PREDIÇÃO DA RADIAÇÃO SOLAR VIA REDE NEURAL DE ALTA PERFORMANCE

Lucas Martins de Oliveira
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca - CEFET/ RJ
Rua do Areal, 522 - Parque Perequê, Angra dos Reis
lucas.oliveira.1@aluno.cefet-rj.br

Ezequiel da Silva Oliveira
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca - CEFET/ RJ
Rua do Areal, 522 - Parque Perequê, Angra dos Reis
ezequiel.oliveira@cefet-rj.br

Deilson Martins dos Santos
Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina
Av. Mauro Ramos, 950 - Centro, Florianópolis
deilson.s@aluno.ifsc.edu.br

Ivo Chaves da Silva Junior
Universidade Federal de Juiz de Fora
Rua José Lourenço Kelmer, s/n – Campus Universitário, Juiz de Fora
ivo.junior@ufjf.edu.br

RESUMO

Este trabalho tem como principal objetivo a investigação de redes neurais artificiais que propiciem uma predição de radiação solar confiável, a fim de garantir alta previsibilidade na geração de energia elétrica por fonte fotovoltaica. Dentro do segmento das redes neurais artificiais são adotadas as redes neurais artificiais recorrentes, que se destacam pela utilização de *loops* que permitem a realização do processo de memorização. A eficiência desta técnica é validada através de parâmetros estatísticos e para certificação é realizado o estudo de caso correspondente à previsão de dois anos da radiação solar para a região de São Martinho da Serra, localizado no Rio Grande do Sul.

PALAVRAS CHAVE. Rede Neural Artificial, Radiação Solar, Predição.

ABSTRACT

This work has as main objective the investigation of artificial neural networks that provide a reliable prediction of solar radiation, in order to guarantee high predictability in the generation of electric energy by photovoltaic source. Within the segment of artificial neural networks, recurrent artificial neural networks are adopted, which stand out for the use of loops that allow the memorization process to be carried out. The efficiency of this technique is validated through statistical parameters and for certification a case study is carried out corresponding to the two-year forecast of solar radiation for the region of São Martinho da Serra, located in Rio Grande do Sul.

KEYWORDS. Artificial Neural Networks, Solar Radiation, Prediction.

https://proceedings.science/p/157558?lang=pt-br

1. Introdução

A geração de energia elétrica é essencial para a vida dos seres humanos e deve ser planejada e estruturada para garantir o atendimento aos consumidores de maneira constante e eficiente, além de minimizar os impactos ao meio ambiente. Deste modo, o uso de fontes renováveis para a geração de energia elétrica é de suma importância para reduzir o uso e o impacto negativo que a geração por fontes não renováveis podem causar, pois o combustível fóssil é a principal fonte de impactos ambientais [da Silva e Araújo, 2022]. Dentre estas fontes destacam-se as derivadas do petróleo que provocam, por exemplo, o agravamento do efeito estufa.

A oferta de energia elétrica convertida do sol no Brasil deve ter, segundo MME [2022], uma expansão de 1,5% no ano de 2022, saindo de 2,7% no fim de 2021 para 4,2% no fim do ano seguinte. Sabe-se que a participação da energia solar cresce a cada ano e, apesar de ainda ter baixa porcentagem da matriz elétrica mundial, teve um crescimento expressivo de 2.000% entre os anos de 1996 e 2006 [Mauad et al., 2017]. O Brasil é um país com grande potencial de exploração e conversão dessa fonte de energia em eletricidade devido a sua dimensão continental e sua localização geográfica, visto que possui irradiação global média anual entre 1.200 e 2.400 kWh/m^2/ano. Para fins de comparação, na Alemanha e na Espanha, que são os países da Europa que mais exploram este meio de geração no mundo, os valores ficam em torno de 900 a 1.250 e 1.200 a 1.850 kWh/m^2/ano, respectivamente [EPE, 2022].

Existem alguns problemas provenientes do uso da energia solar que dificultam a sua confiabilidade, uma vez que não se tem o controle desta geração devido à dependência de condições climáticas. Porém, apesar da extensão do Sistema Interligado Nacional (SIN) e sua alta confiabilidade, devido à existência de locais isolados da rede de transmissão e distribuição há um grande número de pessoas que não possuem acesso à energia elétrica [Silva, 2022]. Estas regiões menos favorecidas podem se beneficiar de microrredes de energia através da utilização do gerenciamento ótimo dos recursos energéticos, como gerador a diesel, sistema fotovoltaico, gerador eólico e banco de baterias. Neste caso, realizar a previsão de energia gerada através de fonte solar se torna um fator fundamental para aumentar a previsibilidade desta fonte, pois possibilitaria saber o melhor momento para utilizá-la ao longo do dia para obter maior eficiência da operação do sistema, além de permitir o melhor planejamento ao longo do mês.

Com o avanço da tecnologia e a diversificação da matriz de energia elétrica, há uma tendência de aumentar a participação das energias renováveis na matriz de energia elétrica brasileira [Santos e Oliveira, 2020]. Por este motivo, ter o conhecimento da quantidade futura de incidência de radiação solar numa região possibilitaria determinar a energia elétrica a ser gerada através destas usinas e, deste modo, permitiria realizar a busca pelo gerenciamento energético ótimo do sistema de forma a reduzir o acionamento de usinas termelétricas e, consequentemente, reduzir o valor pago pelos consumidores de energia elétrica.

Existem na literatura diversas ferramentas que permitem realizar a predição de dados, porém cada uma atua com melhor acurácia em casos específicos. Por exemplo, um dos modelos mais populares de predição em séries temporais é o modelo autorregressivo integrado de médias móveis, do inglês *Autoregressive Integrated Moving Average* (ARIMA), segundo Adhikari e Agrawal [2013], e é capaz de explorar a autocorrelação entre os valores de uma série em momentos sequenciais. Além disso, também pode atuar com melhor precisão em casos de autocorrelação para uma estação de sazonalidade, se porventura os períodos observados sejam inferiores a um ano, neste cenário são conhecidos do inglês como *Seasonal Autoregressive Integrated Moving Average* (SARIMA) [Alencar et al., 2018]. Dentre outras técnicas utilizadas para a predição, existe também a rede neural artificial (RNA), que foi inspirada no funcionamento do cérebro humano, que possui

um conjunto de neurônios interligados para interagirem entre si [Campos et al., 2019].

O artigo está organizado conforme a seguir: a seção 2 apresenta a metodologia utilizada, o tipo de rede neural escolhida para o caso de estudo, o modelo de validação utilizado para a RNA, assim como seus cálculos, e apresenta a origem dos dados obtidos para treinamento e predição. A seção 3 aborda o caso de estudo, as aplicações das métricas de erros para este estudo, análise da configuração das camadas ocultas da RNA e os parâmetros utilizados para a configuração interna da rede. Por fim, a seção 4 apresenta a conclusão obtida através da elaboração deste trabalho.

2. Metodologia

2.1. Redes Neurais Artificiais Recorrentes

As redes neurais artificiais recorrentes, do inglês *Recurrent Neural Network* (RNN), são um tipo de RNA que utilizam a técnica de retropropagação, levando em consideração as informações ao longo do tempo, ou seja, o valor anterior se torna importante para o cálculo da próxima iteração, e deste modo permitem que a informação seja armazenada ao longo do tempo, diferente das RNA's tradicionais, que não são capazes de realizar este processo de memorização, ou seja, ela consegue identificar qual informação é mais relevante armazenar ao longo do tempo. Desta forma, os pesos, que são valores calculados dentro das RNA's com o objetivo de melhor representar uma curva que consiga expressar o caso de estudo, são moldados de modo que as informações mais importantes prevaleçam [Academy, 2022]. A escolha da RNN como modelo de RNA a ser utilizado neste trabalho baseou-se nas características apresentadas pela RNN, que permitem que as informações sejam consideradas ao longo do tempo, além de priorizar os dados mais importantes.

A Figura 1 ilustra o fluxograma que representa a metodologia utilizada para a predição elaborada neste trabalho. É possivel observar que a seção 1 representa a etapa inicial, onde os dados são adquiridos e tratados para a adequação dos cálculos e inserção como parâmetros de entrada. A seção 2 apresenta a etapa a qual os dados são separados em conjuntos de teste e treinamento, sendo 90% dados de treino e 10% de teste. A seção 3 refere-se à utilização da RNN, apresentando as etapas de treinamento, teste e refinamento dos pesos da rede. Por fim, na seção 4 são realizados os cálculos e comparação dos parâmetros estatísticos de cada modelo obtido na seção 3 e a determinação do modelo escolhido para predição.

O treinamento da RNN é feito através de um algoritmo do tipo *backpropagation*, mas levando em consideração o fato do desenrolar ao longo do tempo, processo que ficou conhecido como retropropagação através do tempo, do inglês *backpropagation through time* [Géron, 2019]. Uma célula de memória pode ser identificada como o elemento da RNN que preserva um conhecimento anterior [Géron, 2019]. Dentro deste segmento, há a célula de memória de curto prazo, do inglês *Long Short-Term Memory* (LSTM), que é decomposta em um vetor de estado de curto prazo e outro de longo prazo e, deste modo, possibilita que a rede diferencie os dados mais importantes ao longo do tempo, permitindo que aprenda e modele o sistema a ser previsto de forma a obter melhor desempenho com um curto tempo de convergência.

A RNN elaborada neste trabalho foi implementada através da linguagem de programação *Python*, com o auxílio das bibliotecas: *pandas, numpy, matplotlib,* e dos seguintes *frameworks*: *keras e scikit-learn.* Os dados utilizados para a previsão utilizam valores de medição e previsão discretizados a cada minuto correspondentes ao mês inteiro, deste modo sabe-se que uma análise diária apresenta 1.440 dados, correspondentes as 24 horas, e uma previsão mensal apresenta 43.200 dados, referentes a um mês com 30 dias.

2.2. Validação do Modelo de Rede Neural Artificial

Para que seja possível escolher e validar a arquitetura da rede a ser utilizada, é necessário avaliar o desempenho através de algumas métricas de erros. Para este trabalho foram adotados

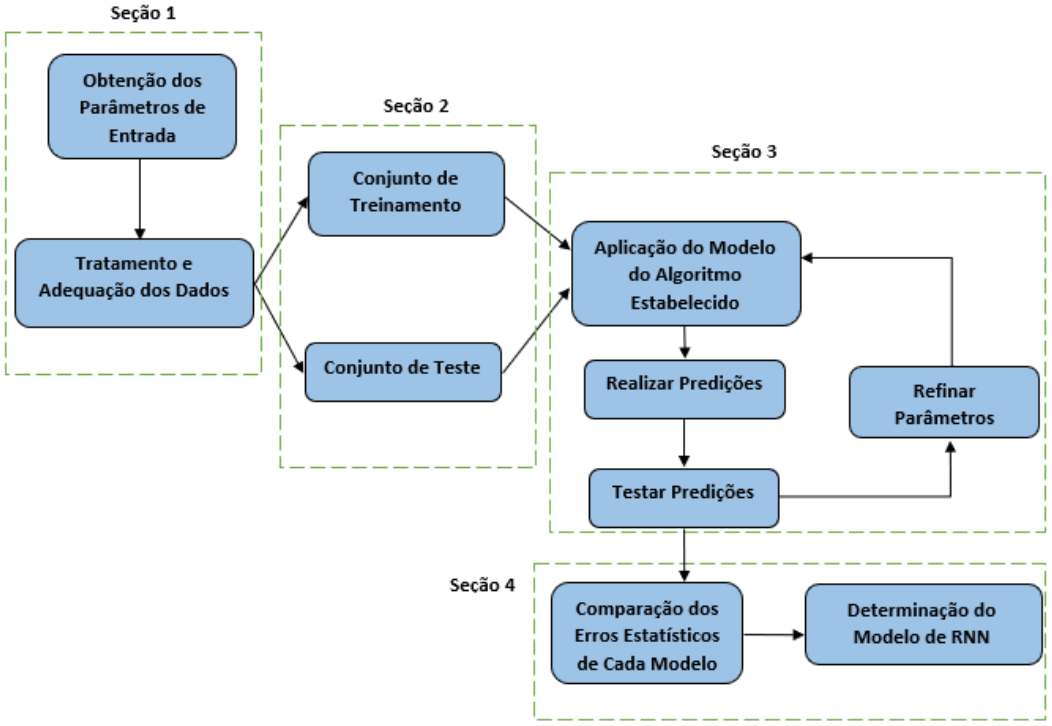


Figura 1: Fluxograma da metodologia para previsão da radiação solar.
Fonte: Elaborada pelo autor

alguns dos parâmetros estatísticos difundidos na literatura a fim de validar as predições da série temporal: (1) erro quadrático médio da raiz, do inglês *Root Mean Squared Error* (RMSE), (2) erro absoluto do valor médio percentual, do inglês *Mean Absolut Percentage Error* (MAPE) e (3) coeficiente U de Theil (UTheil) [Melo et al., 2020].

Esta escolha se baseia pelo fato da métrica RMSE penalizar desvios maiores, essa característica é de suma importância para avaliar o desempenho dos modelos. É possível afirmar que a rede neural terá melhor desempenho quanto menor for o valor de RMSE e MAPE [Olatomiwa et al., 2015]. O coeficiente UTheil é uma métrica de erro que analisa a qualidade da previsão, sendo desejado que o valor seja menor que um e quanto mais próximo de zero for este valor, melhor será a qualidade da previsão [Theil, 1966].

$$RMSE = \sqrt{\frac{1}{n}\sum_{j=1}^{n}(y_j - y'_j)^2} \tag{1}$$

$$MAPE = \frac{1}{n}\sum_{j=1}^{n}\left|\frac{y_j - y'_j}{y_j}\right| \tag{2}$$

$$UTheil = \frac{\sqrt{\sum_{j=1}^{n}(y_j - y'_j)^2}}{\sum_{j=1}^{n}(y_j - y_{j-1})^2} \tag{3}$$

Onde os coeficientes das equações 1, 2 e 3 são:

- y_j: saída desejada ou valor obtido através de medição para a iteração índice j;
- y'_j: saída obtida através de previsão para a iteração índice j;
- y_{j-1}: saída desejada ou valor obtido através de previsão para a iteração $j-1$;
- n: número de previsões realizadas

Os dados utilizados nesta pesquisa foram obtidos gratuitamente no site da rede SONDA - Sistema de Organização Nacional de Dados Ambientais, a qual fornece uma base de dados para a pesquisa, desenvolvimento e operação em energias renováveis no Brasil, um projeto criado pelo Instituto Nacional de Pesquisas Espaciais (INPE).

Após a obtenção destes, faz-se necessário realizar o tratamento e processamento dos dados, ou seja, realiza-se uma filtragem apenas dos dados de interesse para a análise em questão, é verificado a existência de valores nulos ou negativos para a adequação, e por fim, realizado o escalonamento destas variáveis para valores entre 0 e 1, como ilustrado na seção 1 da Figura 1. Como parâmetros de entrada da rede neural foram utilizados os dados de radiação global horizontal (W/m^2), iluminância (kLux), temperatura do ar na superfície (C) e umidade do ar (%) relacionados à região de São Martinho da Serra - RS, localizado no Rio Grande do Sul. Estes parâmetros físicos estão dispostos em minutos e foram utilizadas para o treinamento da RNN a quantidade referente a dois anos.

3. Estudo de Caso

Os dados referentes aos anos de 2013 e 2014 foram utilizados para a realização do treinamento e validação da rede. Após a seleção destes dados foi possível treinar a rede, obtendo o modelo de RNN-LSTM. Os parâmetros de configuração mostrados na Tabela 1 foram utilizados como estrutura da RNN adotada neste estudo de caso.

Tabela 1: Parâmetros utilizados na RNN elaborada

Função de ativação nas camadas ocultas	relu
Função de ativação na camada de saída	sigmoid
Otimizador	adam
Função perda	mae
Batch size	2.048
Taxa de aprendizado	0,001
Epochs	35

Definiu-se o máximo de duas camadas ocultas para a RNA em estudo, a fim de não aumentar a sua complexidade e de que não seja requerido maior esforço computacional. De modo que foi investigado qual a melhor arquitetura de RNN-LSTM para a previsão da radiação global horizontal realizada. Para encontrar esta estrutura a ser utilizada foi realizada uma busca exaustiva variando o número de neurônios nas camadas ocultas a cada 10 neurônios artificiais, sendo o intervalo entre 30 e 70 na primeira camada e intervalo de 10 a 70 na segunda. Este procedimento de busca exaustiva resultou em 35 arquiteturas testadas, cuja variação foi estabelecida de forma empírica.

Para analisar o desempenho dos modelos de previsão para a cidade de São Martinho da Serra - RS é apresentada na Tabela 2 o número de neurônios na primeira camada oculta, o número de neurônios na segunda camada oculta, as métricas estatísticas, RMSE, MAE e UTheil calculadas para o conjunto de testes, e o tempo computacional necessário para treinar e validar a RNN-LSTM de acordo com cada configuração de neurônios estabelecida.

https://proceedings.science/p/157558?lang=pt-br

Tabela 2: Análise das arquiteturas encontradas da RNN-LSTM para a previsão

1^acam. oculta	2^acam. oculta	RMSE(W/m^2)	MAPE(%)	UTheil	Tempo comp.(s)
30	10	74,0773	124,2311	0,9857	22,2566
30	20	74,0915	113,7569	0,9859	21,0011
30	30	74,4514	131,4239	0,9907	22,2998
30	40	73,6779	90,4098	0,9804	22,2928
30	50	74,5833	81,4591	0,9923	22,3514
30	60	74,1334	43,3744	0,9865	22,3022
30	70	74,7279	78,8337	0,9943	22,2815
40	10	74,4570	70,5015	0,9908	22,3262
40	20	73,7302	95,2552	0,9810	20,8891
40	30	73,8228	51,5306	0,9822	20,7314
40	40	74,2406	80,0284	0,9879	22,8145
40	50	74,1911	63,6129	0,9871	22,3022
40	60	73,9796	66,5854	0,9844	21,1276
40	70	74,5259	52,6321	0,9917	20,7377
50	10	73,6803	109,0346	0,9804	21,4070
50	20	74,2011	47,6565	0,9874	21,9065
50	30	74,4643	70,1229	0,9909	22,9012
50	40	73,6031	42,4742	0,9794	22,3581
50	50	73,9589	70,6946	0,9840	22,3106
50	60	73,9326	53,2571	0,9838	21,7468
50	70	74,2080	63,1987	0,9874	22,3752
60	10	74,5025	104,7375	0,9913	42,8084
60	20	73,7834	51,4174	0,9818	22,3738
60	30	74,6082	98,1068	0,9928	23,8771
60	40	74,2546	48,7443	0,9880	21,8798
60	50	74,3311	46,4506	0,9890	22,5223
60	60	73,5593	73,4895	0,9788	22,1616
60	70	73,7707	59,7524	0,9816	22,1822
70	10	74,7580	92,6494	0,9948	42,8694
70	20	73,9117	57,3164	0,9835	42,7880
70	30	74,0164	39,5482	0,9849	42,8257
70	40	74,2865	49,6225	0,9885	22,4970
70	50	74,2177	59,2302	0,9876	22,0568
70	60	74,5764	47,4470	0,9923	22,3203
70	70	74,0033	53,0519	0,9847	22,4441

Através dos dados obtidos na Tabela 2, foi proposto o cálculo da média aritmética dos parâmetros estatísticos e tempo computacional normalizados pela média de cada parâmetro em que o menor valor das médias encontradas indicará possível configuração adotada. Outra proposta para análise realizada foi escolher as configurações da RNN-LSTM que obtiveram como menor resultado de cada parâmetro estatístico analisado, ou seja, menor RMSE, MAPE e UTheil.

Para a definição do modelo que apresenta a menor média dos valores normalizados, obteve-se o valor de 0,8745 como menor média para a configuração de 50 neurônios na primeira camada oculta e 40 na segunda camada oculta (RNN-LSTM 50-40), por meio desta análise, adotou-se a combinação destacada em amarelo na Tabela 2. Já a melhor configuração obtida para o menor valor do MAPE foi, conforme destacado em verde, 60 neurônios em ambas as camadas ocultas (RNN-LSTM 60-60) e a combinação de neurônios para os menores valores de RMSE, assim como para UTheil, foi de 70 na primeira camada oculta e 30 na segunda camada oculta (RNN-LSTM 70-30), como mostrado na cor cinza.

Feito isto, para cada uma das três combinações escolhidas foram realizadas predições de minuto a minuto para cada um mês, no período de 24 meses, iniciando em janeiro de 2015 e terminando em dezembro de 2016. Para cada mês foi obtido um valor de erro referente aos dados medidos e os dados previstos através da RNN-LSTM. Com base nisso, elaborou-se os gráficos para comparação dos parâmetros estatísticos, conforme apresentados nas Figuras 2, 3 e 4.

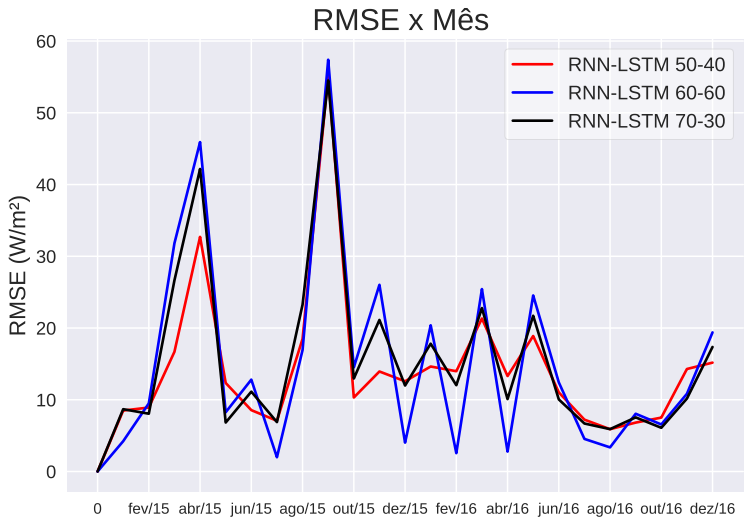


Figura 2: RMSE obtido para cada configuração de rede.
Fonte: Elaborada pelo autor

A Figura 2 apresenta o RMSE para cada mês de previsão calculado para cada combinação de neurônios definida. Pode-se observar que das configurações analisadas a RNN-LSTM 50-40 obteve menor variação com relação aos demais, enquanto a RNN-LSTM 60-60 oscilou bastante, tendo os maiores e menores picos. Já a RNN-LSTM 70-30 se comportou na média em relação aos demais.

Os valores do MAPE para cada mês de previsão calculado para cada configuração de neurônio definida estão apresentados na Figura 3. Pode-se observar que a RNN-LSTM 60-60 se destacou das demais possuindo os menores valores de erro para boa parte da previsão, enquanto os demais possuíram valores maiores de erro percentual.

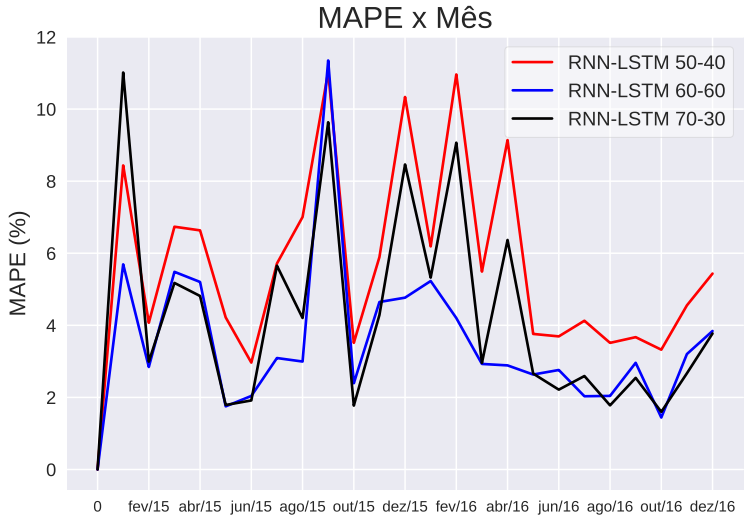


Figura 3: MAPE obtido para cada configuração de rede.
Fonte: Elaborada pelo autor

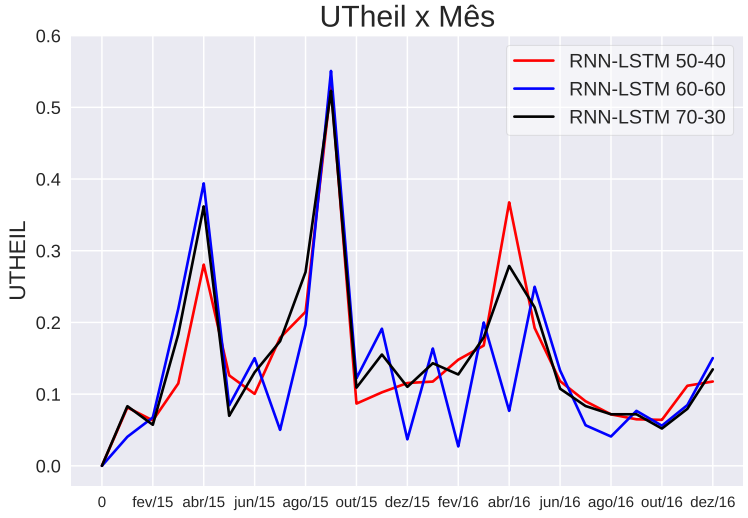


Figura 4: UTHEIL obtido para cada configuração de rede.
Fonte: Elaborada pelo autor

A Figura 4 apresenta o cálculo do coeficiente U de Theil para cada mês de acordo com as configurações definidas. Como dito anteriormente, deseja-se que esta métrica seja menor que um e mais próximo de zero. Sendo assim, através da análise gráfica pode-se observar que a configuração que possui mais picos próximos de zero é a RNN-LSTM 60-60.

Para melhor auxiliar na análise e escolha da configuração da RNN, calculou-se as médias de cada erro, para cada configuração de RNN-LSTM, conforme apresentado na Tabela 3.

Analisando a Tabela 3 pode-se observar em verde que a RNN-LSTM 60-60 obteve a menor média aritmética de MAPE e UTheil, enquanto que em amarelo está ilustrada a RNN-LSTM 50-40, que obteve o menor valor de média para o RMSE, embora a RNN-LSTM 60-60 tenha apre-

Tabela 3: Análise dos erros das arquiteturas encontradas

Métricas	Configuração de rede	Média
RMSE (W/m^2)	RNN-LSTM 50-40	14,2172
	RNN-LSTM 60-60	14,9686
	RNN-LSTM 70-30	15,2975
MAPE (%)	RNN-LSTM 50-40	5,61639
	RNN-LSTM 60-60	3,53655
	RNN-LSTM 70-30	4,21030
Utheil	RNN-LSTM 50-40	0,1450
	RNN-LSTM 60-60	0,1367
	RNN-LSTM 70-30	0,1511

sentado valor próximo a este. Logo, a combinação escolhida foi a RNN-LSTM 60-60, pois possui duas métricas de erro com médias menores.

Por meio da análise dos resultados obtidos através dos valores dos parâmetros estatísticos, pode-se afirmar que os resultados são satisfatórios e a RNN-LSTM selecionada pode ser considerada eficiente para a predição de radiação global horizontal na região de São Martinho da Serra - RS. Deste modo, na Figura 5 está exposto a previsão de radiação global horizontal, utilizando a configuração de rede escolhida, para o mês de setembro de 2015, correspondente ao mês de maiores erros encontrados pelas métricas calculadas. Do mesmo modo, a Figura 6 apresenta a previsão para o mês de fevereiro de 2016, relativo ao mês de menor coeficiente UTheil calculado.

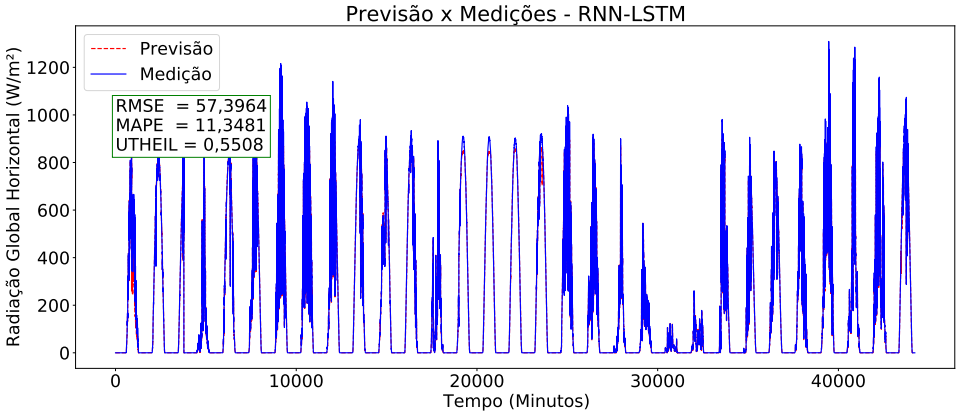


Figura 5: Previsão de incidência solar para o Mês de Setembro de 2015.
Fonte: Elaborada pelo autor

Através da análise da comparação das Figuras 5 e 6, nota-se que visualmente torna-se difícil analisar os erros de previsão. Portanto, dentre as RNNs analisadas neste trabalho, a escolhida foi a que apresentou o menor UTheil, sendo assim, para a escolha do mês de melhor resultado foi adotado este critério, correspondente ao mês de fevereiro de 2016, pois obteve o valor do coeficiente próximo a zero, sendo 0,027. Por outro lado, a previsão com o pior resultado ocorreu no mês de setembro de 2015, pois teve os valores mais altos para todos os parâmetros estatísticos, sendo 57,39 W/m^2 para RMSE, 11,3% para o MAPE e 0,55 para UTheil. Ainda assim, obteve o coeficiente

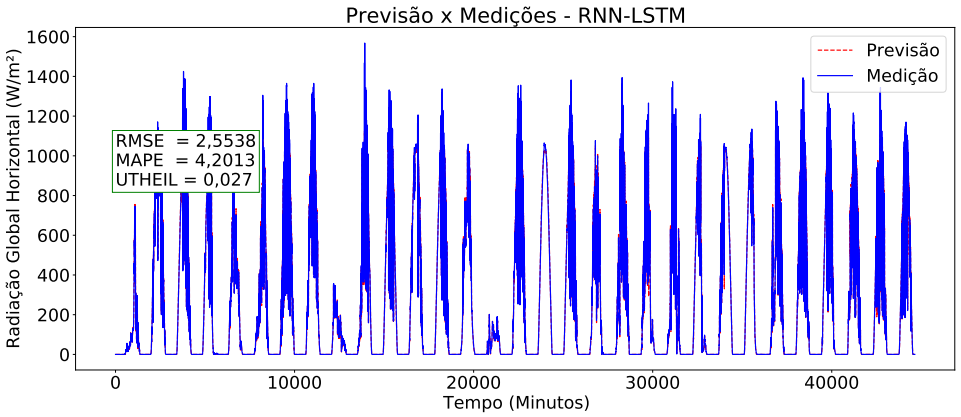


Figura 6: Previsão de incidência solar para o Mês de Fevereiro de 2016.
Fonte: Elaborada pelo autor

UTheil menor que 1, o que se configura um valor desejável para este parâmetro, o que também valida a simulação. Mesmo que exista esta diferença entre este mês e os demais, o RMSE foi de 57,39W/m^2, e a grandeza das previsões de radiação global horizontal atingiu picos entre 1.000 e 1.200 W/m^2 para o mesmo mês. Ou seja, a RNN-LSTM teve resultados de excelente qualidade para os meses de menores métricas estatísticas e também teve um comportamento satisfatório para os meses de maiores valores estatísticos calculados, com base na ordem de grandeza dos parâmetros utilizados para validação.

4. Conclusão

A predição de radiação global horizontal possibilita o conhecimento da quantidade de geração elétrica oriunda dos recursos solares, sendo de extrema importância para realizar o gerenciamento ótimo dos recursos energéticos, buscando o menor custo de operação do sistema e a redução da utilização de combustíveis fósseis. Portanto, uma técnica que propicie uma predição de qualidade é de suma importância.

A RNN-LSTM apresentada e investigada neste trabalho se mostrou eficaz diante das análises dos parâmetros estatísticos estabelecidos, sendo notório o excelente desempenho diante dos baixos valores das referidas métricas.

Como propostas de estudos futuros, podem ser estudadas variações da rede neural, com o intuito de obter resultados com menores erros de previsão em relação aos dados medidos. Além disto, pode-se realizar a aplicação deste algoritmo, com as devidas adequações, para obter a previsão da velocidade do vento, a qual também possibilita a conversão em energia elétrica e, deste modo, permitirá a otimização destes recursos renováveis através do gerenciamento ótimo da matriz de geração de energia elétrica, a fim de obter a redução da utilização de fontes não renováveis e assim reduzir os custos de geração de energia.

Referências

Academy, D. S. (2022). Deep learning book, 2022. https://www.deeplearningbook.com.br/redes-neurais-recorrentes/. Acessado: 22-05-2022.

Adhikari, R. e Agrawal, R. K. (2013). An introductory study on time series modeling and forecasting. *arXiv preprint arXiv:1302.6613*.

Alencar, D. B. d. et al. (2018). Modelo híbrido baseado em séries temporais e redes neurais para previsão da geração de energia eólica.

Campos, I. S. L., Martins, F. R., e de Lima, F. J. L. (2019). Previsão de irradiância solar na região sudeste do brasil empregando o modelo de mesoescala wrf ajustado por redes neurais artificiais (rnas).

da Silva, H. M. F. e Araújo, F. J. C. (2022). Energia solar fotovoltaica no brasil: Uma revisão bibliográfica. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 8(3):859–869.

EPE (2022). Plano decenal de expansão de energia 2022. `https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-49/topico-86/Relat%C3%B3rio%20Final%20do%20PDE%202022.pdf#search=crescimento%20solar`. Acessado: 22-05-2022.

Géron, A. (2019). *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. Alta Books.

Mauad, F. F., Ferreira, L., e Trindade, T. C. G. (2017). Energia renovável no brasil. *Análise das principais fontes energéticas renováveis brasileiras*, p. 740–1.

Melo, D. S., Oliveira, L. W., e Oliveira, J. G. (2020). Aplicação de redes neurais artificiais para previsão de velocidade de vento considerando variáveis correlacionadas. *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, 1(1).

MME (2022). Boletim mensal de energia. `https://www.gov.br/mme/pt-br/assuntos/secretarias/spe/publicacoes/boletins-mensais-de-energia/2022-2/portugues/1-boletim-mensal-de-energia-fevereiro-2022`. Acessado: 22-05-2022.

Olatomiwa, L., Mekhilef, S., Shamshirband, S., Mohammadi, K., Petković, D., e Sudheer, C. (2015). A support vector machine–firefly algorithm-based model for global solar radiation prediction. *Solar Energy*, 115:632–644.

Santos, D. M. e Oliveira, E. S. (2020). Investigação de redes neurais artificiais para predição da velocidade do vento. *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, 1(1).

Silva, W. C. (2022). *A geração de energia solar como fator de desenvolvimento econômico sustentável: aspectos jurídicos, econômicos e perspectivas para seu incentivo*. Editora Dialética.

Theil, H. (1966). Measuring the accuracy of point predictions. *Applied Economic Forecasting. North Holland Publishing Company. Amsterdam*, p. 15–36.

https://proceedings.science/p/157558?lang=pt-br