 6.

$$K_t = \frac{I}{I_0} \quad (6)$$

## 2.5 Interações entre radiação solar e a cobertura de nuvens

De maneira geral, as nuvens desempenham um papel de extrema relevância frente aos processos radiativos ocorrentes na atmosfera, isto é, exercendo grande influência na transmitância da radiação solar. Porém, esta interação com a radiação pode ser considerada complexa, já que a mesma varia com as características das nuvens, as quais podemos citar: densidade, quantidade, forma, tipo e composição. Em alguns instantes, a reflexão que ocorre pelas laterais das nuvens pode ocasionar valores de irradiância maiores do que em casos de céu limpo (MOOJEN, CAVALCANTE, MENDES, 2012). Define-se albedo ou coeficiente de reflexão como sendo a capacidade de reflexão de uma determinada superfície quando atingida por qualquer tipo de radiação. Apesar do tipo de reflexão mencionado anteriormente, os topos das nuvens apresentam-se como sendo os maiores refletores de radiação da atmosfera, tendo seu albedo variando para menores valores entre nuvens finas e maiores valores para nuvens mais densas (FIORIN, Daniel et al, 2011). Aliado a isso, quanto maior a quantidade de água (gotículas ou gelo) presente na composição da nuvem, maior será a ocorrência do espalhamento Mie (albedo) e, conseqüentemente, menor será a incidência direta de irradiação solar na superfície.

## 2.6 Conclusões

Em ambos os tipos de espalhamento, Rayleigh e Mie, existe uma forte dependência espectral em termos de comprimento de onda para a intensidade do espalhamento. Adicionalmente, o espectro da radiação solar varia de acordo com a composição da atmosfera, sobretudo em relação à presença de H<sub>2</sub>O, CO<sub>2</sub>, O<sub>2</sub> e O<sub>3</sub>, o qual impactará diretamente na capacidade de geração de energia fotovoltaica. Tais comportamentos da radiação eletromagnética dificultam a estimativa da irradiância solar. Apesar de relevante, a cobertura de nuvens representa a principal fonte de erro nas estimativas obtidas por meio de previsões baseadas em modelos matemáticos da irradiância solar no topo da atmosfera, conforme a Equação 3.

Considerando o exposto, o grupo de pesquisas em energias renováveis do IFPE Campus Pesqueira optou por utilizar um equipamento que captura imagens do Céu para realizar estimativas e previsões de curto prazo da irradiância solar. Este equipamento é denominado *Total Sky Imager* (TSI) e está atualmente em desenvolvimento através deste trabalho de TCC, além de outros trabalhos PIBIC.

## 2.7 Redes Neurais Artificiais (RNAs)

Tendo sua origem inspirada nos neurônios reais, as RNAs são classificadas como sendo um sistema computacional de processamento de informações, o qual consiste em um grupo interconectado de neurônios artificiais distribuídos e organizados em diferentes camadas (GUARNIERI, Ricardo et al., 2007). Tendo uma grande capacidade de aprendizagem, as RNAs são aptas a compreender as complexas relações não lineares entre os dados de entrada e os dados de saída.

Em geral, o processo de aprendizagem das RNAs se assemelham ao realizado pelo cérebro humano em duas formas: (i) o conhecimento é adquirido através de um processo de aprendizagem, o qual a rede é submetida a um conjunto de amostras contendo diferentes graus de relação com a resposta desejada e (ii) à medida que o processo de aprendizagem ou treinamento acontece, todo o conhecimento adquirido é armazenado nos pesos sinápticos, os quais são ajustados no decorrer dos processos a fim de obter uma melhor resposta da RNA (FLECK, Leandro et al. 2016).

Podendo lidar com problemas de diferentes níveis de complexidade, as RNA possuem aplicações que variam nas diversas áreas do conhecimento, com destaque para reconhecimento de padrões, previsão, estimativas de recursos energéticos e entre outras aplicações.

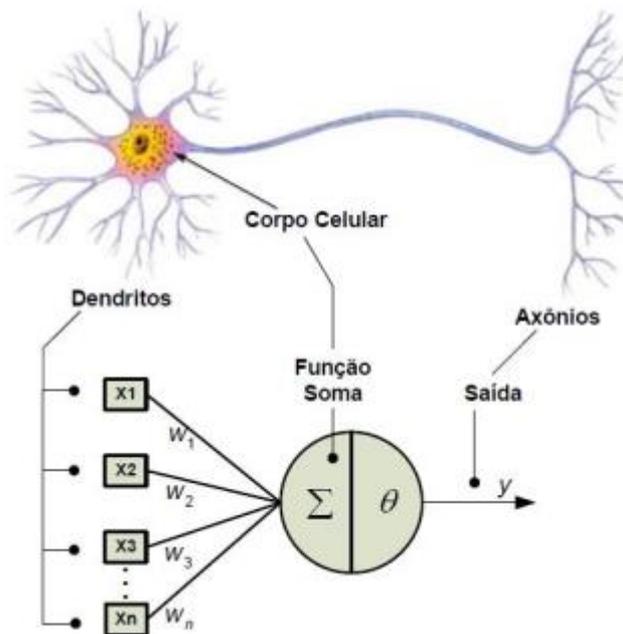
## 2.8 Neurônio artificial

Como já mencionado anteriormente, em se tratando de aprendizagem, as RNAs tentam reproduzir o comportamento desempenhado pelos neurônios reais. Na Figura 12, pode-se observar a semelhança de um neurônio biológico com um neurônio artificial, o qual possui conexões de entrada ( $X_1, X_2, \dots, X_n$ ) semelhantes aos dendritos biológicos, a função soma ( $\Sigma$ ) representa o corpo celular e por último, temos os sinais de saída ( $y$ ) do neurônio artificial que equivalem aos axônios, responsáveis por fornecer a informação processada pelo neurônio como um todo.

No neurônio artificial, ainda temos o conjunto de pesos sinápticos ( $W_1, W_2, \dots, W_n$ ) responsáveis por ponderar as variáveis de entrada, ou seja,

possuem a capacidade de excitar ou inibir os sinais de entrada (HEINEN, Eduarth, 2018). A princípio, os pesos são gerados com valores aleatórios, os quais são ajustados à medida que os treinamentos da RNA são realizados.

**Figura 12 – Comparativo entre neurônio biológico e artificial.**



Fonte: BON, Frederico (2020)

Dito isto, a saída de um neurônio pode ser composta pela multiplicação das inúmeras entradas pelos seus respectivos pesos sinápticos, que posteriormente são somados e levados até uma determinada função de ativação ( $g$ ) (BON, Frederico, 2020). Esta operação é descrita matematicamente pela Equação 7.

$$y = g(\sum_{i=1}^n W_i \cdot x_i - \theta) \quad (7)$$

O termo " $\theta$ " é denominado bias ou limiar de ativação. Durante o processo de treinamento da RNA, os pesos sinápticos e limiares de ativação devem se ajustar durante os processos de aprendizagem, desta forma havendo aprendizagem por parte da rede (SEVERO, Luana, 2019). Em termos gerais, o potencial de ativação de um neurônio está diretamente ligado à função de ativação, que neste caso, possui diversos modelos aplicáveis a inúmeros problemas. De acordo com Faria (2014), uma das funções de ativação mais utilizadas em RNAs diz respeito à função sigmoide, a qual consiste em uma função monótona crescente, com propriedades assintóticas.

## 2.9 Arquitetura das RNAs

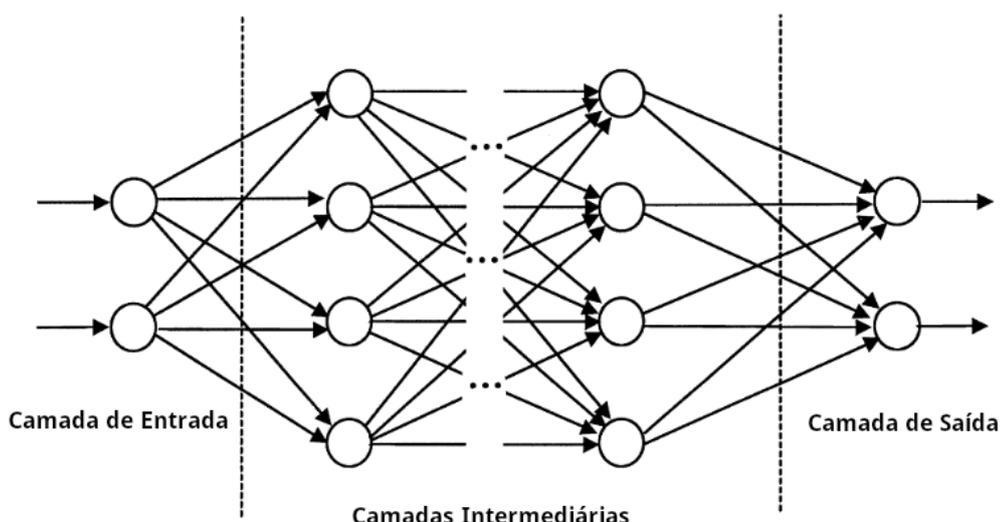
Em termos quantitativos, enquanto uma rede neural biológica é composta por bilhões de neurônios em funcionamento, o número de neurônios artificiais presentes em uma arquitetura de RNA, pode variar entre dezenas e centenas. Este valor varia de acordo com a complexidade do problema envolvido e do tipo de arquitetura empregado durante o desenvolvimento da rede.

Basicamente, a arquitetura de uma RNA é constituída de uma camada de entrada, uma camada intermediária, esta podendo ou não existir, e uma camada de saída (REMES, Chrystian, 2013), em que:

- **Camada de entrada:** é a camada onde os dados são inseridos e posteriormente processados pela rede. Esta camada pode ser composta por neurônios ou por apenas conexões de entrada.
- **Camada intermediária:** sendo composta por um número arbitrário de neurônios, esta camada é responsável por processar e armazenar todo o conhecimento acumulado durante os processos. Dependendo do tipo de topologia escolhida, esta camada pode ser subdividida em várias subcamadas.
- **Camada de saída:** consiste na camada onde é obtida a resposta da RNA. Dependendo da arquitetura escolhida, esta camada pode ser constituída de neurônios ou de apenas conexões de saída.

As RNAs podem ser criadas seguindo diferentes tipos de arquitetura, nas quais será definido o número de camadas internas, número de neurônios, a função de ativação, tipo de treinamento, entre outros aspectos. Em relação ao número de camadas, existe a possibilidade de desenvolver redes em que a camada intermediária possui apenas um neurônio, sendo esta apta a lidar com problemas específicos e de menor complexidade (HAYKIN, Simon, 2001). Por outro lado, redes neurais de múltiplas camadas possibilitam a existência de inúmeros neurônios entre a entrada e saída da RNA, como ilustrado na Figura 13.

**Figura 13 – Arquitetura de RNA com múltiplas camadas intermediárias.**



Fonte: Adaptado de SANTOS, Bruno (2010)

Dentre as diversas possibilidades de arquitetura disponíveis para estudo e implementação, podemos destacar dois tipos: redes *feedforward* e redes recorrentes (RNN).

Na arquitetura *feedforward* por exemplo, sua estrutura pode ser definida em camadas simples ou em camadas múltiplas, este último se referindo ao tipo MLP, o qual já foi mencionado neste texto. Nesta topologia, os neurônios são conectados única e exclusivamente a camada seguinte, ou seja, a informação percorre a rede seguindo uma única direção, indo da camada de entrada, passando pelas camadas intermediárias e por fim, indo até a camada de saída, este processo é realizado apenas em uma única vez (SANTOS, Bruno, 2010).

Já a arquitetura recorrente ou realimentada, consiste em uma rede em que as saídas dos neurônios são utilizadas como sinais de entrada para outros neurônios e desta forma, funcionando como uma memória de curto prazo (HEINEN, Eduarth, 2018). Durante a fase de treinamento, além de elaborar respostas adequadas aos dados de entrada, este tipo de rede produz um mapeamento das relações temporais através da sequência de exemplos a ela fornecidos. Identificar tais relacionamentos requer que durante o aprendizado seja ajustado não somente os pesos sinápticos em proporção ao erro atual, mas também ao erro nas estimativas obtidas anteriormente.

## 2.10 Aprendizagem das RNAs

Durante a etapa de aprendizagem ou treinamento da RNA, os pesos sinápticos são ajustados à medida que interagem com os dados de entrada, este processo é realizado até que se extraia as características suficientes para representação do problema de forma satisfatória. Como já mencionado neste texto, os valores representativos de cada peso, são gerados aleatoriamente e desta forma, a medida que a RNA executar os treinamentos, esses pesos são ajustados e fixados a fim de gerar novas respostas, conseqüentemente alcançando respostas mais precisas por parte da RNA.

Segundo Santos (2010), os treinamentos podem ser classificados em dois tipos, “supervisionados” e “não supervisionados”. No primeiro, são apresentados à rede dados de entrada e dados de saída desejados (valores alvo). Com isso, a rede passa a calcular as saídas resultantes das entradas, comparando-as com os valores alvos. Este processo pode ser realizado a cada interação, isto é, quando o treinamento é sequencial, ou ao final da apresentação de todo o conjunto de dados, este sendo denominado de treinamento por lote. Este tipo de treinamento é comumente utilizado em estudos que possuem a finalidade de previsão ou estimativa de recursos energéticos solares e conseqüentemente será o modelo empregado neste trabalho de TCC.

Já no treinamento não supervisionado, apenas são fornecidos à rede dados de entrada que, após o ajuste dos pesos sinápticos, são organizados e agrupados em diferentes classes de acordo com suas características (LOPES, José, 2010). Este tipo de treinamento tem a finalidade de classificação dos dados a partir do reconhecimento de padrões, isto é, detecção de características em comum entre as amostras fornecidas à RNA. Dito isto, este tipo de treinamento não será empregado neste trabalho de TCC.

## 3 METODOLOGIA

Tendo em vista as diversas abordagens com equipamentos muitas vezes de alto custo (*Total Sky Imager*) ou de difícil acesso (estações solarimétricas), este trabalho segue uma orientação voltada ao cumprimento dos objetivos dentro da melhor relação custo/benefício. A metodologia aqui apresentada levou em consideração a utilização de equipamentos com baixo custo de aquisição e de equipamentos e *softwares* fornecidos pela própria instituição IFPE- Campus Pesqueira.

Nesta seção, será apresentada a metodologia proposta, onde será discutido a coleta de dados e o desenvolvimento de uma RNA com foco em estimativa de iluminância em uma determinada área, a fim de obter valores que possam nos levar a

índices de irradiação solar. Inicialmente será apresentado uma breve descrição da (i) coleta de dados (captura de imagens), em seguida o (ii) processamento de imagens e, por fim, (iii) o desenvolvimento de diferentes configurações para a RNA.

### 3.1 Coleta de dados

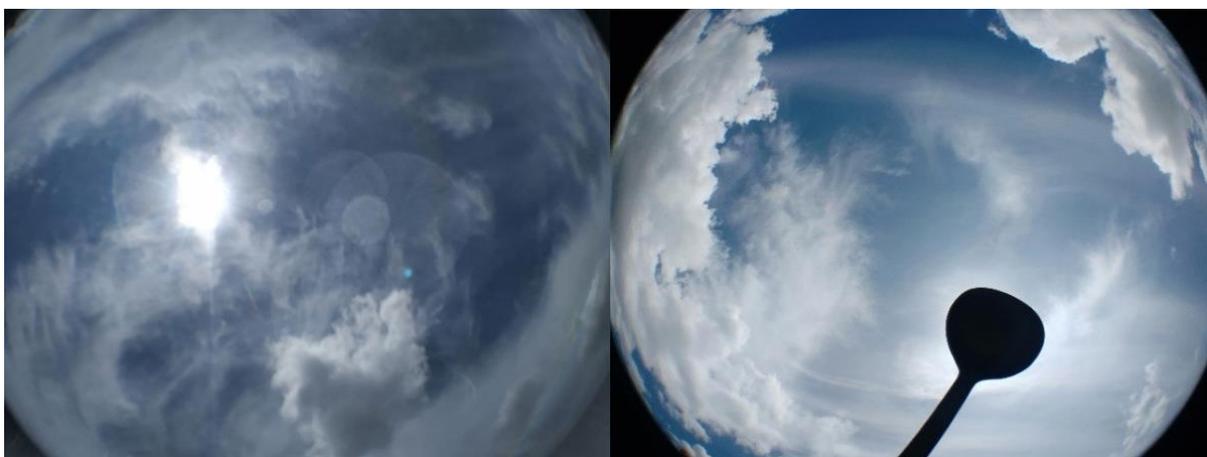
Considerando a necessidade de uma base de dados suficiente (contendo informações de entrada e de saída) para treinamento e validação da RNA, a etapa inicial desta metodologia consiste na coleta de dados. Para cumprimento desta tarefa, desenvolvemos nossa própria metodologia de aquisição de dados, a qual consistia em obter várias imagens do céu ao longo do dia. A partir das imagens adquiridas, foram extraídas as características que formam o conjunto de dados de entrada da RNA. As imagens foram adquiridas entre as 6h da manhã com término às 17h da tarde. Esta etapa do processo foi realizada de forma manual e periódica, isto é, as imagens foram obtidas manualmente a cada 15 minutos sem nenhum tipo de equipamento automatizado. O processo de coleta de dados ocorreu nos dias 7 de abril e 2 de julho de 2019.

Como ferramenta de aquisição de imagens, utilizou-se de uma lente “olho de peixe” de baixo custo acoplada a um *smartphone*. Note que, o uso de uma lente deste tipo, permite a ampliação do campo de visão da câmera, porém, causando distorções na imagem. A remoção desta distorção inserida por tal lente, trata-se de objeto de pesquisa de outro TCC, sendo assim não será implementado neste trabalho.

Durante a aquisição das imagens, notou-se que, para ocasiões com radiação solar direta (sem nenhuma oclusão por parte da cobertura de nuvens sobre ele) era necessário utilizar um aparador para bloquear a incidência de tal radiação direta, pois, sem o auxílio desse aparador, muita luz incidia diretamente no sensor da câmera, gerando saturação na parte do sensor referente a posição do sol, dificultando a distinção entre o sol e uma nuvem clara. Adicionalmente, no caso da lente suja ou lentes com impurezas na fabricação, há um efeito significativo da difração da luz referente a radiação direta, tendo como consequência distorções na imagem e redução na precisão do sistema.

A aplicação do aparador é ilustrada na Figura 14. A partir da bibliografia estudada, o uso de tal aparato já foi observado em outras metodologias e em todos os equipamentos TSI comerciais.

**Figura 14 – Imagens capturadas sem e com o uso do aparador.**



Fonte: Próprio autor.

Ao final desta etapa de coleta de dados, foram adquiridas um total de 83 imagens, sendo 38 obtidas no primeiro dia (7 de abril de 2019) e 45 obtidas no segundo dia (2 de julho de 2019).

Juntamente com a lente e o *smartphone*, também foi empregado o uso de um luxímetro, este responsável por nos fornecer medidas de intensidade luminosa no momento em que cada imagem era registrada. As intensidades luminosas formam o conjunto de dados de saída da RNA, utilizado para treinamento e validação da rede. O luxímetro e a lente “olho de peixe” são apresentados na Figura 15.

**Figura 15 – Luxímetro e lente olho de peixe.**



Fonte: Próprio autor.

Comercialmente, existem aparelhos cuja finalidade é realizar leituras diárias referentes à irradiância solar. Dentre estes aparelhos, por exemplo, podemos citar o piranômetro, comumente utilizado em estações solarimétricas. Mesmo tendo conhecimento de tal aparelho, sua utilização torna-se inviável para realização deste trabalho, devido a seu alto custo de aquisição, bem como a necessidade de outros equipamentos para armazenamento e posteriormente consulta dos dados coletados, já que o piranômetro não possui estas funcionalidades nativamente. Sendo assim, apesar de não fornecer diretamente valores de irradiância solar, optamos por utilizar um luxímetro levando em consideração o fato deste aparelho nos fornecer de maneira prática e objetiva, dados (*lux*) capazes de nos levar a índices de irradiância solar. Além disso, este aparelho foi cedido pelo IFPE - Campus Pesqueira e, desta forma, evitando custos em aquisição. Um estudo realizado por Michael (2019) aponta que em se tratando de converter valores de lux em índices de irradiância, a literatura científica não apresenta nenhum método padronizado e que ainda são encontrados em fontes da internet valores conflitantes. Porém, em seu estudo, o autor estabelece um guia teórico e laboratorial de conversão, no qual é apresentado um fator de conversão em que  $1000 W/m^2$  equivalem a aproximadamente  $120000 lux$ .

Considerando que  $1 \text{ lux} = 1 \text{ lm/m}^2$  (lúmen/metro quadrado) e que irradiância é dada em  $W/m^2$ , temos que:

$$\frac{1000 \text{ W/m}^2}{120000 \text{ lm/m}^2} \approx 0,0083 \text{ W/lm}$$

$$\therefore (0,0083 \text{ W/lm}) \cdot 1 \text{ lm/m}^2 \approx 0,0083 \text{ W/m}^2$$

### 3.2 Processamento e extração de dados das imagens

Tendo em vista que cada imagem adquirida durante o processo descrito anteriormente, juntamente com os dados do luxímetro, possuem informações relevantes para o treinamento da RNA, optamos por utilizar um algoritmo de processamento de imagens, este sendo plenamente capaz de extrair tais informações. Este algoritmo foi desenvolvido durante um dos trabalhos PIBIC do IFPE - Campus Pesqueira, e utiliza uma *toolbox* da ferramenta computacional MatLab.

A princípio este algoritmo era capaz apenas de diferenciar nuvem de céu, segmentar as nuvens (indicando com retângulos em seu entorno) e marcar o seu centro de massa (indicando com um ponto). Porém, para a realização do nosso trabalho, decidimos avançar no desenvolvimento do algoritmo de processamento de imagens e extrair mais informações, tais como a identificação das nuvens, seleção das 3 maiores, distância entre os centros de massa das nuvens e o centro de massa do sol. A ideia é selecionar as características que facilitam o trabalho de treinamento da RNA. Desta forma, com o auxílio do luxímetro e os ajustes realizados no algoritmo de processamento de imagens, fomos capazes de extrair informações referentes a:

- **Intensidade da Luz (Lux)**

Conforme visto na seção anterior, a intensidade da luz está diretamente relacionada com a irradiância solar e será a referência utilizada para treinamento e validação da RNA.

- **Horário da captura da imagem**

A irradiância solar extraterrestre é conhecida, e depende do horário, conforme visto na seção 2.

- **Tempo de exposição do sensor da câmera do *smartphone***

A câmera fotográfica, através do fotômetro interno, ajusta o tempo de exposição do obturador visando equalizar a intensidade capturada em cada pixel. Quanto maior o tempo de exposição, mais luz entra e incide sobre o sensor da câmera, e mais “clara” será a imagem. Portanto, o tempo de exposição está diretamente relacionado com a irradiância solar.

- **Destaque das três maiores nuvens**

Excesso de informações nas entradas de uma rede neural pode causar dificuldades no treinamento da rede ou necessidade de um conjunto de testes muito mais amplo em relação ao conjunto que dispomos nesta pesquisa. Portanto, visando reduzir o conjunto de informações para aplicação na RNA, selecionamos as três maiores nuvens presentes na imagem uma vez que estas representam, em geral, maior impacto nos pesos da RNA. Por meio do algoritmo de processamento de imagem, o qual também nos permite ter um levantamento total do número “n” de nuvens presente em cada imagem

capturada, foram atribuídos valores (1, 2, 3, 4, ..., n) representativos para cada nuvem ali presente. Desta forma, ao solicitar a indicação das três maiores nuvens por meio do algoritmo, três números são exibidos no MatLab, indicando numericamente quais as maiores nuvens dentre as presentes na imagem em questão.

- **Distância das três maiores nuvens em relação ao sol**

Neste caso, poderíamos definir como características as posições absolutas das nuvens, em um sistema de coordenadas cartesianas. Contudo, o conjunto de dados necessários para treinamento da rede seria proibitivo neste trabalho de TCC uma vez que quanto mais linear a relação entre a característica e a saída do sistema, mais fácil será o treinamento da RNA. Portanto, observamos que a distância entre o centro de massa das nuvens e o centro de massa do sol apresenta uma relação mais adequada para o treinamento da RNA porque representa melhor a cobertura de nuvens sob o sol.

- **Tamanho das três maiores nuvens, baseado na densidade de pixels**

Assim como no item anterior, o tamanho da nuvem tem relação direta com a capacidade de absorção da radiação solar e, conseqüentemente, com a irradiância solar.

- **Condição atmosférica**

Ainda visando facilitar o treinamento da RNA, foi estabelecida uma escala para indicar a cobertura de nuvens, em que para um céu nublado atribuímos o valor (1), para parcialmente nublado atribuímos (2), quase que totalmente limpo (3) e para um totalmente sem nuvens (4). Assim como no item anterior, a cobertura de nuvens tem relação com a irradiância solar.

Para calcular a distância entre o centro de massa das nuvens e do sol, é necessário obter as coordenadas destes centros de massa. Como não é foco deste TCC a automatização do processamento de imagens, a obtenção do centro de massa do sol foi realizada “manualmente”, visto que este algoritmo ainda não foi desenvolvido em outro TCC. Esta será a primeira etapa a ser detalhada. A Figura 16 destaca a marcação da posição em que o sol estava na imagem.

Também classificamos “manualmente” a condição atmosférica no momento da aquisição da foto, conforme já citado. Esta classificação foi realizada de acordo com a percepção visual do estudante, sem uso de nenhum algoritmo de classificação. Contudo, há previsão da elaboração deste algoritmo em outro TCC.

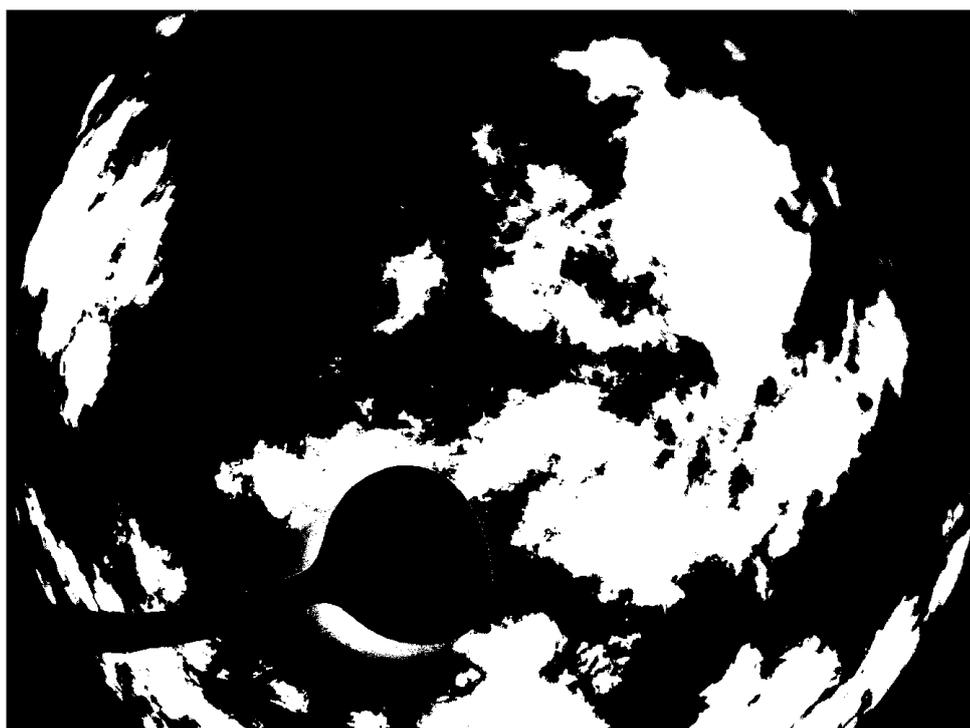
**Figura 16 – Imagem com a posição do sol destacada em vermelho. Nesta imagem foi atribuída a classificação de “parcialmente nublado”.**



Fonte: Próprio autor.

Feito isso, demos início a primeira etapa do processamento das imagens, em que distinguimos o que é nuvem e o que é céu. Esta etapa tem como finalidade separar a imagem em duas regiões. Neste caso, apenas por uma questão estética, destacamos as nuvens na cor branca e o que não fosse nuvem na cor preta. Esta segmentação pode ser vista na Figura 17.

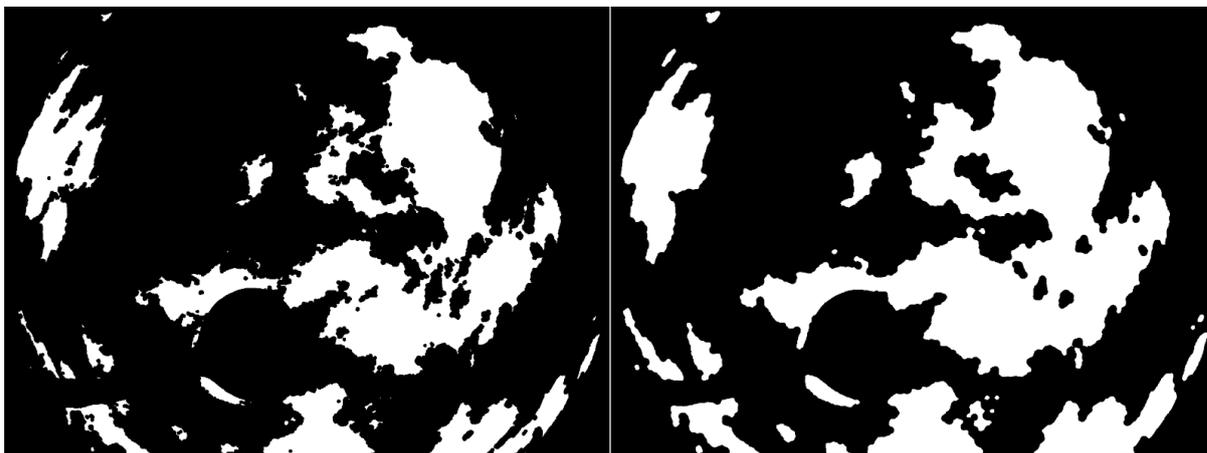
**Figura 17 – Segmentação da Imagem.**



Fonte: Próprio autor.

Na sequência, aplicamos um algoritmo de morfologia matemática, capaz de remover irregularidades nas bordas das nuvens, preenchendo pequenos buracos e removendo pequenas nuvens, estas consideradas de menor relevância quando comparadas às nuvens de dimensões muito maiores. Estes ajustes podem ser vistos na Figura 18.

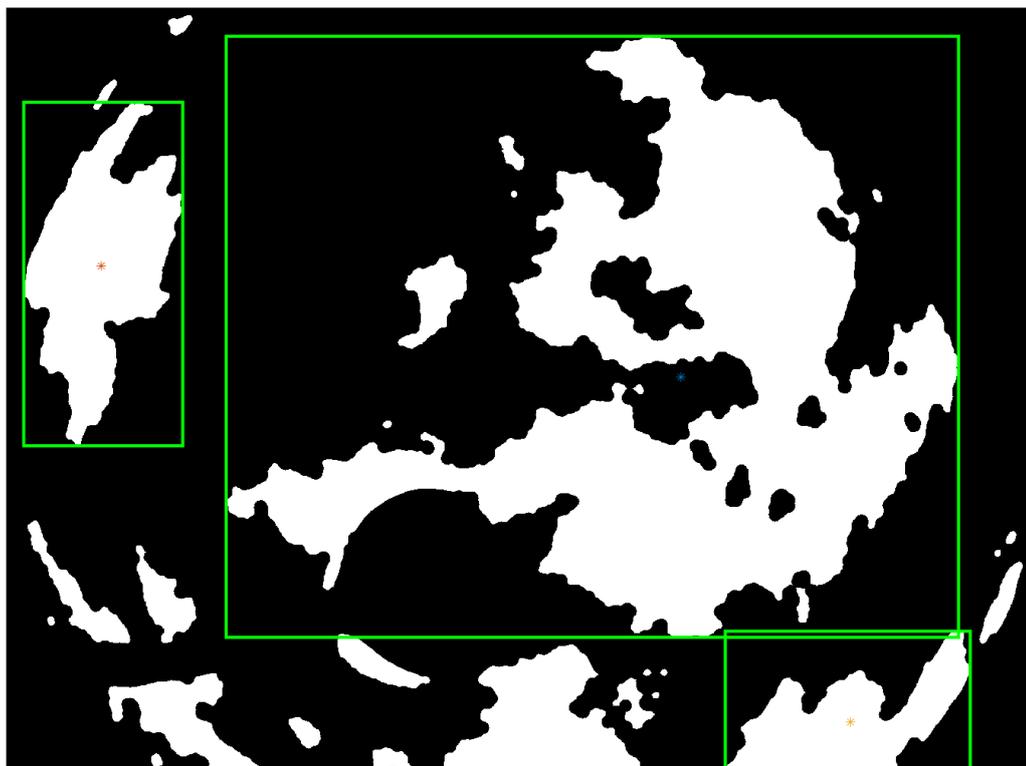
**Figura 18 – Aplicação do algoritmo de morfologia matemática.**



Fonte: Próprio autor.

Para finalizar o processamento das imagens, calculamos o centro de massa das nuvens e suas dimensões. Porém, optamos por calcular apenas para as três maiores nuvens. Esta etapa do processamento é representada na Figura 19, entretanto, os valores referentes às dimensões das nuvens destacadas, são exibidos diretamente no próprio MatLab. Como mencionado anteriormente, a decisão envolvendo a escolha das três maiores nuvens, foi devido ao fato de que são essas nuvens que geram um maior impacto na irradiância de uma determinada área.

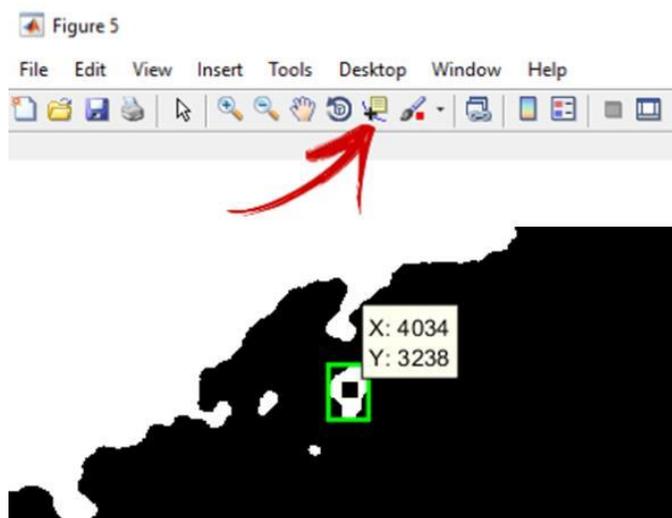
**Figura 19 – Destaque visual das maiores nuvens e seus respectivos centros de massa.**



Fonte: Próprio autor.

Considerando que a distância das três maiores nuvens em relação ao sol seria um dos dados de entrada da RNA, primeiro seria necessário determinar as coordenadas destes pontos. Para isso, utilizamos uma ferramenta do próprio MatLab, a qual nos forneceu valores em termos de X e Y, como exposto na Figura 20. Este procedimento foi realizado “manualmente” visto que a automação desta atividade não faz parte deste TCC. Para obtenção do valor referente a distância (D), utilizamos a Equação 8.

**Figura 20 – Ferramenta utilizada para determinar o centro de massa do sol e das nuvens.**



Fonte: Próprio autor.

$$D = \sqrt{(X_{nuvem} - X_{sol})^2 + (Y_{nuvem} - Y_{sol})^2} \quad (8)$$

Note que a utilização de uma lente olho de peixe causa distorções neste dado de distância. No trabalho de Limeira (2020), realizado no IFPE - Campus Pesqueira, um algoritmo para remoção desta distorção foi desenvolvido. Porém, desconsideramos tal efeito neste trabalho visto que esta parte do TCC foi desenvolvida em paralelo com o trabalho de Limeira e, portanto, o algoritmo ainda não estava desenvolvido.

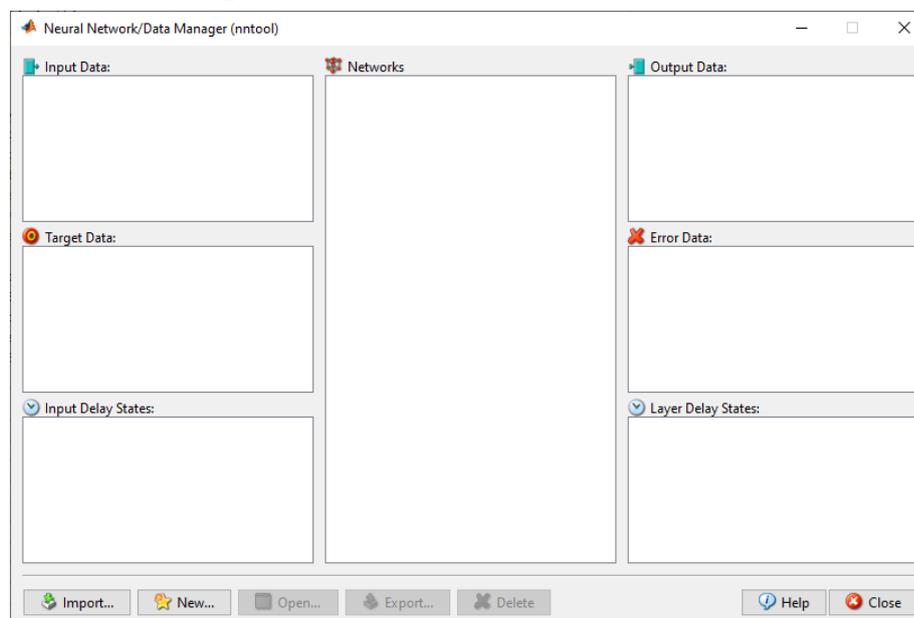
Finalmente, como informação adicional para a entrada da RNA, buscamos nas propriedades de cada imagem o tempo de exposição do sensor da câmera durante a captura da imagem. Após extrairmos todas essas informações, organizamos todos esses dados em uma planilha para que em seguida pudéssemos transferi-los para o MatLab de maneira mais simples.

### 3.3 Desenvolvimento da RNA

Uma vez montada a base de dados através das informações extraídas das imagens obtidas e do luxímetro, os quais foram capazes de registrar dados referentes a diferentes condições de sombreamento ao longo dos dias (dias em que ocorreu a coleta de dados), a próxima etapa é o desenvolvimento e configuração da RNA, ou seja, determinar os parâmetros finais de treinamento e testes da RNA, este último será discutido nos resultados deste TCC.

Para o desenvolvimento e futuros testes da RNA, optamos por utilizar a *Neural Network Toolbox* na ferramenta computacional MatLab, mencionada na seção anterior. Esta escolha levou em consideração a praticidade e eficiência em construir e configurar RNAs de maneira rápida e com confiabilidade, em interface gráfica, a qual pode ser vista na Figura 21.

**Figura 21 – Neural Network Toolbox.**



Fonte: Próprio autor.

O tipo de RNA escolhido foi a *Feedforward Backpropagation*. Em uma rede deste tipo, cada camada se conecta apenas à camada seguinte, isto é, toda a informação percorre apenas um caminho, partindo da camada de entrada rumo à camada de

saída. O treinamento aqui aplicado foi do tipo supervisionado, como já mencionado neste trabalho. Tais parâmetros foram escolhidos devido seus usos em outros trabalhos similares.

Durante a fase de criação da RNA, foram construídas um total de 10 configurações, nas quais foram atribuídos diferentes números de camadas (camadas intermediárias) e de neurônios em sua composição. Entretanto, foram utilizados os valores padrões do MatLab para a função de treinamento, função de aprendizagem e a função de desempenho. Mas, de fato, para saber os impactos causados por tais funções, seria necessário um estudo mais aprofundado, seguido de mais testes.

Com relação ao treinamento, conforme descrito anteriormente, foram utilizados como entrada da rede:

1. Distância das três maiores nuvens em relação ao sol (3 entradas na RNA para receber estas informações);
2. Tamanho das três maiores nuvens (3 entradas);
3. Tempo de exposição do sensor da câmera durante o momento de captura da imagem;
4. Condição climática no momento de aquisição da imagem;
5. Horário em que a imagem foi capturada.

Apesar de termos as informações das datas em que esses dados foram adquiridos, estas informações não foram consideradas durante a fase de treinamento, pois a data só seria importante caso tivéssemos um banco de dados anual.

Por fim, como valor alvo, foram utilizadas as leituras do luxímetro obtidas durante a aquisição de cada imagem, já que estes seriam os valores que buscávamos obter posteriormente como resposta da rede.

#### 4 RESULTADOS E ANÁLISE

A fim de obter os melhores resultados possíveis com a base de dados disponível, alguns modelos (número de camadas intermediárias e números de neurônios por camadas) de RNAs foram estudados, testados e implementados no MatLab por meio da *Neural Network Toolbox*, apresentada na seção anterior. A seguir, será apresentado um breve relato a respeito das configurações testadas, os métodos de avaliação para escolha da melhor configuração de rede e, em seguida, os resultados obtidos por tal configuração.

Tendo em vista os diferentes tipos de informações que seriam utilizadas como entrada da RNA, bem como o tipo de resposta que buscamos, todas as configurações projetadas neste trabalho possuem 9 conexões de entrada e apenas 1 conexão de saída. Estes valores permaneceram os mesmos em todas as configurações ao longo de todo o processo de treinamento e simulações, apenas variando o número de camadas internas e de neurônios, como mencionado na subseção 4.3. No total foram projetadas, treinadas e testadas 10 configurações (contendo 10, 20, 30, 40 ou 50 neurônios em 1 camada interna, ou 10, 20, 30, 40 ou 50 neurônios em 2 camadas internas, e sempre 1 camada de saída), após isso, um novo conjunto de dados de entrada foi usado para realizar a validação, a fim de analisarmos a estimativa de iluminação gerada por cada configuração.

A princípio, como método de avaliação para determinar qual configuração apresentaria resultados mais precisos, foram coletados os valores referentes ao erro

médio quadrático, o qual é responsável por indicar numericamente o desempenho alcançado pela RNA e, após isso, realizamos um comparativo entre as 10 configurações, considerando estes valores em função do número de neurônios. Este comparativo é apresentado nas Tabelas 5 e 6. Na Tabela 5 encontram-se as configurações projetadas com apenas uma camada intermediária. Já na Tabela 6, estão as configurações projetadas com duas camadas internas, porém é necessário destacar que, apesar de haver duas camadas intermediárias, o número de neurônios atribuídos durante a construção da RNA não foi dividido entre as camadas internas, ou seja, o número de neurônios presente na segunda camada intermediária é análogo ao número atribuído para a primeira.

**Tabela 5 – Comparativo entre as configurações compostas por 1 camada interna, mais a camada de saída.**

Configuração	Nº de neurônios na camada interna (1 camada interna)	Erro médio quadrático
RNA-1	10	1,72E-02
RNA-2	20	1,01E-05
<b>RNA-3</b>	<b>30</b>	<b>5,66E-08</b>
RNA-4	40	0,00175
RNA-5	50	1,58E-03

Fonte: Elaborado pelo autor.

**Tabela 6 – Comparativo entre as configurações compostas por 2 camadas internas, mais a camada de saída.**

Configuração	Nº de neurônios na camada interna (2 camadas internas)	Erro médio quadrático
RNA-6	10	4,54E-04
RNA-7	20	0,0154
<b>RNA-8</b>	<b>30</b>	<b>6,84E-08</b>
RNA-9	40	4,18E-03
RNA-10	50	2,79E-03

Fonte: Elaborado pelo autor.

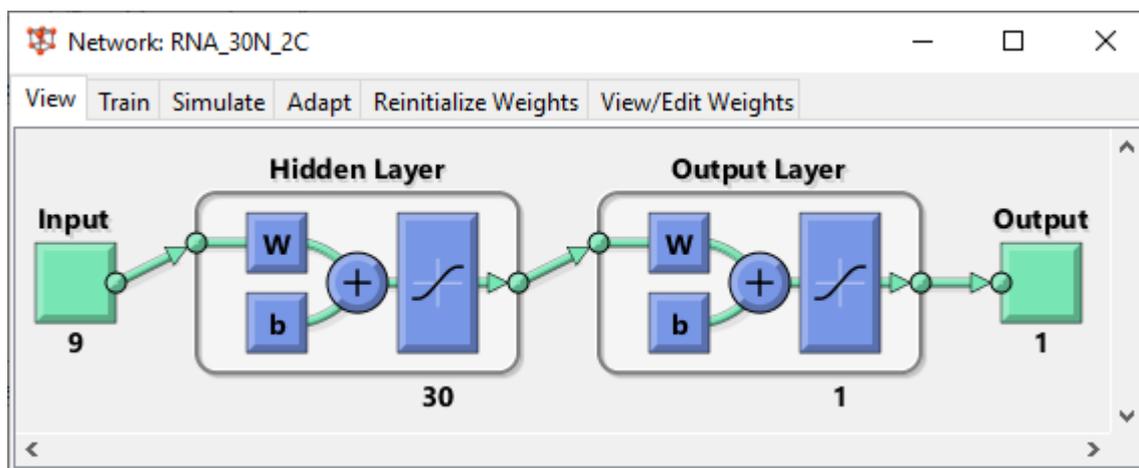
Analisando os valores do erro médio quadrático alcançado por cada configuração, nota-se que as configurações RNA-3 e RNA-8 alcançaram os menores valores para o erro médio quadrático. Nas duas configurações destacadas, foram atribuídos 30 neurônios em suas camadas intermediárias (Tabelas 5 e 6), o que torna a escolha deste número adequada para realização deste trabalho.

Mesmo a configuração RNA-8 tendo uma camada de neurônios a mais (30 neurônios na primeira camada interna, mais 30 neurônios na segunda camada interna, totalizando 60 neurônios nas camadas intermediárias), a configuração RNA-3 foi a que obteve o menor erro médio quadrático, apesar da diferença entre ambas ser pequena. A configuração RNA-3 é ilustrada na Figura 22.

De maneira geral, apesar de ter sido testado a possibilidade de usar outras camadas (contendo cada vez mais neurônios, à medida que o número de configurações avançava) nas RNAs, não houve mudanças significativas no

desempenho de nenhuma configuração testada. Este comportamento, sinaliza aquilo que já tinha sido visto em outros trabalhos, ou seja, ter uma rede neural composta com mais neurônios, além do necessário, não garante uma rede mais “inteligente”. Se faz necessário o estudo de outros fatores que afetam diretamente o seu desempenho (tipo de RNA empregado, funções de treinamento, de ativação, número de amostras para treinamento, entre outros fatores).

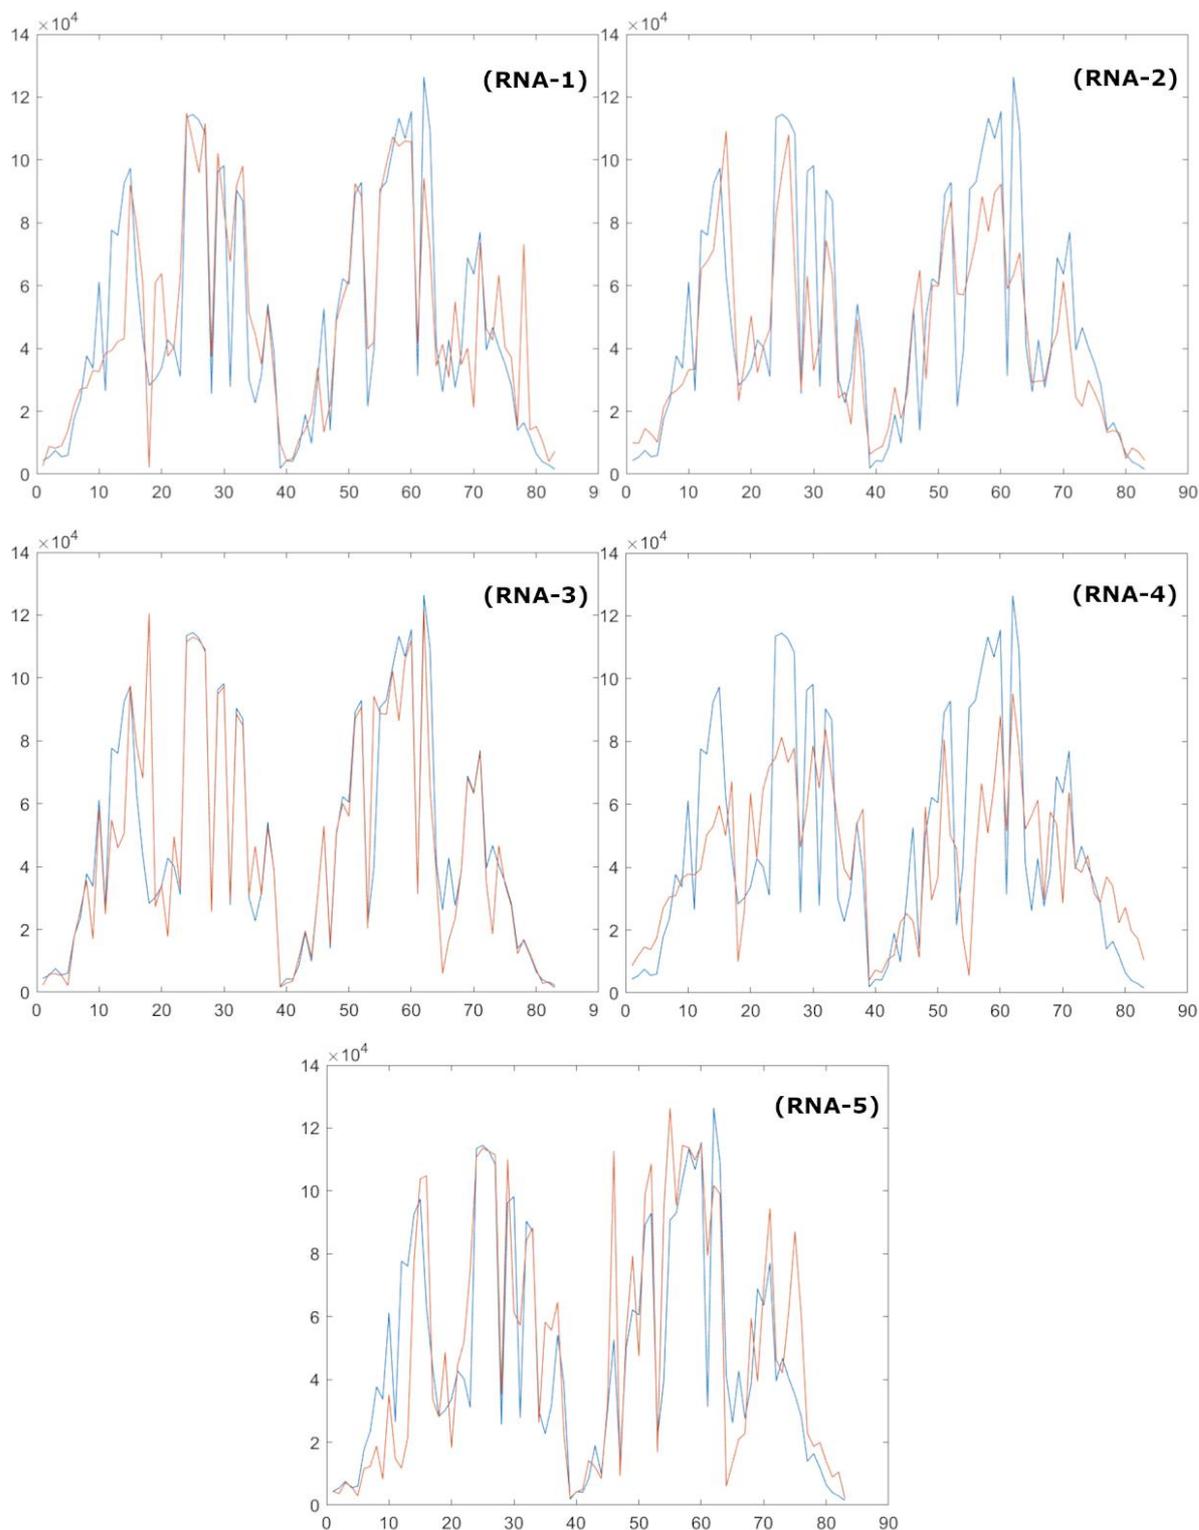
**Figura 22 – Configuração que apresentou os melhores resultados.**



Fonte: Próprio autor.

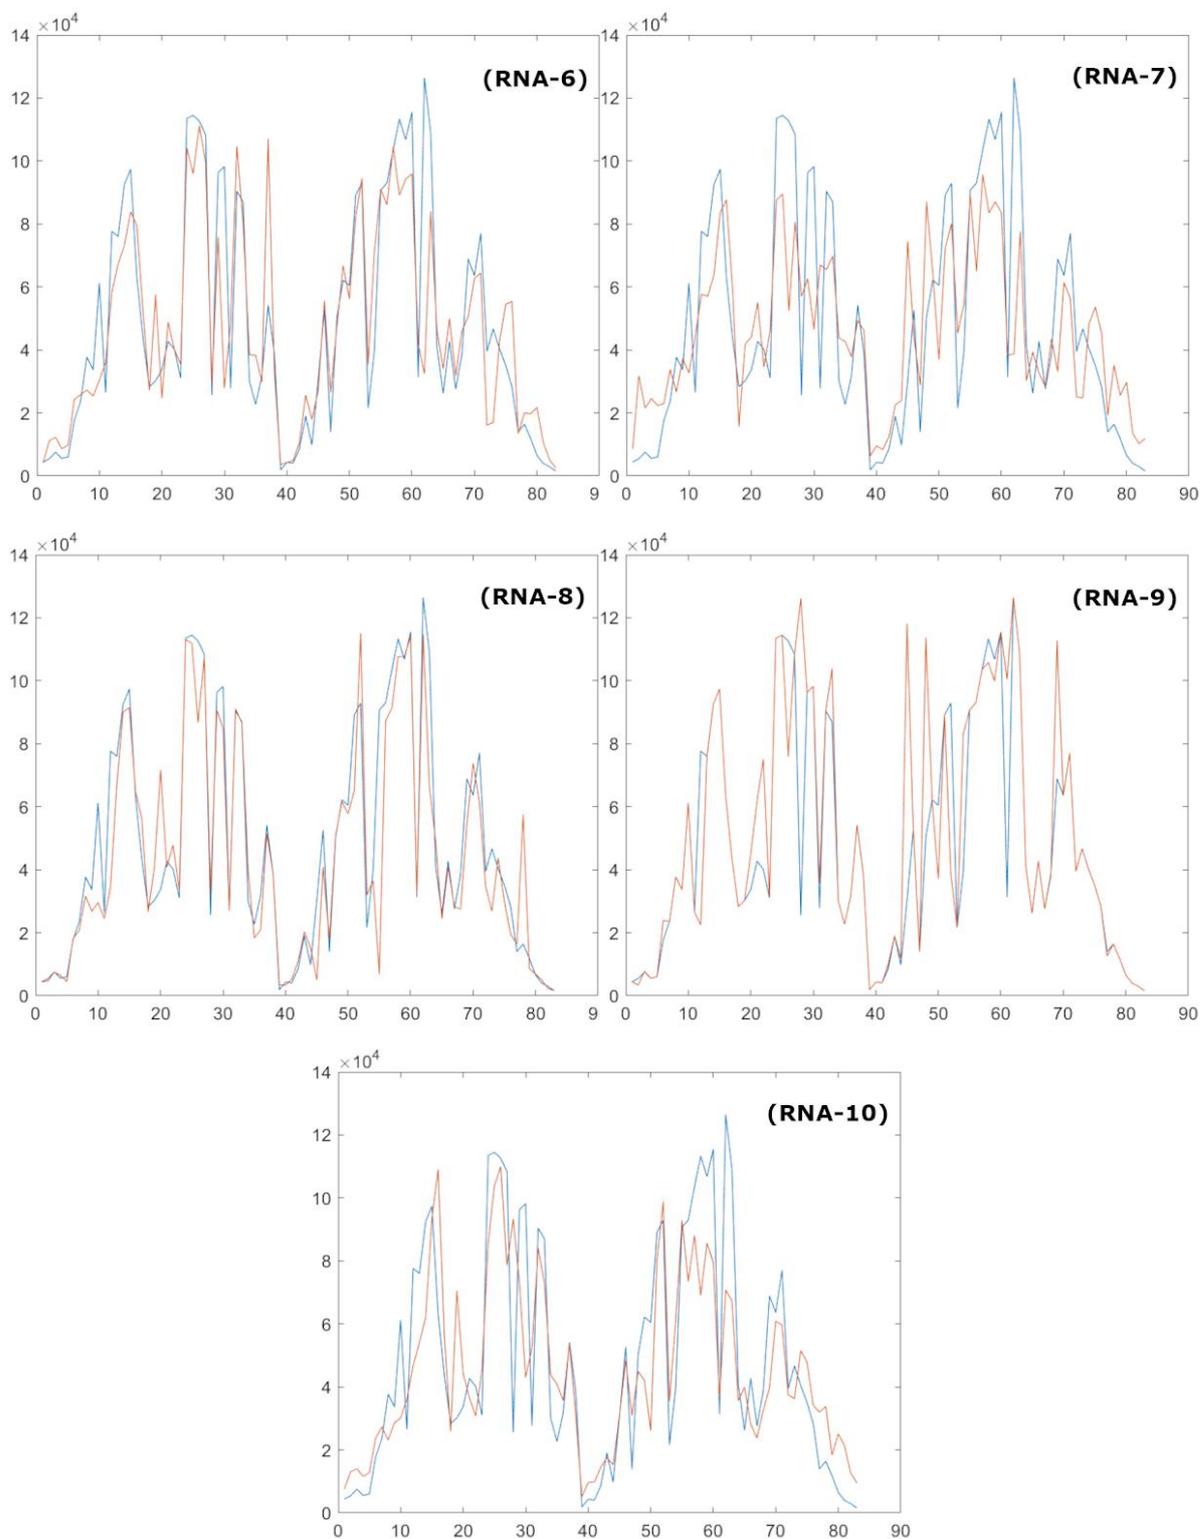
Nas Figuras 23 e 24 são apresentados gráficos referentes às saídas de cada configuração de rede e os comparando com o gráfico gerado a partir dos dados do luxímetro, observamos que em alguns casos houve bastante discrepância entre os valores estimados em relação aos valores esperados, apresentando alguns picos em determinadas regiões dos gráficos. Como esperado, estes picos ocorrem com maior frequência em configurações que apresentam um maior valor do erro médio quadrático, fornecendo respostas bem distintas das esperadas. Dentre as configurações testadas, as configurações RNA-4 e RNA-7 foram as que obtiveram os piores resultados em relação às demais, fornecendo estimativas de iluminância bem distintas do esperado. Na Figura 25 é destacado a curva resultante da configuração que obteve o menor erro médio quadrático, ou seja, a configuração RNA-3.

**Figura 23 – Comparativo entre o gráfico gerado pelos dados do luxímetro e os gráficos gerados a partir das saídas de cada RNA projetada com apenas 1 camada intermediária. O gráfico em azul representa os dados do luxímetro e o gráfico em laranja representa os dados fornecidos pela rede. No eixo vertical estão representados os valores de intensidade luminosa, já no eixo horizontal, encontram-se valores referentes ao número de amostras utilizados.**



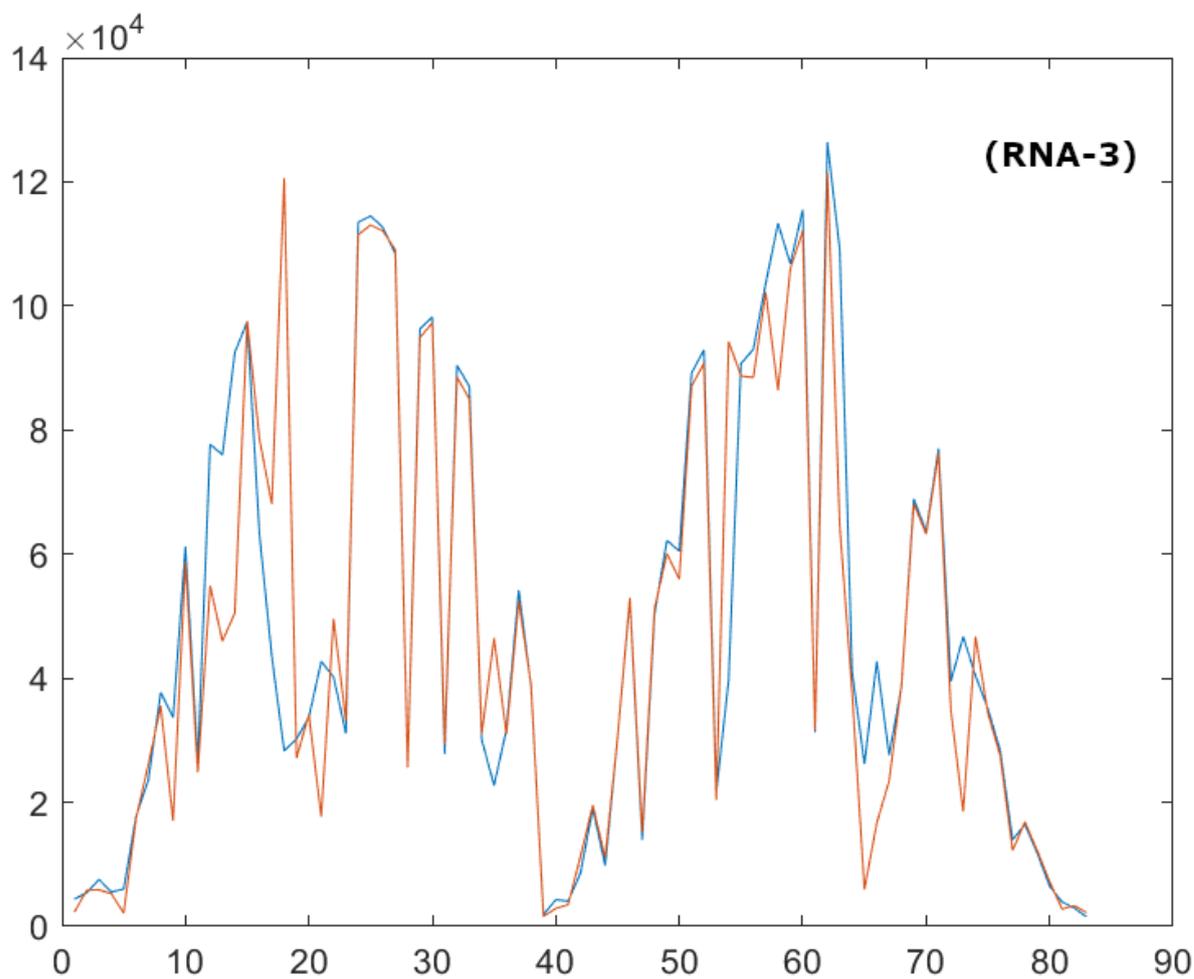
Fonte: Próprio autor.

**Figura 24 – Comparativo entre o gráfico gerado pelos dados do luxímetro e os gráficos gerados a partir das saídas de cada RNA projetada com 2 camadas intermediárias.**



Fonte: Próprio autor.

**Figura 25 – Configuração que obteve o melhor resultado dentre as demais.**



Fonte: Próprio autor.

## 5 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo avaliar a possibilidade de aplicação de RNAs em estimativas de valores de iluminância, os quais nos possibilitaram chegar em índices de irradiação solar.

A princípio, uma descrição detalhada, contendo a principal fonte de pesquisa consultada, bem como a utilização de técnicas para seleção de artigos de maior relevância, foi apresentada. Este processo resultou na seleção de 5 artigos, os quais foram estudados e descritos brevemente, como exposto.

Para compreensão adequada dos aspectos que foram tratados neste TCC, foram apresentados conceitos acerca de fenômenos radiativos ocorrentes na atmosfera, onde descrevemos os processos de espalhamento causados pelos constituintes atmosféricos, bem como dos impactos causados pela cobertura de nuvens na irradiância solar. Além disso, tendo em vista a aplicação de RNA na realização deste trabalho, uma breve descrição sobre é apresentada, explorando desde conceitos que inspiraram o seu surgimento, até as características básicas de seu funcionamento.

Para a geração da base de dados para treinamento e validação da RNA, foram utilizados um *smartphone*, uma lente “olho de peixe” de baixo custo e um luxímetro,

nos fornecendo dados adicionais para o treinamento e validação da rede. Este processo ocorreu nos dias 7 de abril e 2 de julho de 2019, reunindo um total de 83 imagens adquiridas. Após isso, iniciou-se o processamento de imagem, o qual nos possibilitou acesso a informações contidas em cada imagem que, posteriormente, nos levaram à saída desejada por parte da rede. Para realização desta tarefa, foi utilizado um algoritmo de processamento de imagens, desenvolvido durante um dos trabalhos PIBIC no IFPE - Campus Pesqueira. Ao fim desta etapa de processamento, uma parcela do banco de dados foi empregada durante a fase de treinamento, enquanto a outra, foi utilizada na simulação final da RNA, a fim de compararmos com as leituras do luxímetro (conjunto de validação). O volume de dados disponível se mostrou suficiente para a realização deste trabalho.

Tendo em vista sua aplicação em trabalhos similares, o tipo de rede aqui empregado foi a *Feedforward Backpropagation*. Apesar de terem sido feitos alguns testes com diferentes configurações de rede, variando o número de neurônios presentes nas camadas internas e o número de camadas internas, alguns parâmetros foram mantidos em seus valores padrões. Aliado a isto, o tipo de treinamento utilizado foi do tipo supervisionado, o qual se mostrou adequado para a natureza deste trabalho, visto que a base de dados foi montada seguindo sua lógica de funcionamento, contendo dados de entrada e dados utilizados como alvo para a RNA.

A partir dos resultados alcançados, conclui-se que uma RNA pode representar de maneira adequada a função de estimar valores relacionados à irradiância solar. Durante os testes, a configuração contendo 30 neurônios em uma camada intermediária (RNA-3), se mostrou mais eficiente, retornando valores próximos dos esperados, desta forma, tornando-se a configuração escolhida para cumprimento do objetivo tratado neste TCC.

Apesar do conjunto de dados ainda restrito, foi possível observar claramente que é tecnicamente viável a aplicação de RNA para estimação da irradiância solar. Os algoritmos de aquisição e processamento de imagem, e a seleção das características relevantes para a RNA, se mostraram adequadas. Como projeto futuro, visando o aperfeiçoamento da RNA, é necessário expandir os dados adquiridos, incluindo a temperatura e a potência gerada na usina solar do IFPE Campus Pesqueira, bem como aumentar o número de imagens capturadas e incluir o algoritmo de remoção da distorção inserida pela lente olho de peixe. Adicionalmente, é recomendado testar novas arquiteturas de RNA, apesar dos bons resultados apresentados na arquitetura selecionada.

Outro ponto que devemos destacar é a possibilidade de agendas futuras com a utilização deste trabalho como fonte para o ensino de conteúdos relacionados com a Física, na medida em que são explorados os conteúdos de reflexão, absorção e refração de ondas eletromagnéticas por parte dos constituintes atmosféricos. Isso é possível devido ao fato destes assuntos terem sido tratados não de maneira isolada, mas, contextualizada, descrevendo os impactos na irradiância solar durante o seu percurso até a superfície terrestre. Mesmo que este trabalho traga respostas para um problema de natureza técnica, o aprofundamento dado a esses conteúdos são elementos fundamentais para que a sua utilização no ensino de física seja recomendada.

Por fim, recomendamos a interdisciplinaridade entre as diversas áreas do conhecimento, como ficou altamente comprovada neste trabalho entre a Física e a

Engenharia Elétrica, para que, através dessas ações o conhecimento científico e tecnológico, possa ser um elemento a mais no combate ao negacionismo que se encontra altamente presente em nossa sociedade, e que, através da participação dos jovens nesse processo de construção e difusão científica possa atingir de maneira igualitária todos os níveis educacionais.

## REFERENCIAS

AMORIM, Bruna. **Absorção da radiação por aerossóis na Amazônia**. 2015. Dissertação (Mestrado em Ciências) - Universidade de São Paulo, São Paulo, 2015.

BENEDITO, Raphael. **Determinação de curvas de irradiância solar utilizando redes neurais artificiais para aplicação no planejamento eletro-energético de microrredes**. In: **Congresso Brasileiro de Inteligência Computacional**, nº 14, 2019, Belém.

BEZERRA, Francisco. Energia solar. **Caderno Setorial ETENE**. Fortaleza, n. 110, mar. 2020.

BON, Frederico. **Redes neurais artificiais aplicadas à previsão de irradiância global horizontal no contexto de cidades energeticamente inteligentes**. 2020. Dissertação (Mestrado em Engenharia Urbana) - Universidade Federal de São Carlos, São Carlos, 2020.

FILHO, Manoel. **Modelagem e previsão de flutuações da irradiância solar de curta duração**. 2019. Tese (Doutorado em Ciências) - Universidade Federal de Pernambuco, Recife, 2019.

CARPES, Felipe. **Rastreamento de máxima potência fotovoltaica através de redes neurais artificiais perceptron multicamadas**. 2017. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Federal do Pampa, Rio Grande do Sul, 2017.

DANTAS, Antonio; CARVALHO, Luiz; NETO, Pedro. **GNE 109: Agrometeorologia**. Lavras: Editora UFLA, 2010.

FARIA, Waltenir. **Estudo do sombreamento parcial em módulos fotovoltaicos através da resistência série e das redes neurais artificiais**. 2014. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Uberlândia, Uberlândia, 2014.

FIORIN, Daniel et al. Aplicação de redes neurais e previsões de disponibilidade de recursos energéticos. **Revista Brasileira de Ensino de Física**, v. 33, n. 1, 2011.

FLECK, Leandro et al. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovadora e Tecnologia**, Paraná, v. 1, n. 13, p. 47-57, jun. 2016.

GASPERACCO, Wellington. **Rede neural artificial aplicada ao rastreamento de pontos de máxima potência de painéis fotovoltaicos com sombreamento parcial**. 2018. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Espírito Santo, Vitória, 2018.

GUARNIERI, Ricardo et al. **Previsão de radiação solar utilizando modelo de mesoescala: Refinamento com redes neurais.** *In: Congresso Brasileiro de Energia Solar*, nº 1, 2007, Fortaleza.

HAYKIN, Simon. **Redes neurais: Princípios e prática.** Ed. 2. Porto Alegre: Bookman, 2001.

HEINEN, Eduarth. **Redes neurais recorrentes e XGBoost aplicados à previsão de radiação solar no horizonte de curto prazo.** 2018. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de São Carlos, São Carlos, 2018.

KRAPAS, Sonia; SANTOS, Paulo. Modelagem do espalhamento Rayleigh da luz com propósito de ensino e de aprendizagem. **Caderno Brasileiro de Ensino de Física**, Niterói, v. 19, n. 3, p. 341-350, dez. 2002.

LATORRE, Marcelo. Correção atmosférica: conceitos e fundamentos. **Espaço & Geografia**. v. 5, n. 1, p. 153-178, mar. 2002.

LIMEIRA, Matheus et all. Desenvolvimento de algoritmo para remoção da distorção causada por lente olho de peixe. **Brazilian Journal of Development**. Curitiba, v. 7, n.1, p. 6587-6605, jan. 2021.

LIU, Kuo-Nan. **An Introduction to Atmospheric Radiation.** Ed. 2. *New York: Academic Press*, 2002.

LOPES, José. **Previsão de produção fotovoltaica a muito curto prazo usando análise e modelação de dinâmica de sombras.** 2010. Dissertação (Mestrado em Engenharia Electrotécnica e de Computadores) - Faculdade de Engenharia da Universidade do Porto, Porto, 2010.

MARQUEZ, Ricardo; COIMBRA, Carlos. Intra-hour DNI forecasting based on cloud tracking image analysis. **Solar Energy**. v. 91, p. 327-336, mai. 2012.

MICHAEL, Peter. A Conversion Guide: Solar Irradiance and Lux Illuminance. **IEEE Dataport**; 2019. Disponível em: <<https://dx.doi.org/10.21227/mxr7-p365>>. Acesso em: 09 de fevereiro de 2021.

MOOJEN, Thomaz; CAVALCANTE, Rosane; MENDES, Carlos. Avaliação da radiação solar com base em dados de nebulosidade. **GEOGRAFIA (Londrina)**. v. 21, n. 3, 2012.

PEIXOTO, Jose; OORT, *Abraham*. **Physics of Climate.** Ed. 1. *New York: American Institute of Physics Press*, 1992.

REMES, Chrystian. **Caracterização por simulação numérica de painéis fotovoltaicos e método de rastreamento do máximo ponto de potência baseado em redes neurais artificiais.** 2013. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade do Estado de Santa Catarina, Joinville, 2013.

SANTOS, Bruno. **Previsão de produção de centrais solares a muito curto prazo.** 2010. Dissertação (Mestrado em Engenharia Eletrônica e de Computadores) - Faculdade de Engenharia da Universidade do Porto, Porto, 2015.

SANTOS, Cícero. **Irradiância solar global com diferentes modelos para Alagoas.** 2012. Dissertação (Mestrado em Meteorologia) - Universidade Federal de Alagoas, Maceió, 2012.

SEVERO, Luana. **Rastreamento de máxima potência através de redes neurais artificiais aplicado a um sistema fotovoltaico conectado à rede**. 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Federal do Pampa, Rio Grande do Sul, 2019.

TOGAWA, André. **Previsão de irradiância solar por rastreamento de nuvens utilizando imagens**. 2014. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) - Universidade de Brasília, Brasília, 2014.

YAMASOE, Marcia; CORRÊA, Marcelo. **Processos radiativos na atmosfera: fundamentos**. São Paulo: Oficina de Textos, 2016.