

Previsão da Geração de Energia Fotovoltaica Utilizando Inteligência Artificial em Séries Temporais

Fillipe de A. Andrade* Acbal R. Andrade Achy**
Gildeberto de Souza Cardoso*** Leizer Schnitman****

* *Discente do Bacharelado em Engenharia Elétrica, Universidade Federal do Recôncavo da Bahia, BA, (e-mail: fillipe.edu@ufbr.edu.br).*

** *Docente do Bacharelado em Engenharia Elétrica, Universidade Federal do Recôncavo da Bahia, BA (e-mail: acbal@ufbr.edu.br)*

*** *Docente do Bacharelado em Engenharia Elétrica, Universidade Federal do Recôncavo da Bahia (e-mail: gildeberto@ufbr.edu.br)*

**** *Docente do Programa de Pós Graduação em Engenharia Mecatrônica, Universidade Federal da Bahia (email:leizer@ufba.br)*

Abstract: This paper present a quick analysis about the use of machine learning algorithms, being more specific the Neural Network LSTM and Facebook Prophet for the forecasting about the generation of electricity for Photovoltaic Plant. Reaching results above 90%, showing the viability and highest dots for each kind of machine learning, to leverage the study and implemetation of Solar Energy. Where was analyzed that the LSTM reached the better accuracy than Prophet, however considering wich Prophet spend less time than LSTM. Finally is comproved the viability of the strong points of each Artificial Inteligence covered for this study.

Resumo: O artigo apresentado mostra uma breve análise do uso de algoritmos de aprendizado de máquina, sendo mais específico as Rede Neural LSTM e o Facebook *Prophet*, para a predição da produção de energia elétrica de uma Usina Fotovoltaica. A metodologia foi baseada em um banco de dados encontrado no site *Kaggle*, onde todo o processo de aprendizagem de máquina foi feito. Os resultados obtidos alcançaram marcas superiores a 90%, onde foi analisado que o LSTM obteve melhor precisão com menor quantidade de dados, em contrapartida o *Prophet*, mesmo com resultado inferiores teve uma precisão aceitável considerando o menor tempo de processamento. Por final é comprovada a viabilidade e os pontos fortes de cada tipo de inteligência artificial abordada, para alavancar estudos e implementações da Energia Solar

Keywords: Nural Network; Forecast; Photovoltaic Plant; Machine Learning; Solar Energy.

Palavras-chaves: Redes Neurais, Previsão, Usina Fotovoltaica, Aprendizado de Máquina, Energia Solar .

1. INTRODUÇÃO

O crescimento econômico e social de uma nação está intimamente associado ao potencial energético acessível para consumo, especificamente a energia elétrica tem um papel indispensável no desenvolvimento da sociedade no século XXI. Por este motivo, a geração de energia vem sendo alvo de pesquisa em todo mundo, acarretando em inovações tecnológicas e eficiência cada vez maior na produção de energia elétrica. Atendendo às preocupações ambientais, as fontes de energia estão tendendo cada vez mais a ser de caráter renovável, pois os recursos minerais e fósseis estão entrando em condição de escassez, além da poluição gerado por estes materiais (Machado, 2015).

No âmbito do estudo de energias renováveis, segundo Frontin (2017) a energia solar desponta como uma das formas mais utilizadas de produção de eletricidade. Este tipo de matriz energética utiliza como fonte primária a radiação solar, e com instalação relativamente simples quando com-

para a outras formas de geração de energia predominante no Brasil, como por exemplo as Hidrelétricas. Por este motivo o governo brasileiro criaram leis de incentivo para a aplicação de usinas fotovoltaicas para consumidores individuais e industrias, Fomentando a economia neste setor gerando uma previsão de crescimento de 2,94 GW para 90 GW de potência para usinas instaladas até em 2050 (EPE, 2020).

Mesmo com todos os incentivos fiscais do governo brasileiro, ainda há uma grande incerteza do retorno financeiro no investimento para a aplicação, principalmente na modalidade de consumidores individuais em que o retorno tende ser mais tardio. Isto é ocasionado pela incerteza da quantidade de energia elétrica gerada ao decorrer do ano, visto que é sabido o comportamento da radiação solar no Brasil, o qual varia de acordo com as estações do ano (Frontin, 2017).

Uma das estratégias para melhorar e orientar a previsão do retorno do investimento para futuros produtores de

energia fotovoltaica é utilizando ferramentas computacionais inteligentes como a Inteligência Artificial (IA) com o objetivo de ajudar a alavancar o a rentabilidade na área. Dentre as diversas maneiras de implementar o aprendizado de máquina, as séries temporais como base de estimação tem ganhado mais adeptos.

O uso de séries temporais associados a IA para resolução de problemas de estimação envolvendo geração de energia fotovoltaica obtém resultados satisfatórios, pois o conceito de séries temporais utiliza de características intrínsecas à geração de energia elétrica, tais como: variações do tempo, clima e sazonalidade. Trabalhos como o de Barros Alencar et al. (2020) mostra a eficiência desses tipos de inteligência utilizando a Rede Neural Recorrente e o Facebook Prophet para a predição da frota de carros ao decorrer do tempo, obtendo uma melhor precisão na Rede Neural do que no *Prophet*. Balti et al. (2021) em seu trabalho discorre do estudo do período da seca em uma província chinesa onde os os mesmos modelos de inteligência Artificial foram utilizados obtendo bons resultados entretanto a do tipo LSTM da mesma maneira obteve melhores resultados do que desenvolvida pelo Facebook .

Diante das motivações expostas anteriormente, este artigo tem o objetivo de a construção de um estudo analítico de predição de uma série temporal relacionada a potência gerada pelos módulos de uma usina fotovoltaica, com base em dados reais para sua comprovação. Utilizando para este meio métodos de aprendizado supervisionado, sendo eles as Rede Neurais Recorrentes do tipo LSTM e o Facebook Prophet, os quais foram testados em dois fatores de disponibilidade de dados diferentes.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Sistemas Fotovoltaicos

Segundo Camargo (2017) os sistemas fotovoltaicos (FV), são um tipo de fonte de energia de cunho renovável, o qual utiliza a radiação solar como matéria prima. Esta geração é do tipo descentralizada, podendo ser instalados nos centros de consumos, como em áreas urbanas aproveitando área disponível nos telhados das construções para fixação das placas e fornecer eletricidade ao local e com a opção de vender a rede concessionária.

Células Fotovoltaicas. São compostas de semicondutores sendo as mais utilizadas as de silício, os quais são elementos químicos com características intermediárias entre metais e ametais, convertendo a luz solar em energia elétrica por meio do efeito fotoelétrico. Uma única célula fotovoltaica gera em torno de 2 W, valor insuficiente para a utilização em praticamente qualquer tipo de aplicação, por este motivo, as células solares são arranjadas em série formando ramos, e esses, agrupados em paralelo obtendo assim um módulo fotovoltaico de tensões e correntes maiores, (Ishaque and Salam, 2013).

Inversores. Têm o papel principal de converter corrente contínua proveniente das placas fotovoltaica para corrente alternada que será injetada na rede elétrica, secundariamente ser um dispositivo de proteção do sistema fotovoltaico podem de medir a quantidade de energia gerada

pelos módulos solares, (Frontin, 2017). Os inversores têm um valor associado de eficiência, isso se dá pela perda associada na conversão de tensão contínua para alternada, sendo então seu cálculo dado pela divisão da potência contínua em alternada.

2.2 Séries Temporais

Reis (2020) define em seu trabalho que as séries temporais são um conjunto de valores de determinado fenômeno estudados ao decorrer do tempo, sendo que esta variação temporal é dividida em intervalos iguais. Este tipo de série tem componentes que o caracterizam em seu comportamento, onde a Equação (1) a identifica matematicamente:

$$Y = T + C + S + I \quad (1)$$

Sendo os parâmetros dados por:

- Tendência (T): Análise do comportamento da variável global ao decorrer do intervalo de tempo, podendo ser de crescimento ou decrescimento.
- Ciclo (C): Estudo específico do modo que variável se comporta em pequenos intervalos de tempo, os quais se repetem com certa periodicidade;
- Sazonalidade (S): Comportamento específico do objeto de estudo em cada determinado de tempo, como temperatura do sol nas estações do ano.
- Variação Irregular (I): Valores que não podem ser previstos, pois são ocasionados por fatores externos os quais não se tem controle.

O detalhamento do conteúdo pode ser visto em Reis (2020) que demonstra melhor como é o comportamento normal de uma série temporal e gráficos sobre o tema.

2.3 Modelos para predição de Séries Temporais

As séries temporais têm diferentes métodos de previsão utilizando modelos matemáticos manuais e computacionais, entretanto o objeto de estudo deste trabalho são previsores computacionais utilizando IA com aprendizado supervisionado, sendo estes previsores o Facebook *Prophet* e LSTM ("*Long Short Term Memory*").

LSTM. Tipo de rede neural artificial (RNA), sendo o conceito básico deste modelo a reprodução de um neurônio biológico em um modelo que possa ser reproduzido por uma máquina. Contudo, ao decorrer do tempo as RNA's, tiveram que evoluir com a complexidade dos problemas que lhe eram propostos surgindo o *Deep Learning* que nada mais é que a adição de camadas a rede neural tornando-a mais densa, (Cerqueira et al., 2001). A Figura 1 mostra um modelo de rede neural artificial simples, onde existem as entradas camada oculta e saída cada neurônio da camada oculta tem uma função de ativação que a depender a soma dos pesos das entradas podem ativar com valor binário (0 ou 1).

Apesar da evolução das redes neurais, ainda havia problema para sua implementação, pois a falta de memória de eventos passado inviabilizava o uso da técnica, os quais baseiam este tipo de evento. Por este motivo sua estrutura foi modificada e implementada as Redes Neurais Recorrentes, as quais tem memória de eventos passados que

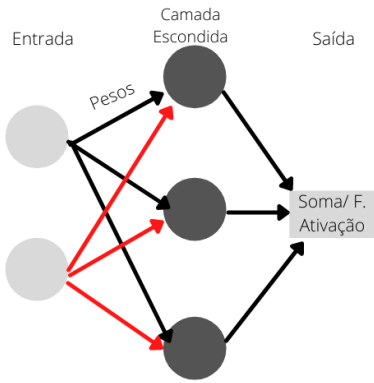


Figura 1. Exemplo de Rede Neural Artificial (Fonte: Autoria Própria)

podem influenciar em valores futuros (Gomide, 2012). A LSTM é um tipo de RNA Recorrente aprimorada, onde sua construção é feita pela adição de células de memória na rede neural manipulando essa rede. Com este artifício a RNA consegue se adaptar a séries temporais com mais facilidade, e prevendo situações a longo prazo, (Santos, 2019). A Figura 2 mostra uma LSTM na prática onde é visível as células de memória, onde eles armazenam estados passados.




Figura 2. Rede Neural Recorrente LSTM (Fonte: Autoria Própria)

Segundo Santos (2019), cada célula de memória de uma RNA recorrente tem em seu interior funções para receber, liberar e ler dados inseridos em sua memória que em cada instante de tempo, tendo a capacidade de transferir os dados recebidos para outras células da rede neural. A memória de cada célula também pode conter um fator de esquecimento, para que não haja uma intervenção maior do que a necessária em valores futuros

Facebook Prophet. é um algoritmo disponibilizado pelo Facebook com o objetivo de prever valores futuros de uma série temporal com um menor esforço computacional. A Figura 3 mostra como o algoritmo funciona, onde é ilustrado o seu processo de funcionamento, composto por um algoritmo cíclico feito de inspecionar o problema visualmente para que em função disso seja modelado as variáveis do algoritmo se adaptando então, ao problema.

Este tipo de IA tem como grande vantagem a análise de todos os aspectos da série temporal e suas características contidas na Equação (1), fazendo que seja bastante aplicado em análises temporais. O estudo feito por Zunic

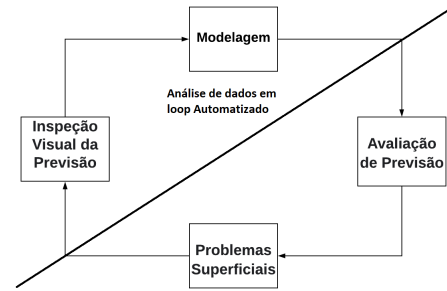


Figura 3. Funcionamento do Algoritmo Prophet

et al. (2020), mostra os conceitos e aplicação de uma série temporal sobre vendas com dados reais.

3. MATERIAIS E MÉTODOS

3.1 Base de Estudo

O ambiente de estudo deste artigo é uma base de dados pública localizada no site *Kaggle*, intitulado *"Solar Power Generation Data"*. O dado é composto de informações de geração e clima de duas usinas fotovoltaicas que existem na Índia compreendidos de 34 dias, dos meses de maio a junho, sendo que o objeto da análise é feito em somente em uma Usina.

A unidade de geração tem duas tabelas sendo uma representada pelos componentes da geração do sistema e clima no local em cada momento do dia, sendo o intervalo de medição de 15 minutos. A Tabela 1 mostra o escopo da do banco de informações relacionados a produção de eletricidade com seus fatores.

Tabela 1. Base de Dados de Geração da Usina FV, (Fonte: Autoria Própria)

| DATA | POT_CC | POT_AC | GER_DIA |
|---------------------|-----------|----------|----------|
| 2020-05-15 11:15:00 | 160301,22 | 15683,71 | 47752,76 |
| 2020-05-15 11:30:00 | 155409,16 | 15207,28 | 51726,05 |
| 2020-05-15 11:45:00 | 167668,19 | 16401,58 | 55271,10 |
| 2020-05-15 12:00:00 | 155821,69 | 15250,80 | 59620,94 |
| 2020-05-15 12:15:00 | 209569,39 | 20477,01 | 63932,30 |

Sendo a legenda dada por:

- **DATA:** Data e horário da coleta dos dados;
- **POT_CC:** Potência contínua gerado pelos módulos solares;
- **POT_AC:** Potência alternada convertido pelo inversor;
- **GER_DIA:** Geração diária de energia elétrica.

A Tabela 2 por sua vez mostra o formato de como foi armazenado as informações sobre o clima do local da usina.

Tabela 2. Base de Dados do Clima da Usina FV, (Fonte: Autoria Própria)

| DATA | AMBIENTE | MODULO | IRRADIAÇÃO |
|---------------------|----------|--------|------------|
| 2020-05-15 11:15:00 | 30,22 | 50,01 | 0,59 |
| 2020-05-15 11:30:00 | 30,29 | 49,84 | 0,56 |
| 2020-05-15 11:45:00 | 30,81 | 47,84 | 0,47 |
| 2020-05-15 12:00:00 | 31,31 | 49,18 | 0,51 |
| 2020-05-15 12:15:00 | 31,51 | 49,84 | 0,79 |

Sendo a legenda dada por:

- **AMBIENTE:** Temperatura ambiente no local da usina;
- **MODULO:** Temperatura nos módulos FV;
- **IRRADIADIAÇÃO:** Irradiação incidida nos módulos FV.

3.2 Metodologia do Experimento Simulado

A partir desses bancos de dados, foi utilizado os passos exemplificados na Figura 4 onde é mostrado através de um fluxograma o desenvolvimento do algoritmo proposto para solução do problema.

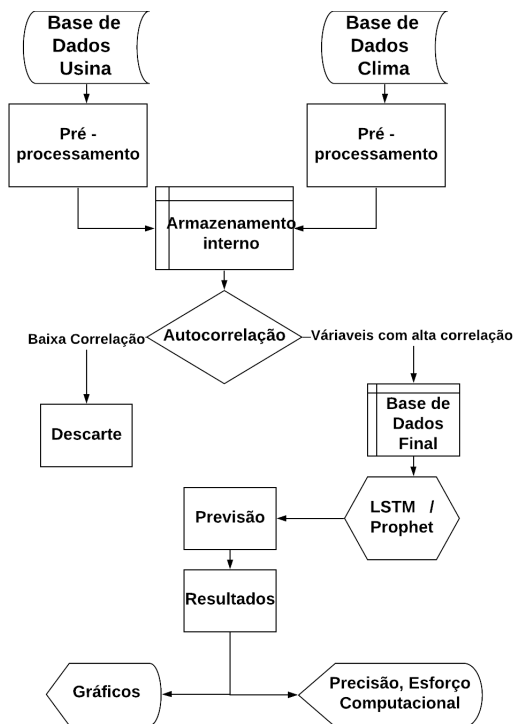


Figura 4. Fluxograma para a Análise da Série Temporal (Fonte: Autoria Própria)

A Figura 4 mostra que as bases de dados recebidas do site *Kaggle* são pré-processadas e depois unidas em uma planilha, com base no tempo de medição de cada amostra. Após isso é escolhido a componente a ser analisado como série temporal, que é a potência contínua produzida pelos módulos FV.

No pré-processamento dos dados é necessário a escolha dos dados mais relevantes para o modelo, sendo assim é necessária uma correlação entre as informações contidas na Tabela 1 e 2, através deste processo de correlação pode ser observado os dados de clima que mais influenciam na geração de energia. A Figura 5 ilustra uma tabela de correlação entre as variáveis estudadas, onde a partir dela foram escolhidas as informações mais relevantes para a predição da série temporal.

Estudando o diagrama de Correlação da Figura 5, observa-se que os dados de temperatura do módulo e irradiação são os valores mais elevados de correlação com a potência CC gerada. Por este motivo foram escolhidos somente estes dois fatores climáticos para a previsão dos modelos, sendo

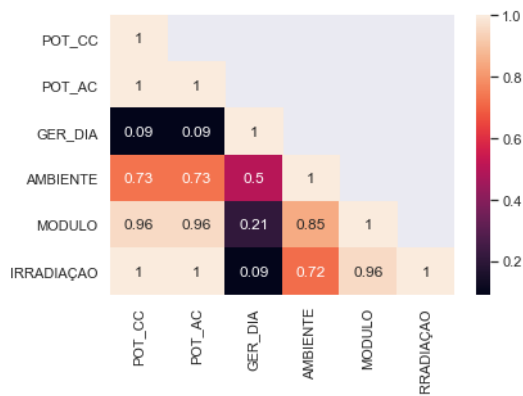


Figura 5. Correlação entre as Variáveis do Banco de Dados (Fonte: Autoria Própria)

o LSTM realizado através do algoritmo exemplificado no fluxograma da Figura 6.

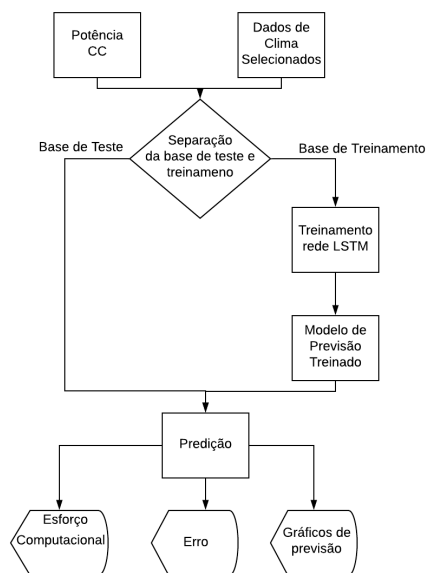


Figura 6. Fluxograma da Rede Neural Recorrente tipo LSTM na solução do problema (Fonte: Autoria Própria)

Após a visualização da execução do algoritmo, é necessário a escolha de parâmetros para a execução dos algoritmos, sendo que uma melhor escolha desses parâmetros influencia em resultados mais precisos e com um menor esforço computacional. A Tabela 3 mostra os principais parâmetros que compõem o algoritmo da Rede Neural.

Observando a Tabela 3 é explicitado que são necessários 100 medições da base de dados para que o LSTM venha prever um valor futuro de geração e assim consequentemente, isso é ocasionado pelas camadas escondidas possuem células de memória como descrito na teoria. O limite de épocas fixado em 100, entretanto se a taxa de aprendizado não obter uma evolução de 10^{-6} o algoritmo se encerra. Para o método Prophet, é de suma importância lembrar que ele não é executado como uma rede neural, sendo assim não tem estes requisitos, somente o cálculo de erro e precisão que são os mesmos da RNA.

Tabela 3. Parâmetros da RNA tipo LSTM,
 (Fonte: Autoria Própria)

| Parâmetros | Valor |
|-------------------------------|-------------------------|
| Entradas da Rede Neural | 100 |
| Nº de camadas Escondidas | 3 |
| Neurônios na Camada Escondida | 50 |
| Nº de Saídas | 1 |
| Função de Ativação Saída | Sigmoid |
| Função de Otimização | Adam |
| Tipo de Erro executado | Erro Quadrático Médio |
| Nº de Épocas | 100 |
| Condição de Parada | Taxa de Erro $<10^{-6}$ |

Para o *Prophet*, por se basear na Equação (1), teve os parâmetros contidos na Tabela 4, onde são compostos por fatores de sazonalidade e intervalo de previsão.

Tabela 4. Parâmetros para o modelo Prophet
 (Fonte: Autoria Própria)

| Parâmetros | Valor |
|-----------------------|------------|
| Sazonalidade Anual | Falso |
| Sazonalidade Diária | Verdadeiro |
| Intervalo de previsão | 15 min |

Analisando os parâmetros gerais, observa-se que a escolha do intervalo de tempo acompanha o valor da base de dados com intuito de prevenção de conflitos. A escolha pela sazonalidade diária definiu-se pela configuração da série temporal voltada a este fenômeno.

3.3 Parâmetros de Teste e Treinamento

Para a execução da simulação tem-se a divisão em duas situações, em que no primeiro momento, para a base de treinamento foi utilizada do dia 15/05 às 00:00 até 03/06 às 03:45 que compreende 55% da base de dados, e o restante do dia 03/06 às 04:00 até 17/06 no tempo 23:45 para teste. Conseqüente foi utilizado para treinamento valores do dia 15/05 às 00:00 até 08/06 às 02:15 que equivale a 70% da base de dados, e o restante do dia 08/06 às 02:30 até 17/06 no tempo 23:45 para teste. Visualizando a Figura 7 é visível graficamente a separação da base de treinamento e teste em 55% e 70% respectivamente.

Ao analisar a Figura 7 nota-se a importância de cada amplitude no gráfico referência um dia completo para os dados da usina, ficando mais clara a divisão das bases. Após desses estudos de pré-processamento os modelos de *forecasting* foram utilizadas em ambas situações, obtendo seus respectivos resultados

4. RESULTADOS

Seguindo a lógica da metodologia, os resultados foram divididos com base na quantidade de dados para a análise e comparação dos algoritmos de aprendizado de máquina em diferentes fatores, para que no final fosse feita uma avaliação geral dos algoritmos.

4.1 Treinamento com 55% do da Base Total

Para essa configuração foi treinado o modelo de RNA e o modelo Prophet e apresentado em forma de gráfico. A Figura 8 mostra os esboços da previsão de 15 dias da série

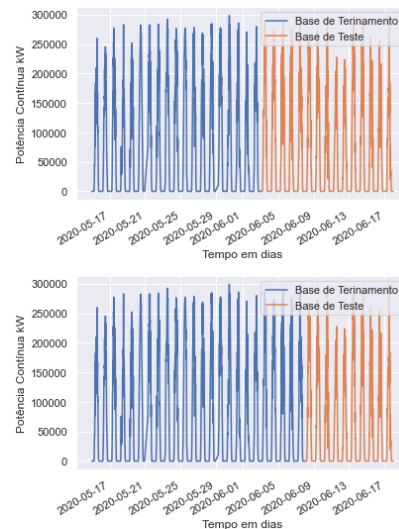


Figura 7. Configuração da Base de Treinamento e Teste em cada Simulação

temporal dos dois modelos sobre a produção de energia FV em comparação com a produção real.




Figura 8. Previsão e Produção Real da Potência CC da Usina FV com 55% do Total dos dados (Fonte: Autoria Própria)

Conforme mostrado na Figura 8, é visto que os dois modelos conseguem observar a variação da série temporal. Entretanto, de certo modo que o modelo LSTM obteve o uma melhor descrição do fenômeno com essa configuração de dados.

4.2 Treinamento com 70% do da Base Total

Prosseguindo para a simulação referente a 70% da base de dados, o experimento foi executado para os dois modelos mostrando os gráficos contidos na Figura 9 sobre a mesma óptica da Figura 8, mudando somente a quantidade de dias previstos que caiu para 10 devido ao tamanho dos dias para teste disponíveis nesta situação na base de dados.

Analisando os gráficos da Figura 9 é observado da mesma maneira que os modelos tiveram performances aceitáveis. Todavia, é nítida a melhora do *Prophet*, isso se dá pelo fato de não ser uma RNA e não treinar repetidamente sua base de treinamento em relação a LSTM este tipo de aprendizagem de máquina necessita de uma maior quantidade de dados para obter uma melhor precisão.

4.3 Avaliação Geral

Para uma melhor exemplificação da eficiência das simulações feitas no artigo as Tabela 5 e 6 foram construídas




Figura 9. Previsão e Produção Real da Potência CC da Usina FV com 70% do Total dos dados, (Fonte: Autoria Própria)

contendo valores de precisão, erro e esforço computacional de cada modelo executado.

Tabela 5. Resultados das Simulações para o LSTM, (Fonte: Autoria Própria)

| Parâmetros | LSTM (Base 55 %) | LSTM (Base 70 %) |
|-------------------|------------------|------------------|
| Precisão (%) | 92,17 | 93,10 |
| Épocas Utilizadas | 72 | 66 |

Tabela 6. Resultados das Simulações para o Facebook Prophet, (Fonte: Autoria Própria)

| Parâmetros | Prophet (Base 55%) | Prophet (Base 70%) |
|--------------|--------------------|--------------------|
| Precisão (%) | 86,34 | 92,01 |

Analisando os resultados obtidos nas Tabelas 5 e 6 é notório a alta precisão de ambas as simulações chegando a valores superiores a 85% em ambas as situações. Entretanto comparando os experimentos em função dos modelos, é visto que na base de treinamento em 55% o LSTM se sobressai com uma melhor precisão pela boa adaptação do modelo a poucos dados em comparação ao outro algoritmo.

Na outra configuração de dados, é notório a recuperação do Prophet pelo aumento da quantidade de dados para treinamento, sendo suficiente para uma melhora imediata chegando a valores próximos ao LSTM, com um menor tempo de processamento pois não é necessário épocas de treinamento e esforço computacional para sua previsão. Todavia a Rede Neural Recorrente também teve uma melhora de precisão e de esforço computacional diminuindo o número de épocas para a construção dos pesos.

5. CONCLUSÃO

Este trabalho mostrou que a análise de série temporal foi escolhida de maneira correta na descrição da produção de energia por uma Usina Solar. Através desse estudo foi possível descrever o provável comportamento da produção de eletricidade pela Usina FV.

A rede LSTM se mostrou eficaz para a predição deste tipo de problema sendo extremamente adaptável a números a restritos e abundantes de dados, pelas simulações a sua precisão chegou a números maiores a 90%, deixando claro sua adaptabilidade a situações de escassez de dados, apesar de necessitar de um considerável esforço computacional.

O estudo sobre o Prophet indicou uma precisão aceitável em ambas as situações, entretanto a quantidade de dados disponíveis influencia substancialmente na sua precisão variando de 86,34 % a 92,01%. Entretanto, podendo ser

aplicado aos dois casos por causa de que os valores de performance são aceitáveis.

Por fim, foi satisfatório os resultados obtidos com as simulações feitas, deixando claro os pontos fortes de cada algoritmo. Sendo situações de poucos dados em uma usina a utilização do LSTM pela sua boa performance a esta modalidade, todavia usinas FV com a situação contrária podem contar com o Facebook Prophet com valores aceitáveis e melhor tempo de processamento.

REFERÊNCIAS

- Balti, H., Abbes, A.B., Mellouli, N., Sang, Y., Farah, I.R., Lamolle, M., and Zhu, Y. (2021). Big data based architecture for drought forecasting using lstm, arima, and prophet: Case study of the jiangsu province, china. In *2021 International Congress of Advanced Technology and Engineering (ICOTEN)*, 1–8. doi:10.1109/ICOTEN52080.2021.9493513.
- Camargo, L.T. (2017). Projeto de sistemas fotovoltaicos conectados à rede elétrica. 101.
- Cerqueira, E.O.d., Andrade, J.A.C.d., Poppi, R.J., and Mello, C. (2001). Redes neurais e suas aplicações em calibração multivariada. *Química Nova*, 24, 864 – 873. URL http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-40422001000600025&nrm=iso.
- de Barros Alencar, V.A.S., Pessamilio, L.R., da Silva, F.R., Bernardino, H.S., and Vieira, A.B. (2020). Predição de séries temporais de demanda em modelos de compartilhamento de veículos para modelos uni e multi variáveis. In *Anais do IV Workshop de Computação Urbana*, 84–96. SBC.
- EPE (2020). Matriz energética nacional 2020 - ano base 2019. *Empresa de Pesquisa Energética*, p. 183.
- Frontin, Sergio O e Godoy, N. (2017). *Usina Fotovoltaica Jaíba Solar : Planejamento e Engenharia*, volume 1. Brasília, DF.
- Gomide, F.A. (2012). Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. *Sba: Controle Automação Sociedade Brasileira de Automatica*, 23, 649 – 652. URL http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592012000500011&nrm=iso.
- Ishaque, K. and Salam, Z. (2013). A review of maximum power point tracking techniques of pv system for uniform insolation and partial shading condition, renewable and sustainable energy reviews. 19, 475–488.
- Machado, Carolina T e Miranda, F.S. (2015). Energia solar fotovoltaica: uma breve revisão. *Revista virtual de química*, 7(1), 126–143.
- Reis, M.M. (2020). Ine 7001 análise de séries temporais. 4. URL <https://www.inf.ufsc.br/~marcelo.menezes.reis/Cap4.pdf>.
- Santos, G. (2019). Uma aplicação de redes neurais recorrentes do tipo lstm à previsão dos preços de curto prazo do mercado de energia elétrica brasileiro. p. 76.
- Zunic, E., Korjenić, K., Hodžić, K., and Donko, D. (2020). Application of facebook’s prophet algorithm for successful sales forecasting based on real-world data. *International Journal of Computer Science and Information Technology*, 12. doi:10.5121/ijcsit.2020.12203.