

UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Josman Silva Rodrigues

Análise de Incertezas em Modelos de *Deep Learning* Utilizados em Previsão de Geração de Energia Fotovoltaica

João Pessoa - PB

2022

Josman Silva Rodrigues

Análise de Incertezas em Modelos de *Deep Learning* Utilizados em Previsão de Geração de Energia Fotovoltaica

Trabalho de Conclusão de Curso apresentado
à Coordenação de Engenharia Elétrica do
Centro de Energias Alternativas e Renováveis
da Universidade Federal da Paraíba como
parte dos requisitos necessários para a obten-
ção do título de Engenheiro Eletricista.

Universidade Federal da Paraíba
Centro de Energias Alternativas e Renováveis
Curso de Graduação em Engenharia Elétrica

Orientador: Prof. Dr. Juan Moises Mauricio Villanueva

João Pessoa - PB

2022

Catálogo na publicação
Seção de Catalogação e Classificação

R696a Rodrigues, Josman Silva.

Análise de Incertezas em Modelos de Deep Learning
Utilizados em Previsão de Geração de Energia
Fotovoltaica / Josman Silva Rodrigues. - João Pessoa,
2022.

59 f. : il.

Orientação: Juan Moises Mauricio Villanueva.
TCC (Graduação) - UFPB/CEAR.

1. Redes Neurais Artificiais. 2. Monte Carlo
Dropout. 3. Energia Solar. 4. Modelos de previsão. I.
Villanueva, Juan Moises Mauricio. II. Título.

UFPB/CT/BSCT


CDU 621.3(043.2)

Josman Silva Rodrigues


Análise de Incertezas em Modelos de *Deep Learning* Utilizados em Previsão de Geração de Energia Fotovoltaica

Trabalho de Conclusão de Curso apresentado
à Coordenação de Engenharia Elétrica do
Centro de Energias Alternativas e Renováveis
da Universidade Federal da Paraíba como
parte dos requisitos necessários para a obten-
ção do título de Engenheiro Eletricista.


Data de Aprovação: 21 / 06 / 2022



Prof. Dr. Juan Moises Mauricio
Villanueva
(Orientador)
Universidade Federal da Paraíba



Prof. Dr. Euler Cássio Tavares de
Macedo (Avaliador)
Universidade Federal da Paraíba



Prof. Dr. Yuri Percy Molina Rodriguez
(Avaliador)
Universidade Federal da Paraíba

João Pessoa - PB
2022

Dedico este trabalho a meus pais, Josimar Rodrigues de Souza e Maria da Vitória Silva Rodrigues, e a meu avô Antônio Rodrigues Neto (*in memoriam*).

À vocês toda minha gratidão e amor!

Agradecimentos

Primeiramente agradeço a Deus pelo dom da vida e por ter permitido que eu chegasse até aqui.

Agradeço a meus pais, Josimar Rodrigues e Maria da Vitória e as minhas irmãs, Joyce Raquel e Maria Izabel que sempre me apoiaram e me motivaram durante toda a graduação, com conselhos valiosos. Com muito esforço e união, nunca deixaram nada me faltar. Portanto, este trabalho só foi realizado principalmente por causa deles.

Também deixo meus agradecimentos aos meus amigos que me acolheram no início de minha jornada acadêmica, os quais considero como minha segunda família. Agradeço a Bruno, Ceiza, Betânia, Dona Cristina e todos aqueles que me apoiaram no início de minha carreira.

Agradeço ao meu orientador, o Prof. Dr. Juan Villanueva, por todos os ensinamentos repassados nesta e em outras atividades desempenhadas, além da paciência e solicitude durante toda a orientação. Também deixo os agradecimentos por todos os valiosos conselhos, os quais me ensinaram como um profissional deve se portar no mercado e na vida acadêmica.

Por fim, agradeço aos meus amigos e colegas que estiveram presentes nos momentos bons e difíceis da graduação e que contribuíram para que eu chegasse até aqui. Portanto, deixo meus agradecimentos a José Vinícius, Filipe Bulhões, Vinícius Lisboa, Pedro Pinto, Ítalo Sibaldo e Tarcísio José. Os momentos vivenciados, agradáveis e difíceis, me fizeram aprender muito e a me tornar a pessoa que sou hoje.

Tudo vale a pena quando a alma não é pequena.
(Fernando Pessoa)

Resumo

A energia fotovoltaica vem ganhando grande espaço na matriz energética mundial como estratégia para contornar as crises energéticas ao tempo que auxilia na redução de impactos ambientais, por ser um tipo de energia limpa e renovável. Entretanto a natureza intermitente desse tipo de geração de energia elétrica causa dificuldades na gestão da operação das mesmas, causando problemas de instabilidade e baixa confiabilidade na conexão de pontos de geração ao sistema integrado, o que motiva o desenvolvimento de modelos de previsão de energia solar fotovoltaica, como ferramenta de auxílio no planejamento da operação. Entretanto, tais modelos possuem incertezas associadas que podem afetar de maneira significativa a previsão de energia, causando mais problemas na confiabilidade da previsão. Portanto, o presente trabalho apresenta uma análise das incertezas em modelos de previsão baseados em redes neurais artificiais (RNA) para aplicação em geração de energia fotovoltaica, realizando uma aproximação Bayesiana da RNA através da técnica do Monte Carlo *Dropout*. Os resultados demonstram valores de incertezas máximas inferiores a 1 kWh para os parâmetros escolhidos nas análises durante as estações do ano em diferentes cenários de estudo.

Palavras-chave: Redes Neurais Artificiais. Monte Carlo *Dropout*. Energia Solar. Modelos de previsão.

Abstract

Photovoltaic energy has been gaining a large space in the world energy matrix as a strategy to circumvent the energy crises while helping to reduce environmental impacts, as it is a clean and renewable type of energy. However, the intermittent nature of this type of power generation causes difficulties in managing its operation, causing problems of instability and low reliability in the connection of generation points to the integrated electrical system, which motivates the development of energy forecast models as a tool to assist in operation planning. However, such models have associated uncertainties that can significantly affect the energy forecast, causing more problems in the reliability of the forecast. Therefore, the present work presents an analysis of uncertainties in forecast models based on artificial neural networks (ANN) for application in photovoltaic power generation, performing a Bayesian approximation of the ANN through the Monte Carlo *Dropout* technique. The results demonstrate maximum uncertainty values of less than 1 kWh for the parameters chosen in the analyses during the seasons in different study scenarios.

Keywords: Artificial Neural Networks. Monte Carlo Dropout. Solar Energy. Forecasting Models.

Lista de ilustrações

Figura 1 – Consumo de energia elétrica a nível mundial entre os anos 1990 a 2020.	16
Figura 2 – Porcentagem de geração de energia solar na geração total produzida mundialmente.	17
Figura 3 – Estrutura de um painel fotovoltaico.	20
Figura 4 – Esquematização de um sistema isolado de geração fotovoltaica.	21
Figura 5 – Esquematização de um sistema de geração fotovoltaica conectado à rede elétrica.	22
Figura 6 – Diagrama com as subdivisões da Inteligência Artificial.	23
Figura 7 – Representação de um neurônio biológico.	24
Figura 8 – Representação do neurônio artificial.	25
Figura 9 – Ilustração do perceptron idealizado por Rosenblatt em 1958.	26
Figura 10 – Representação de uma rede perceptron multicamadas	27
Figura 11 – RNA após aplicação do <i>dropout</i>	28
Figura 12 – RNA durante a aplicação do <i>dropout</i>	29
Figura 13 – Dados de geração colhidos para um dia.	33
Figura 14 – Energia acumulada por dia durante os anos.	34
Figura 15 – Geração de um dia com a aplicação da média móvel.	37
Figura 16 – Geração de um dia com a aplicação da média móvel.	37
Figura 17 – Exemplo da estrutura do banco de dados.	39
Figura 18 – Divisão dos dados de energia gerada em treinamento e validação. . . .	39
Figura 19 – Divisão dos dados de energia gerada em treinamento e validação. . . .	40
Figura 20 – Topologia da RNA implementada para o problema de previsão.	41
Figura 21 – Tipos de curva de geração para um dia de cada estação do ano.	44
Figura 22 – Comportamento da curva de geração de energia acumulada por dia durante os anos	46
Figura 23 – Intervalos de predição da geração de um dia durante o inverno para cada probabilidade de <i>dropout</i>	49
Figura 24 – Intervalos de predição da geração acumulada por dia durante a primavera para cada probabilidade de <i>dropout</i>	49
Figura 25 – Intervalos de predição no caso de estudo 1 para cada valor de λ	51
Figura 26 – Intervalos de predição no caso de estudo 2 para cada valor de λ	52
Figura 27 – Intervalos de predição no caso de estudo 1 para cada valor de l	53
Figura 28 – Intervalos de predição no caso de estudo 1 para cada valor de l	54

Lista de tabelas

Tabela 1	–	Dados colhidos da plataforma NASA POWER	35
Tabela 2	–	Desempenho do modelo de previsão considerando a geração durante um dia.	45
Tabela 3	–	Desempenho do modelo para o caso de geração acumulada por dia . . .	47
Tabela 4	–	Incertezas máximas associadas para cada probabilidade de <i>dropout</i> . . .	48
Tabela 5	–	Incertezas máximas associadas para cada valor de peso da regularização L2.	50
Tabela 6	–	Incertezas máximas associadas para cada <i>length scale</i>	53

Lista de abreviaturas e siglas

EIA	<i>U.S Energy Information Administration</i>
ANEEL	Agência Nacional de Engenharia Elétrica
RNA	Redes Neurais Artificiais
CA	Corrente Alternada
CC	Corrente Contínua
NASA	<i>National Aeronautics and Space Administration</i>
NASA POWER	NASA Predictions Of Worldwide Energy Resources
CRESESB	Centro de Referência para as Energias Solar e Eólica Sérgio de S. Brito
kW	Quilowatts
MW	Megawatts
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
MAE	<i>Mean Absolute Error</i>
RMSE	<i>Root Mean Squared Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
RNN	<i>Recurrent Neural Networks</i>
LSTM	<i>Long Short-Term Memory</i>

Lista de símbolos

y_k	Saída do k-ésimo neurônio da RNA
φ	Função de ativação
W_i	Matriz de pesos aplicada a i-ésima entrada
X_i	i-ésima entrada do neurônio
b_k	Limiar de ativação do k-ésimo neurônio
u_k	Potencial de ativação
p	Probabilidade de <i>dropout</i>
λ	Peso da regularização L2
$r^{(l)}$	Vetor de variáveis aleatórias da camada l
N	Número de amostras
$\hat{y}_t$	Valor da t-ésima previsão
$\mathbb{E}(\hat{y})$	Média aritmética das previsões
$Var(\hat{y})$	Variância das previsões
τ	Fator de precisão
T	Número de varreduras (<i>forward-passes</i>) realizado na RNA
r_{xy}	Coefficiente de correlação amostral de Pearson
x_i	Valor da i-ésima amostrada variável x
$\bar{x}$	Média amostral das amostras da variável x
y_i	Valor da i-ésima amostrada variável y
$\bar{y}$	Média amostral das amostras da variável y
K_t	Índice de céu claro
I_r	Irradiação refletida no topo da atmosfera
I_T	Irradiação total que atinge a atmosfera

z_n	<i>z-score</i> da n-ésima amostra
x_n	Valor da n-ésima amostra
σ	Valor do desvio padrão
x_{norm}	Valor normalizado da amostra x
x_{min}	Valor mínimo da amostra x
x_{max}	Valor máximo da amostra x

Sumário


1	INTRODUÇÃO	16
1.1	Objetivos	19
1.1.1	Objetivo Geral	19
1.1.2	Objetivos Específicos	19
1.2	Visão geral da organização do trabalho	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Energia Solar Fotovoltaica	20
2.1.1	Aspectos Construtivos dos Painéis Solares	20
2.1.2	Sistemas de Geração Fotovoltaica	21
2.1.2.1	Sistemas Isolados	21
2.1.2.2	Sistemas Conectados à Rede	22
2.2	Redes Neurais Artificiais	23
2.2.1	O Neurônio Biológico	24
2.2.2	O Neurônio Artificial	24
2.2.2.1	Modelo Matemático do Neurônio Artificial	25
2.2.3	O Modelo Perceptron	26
2.2.4	Rede Perceptron Multicamadas	27
2.2.5	Treinamento da Rede Neural	28
2.3	<i>Dropout</i> como Técnica de Regularização	28
2.4	Incertezas em Modelos de <i>Deep Learning</i>	30
2.4.1	Tipos de Incerteza em <i>Deep Learning</i>	30
2.5	<i>Dropout</i> como Aproximação Bayesiana de uma RNA	31
2.5.1	Obtenção das Incertezas	32
3	METODOLOGIA	33
3.1	Descrição dos Dados	33
3.1.1	Dados de Geração de Energia	33
3.1.2	Dados Meteorológicos	34
3.2	Pré-Processamento dos Dados	35
3.2.1	Deteção e Remoção dos <i>Outliers</i>	36
3.2.2	Suavização dos Gráficos dos Dados	36
3.2.3	Normalização dos Dados	38
3.3	Modelo de Previsão	38
3.3.1	Formação do Banco de Dados	38
3.3.2	Divisão dos Conjuntos de Treino e Teste	38

3.3.3	Topologia da RNA	39
3.3.3.1	Escolha dos Hiperparâmetros da RNA	40
3.3.4	Métricas de Avaliação do Modelo	42
3.3.4.1	Erro Absoluto Médio	42
3.3.4.2	Erro Percentual Absoluto Médio	42
3.3.4.3	Raiz do Erro Médio Quadrático	43
4	RESULTADOS	44
4.1	Modelo de Previsão	44
4.2	Caso 1: Previsão de geração durante o dia	45
4.3	Caso 2: Previsão de geração acumulada por dia	46
4.4	Análises das Incertezas do Modelo de Previsão	47
4.4.1	Influência da Probabilidade de <i>Dropout</i>	47
4.4.2	Influência da Regularização L2	50
4.4.3	Influência do <i>length scale</i>	52
5	CONCLUSÕES	55
	REFERÊNCIAS	57

1 Introdução

A demanda energética mundial vem crescendo continuamente ao longo das décadas. Estima-se que o consumo mundial anual de energia é de por volta 25000 TWh, com projeção de dobrar esse valor por volta do ano 2050 e triplicar no final do século 21 (PREMA et al., 2022). Esse cenário, aliada à alta dependência dos combustíveis fósseis e suas consequências, como poluição, mudanças climáticas e agravamento do efeito estufa, podem levar a humanidade a uma crise energética acentuada, com o aumento dos preços da energia devido aos custos com a geração a partir de fontes não-renováveis, como usinas termelétricas. Na Figura 1 está ilustrado o gráfico do consumo de energia elétrica a nível mundial entre os anos 1990 a 2020, a qual foi construída a partir de dados do site da *U.S Energy Information Administration* (EIA). Logo, diante do cenário apresentado, foram motivados interesses nas últimas décadas em formas alternativas e limpas de gerar energia (ELAVARASAN et al., 2020).

Figura 1 – Consumo de energia elétrica a nível mundial entre os anos 1990 a 2020.




Fonte: Adaptado de (EIA, 2022)

Como forma de solucionar a crise energética, foram exploradas as energias renováveis, principalmente energia solar e eólica, que vêm ganhando bastante espaço nas discussões sobre expansão das fontes de energia no setor elétrico, devido ao fato das mesmas não gerarem poluentes e ajudarem na redução do efeito estufa. Dentre elas, os sistemas fotovoltaicos se destacam por serem a modalidade de geração de energia renovável que mais cresce ao redor do mundo. Além disso, devido aos preços cada vez mais baixos dos módulos fotovoltaicos em relação aos crescentes custos de geração a partir de combustíveis fósseis, espera-se uma grande competitividade entre as fontes de geração de energia no futuro. Assim a energia solar se tornará uma das fontes de energia mais significantes (YANG et al., 2014). Na Figura 2 está ilustrada o percentual de energia solar e eólica gerada em relação ao total gerado entre os anos 1990 a 2020, onde observa-se o crescimento

acentuado da contribuição da energia solar na matriz energética mundial.

Figura 2 – Porcentagem de geração de energia solar na geração total produzida mundialmente.



Fonte: Adaptado de (EIA, 2022)

Enquanto a energia solar, bem como outras fontes de energia renováveis, contribuem de maneira significativa para um futuro mais sustentável, a característica intermitente das mesmas fazem com que a operação das redes que elas estão incluídas seja um grande desafio. Segundo a Agência Nacional de Engenharia Elétrica (ANEEL), uma fonte intermitente é caracterizada quando a geração de energia ocorre somente no momento em que o recurso utilizado para a geração de energia se encontra disponível. No caso da energia solar, a geração é bastante afetada por variáveis climáticas, como temperatura, precipitação, hora do dia, etc. Por consequência, a intermitência na geração fotovoltaica em larga escala pode causar desequilíbrios entre a o suprimento de energia e a demanda, influenciando na confiabilidade do sistema elétrico (WANG et al., 2019).

Portanto, prever a quantidade de energia gerada de maneira precisa é uma alternativa viável para contornar o problema da intermitência, já que uma previsão de alta exatidão é uma ferramenta de grande importância para concessionárias de energia, propiciando um planejamento adequado do despacho de energia solar e análise futura da confiabilidade do sistema elétrico. Segundo (YANG et al., 2014) os modelos de previsão podem ser divididos em dois tipos: modelos de previsão indireta e modelos de previsão direta. Os modelos de previsão direta fazem a previsão de irradiação solar baseados em dados históricos de irradiação solar e clima, e depois as previsões são convertidas em dados de geração. Os modelos de previsão direta utilizam, além de dados de irradiação e clima, dados históricos de geração. Para o tipo de previsão indireta, podem ser citados estudos recentes que utilizam Transformada de Wavelet (BABU; RAY, 2019), técnicas de *machine learning* (MUTAVHATSINDI; SIGAUKE; MBUVHA, 2020) e *deep learning* (PAZIKADIN et al., 2020). Para o tipo de previsão direta pode se citado o trabalho de (PAWAR; MITHULANANTHAN; RAZA, 2020) que utiliza técnicas de *machine learning*, como o *support vector regression* (SVR). Também podem ser citados os trabalhos de

(ZHOU et al., 2021) e (JAIDEE; PORA, 2019), que utilizam, respectivamente, algoritmos baseados em redes neurais convolucionais e algoritmos híbridos, isto é, que combinam um modelo baseado em redes neurais artificiais com outros algoritmos de otimização, a exemplo de algoritmos genéticos (AG).

Portanto, torna-se relevante o interesse no desenvolvimento de modelos de previsão de geração de energia. Também nota-se que os algoritmos de *deep learning*, mais especificamente as redes neurais artificiais (RNA) são as mais aplicadas em problemas de previsão. Contudo, devido à natureza intermitente da energia solar, aliada a incerteza gerada pelas medições dos inversores, temperatura dos módulos solares, cabeamento, etc., podem haver instabilidades na previsão, podendo causar problemas futuros. Logo, é preciso saber a precisão do modelo implementado. Para isso, faz-se necessário realizar a análise das incertezas associadas ao modelo de previsão adotado, quantificando o montante de energia que pode faltar ou ultrapassar a média prevista em um determinado momento do horizonte de previsão (hora, dia, mês ou ano) a partir da concepção de intervalos de confiança e determinar se o modelo é seguro para aplicação, utilizando como base as normas regulamentadoras das concessionárias de energia, por exemplo.

Visto a importância de se analisar e diminuir as incertezas em um modelo de previsão, muitos estudos são desenvolvidos nessa temática. Em (ELA et al., 2013) são apresentados os impactos técnicos e financeiros das incertezas em previsões de geração de energia solar, onde mostra-se que pequenas variações podem resultar em custos milionários para a operadora da geração além do desequilíbrio entre a geração e carga resultante do planejamento equivocado. Em relação a modelos de previsão utilizando RNA, em (LIU et al., 2018) é apresentada uma estratégia para determinar as incertezas em modelos de previsão de geração fotovoltaica utilizando intervalos de predição gerados a partir do método denominado *nonparametric kernel density estimation* (NKDE). Já em (AUPKE et al., 2021) foi desenvolvida uma análise de incertezas em modelos de previsão de geração fotovoltaica com avaliação de diferentes fatores que alteram a incerteza do modelo. Em (NAZREEN; RAMAKRISHNAN, 2019) e (VYAS et al., 2019) são desenvolvidas estratégias de estimação de incertezas em modelos relacionados a reconhecimento de fala utilizando a técnica do *Monte Carlo Dropout*, uma abordagem modificada do *dropout* convencional (SRIVASTAVA et al., 2014a) em redes neurais artificiais.

Portanto, visto a pertinência do tema de análise de incertezas em modelos de previsão, a contribuição deste trabalho é realizar a análise de incertezas em modelos de previsão de energia fotovoltaica. Tais modelos são baseados em técnicas de *deep learning*, mais especificamente redes neurais artificiais. Será utilizada a técnica do *Monte Carlo Dropout* para extrair as incertezas do modelo, bem como será feita alterações nos parâmetros da técnica para analisar o comportamento das incertezas associadas ao modelo implementado.

1.1 Objetivos

1.1.1 Objetivo Geral

Desenvolver um modelo previsão de energia fotovoltaica baseado em redes neurais artificiais, considerando a influência do clima. Com a finalidade de avaliar a qualidade da previsão, será realizada a análise de incertezas do modelo utilizando a técnica do Monte Carlo Dropout.

1.1.2 Objetivos Específicos

- Observar o comportamento do modelo de previsão implementado em cada estação do ano para diferentes horizontes de previsão;
- Quantificar e qualificar as incertezas do modelo, considerando diferentes parâmetros.

1.2 Visão geral da organização do trabalho

Além da introdução, o restante do trabalho possui mais quatro capítulos, totalizando um total de cinco.

O segundo capítulo é constituído do referencial teórico utilizado como base para este trabalho. Neste capítulo serão apresentados uma visão geral acerca da energia solar fotovoltaica e os principais conceitos sobre séries temporais e modelos de previsão, redes neurais artificiais e conceitos sobre o *Monte Carlo Dropout*.

No capítulo seguinte será apresentada a metodologia utilizada na implementação do modelo de previsão de geração de energia fotovoltaica e os parâmetros utilizados na técnica de extração e análise de incertezas. Logo, serão descritos os dados utilizados, bem como o pré-processamento realizado nos mesmos. Também será apresentada a topologia da RNA e quais as considerações de escolha dos parâmetros do *Monte Carlo dropout*.

No capítulo quatro serão apresentados os resultados obtidos do modelo e suas respectivas análises quantitativas e qualitativas acerca das incertezas e precisão do modelo implementado.

Finalmente, no capítulo cinco, serão apresentadas as considerações finais acerca do trabalho e dos resultados, com sugestões de pesquisas futuras nas mesmas temáticas estudadas neste trabalho.

2 Fundamentação Teórica

2.1 Energia Solar Fotovoltaica


A constante busca por um mundo mais sustentável, a iniciar pela independência dos combustíveis fósseis, fizeram o ser humano buscar outras fontes de energia menos poluentes e renováveis, onde destaca-se a energia solar, também conhecida como energia fotovoltaica. A energia solar é uma das que mais cresce no mundo devido à sua flexibilidade de operação e facilidade na instalação dos seus equipamentos, que a cada ano vêm diminuindo seu valor agregado, motivando ainda mais a migração da geração centralizada convencional para a geração distribuída, onde qualquer pessoa pode gerar sua própria energia com o sistema instalado localmente.

A energia solar utiliza-se do fenômeno fotovoltaico para gerar energia utilizando painéis construídos com materiais semicondutores. Tal efeito foi observado pela primeira vez em 1839, pelo físico francês Edmond Becquerel e de fato consolidado e descrito pelas equações de Albert Einstein, em 1905. Becquerel causou o aparecimento de uma tensão elétrica quando iluminou uma placa de metal imersa em uma solução eletrolítica. Esse experimento se tornou a base para o princípio da geração fotovoltaica e do funcionamento dos painéis solares, também conhecidos como painéis fotovoltaicos.

2.1.1 Aspectos Construtivos dos Painéis Solares

A fonte de energia para a conversão da energia no fenômeno fotovoltaico vem do sol, sendo interessante citar que a superfície da terra recebe cerca de seis mil vezes mais energia advinda do sol do que nossa demanda total de energia (MASTERS, 2004). A conversão de energia começa nos painéis solares, os quais são formados por várias estruturas, como mostrado na Figura 3.

Figura 3 – Estrutura de um painel fotovoltaico.



Fonte: (SOLAR, 2014)

As células fotovoltaicas são fabricadas a partir de materiais semicondutores, as quais formam um conjunto que se distribui por toda a área do painel. Além das células, existem painéis de vidro que são utilizadas para aumentar a capacidade de penetração dos raios solares nas células, reduzindo a reflexão na superfície dos painéis, bem como existem isolantes elétricos entre as superfícies condutoras. Por fim, em cada painel existe uma caixa de junção, onde é feita a conexão de módulos adjacentes, formando as *strings*, associadas em série, paralelo ou em associação conjunta das duas anteriores (mista).


A análise da potência gerada por um painel é baseada na irradiância penetrante no painel, cuja unidade é W/m^2 , ou Watts por unidade de área (m^2), onde essa área corresponde a área do painel fotovoltaico. Esses dados são importantes nos dimensionamentos dos sistemas fotovoltaicos que vão desde sistemas de pequeno porte, como os instalados em residências, a sistemas de grande porte, como usinas formadas por milhares de painéis e alocados em regiões abertas com grandes áreas territoriais. Portanto, bancos de dados com dados de irradiação a partir de imagens satelitais e/ou estações de medição são disponibilizados de maneira gratuita na internet, a exemplo do projeto *NASA Predictions Of Worldwide Energy Resources* (NASA POWER) e dos dados disponíveis no *site* do Centro de Referência para as Energias Solar e Eólica Sérgio de S. Brito (CRESESB).

2.1.2 Sistemas de Geração Fotovoltaica

2.1.2.1 Sistemas Isolados

Também conhecido como sistemas *off-grid*, os sistemas fotovoltaicos isolados são caracterizados por não possuírem conexão com a rede de distribuição de energia elétrica, sendo bastante aplicadas em locais remotos, ou seja, onde não é possível construir infraestruturas de redes elétricas. Um esquema de um sistema isolado é ilustrado na Figura 4.

Figura 4 – Esquematização de um sistema isolado de geração fotovoltaica.



Fonte: Autoria Própria


Como ilustrado na Figura 4, os sistemas isolados possuem um sistema de armaze-

namento em bancos de baterias, que acumulam a energia gerada para ser utilizada durante períodos de baixa geração em um dia, inclusive à noite. Também nota-se a presença de um controlador de carga, que é responsável por gerenciar a carga dos bancos de baterias, evitando sobrecargas e/ou descargas excessivas, aumentando sua vida útil. Além disso, considerando que a maioria dos equipamentos residenciais e industriais utilizam a energia na forma de corrente alternada (CA) e visto também que nas conexões elétricas de saída dos módulos solares é produzida corrente contínua (CC), nota-se que é necessário realizar a conversão para corrente alternada nos níveis adequados para que a mesma seja utilizada pelos equipamentos. Para isso, faz-se o uso de um conversor CC/CA (ou inversor) entre a ligação CC dos painéis e a instalação elétrica do local.

2.1.2.2 Sistemas Conectados à Rede

Os sistemas fotovoltaicos mais convencionais são os conectados à rede elétrica. Este tipo de sistema utiliza a energia proveniente da rede elétrica em períodos de baixa geração e no período noturno. Quando há um nível de geração acima do consumido, o excedente também pode ser introduzido na rede, gerando créditos que podem ser utilizados na conta de energia da unidade consumidora. Uma esquematização de um sistema conectado à rede está ilustrado na Figura 5.

Figura 5 – Esquematização de um sistema de geração fotovoltaica conectado à rede elétrica.



Fonte: Autoria Própria


Como pode-se notar na Figura 5, é utilizado um medidor de energia do tipo bidirecional, isto é, que permite registrar o consumo de energia da rede de distribuição e o total de energia proveniente da geração fotovoltaica injetada na rede elétrica. Os sistemas conectados se tornam mais econômicos do que os sistemas *off-grid* por não precisarem de sistemas de armazenamento em baterias, além de terem a vantagem de converter o excedente de energia gerado em créditos que podem ser aproveitados na conta de energia. Isso faz com que os sistemas conectados à rede sejam os mais utilizados em configurações de geração de pequeno porte com geração que não ultrapassa unidades de quilowatts (kW), como em residências, bem como configurações de grande porte, a exemplo de usinas com capacidade de geração que ultrapassam valores em megawatts

(MW). Todavia, os sistemas conectados à rede são os mais afetados pela característica intermitente da energia solar, já que não é possível armazenar a energia. Isso pode acarretar em imprevistos em momentos em que há maior consumo de energia e o sistema não entrega o suficiente. Portanto, faz-se necessário um sistema de previsão preciso para auxiliar o cliente no planejamento do consumo e receita gerada pela geração de energia em um determinado dia no futuro. A ferramenta pode também auxiliar as concessionárias de energia no planejamento do despacho de energia. Portanto um modelo preciso possibilita um retorno econômico favorável para clientes e concessionárias, além de propiciar um consumo sustentável da energia elétrica.

2.2 Redes Neurais Artificiais

Dentro do universo da inteligência artificial pode-se citar dois subconjuntos, que são *machine learning* e *deep learning*, como ilustrado no diagrama da Figura 6. Técnicas de *machine learning* utilizam dados para que seja possível fazer a máquina reproduzir algum comportamento humano, que é a base da inteligência artificial, mas nela são utilizados técnicas puramente estatísticas e nada é programado explicitamente. Nas técnicas de *deep learning* estão as redes neurais artificiais (RNA), que são estruturas inspiradas no neurônio biológico do cérebro humano e possuem grande capacidade de memorização em processos que envolvem extração de padrões e características de grande volume de dados para influenciar em uma saída específica.

Figura 6 – Diagrama com as subdivisões da Inteligência Artificial.




Fonte: Autoria Própria

Portanto, as RNAs são algoritmos que possuem alta capacidade de aprender o comportamento dos dados a partir da extração de suas características e relações entre si. O aprendizado da rede é realizado por meio de um algoritmo iterativo de treinamento que utiliza parte dos dados originais, e a partir desta etapa a rede é capaz de generalizar seu conhecimento para gerar resultados aplicáveis em qualquer situação, isto é, apresentando respostas satisfatórias para dados nunca antes apresentados à rede.

2.2.1 O Neurônio Biológico

A célula elementar do sistema nervoso cerebral é o neurônio e seu papel se resume a conduzir impulsos (estímulos) elétricos, advindos de reações físicos-químicas, sob determinadas condições (SILVA; SPATTI; FLAUZINO, 2010). O cérebro humano possui bilhões de neurônios interconectados e cada um deles é constituído por um corpo central (também denominado soma), diversos dendritos e um axônio, como ilustrado na Figura 7. Os dendritos são responsáveis por receberem os estímulos elétricos de outros neurônios por meio das conexões neurônio a neurônio, denominadas de sinapses. O axônio é o meio de comunicação entre os neurônios e tem a função de propagar a saída de cada corpo central para os dendritos dos próximos neurônios. No soma, ou corpo celular é realizado o processamento e as combinações dos milhares de sinais advindos dos dendritos.

Figura 7 – Representação de um neurônio biológico.



(SILVA; SPATTI; FLAUZINO, 2010)


Os sinais recebidos nos dendritos podem ser ou excitatórios - o que significa que eles tendem a fazer o neurônio disparar (gerar um impulso elétrico) - ou inibitórios - o que significa que eles tendem a evitar que o neurônio dispare (ACADEMY, 2022). Esse sinal é bastante conhecido como limiar de ativação, ou *threshold*. Logo, quando dois sinais excitatórios ou dois sinais inibitórios se encontram, eles podem ser amplificados. Já quando um sinal excitatório se encontra com um inibitório, eles se cancelam. A atenuação e/ou amplificação dos sinais está relacionada a pesos, denominados de pesos sinápticos, que atuam como fator multiplicativo do sinal de origem do neurônio. Portanto, um peso positivo indica um sinal excitatório, enquanto um peso negativo indica um sinal inibitório. Os pesos também podem ser chamados de memória, considerando que seus valores são estabelecidos por meio do treinamento recebido pelo cérebro durante os anos, caracterizando o processo de memorização (BOOK, 2018).

2.2.2 O Neurônio Artificial

Os neurônios artificiais foram propostos em 1943, por Warren McCulloch e Walter Pitts, sendo os modelos de neurônio utilizados nas RNAs e são baseados na concepção do neurônio biológico explicado anteriormente. Os neurônios artificiais são, portanto, formados

por unidades de processamento simples, que são interconectados por ligações com um peso associado e possuem um valor de limiar, conhecido como *bias*. Na Figura 8 está ilustrado um neurônio artificial.

Figura 8 – Representação do neurônio artificial.



Fonte: Autoria Própria

A partir da Figura 8 pode-se fazer uma relação simples do neurônio biológico, ilustrado na Figura 7, com o neurônio artificial. Os impulsos elétricos são representados pelas entradas, as camadas de entrada simbolizam os dendritos e os pesos sinápticos são associados com um valor numérico W_n , onde n é a n -ésima unidade de entrada. Os pesos sinápticos são atualizados a cada iteração na etapa de treinamento da rede, e os valores finais são determinados ao final desta etapa.

A soma ou corpo celular é representada por uma composição de dois módulos, o primeiro é um somatório dos estímulos de entrada, multiplicados pelo seu fator excitatório (pesos sinápticos), e posteriormente uma função de ativação, que definirá com base nas entradas e pesos sinápticos, qual será a saída do neurônio (BOOK, 2018). Além disso, o limiar de ativação (ou *threshold*) é representado pelo *bias*, b_k . Portanto, se a saída de um neurônio possui um valor acima do limiar especificado, este é ativado, enviando dados para a próxima camada da rede (IBM, 2022). Finalmente, as terminações sinápticas são representadas pela saída y .

2.2.2.1 Modelo Matemático do Neurônio Artificial

Portanto, considerando o neurônio artificial apresentado anteriormente, tem-se a seguinte relação para a saída y_k :

$$y_k = \varphi\left(\sum_{i=1}^n W_i X_i - b_k\right) \quad (2.1)$$

Em que y_k é a saída do neurônio artificial, X_i é a i -ésima entrada do neurônio, W_i

é o peso sináptico aplicado na i -ésima entrada, b_k é o limiar de ativação (*bias*) e φ é a função de ativação.

Considerando que a saída do neurônio depende do potencial de ativação para gerar um sinal excitatório ou inibitório, pode-se analisar, da Figura 8 e da Equação 2.1, que o potencial de ativação, u_k , é determinado pela Equação 2.2 a seguir:


$$u_k = W_i X_i - b_k \quad (2.2)$$

Portanto, a partir das equações pode-se indagar que os pesos em um neurônio referem-se ao seu conhecimento, sendo responsáveis por determinar a relevância de cada entrada para a saída y ao atribuir pesos maiores para os dados mais relevantes, fazendo o neurônio gerar um potencia de ativação e, posteriormente, a saída desejada.

2.2.3 O Modelo Perceptron

Idealizado em 1958 por Frank Rosenblatt, o modelo perceptron é uma das primeiras instâncias das redes neurais artificiais, cujo propósito era implementar um modelo computacional baseado na retina do olho humano (ROSENBLATT, 1958). O perceptron é basicamente uma rede composta por um único neurônio, como ilustrado na Figura 9.

Figura 9 – Ilustração do perceptron idealizado por Rosenblatt em 1958.



Fonte: Autoria Própria

O modelo proposto por Rosenblatt é geralmente utilizado para classificação binária, sendo um bom representante de condicionais lógicos (NOT, AND, OR, etc.), com exceção do condicional XOR, que só é possível com a associação de mais de um perceptron. A partir das Figuras 8 e 9, e da equação 2.1, pode-se formular a classificação binária do perceptron como:

$$saída = \begin{cases} 0, & \text{se } W.X \leq b \\ 1, & \text{se } W.X \geq b \end{cases} \quad (2.3)$$


Finalmente, como no neurônio biológico, a saída do neurônio artificial perceptron pode se conectar a outros adjacentes de diversas maneiras, formando uma rede com

topologias diversas e obtendo diferentes resultados. Essas conexões formam uma rede com vários neurônios totalmente interconectados, constituindo a rede neural com a mais simples topologia, conhecida como Rede Perceptron Multicamadas.

2.2.4 Rede Perceptron Multicamadas

A Rede Perceptron Multicamadas, ou *Multilayer Perceptron* (MLP), é uma classe da rede neural *feedforward* totalmente conectada, isto é, possui vários neurônios interconectados em camadas intermediárias, chamadas de camadas ocultas. Diferentemente da rede perceptron, as redes MLP podem ter vários neurônios na camada de saída em problemas com múltiplas variáveis ou, em problemas de previsão, quando se quer obter previsões em diferentes intervalos de tempo. Na Figura 10 está ilustrada uma rede perceptron multicamadas.

Figura 10 – Representação de uma rede perceptron multicamadas



Fonte: Autoria Própria

Para o treinamento da rede, geralmente utiliza-se o algoritmo de *backpropagation*. Esse algoritmo de treinamento calcula os erros entre as saídas dos neurônios das camadas ocultas e da camada de saída para recalcular os pesos destas camadas. Logo após isso, os pesos são atualizados e o algoritmo é executado novamente até atingir um critério de tolerância para o erro.

As redes MLP podem adaptar seus pesos, sendo capazes de modelar funções complexas e descartar entradas irrelevantes e ruído (VELO; LÓPEZ; MASEDA, 2014). Portanto, as redes MLP são frequentemente aplicadas em problemas de previsão em ciência e engenharia devido à sua alta capacidade de aprendizagem e generalização, considerando uma boa calibração de seus hiperparâmetros.


2.2.5 Treinamento da Rede Neural

Analogamente ao processo de memorização que é feito no cérebro humano, as RNAs realizam um processo de treinamento baseados nas entradas que a rede recebe para gerar uma saída específica. Tal processo de treinamento consiste na atualização dos pesos W_n por meio de iterações, também chamadas de épocas. Entretanto, alguns problemas podem ser enfrentados durante o treinamento, que são o *Underfitting* e o *Overfitting*. O *underfitting* acontece quando o modelo não é capaz de identificar a relação entre as variáveis de entrada e a saída, resultando em um erro considerável no conjunto de dados de treinamento e também no conjunto de dados de teste, ambos em relação a saída do modelo. O *overfitting* é o inverso do *underfitting*, com baixos valores de erro nos dados de entrada, mas um alto valor de erro nos dados de teste, resultando num modelo com baixa capacidade de generalização (IBM, 2021). Para resolver os problemas durante a etapa de treinamento podem ser adotadas técnicas de regularização. Dentre as estratégias, que vão desde escolha de variáveis a interrupção do treinamento, a mais utilizada para contornar o problema do *overfitting* é utilizar o *Dropout*.

2.3 *Dropout* como Técnica de Regularização

Segundo (SRIVASTAVA et al., 2014b), a técnica do *dropout* foi desenvolvida com base nos processos de cruzamento e mutação naturais, e a fim de evitar o *overfitting* em redes neurais artificiais. A técnica consiste em retirar, temporariamente, neurônios das camadas (visíveis ou escondidas) da rede neural, bem como suas conexões de entrada e saída, como ilustrado na Figura 11. Como o *dropout* é uma técnica de regularização estocástica, os neurônios são retirados da rede de maneira aleatória durante a fase de treinamento, seguindo uma probabilidade p . Na fase de teste, os pesos de saída de cada neurônio são simplesmente multiplicados por p .

Figura 11 – RNA após aplicação do *dropout*.



Fonte: Autoria Própria

Portanto, a técnica proporciona novas topologias mais otimizadas na mesma rede neural a cada desativação de neurônios, pois novos pesos serão obtidos, que por consequência

novas saídas serão geradas. Uma rede com n unidades (neurônios) pode ser vista como um conjunto de 2^n sub-redes otimizadas (SRIVASTAVA et al., 2014b).

Considerando uma RNA com L camadas escondidas, sendo l o índice de cada camada, com $l \in \{1, 2, \dots, L - 1\}$, $y^{(l)}$ o vetor de saídas da camada l , e ainda $W^{(l)}$ e $b^{(l)}$ os pesos e *bias* da camada l , pode-se escrever matematicamente a saída da rede neural *feedforward*.

$$y_i^{(l+1)} = \varphi(W_i^{(l+1)}y^l + b_i^{(l+1)}) \quad (2.4)$$

Com φ sendo a função de ativação do neurônio.

Aplicando o *dropout*, pode-se reescrever a Equação 2.4, considerando $r^{(l)}$ como sendo um vetor de variáveis aleatórias independentes com distribuição de Bernoulli, com cada uma possuindo probabilidade p , com $p \in [0, 1]$. Logo, tem-se:


$$r^{(l)} \sim \text{Bernoulli}(p), \quad (2.5)$$

$$\tilde{y} = r^{(l)} * y^{(l)}, \quad (2.6)$$

$$y_i^{(l+1)} = \varphi(W_i^{(l+1)}\tilde{y}^{(l)} + b_i^{(l+1)})$$

Na Equação 2.6 é realizado uma multiplicação termo a termo (*) entre o vetor de variáveis aleatórias e o vetor de saída da camada l para criar as saídas otimizadas $\tilde{y}^{(l)}$, que serão utilizadas como entradas para a próxima camada oculta. Na Figura 12 está ilustrada uma rede durante a aplicação do *dropout*. Na etapa de testes, o vetor de pesos é escalonado e multiplicado por p , ou seja, $W_{teste}^{(l)} = pW^{(l)}$ e o restante da operação *feedforward* prossegue agora sem *dropout*.

Figura 12 – RNA durante a aplicação do *dropout*.



Fonte: (SRIVASTAVA et al., 2014b)

Portanto, a probabilidade p é um hiperparâmetro que define a chance da variável aleatória $r^{(l)}$ ser igual a zero, representando a desativação do neurônio. Segundo (SRI-

VASTAVA et al., 2014b) a probabilidade de *dropout* adotada é geralmente de 20% para a camada de entrada e 50% para as camadas escondidas.

Por fim, observa-se que o *dropout* é uma técnica promissora para evitar o *underfitting* em redes neurais artificiais, porém, por ter características estocásticas ao seguir uma distribuição de probabilidade, a técnica vem sendo utilizada para determinar incertezas em modelos de *deep learning*, que aliada a estratégias estatísticas, como o método de Monte Carlo, que se baseia em amostragens aleatórias para obter resultados numéricos.

2.4 Incertezas em Modelos de *Deep Learning*

As fontes de incerteza em um modelo podem ter diversas origens, como ruído nos dados, falta de informações acerca das entradas, dados faltantes, calibração má sucedida dos hiperparâmetros, dentre outros. Tais incertezas podem resultar em problemas em muitas aplicações com inteligência artificial. Por exemplo, em um sistema de pilotagem autônoma de um veículo, um alto valor de incerteza pode ocasionar em graves acidentes. Portanto, classificar e quantificar as incertezas em um modelo pode ser de extrema importância em ferramentas de tomada de decisões e planejamento de operações.

2.4.1 Tipos de Incerteza em *Deep Learning*

Existem dois tipos de incerteza em *deep learning* que são utilizados como base para a maioria dos casos de previsão, que são a **incerteza epistêmica** e a **incerteza aleatória**.

A **incerteza epistêmica** descreve o grau de confiança nos resultados de predição e sua principal causa é a ausência de dados de treinamento do modelo. Portanto, quanto maior a quantidade de dados de entrada, menor a incerteza epistêmica. Pode-se dizer que a incerteza epistêmica é a incerteza ligada diretamente ao modelo.

A **incerteza aleatória** está relacionada diretamente com os dados de entrada. Logo, dados com ruído e alta variância são a principal fonte desse tipo de incerteza. Nesse tipo de incerteza, a adição de mais dados não é suficiente para reduzir o valor da mesma.

Assim sendo, dos tipos de incerteza apresentados, a incerteza epistêmica é a mais desafiadora para se obter, visto que a mesma está diretamente ligada ao modelo e a seu processo de aprendizado. Para conseguir obter a incerteza do modelo, são utilizadas estratégias como treinar uma rede neural Bayesiana, em contrapartida da RNA convencional, cuja característica é puramente determinística.

Em 2015, (GAL; GHAMRANI, 2015) apresentou uma estratégia de baixo custo computacional para obter a incerteza em modelos (epistêmica) baseados em redes neurais artificiais utilizando a técnica do *dropout*, observando-a sob uma perspectiva Bayesiana.

2.5 Dropout como Aproximação Bayesiana de uma RNA

Em comparação com redes neurais não determinísticas, os processos Gaussianos profundos são uma poderosa ferramenta estatística que permite a modelagem de distribuições de funções (GAL; GHAMRAMANI, 2015). Sob a perspectiva Bayesiana, os pesos da RNA são vistos como variáveis aleatórias. Logo, pode-se definir uma distribuição de probabilidade, $P(W)$, para os pesos. Segundo (GAL; GHAMRAMANI, 2015), dada uma matriz de pesos, W_i , formada por variáveis aleatórias para cada camada i , e escrevendo $\omega = \{W_i\}_i^L$, a probabilidade de predição pode ser parametrizada como mostrado na Equação (2.7):

$$p(y_{teste}|x_{teste}, X, Y) = \int p(y_{teste}|x_{teste}, \omega) p(\omega|X, Y) d\omega \quad (2.7)$$

Em que $P(\omega|X, Y)$ é denominada distribuição *a posteriori*. Desta forma, a incerteza pode ser determinada a partir da dispersão dessa distribuição. Contudo, a distribuição da Equação (2.7) é praticamente impossível de computar, sendo necessário a utilização de uma probabilidade mais simples $q(\omega)$, onde as linhas das matrizes de pesos são aleatoriamente zeradas, aproximando a integral da distribuição *a posteriori*. Portanto, pode-se definir $q(\omega)$ como:

$$\begin{aligned} W_i &= M_i \cdot \text{diag}([z_{i,j}]), \\ z_{i,j} &\sim \text{Bernoulli}(p_i), i = 1, 2, \dots, L; j = 1, 2, \dots, K_{i-1} \end{aligned} \quad (2.8)$$

Com p_i sendo as probabilidades da distribuição de Bernoulli, que segue uma distribuição normal com média centrada em zero, M_i uma matriz com variáveis aleatórias com as mesmas dimensões de W_i . Então, pode-se definir uma amostra $\hat{W}$ com a multiplicação de cada elemento de z por uma matriz de parâmetros M , com as mesmas dimensões de W . Em outras palavras, colunas de M são zeradas para se obter $\hat{W}$ (FACURE, 2017).

Portanto, a operação explicada anteriormente, juntamente com as demais demonstrações feitas em (GAL; GHAMRAMANI, 2015), considerando a divergência de Kullback-Leibler entre a probabilidade *a posteriori* aproximada, $q(w)$, e a real, $P(\omega|X, Y)$, é o mesmo adotado quando uma RNA é treinada usando *dropout* com regularização L_2 , que consiste em penalidades aplicadas na função de custo da técnica ao funcionar como fator multiplicativo dos módulos dos pesos, como mostrado na Equação 2.9.

$$\mathcal{L}_{dropout} := \frac{1}{N} \sum E + \lambda \sum (\|W_i\|^2 + \|b_i\|^2) \quad (2.9)$$

Em que N é a quantidade de dados de entrada; E são os erros entre os valores de saída da RNA e os valores reais de teste (*targets*); λ é a matriz *weight-decay*, que define o

grau de penalização do modelo a partir do aumento do valor dos pesos. Portanto, qualquer rede neural treinada utilizando *dropout* pode ser considerada um modelo Bayesiano.

2.5.1 Obtenção das Incertezas

Como apresentado anteriormente, em 2015, Yarin Gal propôs um método para obter as incertezas de um modelo de *deep learning* utilizando o *dropout*. Entretanto, diferentemente do *dropout* original, a técnica proposta é utilizada também na etapa de inferência (teste) do modelo. Ou seja, ao utilizar a técnica, a RNA que antes era determinística, isto é, possuía pesos com valores numéricos, agora é treinada com pesos que seguem uma distribuição de probabilidade, cuja distribuição das predições pode ser dada pela equação (2.10).

$$p(y * | x*) = \int p(y * | x*, \omega) q(\omega) d\omega \quad (2.10)$$

O processo de obtenção de incertezas é manter ativo o *dropout* durante a fase de testes e fazer a obtenção de T valores de previsão $\hat{y}$, para cada amostra na RNA. Esse processo de obtenção de valores é feito ao fazer uma varredura na rede T vezes e colher as amostras de maneira aleatória. Esse tipo de amostragem, bem como o cálculo da integral da Equação (2.10) são feitas utilizando o método de Monte Carlo, o que fez com que a técnica fosse denominada de *Monte Carlo Dropout*. Além disso, as varreduras que são realizadas na rede neural são conhecidas como *foward-passes*. Segundo (GAL; GHAMRANI, 2015), a média das medições pode ser escrita a partir da Equação (2.11).

$$\mathbb{E}(\hat{y}) = \frac{1}{T} \sum_{t=1}^T \hat{y}_t \quad (2.11)$$

Em que $\hat{y}_t$ é cada previsão amostrada na T *foward-pass* pela rede. Além disso, a variância pode ser determinada a partir da Equação (2.12).

$$\text{Var}(\hat{y}) \approx \tau^{-1} + \frac{1}{T} \sum_{t=1}^T \hat{y}_t^T \hat{y}_t - \mathbb{E}(\hat{y})^T \mathbb{E}(\hat{y}) \quad (2.12)$$

Em que τ é uma medida de precisão, sendo representada pela Equação 2.13.

$$\tau = \frac{pl^2}{2N\lambda} \quad (2.13)$$

Assim, para cada ponto, pode-se determinar a previsão para a média e a variância, que será a medida de incerteza. A literatura adota a variância como principal medida de incerteza, porém também pode-se adotar o desvio padrão como incerteza ao calcular a raiz quadrada da variância obtida após os T *foward-passes*.

3 Metodologia


3.1 Descrição dos Dados

Os dados utilizados como base deste trabalho são divididos em dados de potência obtidos de uma usina localizada na cidade de Serra Negra do Norte, no estado do Rio Grande do Norte (RN), e dados meteorológicos do local. Todos os dados foram tratados utilizando a linguagem de programação *Python* e suas bibliotecas adequadas no ambiente do *Google Colab*.

3.1.1 Dados de Geração de Energia

Os dados de potência e energia foram retirados de um banco de dados de geração de uma usina fotovoltaica. Os dados foram colhidos entre 2018 e 2020, com um total de 939 dias e amostragem a cada cinco minutos, sendo disponibilizados em uma planilha do *Excel* em formato *csv* (*comma-separated values*). As informações contidas nos dados incluíam, além da data e hora, medições de corrente, em Ampères (A) e tensão em Volts (V), potência aparente em Volt-Ampère (VA) e energia gerada em Watts-hora (Wh). A variável de interesse para as análises deste trabalho é a energia gerada. Na Figura 13 pode ser visualizada o comportamento da geração de energia durante um dia, onde foram utilizadas as bibliotecas *Pandas* e *Matplotlib* da linguagem *Python* para se obter a imagem a partir dos dados originais.

Figura 13 – Dados de geração colhidos para um dia.




Fonte: Autoria Própria

Como pode-se observar na Figura 13, os dados puderam ser organizados para visualização da quantidade de energia gerada durante um único dia. Todavia, também foi possível obter a visualização do total acumulado de energia gerada durante os três

anos de operação da usina. Isso foi possível obtendo-se o total de energia gerada em cada dia durante anos 2018 e 2020, o que resultou em uma amostra de energia por dia, como ilustrado na Figura 14.

Figura 14 – Energia acumulada por dia durante os anos.



Fonte: Autoria Própria

Como pode-se notar na Figura 14, existem alguns intervalos em que a geração é máxima, correspondendo aos períodos de verão, e outros em que há um decréscimo, sendo os períodos de inverno, caracterizado por tempo nublado e chuvoso, que dificulta a geração de energia, deixando mais evidente o caráter intermitente da energia solar. Além disso, existem picos muito acentuados que podem sinalizar a presença de *outliers* nos dados, isto é, dados faltantes e/ou muito discrepantes, que são consequência de fatores como falta de comunicação entre o servidor *web* e o módulo de comunicação do inversor, perda de conexão com a internet, desligamento programado do inversor para manutenções, dentre outros.

3.1.2 Dados Meteorológicos

Os dados meteorológicos do local foram incluídos com o intuito de auxiliar o modelo de previsão, ao fornecer mais dados de entrada para a RNA. Os dados foram obtidos da plataforma *NASA Prediction Of Worldwide Energy Resources* (NASA POWER), a qual é uma plataforma que disponibiliza gratuitamente um extenso banco de dados solares e meteorológicos obtidos a partir de informações de satélites, amostrados a cada hora, auxiliando a expansão das energias renováveis, construções sustentáveis e agroclimatologia.

Para fazer o *download* dos dados para um determinado local, o usuário precisa informar a latitude e longitude geográficas. Após isso, o usuário seleciona os dados desejados, dentre os diversos disponíveis, que incluem diferentes tipos de irradiação, temperatura, velocidade do vento, umidade, precipitação, ângulo solar, dentre outros.

3.2 Pré-Processamento dos Dados

Já é conhecido que dados faltantes ou variáveis sem relação com o objetivo podem afetar de maneira negativa no desempenho da aprendizagem da rede neural artificial. Portanto, se faz necessária a realização de uma etapa de pré-processamento dos dados de entrada da RNA. Portanto, de posse dos dados necessários, foi iniciada a etapa, que iniciou pela escolha das variáveis a serem incluídas juntamente com os dados de energia provenientes da usina. Primeiramente, foram escolhidas as variáveis que mais faziam sentido com o problema diretamente no banco de dados da NASA, onde foram escolhidas 9 (nove) variáveis. Após isso, foi utilizada uma correlação simples, feita por meio do método *corr()* do *Python*, que utiliza o coeficiente de correlação amostral de Pearson, que pode ser representada pela Equação (3.1).

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.1)$$

Da Equação (3.1) tem-se que r_{xy} é o coeficiente de correlação entre as variáveis x e y , com $\bar{x}$ e $\bar{y}$ sendo as médias amostrais das variáveis e x_i e y_i as amostras individuais de cada variável.

Visto isso, foi possível obter o valor do coeficiente de correlação entre todas as variáveis envolvidas e determinar quais possuem maior relação com a variável de energia produzida, considerando que o valor 1 representa uma correlação perfeita e o valor zero uma correlação nula. Portanto, foram escolhidas variáveis com coeficientes de correlação amostral de Pearson maiores que 0,2, resultando nos dados de irradiação e de clima que estão descritos na Tabela 1.

Tabela 1 – Dados colhidos da plataforma NASA POWER

Dados Obtidos	Unidade	Descrição
Irradiância global horizontal	kWh/m ²	Irradiância total que incide em um plano horizontal na superfície da terra
Índice de céu claro (Kt)	-	Razão entre a irradiância incidente na superfície da terra e a irradiância solar total transmitida através da atmosfera.
Temperatura a 2 metros do solo	°C	Temperatura medida a 2 metros do solo
Umidade relativa a 2 metros do solo	%	Umidade medida a 2 metros do solo
Precipitação	mm	Precipitação (chuva) registrada
Ângulo do zênite solar	graus	Ângulo entre a vertical e o horizonte de visão

Na Tabela1 nota-se a presença de um índice (K_t) que, segundo a plataforma NASA POWER, representa a fração de radiação solar que é transmitida pela atmosfera em relação

a que atinge a superfície da terra. O índice, como descrito, pode ser matematicamente representado por:

$$K_t = \frac{I_r}{I_T} \quad (3.2)$$

Em que I_r é a irradiação que atinge a superfície da terra e I_T é a irradiação total que atinge a atmosfera e é transmitida. Portanto, o índice K_t é adimensional e compreende valores entre 0 e 1. O índice pode ser entendido também como o nível de "clareza" do céu, isto é, o quão limpo está o céu, sinalizando sua relação com a quantidade e densidade de nuvens, que é um dos fatores que atenuam a radiação total antes da mesma atingir a superfície terrestre. Logo, valores mais próximos de 1 representando céu limpo, com poucas nuvens e valores próximos de 0 representando condições de tempo nublado.

3.2.1 Detecção e Remoção dos *Outliers*

A detecção e remoção de dados anômalos e/ou faltantes foi o segundo passo do pré-processamento. Tais dados são conhecidos como *outliers*. Muitos métodos de detecção e correção desses tipos de dados são estudados, sendo a técnica do *z-score* a mais conhecida, como abordado em (ANUSHA et al., 2019). O procedimento de detecção dos *outliers* é relativamente simples utilizando a técnica estatística do *z-score*, que detecta como *outlier* qualquer dado que esteja fora de um intervalo, escolhido neste trabalho como o valor da média dos dados com três vezes o desvio padrão. A expressão matemática do *z-score* é dada pela Equação 3.3.

$$z_n = \frac{x_n - \bar{x}}{\sigma} \quad (3.3)$$

Em que x é o valor da amostra, $\bar{x}$ é a média dos dados e σ corresponde ao desvio padrão. Portanto, no caso específico deste trabalho, se $(x_n - \bar{x}) \geq \pm(3*\sigma)$, o dado é tratado como *outlier*, sendo excluído do conjunto original. Portanto, todo o conjunto de dados meteorológicos e de geração de energia passaram pela detecção e remoção dos outliers.

3.2.2 Suavização dos Gráficos dos Dados


Considerando que algumas variáveis, como as curvas de produção de energia possuem dados que variam consideravelmente em um pequeno intervalo de tempo, foi aplicada uma suavização como mais uma estratégia para facilitar o treinamento da rede neural. Para isso, utilizou-se o artifício da média móvel simples, que calcula a média a partir de uma sequência de amostras dentro da população, sendo bastante utilizada para se observar tendências de um conjunto de dados. Portanto, dado uma sequência

$X = (x_1, x_2, \dots, x_n)$ e sendo n o número de elementos (ou tamanho da janela de dados) de uma subsequência de X , a média móvel pode ser representada pela Equação (3.4).

$$\bar{x} = \frac{x_{i+1} + \dots + x_{i+n}}{n} = \frac{1}{n} \sum_{j=1}^n x_{i+j} \quad (3.4)$$

Com o intuito de melhorar o desempenho da RNA, foi utilizada uma média móvel com uma janela de três amostras vizinhas. Utilizando os dados de energia produzida por dia como exemplo, pode-se obter a Figura 15.


Figura 15 – Geração de um dia com a aplicação da média móvel.



Fonte: Autoria Própria

Analogamente, a média móvel com uma janela de quatro amostras vizinhas foi aplicada nos dados de energia acumulada por dia (Figura 14), já com a correção dos *outliers* aplicada, como ilustrado na Figura 16.

Figura 16 – Geração de um dia com a aplicação da média móvel.



Fonte: Autoria Própria

É importante destacar que foram escolhidas janelas relativamente pequenas para o cálculo da média móvel, para não haver muita perda de informações, já que a média se torna um único valor a partir de amostras vizinhas.

3.2.3 Normalização dos Dados

Normalizar os dados em um intervalo beneficia o modelo de previsão reduzindo seu custo computacional, otimizando o tempo de execução e acelerando a convergência do processo de treinamento. Normalmente os dados são normalizados entre 0 e 1, com a utilização de várias técnicas de normalização. A mais conhecida é a minimax, que foi utilizada neste trabalho e está representada pela Equação (3.5).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.5)$$

Em que x_{norm} corresponde a amostra normalizada, x é o valor da amostra, x_{min} e x_{max} são os valores mínimo e máximo da variável, respectivamente. Com isso, os dados ficam contidos num intervalo de 0 a 1 e posteriormente é feita a operação inversa para determinar o valor da amostra x após as etapas treinamento e teste da RNA. A etapa, neste trabalho, é denominada de desnormalização.

3.3 Modelo de Previsão

Foi construído um modelo de previsão utilizando as bibliotecas *Keras* e *TensorFlow* do *Python*. Todas as análises foram feitas no *Google Colab*.

3.3.1 Formação do Banco de Dados

Considerando que para realizar a previsão de uma determinada variável é necessário utilizar amostras passadas e atuais como entradas da RNA e amostras de dias posteriores como saídas de treinamento e teste. Por exemplo, pode-se utilizar amostras de cinco dias passados, incluindo o dia atual, para prever um único dia futuro. Visto isso, foi construído um banco de dados, que será utilizado para treinamento e teste da rede neural, com as amostras anteriores para cada variável e as amostras futuras da variável de interesse, que é a produção de energia. Portanto, sendo n o número de amostras passadas ou futuras, para uma entrada atual x_k , sua versão com dados passados será escrita como x_{k-n} , e para cada saída atual y_k , sua forma de representação de dados futuros será representada como y_{k+n} . Desta forma, pode-se ilustrar um exemplo na Figura 17, escolhendo os valores a e b como as amostras de referência e N como o número total de amostras que constam nos dados.

3.3.2 Divisão dos Conjuntos de Treino e Teste

Em uma RNA, os dados originais são subdivididos em conjuntos de treinamento e teste. O primeiro será utilizado na etapa de aprendizado da rede, onde se espera um número maior de amostras. O segundo subconjunto é utilizado na etapa de validação das

Figura 17 – Exemplo da estrutura do banco de dados.

Entradas				Saídas			
x_{k-n}	...	x_{k-1}	x_k	y_k	y_{k+1}	...	y_{k+n}
b_n	...	b_1	b_2	a_1	a_2	...	a_n
b_{n+1}	...	b_2	b_3	a_2	a_3	...	a_{n+1}
...	...	...	...	...	...	...	...
b_N	...	b_{N-n}	b_n	a_n	a_{N-n}	...	a_N


Dados de Treinamento

Dados de Validação

saídas da RNA. Não é necessário apresentar um grande volume de dados para a etapa de validação, já que nesta etapa é analisada principalmente a capacidade de generalização da rede.

Neste trabalho, 70% dos dados originais foram separados para o treinamento da rede, e o restante, isto é, 30% dos dados foram utilizados para a etapa de validação da RNA. Na Figura 18 pode ser observada a divisão em subconjuntos de treino e teste das amostras normalizadas de energia gerada em um único dia.

Figura 18 – Divisão dos dados de energia gerada em treinamento e validação.



Fonte: Autoria Própria


Analogamente, para os dados de energia gerada acumulada em um dia durante os anos, tem-se a Figura 19.

Portanto, após determinar a quantidade de dados de treinamento e de validação, foi iniciada a implementação da rede neural artificial, como explicada na seção seguinte.

3.3.3 Topologia da RNA

A topologia da rede neural artificial implementada neste trabalho é do tipo *feed-forward*, a qual consiste num tipo de MLP com todos os seus neurônios interconectados em que o fluxo de informações segue em uma única direção, que no caso deste trabalho vai das entradas para a saída. A escolha dessa topologia se baseou na sua capacidade de

Figura 19 – Divisão dos dados de energia gerada em treinamento e validação.



Fonte: Autoria Própria

lidar com não-linearidades nos dados, que aliadas a algoritmos de treinamento como o *backpropagation* e otimizadores, as mesmas acabam por se tornar bastante adaptáveis a diferentes problemas. Além disso, elas possuem grande simplicidade de implementação e configuração de seus hiperparâmetros, o que facilita o controle da execução da RNA com o devido ajuste dos parâmetros, evitando problemas comuns, como *underfitting* e *overfitting*, ao simplesmente analisar os resultados avaliados pelas métricas adequadas.


3.3.3.1 Escolha dos Hiperparâmetros da RNA

Na Figura 20 está ilustrada a RNA com a topologia adotada, bem como a disposição das entradas e saída do modelo de previsão, onde o índice n representa a quantidade de amostras passadas, e i representa a quantidade de amostras futuras, no caso das saídas. O índice k representa a k -ésima amostra de referência do banco de dados, isto é, as amostras passadas e futuras serão referentes a amostra na posição k do banco de dados.

Nota-se na Figura 20 que a camada de entrada é composta por neurônios com o valor atual de cada variável e também com seu valor atrasado de n dias. As saídas são formadas por neurônios com o valor da variável de interesse com um avanço de i dias, sendo estas os resultados da predição. Desta forma, com o auxílio das descrições dos dados meteorológicos da Tabela 1, além dos dados de energia colhidos da usina, pode-se nomear as entradas da RNA como:

- IGH: Irradiação Global Horizontal
- K_t : Índice de clareza do céu
- T_{2m} : Temperatura a 2 metros do solo

Figura 20 – Topologia da RNA implementada para o problema de previsão.



Fonte: Autoria Própria

- U_{2m} : Umidade Relativa a 2 metros do solo
- P_{mm} : Precipitação registrada no local
- α_{zenite} : Ângulo do zênite solar
- E_{kWh} : Energia gerada em kWh

A rede é formada por duas camadas ocultas, cada uma com 50 neurônios e função de ativação do tipo *Rectified Linear Unit* (ReLU). A escolha da função ReLU se baseou no fato de que seu intervalo de atuação fica ilimitado a partir de zero, sendo recomendada para os dados de validação do problema, que são positivos e maiores que zero. Além disso, a ReLU é mais rápida e fácil de computar do que outras funções de ativação, sendo a mais utilizada em problemas de regressão com RNA. A rede neural implementada utiliza o algoritmo de *backpropagation* durante o treinamento, a qual é o algoritmo padrão de treinamento quando se implementa um modelo do tipo *Sequential* da biblioteca *Keras* da

linguagem *Python*. A função de custo escolhida para atualização dos pesos a cada iteração da RNA foi o erro médio quadrático, do inglês *Mean Squared Error* (MSE), o qual é um estimador do erro que calcula o valor quadrático da diferença entre o valor da saída da RNA (valor predito) e o valor real. O MSE pode ser dado pela Equação (3.6).

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2 \quad (3.6)$$

Em que N é o número de amostras, y_i é o valor atual da amostra e $\hat{y}$ é o seu valor estimado em um intervalo futuro.

3.3.4 Métricas de Avaliação do Modelo

As métricas de avaliação do modelo avaliam se o mesmo é robusto o suficiente para generalizar os valores obtidos em suas saídas para qualquer situação, realizando a estimação dos erros em relação a valores nunca antes apresentados à rede. Portanto, são indicativos da ocorrência dos fenômenos de *overfitting* ou *underfitting*, quando se fazem comparações entre os erros obtidos durante as etapas de treinamento e validação.

3.3.4.1 Erro Absoluto Médio

O erro médio absoluto, do inglês *Mean Absolute Error* (MAE), é um estimador de precisão do modelo, que realiza o cálculo do valor absoluto médio da diferença entre o valor real e o valor obtido na saída da RNA (valor predito). O MAE pode ser representado matematicamente pela equação (3.7).

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}| \quad (3.7)$$

Em que N é o número de amostras, y_i é o valor atual da amostra e $\hat{y}$ é o seu valor estimado em um intervalo futuro. O MAE aplica um peso menor nos erros, logo, se houver algum *outlier* nos dados, este não afetará a métrica de maneira significativa, como acontece na MSE. Portanto, valores de erro próximos a zero indicam que o modelo consegue generalizar bem os valores de suas saídas.

3.3.4.2 Erro Percentual Absoluto Médio

O erro percentual absoluto médio, do inglês *Mean Absolute Percentage Error* (MAPE), é um estimador dos erros do modelo, o qual realiza o cálculo do erro percentual da saída de previsão em relação ao valor real. O MAPE pode ser representado pela Equação (3.8).

$$MAPE = 100\% * \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}}{y_i} \right| \quad (3.8)$$

Em que N é o número de amostras, y_i é o valor atual da amostra e $\hat{y}$ é o seu valor predito (saída da RNA). Portanto, o MAPE pode ser definido também como uma extensão do MAE, possibilitando uma compreensão mais abrangente do resultado ao estimar os erros absolutos do modelo e representá-los em forma de porcentagens, ao multiplicar o fator do somatório por 100%.

3.3.4.3 Raiz do Erro Médio Quadrático

A raiz quadrática média do erro, do inglês *Root Mean Squared Error* (RMSE) é uma métrica de avaliação que se baseia na raiz quadrada do MSE. A expressão matemática da RMSE pode ser vista na Equação 3.9.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (3.9)$$

Em que N é o número de amostras, y_i é o valor atual da amostra e $\hat{y}$ é o seu valor estimado. A RMSE possui maiores penalizações aos valores com maiores discrepâncias em relação ao valor real, sendo mais sensível a *outliers*, diferentemente do que acontece com o MAE.

4 Resultados


Nesta seção serão apresentados os resultados de previsão de energia obtidos do modelo implementado, além das análises das incertezas associadas. Para investigar o comportamento do modelo com diferentes tipos de curva de geração de energia, as análises foram feitas por estação do ano, com o intuito de se obter um método para auxiliar o planejamento do despacho de energia em tais períodos.

4.1 Modelo de Previsão

Inicialmente foi implementado um modelo de previsão de energia baseado nos dados obtidos de uma usina localizada em Serra Negra do Norte (RN). Além disso, foram colhidos dados meteorológicos do local, os quais foram juntados aos dados de geração de energia e pré-processados, como explicado na seção anterior.

Foi observado que a curva de geração de energia diária, bem como o total de energia produzido possuíam variações a depender da estação do ano, onde os registros com maior produção de energia ocorriam no verão e os menores no inverno, devido ao típico período chuvoso e com muitas nuvens, que afetam diretamente na geração fotovoltaica. Na Figura 21 é ilustrado o tipo de curva de geração para um dia de cada estação do ano, obtidos dos dados originais antes passar pela etapa de pré-processamento, com a correção dos *outliers* e suavização da curva com média móvel.

Figura 21 – Tipos de curva de geração para um dia de cada estação do ano.



Fonte: Autoria Própria

A partir da Figura 21 pode-se observar que há menos geração de energia durante o

inverno do que no verão, notadamente vista pela significativa variação dos pontos da curva, que é resultante, dentre outros fatores, da presença de nuvens, características dessa época do ano. Portanto, as análises desta seção serão feitas considerando os dados de geração por estação do ano, tanto no cenário de geração durante o dia, quanto no caso do valor acumulado por dia durante os anos. O intervalo de predição se manterá fixo em todas as análises, o qual foi escolhido para cada cenário como segue:

- Caso 1: Previsão de geração durante o dia

Fazer previsões de 1 (uma) hora adiante considerando 6 (seis) amostras de horas passados.

- Caso 2: Previsão de geração acumulada em um dia

Fazer previsões de 1 (um) dia a frente considerando 7 (sete) amostras de dias passados. Em outras palavras, será feita a previsão de curto prazo de um dia a partir de 7 dias anteriores.

4.2 Caso 1: Previsão de geração durante o dia

Como dito anteriormente, foi escolhido arbitrariamente um intervalo de predição de 6 horas anteriores para previsão de 1 hora adiante. Os resultados foram avaliados com as métricas MAE e RMSE. Foi adicionada a estratégia do *early stopping* no modelo, interrompendo a execução do mesmo quando o erro de validação começar ficar consideravelmente acima do erro de treinamento, levando em conta uma janela de 10 repetições. Visando analisar o comportamento do modelo de previsão com diferentes tipos de curva de geração, os resultados foram separados por estação do ano. Os resultados estão apresentados na Tabela 2, onde foi obtida o total de geração registrada em um dia de cada estação do ano, além do desempenho avaliado pelas métricas MAE e RMSE.

Tabela 2 – Desempenho do modelo de previsão considerando a geração durante um dia.

	Geração Registrada (kWh)	Geração Prevista (kWh)	MAE	RMSE
Verão	16,69	16,03	0,085	0,156
Outono	14,31	14,87	0,133	0,246
Inverno	10,30	12,87	0,110	0,206
Primavera	12,62	12,94	0,081	0,157


Como pode ser observado na Tabela 2, os valores do MAE e RMSE são maiores nos períodos de outono e inverno, indicando que o modelo não consegue prever bem dados que tenham muita variação em pequenos intervalos de tempo, sinalizando uma alta incerteza

dos resultados e sugerindo análises de quantificação das mesmas. Isso também é notado na diferença entre o total da geração registrada nos dados originais após o pré-processamento e os resultados do modelo para as estações do inverno e outono, onde no inverno a diferença foi superior a 2 kWh.

4.3 Caso 2: Previsão de geração acumulada por dia

Analogamente ao que foi feito para o caso anterior, o desempenho do modelo de previsão foi avaliado também para os dados de geração de energia acumulada por dia, durante os anos. Foi escolhido analisar a previsão da geração total acumulada de um único dia a partir de uma semana de amostras anteriores. Na Figura 22 ilustra-se o comportamento das curvas de geração para cada estação do ano, onde a curva azul representa o dado real e a vermelha o dado previsto pela RNA.

Figura 22 – Comportamento da curva de geração de energia acumulada por dia durante os anos



Fonte: Autoria Própria

Neste caso também é observada a dificuldade da RNA em realizar a previsão nas estações do outono e inverno, devido às variações presentes nos dados. Vale salientar que neste caso, como são menos amostras apresentadas ao modelo, já que há uma amostra por dia, há uma diminuição no custo computacional quando comparado ao caso 1, onde os dados são amostrados por hora do dia. Além disso, como não existem dados com valor igual a zero nos dados de geração acumulada, pode-se avaliar o desempenho do modelo utilizando também a métrica MAPE, para uma melhor interpretabilidade dos resultados. Portanto, pode-se mostrar os resultados deste cenário na Tabela 3.

Tabela 3 – Desempenho do modelo para o caso de geração acumulada por dia

	Geração Registrada (kWh)	Geração Prevista (kWh)	MAE (kWh)	RMSE (kWh)	MAPE (%)
Verão	14,51	14,07	0,344	0,450	2,721
Outono	12,91	13,14	0,434	0,542	3,588
Inverno	13,85	13,14	0,329	0,428	2,496
Primavera	14,33	14,96	0,249	0,319	1,839

No cenário de geração acumulada por dia, nota-se que o modelo conseguiu alcançar resultados satisfatórios, com erros percentuais, avaliados pela métrica MAPE, menores que 5%. Todavia, nota-se que os maiores erros ainda permanecem nas estações do outono e inverno. Os valores elevados da RMSE sugerem que as curvas de geração variam muito nas épocas do inverno e outono, resultando em penalidades maiores para tais valores que se distanciam da média calculada, como mostrado no termo quadrático da Equação (3.9). A métrica MAE penaliza menos os dados, que é refletido pelos valores menores do que os avaliados pela RMSE.

4.4 Análises das Incertezas do Modelo de Previsão

Após implementar o modelo de previsão baseado, foram iniciadas as análises das incertezas epistêmicas, isto é, as incertezas do modelo, analisando em qual estação do ano o modelo lida com maiores incertezas. Para isso, foram realizados 1000 *forward passes* na rede neural implementada anteriormente, considerando os mesmos hiperparâmetros, para colher a mesma quantidade de previsões para cada amostra, e a partir disso, calcular a incerteza do modelo pelo método do Monte Carlo *dropout*. É conhecido que a incerteza calculada pelo método é a variância, como demonstrado na equação (2.12), porém, neste trabalho será calculado o desvio padrão dos dados. A fim de analisar a influência do parâmetro τ na incerteza do modelo, serão feitas mudanças nos valores das variáveis de τ , como a probabilidade de *dropout* (p), peso da regularização L2 (λ) e length scale (l).

4.4.1 Influência da Probabilidade de *Dropout*

Com o intuito de analisar como o hiperparâmetro probabilidade de *dropout* das camadas escondidas impactava na incerteza do modelo de previsão para os casos estudados, foi realizada a execução da rede neural artificial variando a probabilidade de *dropout* das camadas escondidas de 10% a 50%, mantendo a probabilidade das camadas de entrada em zero. A escolha do intervalo se baseou na sugestão do trabalho de (SRIVASTAVA et al., 2014a). As variáveis de τ , por padrão, foram escolhidas como sendo iguais a $\lambda = 1 \times 10^{-4}$, $p = 0,3$, $l=0,1$ e N como o número de amostras para cada caso. Os resultados podem ser

vistos na Tabela 4.

Tabela 4 – Incertezas máximas associadas para cada probabilidade de *dropout*.

		Incerteza Máxima (kWh)				
		p = 10%	p = 20%	p = 30%	p = 40%	p = 50%
Caso 1	Verão	0,146	0,212	0,255	0,277	0,355
	Outono	0,159	0,230	0,269	0,308	0,373
	Inverno	0,167	0,246	0,282	0,324	0,402
	Primavera	0,165	0,234	0,273	0,316	0,384
Caso 2	Verão	0,322	0,378	0,624	0,685	0,804
	Outono	0,356	0,368	0,597	0,729	0,815
	Inverno	0,262	0,328	0,329	0,553	0,588
	Primavera	0,299	0,365	0,549	0,637	0,798

Portanto, nota-se que a probabilidade de *dropout* afeta de maneira significativa no intervalo de confiança da previsão, com a a incerteza aumentando ao passo de que aumenta-se a probabilidade de *dropout*. Para representar graficamente os dados da Tabela 4, pode-se escolher um exemplo de cada caso de estudo. Para isso, foi escolhida a estação do inverno para o primeiro caso e a primavera para o segundo caso. Cada nível (shade) de cor representa um valor diferente de probabilidade e o tamanho de cada intervalo é referente a um desvio padrão em relação a média das previsões de cada amostra.


- Caso 1: Previsão de geração durante o dia

No inverno houve maiores valores de incerteza máxima, devido às grandes variações frequentes nos dados de geração de energia. Neste caso, foi encontrada uma incerteza máxima de 0,402 kWh. Uma ilustração pode ser encontrada na Figura 23. Observa-se que o intervalo de confiança possui um tamanho maior no momento em que há as variações mais bruscas dos dados, no horário das 8h às 12h. Ou seja, as não-linearidades frequentes que ocorrem nesta estação do ano afetam a incerteza significativamente, ao passo do aumento da probabilidade de *dropout*, sendo a estação do ano que possui maior incerteza associada.

- Caso 2: Previsão de geração acumulada por dia


No segundo caso de estudo, observou-se um alto intervalo de predição nos primeiros meses da primavera, como observado na Figura 24, sinalizando uma grande incerteza neste período, o que não acontece nos outros períodos. Isso acontece devido ao período chuvoso do final do inverno, com muitas nuvens. A incerteza máxima neste caso foi de 0,798 kWh também para a maior probabilidade de *dropout* adotada, no começo da primavera. Além disso, a Figura 24 demonstra uma das vantagens do método estudado e de se utilizar a

Figura 23 – Intervalos de predição da geração de um dia durante o inverno para cada probabilidade de *dropout*



Fonte: Autoria Própria

Figura 24 – Intervalos de predição da geração acumulada por dia durante a primavera para cada probabilidade de *dropout*



Fonte: Autoria Própria

divisão por estação do ano, que é analisar em que períodos da estação do ano há maiores incertezas, auxiliando no planejamento da operação.

Como observado nas figuras anteriormente, quanto maior a probabilidade de *dropout* para este caso de estudo, menos preciso será o modelo de previsão, já que suas saídas podem assumir valores que se distanciam muito do valor médio das previsões para cada amostra, indicando maior aleatoriedade dos resultados ao aumentar-se a quantidade de unidades desativadas na RNA. Além disso, observa-se que não houve alterações significativas na curva de geração prevista. Logo, o hiperparâmetro p possui maior influência na incerteza do modelo, sem grandes impactos na previsão em si.

O valor de p adequado para o problema estudado foi de 30%. Todavia, é importante destacar que valores acima de 80% podem ter resultados satisfatórios, sendo recomendado o valor de 50% para o hiperparâmetro p , segundo (SRIVASTAVA et al., 2014b). Entretanto, o intervalo das análises abordadas neste trabalho foi escolhido a fim de analisar o impacto

de baixos valores de probabilidade no caso específico de previsão de geração de energia, considerando diferentes comportamentos da curva de geração ao longo das estações do ano. Além disso, como abordado por (GAL; GHAHRAMANI, 2015), as não linearidades da função de ativação ReLU também contribuem com o comportamento observado anteriormente, já que a mesma não é limitada como outras funções, a exemplo da tangente hiperbólica.

4.4.2 Influência da Regularização L2

A regularização L2 é uma técnica bastante utilizada em redes neurais artificiais para se evitar principalmente os fenômenos do *underfitting* e *overfitting*. Na obtenção de incertezas do modelo utilizando a técnica do Monte Carlo *Dropout*, a regularização L2 possui um peso associado à variável τ , onde a mesma é nomeada de λ . Por ser um hiperparâmetro da RNA, o valor do peso da regularização pode ser alterado pelo usuário. Portanto, o peso foi variado de 1×10^{-6} a 1×10^{-2} e aplicado nos dois casos estudados neste trabalho. Os resultados se encontram a seguir, onde, nas figuras, cada nível de cor representa um valor diferente de λ . Na Tabela 5 podem ser vistos as incertezas máximas para cada valor de λ em cada estação do ano para cada caso estudado.

Tabela 5 – Incertezas máximas associadas para cada valor de peso da regularização L2.

		Incerteza Máxima (kWh)				
		$\lambda = 1 \times 10^{-6}$	$\lambda = 1 \times 10^{-5}$	$\lambda = 1 \times 10^{-4}$	$\lambda = 1 \times 10^{-3}$	$\lambda = 1 \times 10^{-2}$
Caso 1	Verão	0,373	0,313	0,358	0,346	0,481
	Outono	0,444	0,357	0,387	0,376	0,487
	Inverno	0,434	0,374	0,412	0,393	0,486
	Primavera	0,420	0,350	0,395	0,378	0,485
Caso 2	Verão	0,936	0,784	0,754	0,754	0,593
	Outono	1,209	0,840	0,719	0,803	0,534
	Inverno	0,679	0,580	0,609	0,598	0,731
	Primavera	0,846	0,730	0,831	0,622	0,729


Analogamente ao que foi feito na seção anterior, foram escolhidas as estações do inverno para exemplificar o primeiro caso de estudo e a estação do outono para exemplificar o segundo caso, sendo as estações do ano com maiores incertezas associadas a um determinado valor de peso de regularização L2 em cada caso de estudo.

- Caso 1: Previsão de geração durante o dia

Durante o inverno, foi obtida uma incerteza máxima de 0,486 para o caso de geração de energia durante o dia, para $\lambda = 1 \times 10^{-2}$. Os valores de incerteza para o caso de estudo pode ser vista na Figura 25, onde nota-se que os momentos de maiores incertezas estão no

horário das 8h às 12h, como no caso anterior. Todavia, é observado que a alteração do peso da regularização não afeta a incerteza em si, mas afetando de maneira significativa as curvas de previsão, indicando que a alteração dos pesos da regularização L2 são impactantes no resultado final do treinamento da RNA, resultando em problemas de *underfitting* caso tais pesos não sejam escolhidos corretamente.

Figura 25 – Intervalos de predição no caso de estudo 1 para cada valor de λ




Fonte: Autoria Própria

- Caso 2: Previsão de geração acumulada por dia

No caso de estudo 2 na estação do outono, obteve-se uma incerteza máxima de 1,209 kWh para $\lambda = 1 \times 10^{-6}$. O resultado é ilustrado na Figura 26, onde cada nível de cor representa um valor diferente de λ . Observa-se que o fenômeno de *underfitting* é bem evidente neste caso, já que o peso da regularização é significativamente pequeno. Todavia, diferentemente do primeiro caso de estudo, é visto que a incerteza foi evidentemente alterada juntamente com a alteração dos pesos, fato resultante das variações ocorridas nos dados e do fenômeno do *underfitting*.

Portanto, nas análises das variações do hiperparâmetro, no primeiro caso estudado, nota-se que não houveram alterações significativas na incerteza do modelo, todavia é evidente o efeito do *underfitting* no modelo em ambos os casos quando os valores da regularização são alterados. Isso é observado nas curvas de previsão, que se distanciam demasiadamente do valor original de geração. O motivo é que o peso atua como um fator multiplicador dos pesos da rede neural, afetando as saídas de acordo com a magnitude do valor. Nota-se também que todas as estações do ano, exceto o inverno, apresentaram incertezas máximas com baixos valores de pesos de regularização, sendo este igual $\lambda = 1 \times 10^{-2}$. Isso deve-se ao fato de que as variações nos dados desta estação do ano demandam um maior peso na regularização para que se evite o fenômeno do *overfitting*.

Figura 26 – Intervalos de predição no caso de estudo 2 para cada valor de λ 

Fonte: Autoria Própria

4.4.3 Influência do *length scale*

O *length scale* é uma variável que não influencia nas etapas de treinamento e teste da rede neural, mas está diretamente ligada à precisão do modelo, sendo uma das variáveis do parâmetro de precisão τ . Além disso, l pode ser definido como a crença *a priori* nas variações dos dados, ou seja, valores elevados de l indicam uma menor crença nas variações dos dados.


Para realizar as análises desta seção, o parâmetro foi variado entre 0,001 e 10, e posteriormente foi calculada a incerteza máxima relacionada a cada valor de l em cada caso de estudo, considerando todas as estações do ano. O cálculo pode ser realizado de maneira simples, por meio da Equação (2.13), que é aplicada na equação da incerteza, cuja expressão é dada pela Equação 2.12. Portanto, o *length scale* não altera o resultado das previsões, já que o mesmo não entra na execução da RNA, sendo que na obtenção das incertezas do modelo, o parâmetro se torna um simples ganho no valor final da incerteza, onde menores valores resultam em maiores incertezas. Na Tabela 6, estão listadas as incertezas máximas de geração de energia, em kWh, para cada caso de estudo, considerando os diferentes valores de *length scale* adotados.

- Caso 1: Previsão de geração durante o dia

Para o primeiro caso de estudo de geração de energia, nota-se que quanto menor o valor de l , maior será a incerteza associada, já que o mesmo está associado à variação dos dados. Além disso, o aumento da área da região do intervalo de previsão deve-se ao fato de que após a realização da operação inversa de τ (τ^{-1}), o valor de l fica no denominador da expressão da incerteza (Equação (2.12)), e como está elevado ao quadrado, quanto menor o valor, maior o valor de τ , e por consequência, maior o valor da incerteza.

Tabela 6 – Incertezas máximas associadas para cada *length scale*.

		Incerteza Máxima (kWh)				
		$l = 0,001$	$l = 0,01$	$l = 0,1$	$l = 1$	$l = 10$
Caso 1	Verão	2,539	0,404	0,365	0,381	0,352
	Outono	2,545	0,430	0,385	0,413	0,380
	Inverno	2,546	0,449	0,426	0,442	0,413
	Primavera	2,547	0,434	0,395	0,425	0,388
Caso 2	Verão	0,972	0,850	0,748	0,737	0,853
	Outono	0,998	0,861	0,920	0,793	0,905
	Inverno	0,796	0,664	0,603	0,549	0,649
	Primavera	0,858	0,706	0,779	0,685	0,751


Figura 27 – Intervalos de predição no caso de estudo 1 para cada valor de l 

Fonte: Autoria Própria

- Caso 2: Previsão de geração acumulada por dia

Para o caso de estudo 2, o maior valor de incerteza também foi para $l=0,001$, pelo mesmo motivo explicado no caso anterior. Também é importante destacar que para o caso do outono, onde foi registrada a maior incerteza, pode-se observar que durante alguns meses da estação do ano o valor da incerteza para $l=0,1$ se aproxima demasiadamente do valor da incerteza para $l=0,001$, como demonstrado na Figura 28. Isso deixa evidente a vantagem do método em se analisar as incertezas também em meses dentro da estação do ano, resultando numa maior calibração dos parâmetros da RNA e do modelo de previsão, sugerindo-se um ajuste dos mesmos em tempo real.

Portanto, como observado nas figuras anteriores e na Tabela 6, as incertezas do modelo são elevadas quando se adota pequenos valores de l , sendo que no caso 1 a variação é demasiadamente maior que no caso 2, já que a variação dos dados é mais frequente na geração acumulada por dia do que no caso de geração durante o dia. Além disso, também nota-se que no caso 1 as incertezas máximas são praticamente iguais, e no caso 2 há maior incerteza durante a estação do outono.

Figura 28 – Intervalos de predição no caso de estudo 1 para cada valor de l 

Fonte: Autoria Própria

Por fim, tem-se que para cada caso de estudo há especificidades relacionadas a variação e características dos dados, que resultam em diferentes comportamentos do modelo de previsão. Foi observado que nos períodos onde os dados tinham maior variação durante o tempo a incerteza relacionada era maior que em outras estações do ano. Portanto, uma das vantagens de se analisar a incerteza nos dois casos de estudo é observar a área do intervalo de incerteza em cada época do ano durante os anos e em um determinado dia do ano, auxiliando tanto concessionárias de energia para geração a longo prazo, quanto a pequenos clientes quando se trata de planejamento a curto prazo de sua geração local.

5 Conclusões

Neste trabalho foram analisados as incertezas em um modelo de previsão baseado em redes neurais artificiais aplicado a um caso de geração em uma usina fotovoltaica. A partir dos resultados obtidos na primeira análise, pôde-se concluir que o comportamento da curva de geração é diferente para cada estação do ano, com o maior total de geração durante o verão, que compreende os meses de dezembro a março, e menor geração durante o inverno, que compõe os meses de junho a setembro, característicos por possuírem clima chuvoso e nublado.

Foi observado que os dados no inverno possuíam muitas variações durante as horas do dia, que é consequência da grande ocorrência de nuvens, que afeta significativamente a geração fotovoltaica. Essa variação abrupta nos dados observados afetou o desempenho do modelo de previsão, onde foi constatado que nos períodos de inverno e outono as previsões possuíam resultados piores nas métricas de avaliação do que em outras épocas do ano, como mostrado na Tabela 2 e Tabela 3, onde foram alcançados um erro percentual médio de 3,58% para o inverno.

As variações constatadas resultaram em maiores incertezas no modelo de previsão implementado, que foram estimadas por meio do Monte Carlo *Dropout* a partir da aproximação Bayesiana da RNA, utilizando o desvio padrão como medida de incerteza, visando uma maior interpretabilidade dos resultados. Contudo, as incertezas permaneceram em um patamar aceitável para operação do sistema, ficando abaixo de 3% em relação ao máximo valor de geração registrado. Uma das vantagens observadas pelo método é identificar os períodos em que há maiores incertezas na geração, auxiliando no planejamento e tomada de decisões na operação de usinas solares. Também foi observado que o modelo teve um desempenho satisfatório para os parâmetros escolhidos quando se analisa a incerteza máxima alcançada, a qual foi inferior a 1 kWh para os dois casos estudados. Esse valor de incerteza também foi alterado com a mudança dos hiperparâmetros da rede neural, onde buscou-se determinar os melhores valores, que retornassem as menores incertezas possíveis. Após as análises, pode-se concluir que todos os parâmetros exercem algum tipo de influência na incerteza do modelo, mesmo que a maioria deles não alterem o resultado de previsão em si.

Finalmente, pode-se sugerir como trabalhos futuros a melhor categorização dos dados das curvas de geração diária, por meio de algoritmos de clusterização utilizados em *machine learning*. Além disso, pode-se implementar métodos mais robustos para identificação e correção dos *outliers* do modelo. Também pode-se fazer uma calibração dos hiperparâmetros da rede neural, utilizando técnicas de busca, como o *grid search* ou

até mesmo métodos baseados em busca exaustiva (gerar e testar). Além disso, também sugere-se a criação de uma interface voltada para a interação do usuário com a ferramenta, que auxilia tanto as concessionárias de energia quanto os pequenos clientes. Por fim, pode-se comparar os resultados da topologia implementada neste trabalho com outras, a exemplo das Redes Neurais Recorrentes, do inglês *Recurrent Neural Networks* (RNN), onde se enquadram as redes neurais de memória de curto prazo, ou *Long Short-Term Memory* (LSTM).

Referências

- ACADEMY, K. *Visão geral da estrutura do neurônio e a sua função*. 2022. Disponível em: <<https://pt.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/overview-of-neuron-structure-and-function>>. Citado na página 24.
- ANUSHA, P. V. et al. Detecting outliers in high dimensional data sets using z-score methodology. *International Journal of Innovative Technology and Exploring Engineering*, 2019. Citado na página 36.
- AUPKE, P. et al. Quantifying uncertainty for predicting renewable energy time series data using machine learning. *Engineering Proceedings*, v. 5, n. 1, 2021. ISSN 2673-4591. Disponível em: <<https://www.mdpi.com/2673-4591/5/1/50>>. Citado na página 18.
- BABU, M. K.; RAY, P. A wavelet neural network model for hourly solar radiation forecasting from daily solar radiation. In: *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*. [S.l.: s.n.], 2019. p. 1–5. Citado na página 17.
- BOOK, D. L. 2018. Disponível em: <<https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>>. Citado 2 vezes nas páginas 24 e 25.
- EIA. 2022. <<https://www.eia.gov/>>. (Acessado em 30/04/2022). Citado 2 vezes nas páginas 16 e 17.
- ELA, E. et al. Impacts of variability and uncertainty in solar photovoltaic generation at multiple timescales. 5 2013. Disponível em: <<https://www.osti.gov/biblio/1081387>>. Citado na página 18.
- ELAVARASAN, R. M. et al. A comprehensive review on renewable energy development, challenges, and policies of leading indian states with an international perspective. *IEEE Access*, v. 8, p. 74432–74457, 2020. Citado na página 16.
- FACURE, M. 2017. Disponível em: <<https://lamfo-unb.github.io/2017/10/22/Monte-Carlo-Dropout/#mc-dropout>>. Citado na página 31.
- GAL, Y.; GHAMRANI, Z. *Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning*. arXiv, 2015. Disponível em: <<https://arxiv.org/abs/1506.02142>>. Citado 4 vezes nas páginas 30, 31, 32 e 50.
- IBM. *What is Underfitting?* 2021. Disponível em: <<https://www.ibm.com/cloud/learn/underfitting>>. Citado na página 28.
- IBM. 2022. <<https://www.ibm.com/cloud/learn/neural-networks>>. (Acessado em 06/05/2022). Citado na página 25.
- JAIDEE, S.; PORA, W. Deep neural network based on genetic algorithm and ensemble methods for regional solar power forecasting in thailand. In: *2019 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS)*. [S.l.: s.n.], 2019. p. 377–380. Citado na página 18.

- LIU, L. et al. Prediction of short-term pv power output and uncertainty analysis. *Applied Energy*, v. 228, p. 700–711, 2018. ISSN 0306-2619. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306261918309826>>. Citado na página 18.
- MASTERS, G. M. Photovoltaic materials and electrical characteristics. In: _____. *Renewable and Efficient Electric Power Systems*. John Wiley & Sons, Ltd, 2004. cap. 8, p. 445–504. ISBN 9780471668824. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/0471668826.ch8>>. Citado na página 20.
- MUTAVHATSINDI, T.; SIGAUKE, C.; MBUVHA, R. Forecasting hourly global horizontal solar irradiance in south africa using machine learning models. *IEEE Access*, v. 8, p. 198872–198885, 2020. Citado na página 17.
- NAZREEN, P. M.; RAMAKRISHNAN, A. G. Improving generalization of monte carlo dropout based dnn ensemble model for speech enhancement and results on real world, traffic noise. In: *2019 IEEE 16th India Council International Conference (INDICON)*. [S.l.: s.n.], 2019. p. 1–4. Citado na página 18.
- PAWAR, P.; MITHULANANTHAN, N.; RAZA, M. Q. Solar pv power forecasting using modified svr with gauss-newton method. In: *2020 2nd Global Power, Energy and Communication Conference (GPECOM)*. [S.l.: s.n.], 2020. p. 226–231. Citado na página 17.
- PAZIKADIN, A. R. et al. Solar irradiance measurement instrumentation and power solar generation forecasting based on artificial neural networks (ann): A review of five years research trend. *The Science of the total environment*, Elsevier B.V, Netherlands, v. 715, p. 136848–136848, 2020. ISSN 0048-9697. Citado na página 17.
- PREMA, V. et al. Critical review of data, models and performance metrics for wind and solar power forecast. *IEEE Access*, v. 10, p. 667–688, 2022. Citado na página 16.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, n. 6, p. 386–408, 1958. An optional note. Citado na página 26.
- SILVA, I. D.; SPATTI, D.; FLAUZINO, R. *REDES NEURAIS ARTIFICIAIS PARA ENGENHARIA E: CIENCIAS APLICADAS - CURSO PRATICO*. [S.l.]: ARTLIBER, 2010. ISBN 9788588098534. Citado na página 24.
- SOLAR, P. 2014. Disponível em: <<https://www.portalsolar.com.br/passa-a-passo-da-fabricacao-do-painel-solar.html>>. Citado na página 20.
- SRIVASTAVA, N. et al. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, v. 15, n. 56, p. 1929–1958, 2014. Disponível em: <<http://jmlr.org/papers/v15/srivastava14a.html>>. Citado 2 vezes nas páginas 18 e 47.
- SRIVASTAVA, N. et al. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014. Citado 4 vezes nas páginas 28, 29, 30 e 49.

VELO, R.; LÓPEZ, P.; MASEDA, F. Wind speed estimation using multilayer perceptron. *Energy Conversion and Management*, v. 81, p. 1–9, 2014. ISSN 0196-8904. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0196890414001277>>. Citado na página 27.

VYAS, A. et al. Analyzing uncertainties in speech recognition using dropout. In: *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. [S.l.: s.n.], 2019. p. 6730–6734. Citado na página 18.

WANG, J. et al. Exploring key weather factors from analytical modeling toward improved solar power forecasting. *IEEE Transactions on Smart Grid*, v. 10, n. 2, p. 1417–1427, 2019. Citado na página 17.

YANG, H.-T. et al. A weather-based hybrid method for 1-day ahead hourly forecasting of pv power output. *IEEE Transactions on Sustainable Energy*, v. 5, n. 3, p. 917–926, 2014. Citado 2 vezes nas páginas 16 e 17.

ZHOU, Y. et al. Short-term solar power forecasting based on convolutional neural network and analytical knowledge. *International Transactions on Electrical Energy Systems*, v. 31, n. 11, p. e13111, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/2050-7038.13111>>. Citado na página 18.