

MODELAGEM DE SISTEMA FOTOVOLTAICO UTILIZANDO ALGORITMOS INTELIGENTES.

José Genilson da Costa Júnior¹

Orientadora: Dra. Romênia Gurgel Vieira²

Resumo: O estudo em questão tem como objetivo desenvolver e analisar algoritmos inteligentes capazes de detectar padrões na produção energética de uma usina solar fotovoltaica através da coleta e análise de dados temporais reais, os quais foram obtidos através de condições ambientais distintas de funcionamento desse sistema. Com isso, o trabalho consiste em uma abordagem de técnicas de inteligência artificial, como redes neurais artificiais, que permitem identificar padrões e comportamentos complexos, que podem melhorar a estimativa da potência gerada a partir de variáveis ambientais, como irradiação solar, temperatura ambiente, umidade e horário do dia. Assim, através do estudo desses algoritmos, a pesquisa busca fornecer uma ferramenta eficiente para monitoramento e planejamento energético, o que promove uma operação mais inteligente e eficiente dos sistemas fotovoltaicos. Os resultados indicaram que o modelo LSTM (Long Short-Term Memory) foi superior ao MLP (Multilayer Perceptron), especialmente em previsões sequenciais, mostrando maior precisão na captura de padrões temporais e climáticos relacionados à produção de energia fotovoltaica. O LSTM demonstrou desempenho superior em dias ensolarados e condições de variação climática mais baixas, enquanto o MLP se saiu relativamente bem em dias com variações climáticas mais altas, como em dias nublados. Portanto, o trabalho destaca a importância da integração entre tecnologias computacionais avançadas, como a Inteligência Artificial, e as fontes de energias renováveis como uma forma estratégica para o aprimoramento da matriz energética.

Palavras-chave: Energia solar. Inteligência artificial. Redes neurais. Sistemas fotovoltaicos.

1. INTRODUÇÃO

A crescente demanda por fontes de energias renováveis, que fundamentam sua geração no aproveitamento de energias como o sol, vento e água para amenizar o uso de combustíveis fósseis na matriz energética, tem impulsionado cada vez mais a expansão de usinas fotovoltaicas (CUNHA; SOBEL, 2021). Nesse viés, também é possível relacionar o aumento dessas tecnologias, que baseiam sua geração energética na captação da energia solar, devido à sua abundância, acessibilidade e potencial energético em diversas escalas de geração. Entretanto, sua intermitência e dependência de variáveis climáticas impõem desafios significativos à previsibilidade e à eficiência da geração energética. (PONRAJ et al., 2023).

Com o avanço da Era da Inteligência Artificial (IA), a qual vem sendo considerada como um dos pilares fundamentais da quarta revolução industrial, a IA surge com o objetivo de substituir as operações realizadas pelo cérebro humano por máquinas. Assim, sua aplicação tem se expandido significativamente para setores estratégicos diversos, como por exemplo, o setor de geração de energia (PONRAJ et al., 2023). Nesse contexto, através da adoção dessas ferramentas baseadas na implementação de redes neurais artificiais, é possível desenvolver meios eficazes e capazes de simular e prever o desempenho de sistemas fotovoltaicos sob variadas condições climáticas e de funcionamento.

Entre os modelos mais fundamentais que utilizam aplicações de IA, podemos destacar o *Perceptron*. Tal estrutura de rede neural artificial foi introduzida por Frank Rosenblatt na década de 1950, com o objetivo de simular o funcionamento dos neurônios biológicos humanos em sistemas computacionais. O *Perceptron* consiste em uma ferramenta que se trata de um modelo supervisionado simples, que pode ser composto por uma ou mais camadas de neurônios artificiais interligados que simulam o cérebro humano nas tomadas de decisão para qualquer tipo de situação (ROSENBLATT, 1958). Tais mecanismos artificiais são capazes de receber variáveis de entrada que possibilitam o aprendizado de padrões de comportamento por meio de classificações a partir de dados de entrada. Esse modelo se destaca por sua simplicidade matemática de funcionamento e de utilização, sendo possível sua aplicação com o intuito de correlacionar variáveis como umidade, temperatura, irradiação solar e horário com a potência gerada de uma produção energética de uma usina FV.

Em estudos como o de Liu et al. (2020) demonstram que redes neurais artificiais, principalmente o modelo LSTM, têm se destacado devido sua capacidade de prever a produção de energia fotovoltaica com base em dados climáticos históricos, o que evidencia a capacidade dessas ferramentas em otimizar sistemas de geração energética. No Brasil, Cunha e Sobel (2021) realizaram um estudo sobre a aplicação de redes neurais artificiais na previsão de geração de energia fotovoltaica no Nordeste. Com isso, é evidenciado a importância de integrar dados climáticos e ambientais, como a irradiação solar e a temperatura ambiente, ao modelo desenvolvido, visando a melhora na precisão das previsões de produção de energia nas usinas fotovoltaicas.

Diante disso, o presente estudo busca desenvolver modelos preditivos capazes de avaliar o desempenho de usinas FV a partir de dados operacionais reais. Isso permite avaliar o desempenho dessas estruturas em condições reais de operação, o que difere de estudos que utilizam dados simulados ou genéricos. Com isso, para a otimização da geração de energia fotovoltaica torna-se necessário a utilização de dados contínuos de variáveis ambientais (irradiação, temperatura e umidade) e temporais para prever a potência gerada em tempo real, visando aprimorar a eficiência e desempenho da usina.

Para isso, será utilizada uma base de dados operacionais de uma das usinas fotovoltaicas instaladas na Universidade Federal Rural do Semi-Árido (UFERSA), localizada no campus de Mossoró-RN, de capacidade de 3 kWp. A análise será realizada utilizando informações históricas registradas pela estação meteorológica da própria universidade, a qual está acoplada à usina analisada em questão, que fornece medições contínuas de variáveis ambientais, como irradiação solar, temperatura ambiente e umidade relativa do ar. Com isso, a utilização desses dados foi fundamental para a construção e análise desses mecanismos preditivos, os quais espera-se que possibilitem uma avaliação do desempenho da previsão da geração de energia elétrica em condições reais de operação.

Diante disso, a crescente demanda por energias renováveis evidencia a importância da energia solar, cujas principais limitações estão diretamente ligadas à dependência de variáveis climáticas.

Este trabalho está estruturado da seguinte maneira: na seção 2, será abordado todo o desenvolvimento do modelo da rede neural artificial, desde o tratamento dos dados até a análise de resultados obtidos; por fim, na seção 3, será discutido acerca das conclusões, às quais serão feitas a partir da análise dos resultados.

2. Coleta de dados

Para a construção da estrutura artificial de um rede neural é necessário a coleta de uma base de dados consistente, a qual contenha as variáveis ambientais que influenciam diretamente na geração elétrica dessa usina, como temperatura, irradiação e umidade. Os dados utilizados neste trabalho foram coletados de uma usina fotovoltaica real, a qual possui uma capacidade de geração de 3 kWp e está situada na Universidade Federal Rural do Semi-Árido (UFERSA), localizada no campus de Mossoró-RN. Os dados que foram obtidos contêm informações sobre variáveis ambientais da localidade em que o sistema está inserido, os quais foram coletados a partir de sensores presentes em uma estação meteorológica que está instalada ao lado da usina.

Assim, através desses sensores, os quais realizam e fornecem medições em tempo real a cada 15 minutos sobre diversos parâmetros meteorológicos, foi possível adquirir informações do período entre setembro de 2024 e junho de 2025, o que ofereceu para o estudo, aproximadamente, 8 meses de informações reais. Entre os dados coletados, é possível obter valores dos seguintes parâmetros: data, horário, irradiação solar, umidade relativa do ar e temperatura ambiente.

Os dados coletados possibilitam uma análise precisa das condições meteorológicas que afetam diretamente a geração de energia. Sobre as informações acerca da potência gerada pela usina, foram obtidas diretamente do sistema de monitoramento do inversor da planta FV. O dispositivo, além de realizar a inversão de corrente contínua para alternada, é responsável por coletar e fornecer dados sobre a produção energética elétrica durante intervalos semelhantes aos intervalos dos sensores utilizados na estação meteorológica da usina.

Desse modo, a análise e modelagem do desempenho elétrico da usina é realizada através da associação de todos esses dados combinados, tornando possível a criação de redes neurais artificiais que recebam essas variáveis como dados de entrada, para a classificação ou predição de valores de potência, e um dado de saída resultante.

2.1. Tratamento de dados

Com os dados brutos necessários para o estudo já obtidos e exportados em formato de planilhas, tornou-se necessário uma série de tratamentos para adequá-los à aplicação do modelo preditivo. Entre os procedimentos, o tratamento se inicia com a junção das tabelas de medições dos sensores meteorológicos (irradiação, temperatura e umidade) com os dados extraídos do inversor da usina (potência gerada), por meio do casamento dos horários de medição. Dessa forma, como os sensores da estação meteorológica e o inversor operam com sistemas independentes, foi necessário realizar uma etapa de alinhamento temporal, o qual foi realizado com o uso da linguagem de programação *Python* (VAN ROSSUM; DRAKE, 2009), por meio de bibliotecas específicas como *Pandas* para manipulação de dados tabulares, como planilhas, e *NumPy* para operações matemáticas mais específicas, utilizadas, por exemplo, para a realização da interpolação entre os dados, quando necessário, para garantir sincronia entre os conjuntos de dados ou o preenchimento de dados faltantes e discrepantes (*outliers*).

Após o pré-processamento e tratamento dos dados, se obteve como resultado uma única planilha contendo informações sobre todos os parâmetros advindos dos sensores e do inversor, com medições agrupadas e organizadas a cada 15 minutos. Assim, o conjunto final de dados se consolidou em cerca de 5.000 linhas de dados, os quais foram distribuídos em gráficos *box plots* apresentados nas Figuras 1 e 2, que oferecem uma visão clara da distribuição dos valores de temperatura, umidade, irradiação e potência gerada na usina e coletados pela estação meteorológica da UFERSA ao longo do período de setembro de 2024 a junho de 2025. Essa representação gráfica é fundamental para identificar padrões, tendências e possíveis anomalias nos dados ambientais que impactam diretamente a geração de energia fotovoltaica.




Figura 1 - Dados de temperatura e umidade (Fonte: Autoria própria)




Figura 2 - Dados de irradiância e potência (Fonte: Autoria própria)

Analisando a Figura 1, o *box plot* da temperatura revela a mediana próxima do centro da caixa, sugerindo uma distribuição relativamente simétrica dos valores registrados no período analisado. Os quartis (Q1 e Q3) delimitam o intervalo onde se concentra a maioria das observações, evidenciando pouca dispersão em dias regulares. Os extremos do *box plot* (bigodes) demonstram a presença de dias tipicamente quentes ou frios, mas sem indicar ocorrência significativa de *outliers*, o que aponta para um comportamento climático estável na região durante o período de coleta. O *box plot* da umidade relativa do ar indica uma maior variabilidade, refletida na largura da caixa e no comprimento dos bigodes. Este padrão revela que a umidade apresentou variações mais marcantes, possivelmente em decorrência de variações sazonais, chuvas esporádicas ou ventos. Não há uma concentração elevada de valores atípicos (*outliers*), o que sugere que mesmo as oscilações mais extremas ainda se mantiveram dentro da faixa típica esperada para o clima local.

O *box plot* apresentado na Figura 2 ilustra a distribuição dos valores de irradiância solar e da potência gerada pela usina ao longo do período estudado. Esta representação gráfica permite identificar padrões de variação e possíveis anomalias nesses parâmetros, fundamentais para a avaliação do desempenho do sistema fotovoltaico. Em relação à irradiância solar, observa-se que a mediana está posicionada próxima ao centro da caixa do *box plot*, indicando que a distribuição dos valores é relativamente equilibrada durante o intervalo analisado. Os quartis (Q1 e Q3) delimitam o intervalo em que a maioria das observações está concentrada, sugerindo que, na maior parte do tempo, a irradiância permaneceu dentro de uma faixa considerada típica para a região. Os bigodes do *box plot* revelam a ocorrência de alguns dias com valores excepcionalmente altos ou baixos de irradiância, possivelmente associados a condições meteorológicas atípicas, como dias de céu encoberto ou períodos de intensa insolação. No entanto, a quantidade de *outliers* é pouco expressiva, o que reforça a confiabilidade dos dados coletados.

No que se refere à potência gerada, a análise do *box plot* revela uma dinâmica semelhante à observada na irradiância, com a mediana bem distribuída e baixa incidência de outliers. Isso indica que a produção energética da usina acompanhou de forma consistente as variações na irradiância solar, reforçando a robustez do sistema e a boa qualidade dos dados. Os extremos do *box plot* sugerem a presença de picos ou quedas excepcionais na geração de energia, que podem estar associados a eventos climáticos específicos ou a intervenções operacionais na usina.

De modo geral, a análise dos *box plots* da Figura 2 demonstra que, tanto a irradiância quanto a potência, apresentaram

distribuições coerentes e estáveis ao longo do período avaliado. A baixa ocorrência de valores anômalos confirma a regularidade das condições ambientais e do funcionamento da usina, elementos essenciais para o desenvolvimento de modelos preditivos confiáveis e precisos na estimativa da geração de energia fotovoltaica.

2.2. Redes Neurais *Perceptron* Multicamadas

Com base nas noções de Silva, Spatti e Flauzino (2016), o modelo Perceptron, desenvolvido por Frank Rosenblatt em 1958, tem como objetivo simular o comportamento de um neurônio biológico em uma rede neural artificial. Sua estrutura é considerada como uma das mais simples para construção de uma rede neural, o que impõe limitações no seu uso e torna o seu modelo incapaz de resolver problemas que não são linearmente separáveis por uma classificação binária. Diante disso, surgiu a necessidade de redes neurais mais complexas e flexíveis, as quais podem ser capazes de abordar problemas que possuem uma classificação que vai além de uma simples separação linear, como o Perceptron Multicamadas (MLP – *Multilayer Perceptron*).

Esse modelo é proposto para ser composto por uma ou mais camadas ocultas entre a camada de entrada e a de saída, assim, cada uma dessas camadas pode ser composta por múltiplos neurônios artificiais que utilizam funções de ativação não lineares para realizar as operações e relações entre as variáveis. Nesse sentido, através do uso de multicamadas, é possível que a estrutura da rede aprenda representações hierárquicas dos dados de entrada, na qual sugere quais parâmetros irão ter mais influência do que outros, o que possibilita que o modelo seja capaz de moldar relações mais complexas entre as variáveis de entrada e saída.

Continuando o pensamento de Silva, Spatti e Flauzino (2016), o Perceptron Multicamadas funciona por meio de um processo denominado de treinamento supervisionado, o qual utiliza algoritmos de retropropagação do erro (*backpropagation*) para ajustar os pesos de cada parâmetro, o que irá sugerir a influência de cada variável de entrada na estrutura da rede neural.

Dessa forma, na Figura 3 é possível entender a estrutura de organização de um Perceptron Multicamadas (MLP) no tratamento de informações, em que sua arquitetura inclui várias camadas escondidas entre a entrada e a saída, o que possibilita o aprendizado de representações complexas. Assim, por meio dessa estrutura, o MLP é capaz de identificar padrões, prever sequências temporais, classificar e realizar regressões, o que o torna uma ferramenta extremamente poderosa, podendo ser aplicada em diversas áreas, como a de engenharia e outras ciências aplicadas.




Figura 3 - Esquema de funcionamento do *Perceptron* multicamadas (Fonte: SILVA; SPATTI; FLAUZINO, 2016)

2.2.1. Funções de ativação do *perceptron* multicamadas

Ainda no pensamento de Silva, Spatti e Flauzino (2016), no modelo de rede neural artificial *Perceptron*

Multicamadas (MLP), as funções de ativação são elementos fundamentais que irão definir como cada neurônio, que está dentro da rede, irá se comportar. Sendo assim, as funções de ativação influenciam diretamente a capacidade da rede de aprender e generalizar a partir dos dados. Desse modo, o objetivo principal das funções de ativação é garantir e introduzir a não linearidade das relações entre as variáveis de entrada e saída, o que possibilita estabelecer correlações entre esses parâmetros mais complexos e mais precisos.

Dentre as principais funções, é possível citar a função Sigmóide ou Logística, a qual se assemelha bastante ao modelo de função linear do *Perceptron* simples, sendo que ela também realiza a classificação binária com a saída com valores entre 0 (zero) e 1 (um), porém com uma certa suavização da sua representação, se assemelhando com uma curva. Ainda nesse contexto, existem diversas funções e formas de realizar a ativação do neurônio dentro da arquitetura de uma rede neural artificial, como a tangente hiperbólica, Relu (*Rectified Linear Unit*), entre outras. O que irá defini-las dentro de uma situação de aplicação será a forma com que o problema necessita ser tratado, indicando assim, qual a função mais apropriada para o contexto aplicado.

2.2.2. Etapas do *perceptron* multicamadas

O funcionamento de um MLP ou *Perceptron* múltiplas camadas ocorre com um fluxo bem estabelecido dentro de toda sua estrutura. O processamento da informação se divide em três fases principais: a progressão da informação, o retorno do erro e o ajuste dos pesos.

De início, na fase de progressão (*forward pass*), os dados que entram no neurônio avançam sequencialmente por cada camada de sua estrutura até se chegar à fase final de propagação do resultado. A partir disso, cada neurônio irá processar cada sinal recebido durante a progressão dos dados na rede, de maneira que haja uma combinação ponderada entre os pesos de cada parâmetro a partir das funções ativação, que irá permitir que o modelo possa captar relações complexas entre as variáveis.

Em seguida, na fase de retorno do erro (*backpropagation*), o resultado obtido é comparado com o valor correto real através de uma função de diferença, como o erro quadrático médio. Por meio desse mecanismo, o erro resultante é propagado da última camada para as camadas anteriores, que possibilita o cálculo da variação do erro em relação aos pesos das conexões entre as camadas. Por fim, os pesos são ajustados, utilizando os gradientes calculados por um otimizador, com o objetivo de refinar a rede e reduzir o erro em cada nova iteração.

Desse modo, este processo se repete por diversas vezes até que a rede consiga aprender e generalizar os padrões presentes nos dados de forma adequada e eficiente para o contexto desejado.

2.3. Redes Neurais Recorrentes (RNN)

Após compreender as ideias fundamentais e os princípios de funcionamento do *Perceptron* multicamadas, é possível abordar arquiteturas mais complexas, as quais serão necessárias para o desenvolvimento de uma rede neural capaz de prever o desempenho de uma usina FV. Nesse contexto, através de redes neurais recorrentes, é possível analisar e tratar problemas que envolvem dependência temporal e contexto sequencial, como tarefas nas quais o dado mais atual está intrinsecamente relacionado com estados anteriores, como séries temporais.

As Redes Neurais Recorrentes (RNN – *Recurrent Neural Networks*) são consideradas como uma classe de Redes neurais artificiais projetadas para processar sequências temporais ou dados ordenados, sendo especialmente mais eficazes na modelagem de dependências temporais e contextuais em séries de dados.

Desse modo, a previsão da potência gerada por uma usina fotovoltaica está diretamente ligada à análise de variáveis meteorológicas que apresentam comportamento característico ao longo do tempo, como a temperatura ambiente, irradiação solar e umidade relativa do ar. Dessa forma, essas variáveis, além de influenciarem diretamente o desempenho dos módulos fotovoltaicos, apresentam essa relação temporal, em que seus valores atuais estão diretamente influenciados pelos seus estados anteriores.

Dentro desse contexto, as Redes Neurais Recorrentes são mais apropriadas para esses tipos de situações, uma vez que suas relações de decisões utilizam de retroalimentação de dados para fornecer mais informações para seus próprios neurônios. Essa autoalimentação interna atua como uma memória rápida, permitindo que a rede guarde informações importantes dos dados inseridos mais recentes anteriormente, as quais teriam mais influência do que dados mais antigos nas tomadas de decisões posteriores (GOODFELLOW; BENGIO; COURVILLE, 2016).

Segundo Goodfellow, Bengio e Courville (2016), embora as redes neurais recorrentes tenham seus benefícios para compreender dados de séries temporais, elas ainda mostram uma certa dificuldade em situações com relações a longo prazo no tempo, tendo em vista que o fenômeno conhecido como desvanecimento (ou explosão) do gradiente durante o treinamento, o que prejudica e compromete o aprendizado de padrões mais antigos. Assim, como a previsão da produção de energia solar de uma usina FV é influenciada diretamente a partir de condições meteorológicas, essas condições exercem efeitos na produção acumulativo durante o tempo, uma vez que através da análise da sequência temporal em períodos que vão além dos momentos mais recentes dessas variáveis, é possível verificar o quanto isso pode afetar na produção de energética do sistema.

2.4. Modelo LSTM (Long Short-Term Memory)

Para suprir os problemas de análise de dados compostos por séries temporárias a longo prazo, destaca-se o modelo LSTM, que foi especificamente projetado para lidar com essas questões de memória de longo e curto prazo. Nesse contexto, por meio de sua estrutura complexa interna, torna-se possível o armazenamento, a atualização e descarte seletivo de informações ao longo da sequência de forma controlada por meio de portas internas que regulam o fluxo de informações dentro da célula de tratamento de dados, o que possibilita o descarte de informações menos influentes, atualização de dados e a saída de informações (HOCHREITER; SCHMIDHUBER, 1997).

Além disso, o modelo LSTM, o qual pode ser entendido como uma extensão das redes neurais recorrentes, é composto por uma arquitetura que pode ser repleta por múltiplas camadas empilhadas, em que a informação é processada várias vezes, e por mais de um neurônio, até chegar ao neurônio final que irá realizar a operação final da rede. Ainda na fase de ativação do neurônio, existem funções matemáticas que são capazes de limitar os valores de saída da rede, o que possibilita alterar a forma e eficiência de como os dados serão tratados.

Entre as principais funções de ativação, existe a função sigmóide, que possui uma habilidade de restringir os valores de saída entre 0 e 1. Essa função é usada nas portas de controle como uma espécie de filtro, que decide a quantidade de dados a ser repassada entre as camadas. Já a função tangente hiperbólica (tanh) serve para mudar o estado interno da célula, que é uma parte interna do neurônio, possibilitando expressar mudanças negativas e positivas, que varia na faixa de -1 a 1.

2.4.1 Otimizadores

Durante a fase de treinamento de uma estrutura LSTM, existem otimizadores que, por meio de algoritmos de descida do gradiente, conseguem ajustar os pesos da função de ativação para minimizar o erro da rede. Entre os destacados otimizadores, destaca-se o Adam (*Adaptive Moment Estimation*), o qual é um dos otimizadores mais utilizados devido à sua eficiência e estabilidade. O Adam consegue adaptar dinamicamente às taxas de aprendizado para cada parâmetro da rede (KINGMA; BA, 2015). Desse modo, o otimizador Adam foi o adotado no modelo LSTM utilizado neste trabalho devido à sua capacidade de lidar com grandes volumes de dados, o que contribui significativamente para um treinamento mais eficiente e estável da estrutura neural desenvolvida.

2.5. Estrutura LSTM para previsão da potência gerada de uma usina FV

Diante de tudo que foi citado, para previsão de potência gerada por sistemas fotovoltaicos, o modelo LSTM torna-se altamente vantajoso, pois como já foi citado, a produção do sistema está diretamente associada à relação das variáveis meteorológicas e seu comportamento sequencial temporal. Portanto, o LSTM é capaz de capturar essas interações temporais de forma mais precisa do que modelos simples, como o *Perceptron* ou RNNs tradicionais, o que torna uma escolha mais apropriada para previsão em séries temporais em longo prazo.

2.6. Implementação de Rede neural em Python

Para a implementação das redes neurais utilizadas neste estudo, foi utilizada a linguagem de programação Python, a qual foi utilizada na sua versão mais atual para garantir os melhores e mais atuais recursos da ferramenta. O Python é uma linguagem de programação que possui recursos importantes para o desenvolvimento de aplicações científicas, principalmente na área de inteligência artificial e ciência de dados (VAN ROSSUM; DRAKE, 2009).

2.6.1 Exploração visual dos dados

Como já foi realizado o pré-processamento e o tratamento dos dados através das bibliotecas integradas ao Python, a etapa de visualização dos dados foi realizada utilizando a mesma linguagem, por meio de bibliotecas especializadas na geração de gráficos e representações visuais, como o Matplotlib, a qual é uma biblioteca amplamente utilizada para criação de gráficos de linha, dispersão, histogramas, mapas de calor e séries temporais.

A etapa de análise visual teve como objetivo identificar padrões, tendências e correlações entre as variáveis meteorológicas (temperatura, umidade e irradiação) e a variável de saída (potência gerada). A utilização desta biblioteca proporcionou uma representação intuitiva dos dados, a qual facilitou a compreensão preliminar do comportamento do sistema fotovoltaico e ajudou a definir estratégias adequadas de modelagem preditiva. Além disso, devido à grande quantidade de valores de medições no conjunto de dados, tendo em vista as medições diárias dos sensores, para uma melhor visualização, na Figura 4 é ilustrado o comportamento da potência e irradiação durante os 3 últimos dias de medições. Desse modo, pode-se destacar um comportamento cíclico da potência e irradiação, em que os seus valores se repetem aproximadamente a cada dia, bem como as variações instantâneas geradas devido à presença de nuvens. Essa condição de nebulosidade é uma característica marcante na região onde o sistema FV está instalado.




Figura 4 - Comportamento da potência gerada e irradiância ao longo do tempo (Fonte: Autoria própria)

2.6.2 Separação em treino e teste

Para dar seguimento ao desenvolvimento da rede, torna-se necessário a divisão de todo o conjunto de dados em duas partes principais: treinamento e teste. Os dados separados para a fase de treinamento devem ser uma quantidade expressiva de informações para que a rede fique bem ajustada. Esses dados de treino são responsáveis por regular os pesos das variáveis de entrada da rede usando otimizadores, o que permitirá que o modelo aprenda as relações que existem entre as variáveis de entrada e saída.

Já o conjunto de teste consiste em uma porcentagem menor do conjunto total de dados que serão realizados testes da rede neural desenvolvida. Ele possibilitará realizar a análise de desempenho da rede através da comparação dos valores previstos da rede com os valores reais que estão no conjunto de dados.

Para realizar a divisão entre treinamento e teste, os dados foram separados de forma que o conjunto de dados para o treinamento tenha 98% de todo o conjunto de dados e os 2% restantes sendo aplicados para o teste, como é mostrado nos dados de potência na Figura 5, sendo os dados na cor azul usados para o treino e os na cor vermelha para o teste. Essa divisão é fundamental para assegurar a confiabilidade do modelo preditivo e garantir que suas estimativas possam ser utilizadas no apoio à operação e planejamento da geração fotovoltaica em cenários meteorológicos variáveis (GOODFELLOW; BENGIO; COURVILLE, 2016).




Figura 5 - Ilustração da divisão dos dados de potência em teste e treino. (Fonte: Autoria própria)

2.6.3 Normalização dos dados

Após a divisão do conjunto de dados em treino e teste, é necessário realizar a etapa de normalização dos dados, que consiste em vários processos de tratamento com os valores reais dos parâmetros de entrada. Essa etapa consiste desde a verificação dos tipos de variáveis, as quais podem ser categóricas ou numéricas, até a transformação da escala de cada variável. Nesse sentido, como o projeto estudado é somente constituído por variáveis do tipo numéricas, a única preocupação será a normalização dos valores numéricos reais, tendo em vista que todos as variáveis devem estar na mesma escala, para que todos os dados fiquem homogêneos e compatíveis com o funcionamento dos algoritmos de aprendizado. Desse modo, como as variáveis potência, temperatura, irradiância e umidade apresentam ordens de grandeza diferentes, a padronização precisa ser feita para não comprometer a eficiência da rede neural. Assim, a normalização evita que variáveis com maior amplitude dominem a função de erro e sobressaiam sobre as demais variáveis.

A biblioteca Scikit-learn, a qual representa um dos inúmeros recursos que já estão integrados ao Python, disponibiliza diversas opções de algoritmos que tem como objetivo o tratamento de informações, como classificar, regredir, agrupar e reduzir a dimensionalidade de dados. Através dessa ferramenta, é possível utilizar métodos comuns, que já incluem a normalização Min-Max, que transformam os dados para um intervalo entre 0 e 1 ou outros intervalos desejados. Dessa forma, a padronização centraliza os dados em torno da média com desvio padrão unitário, em que podem ser comumente utilizados para aplicações de previsão da potência gerada por sistemas fotovoltaicos, uma vez que a normalização se torna essencial para que o modelo aprenda de forma equilibrada a influência de cada variável climática.

2.6.4. Geração de Treino, Validação e Teste

A etapa de geração dos subconjuntos treino, validação e teste é fundamental no desenvolvimento de modelos de redes neurais, pois é através dessas etapas que o neurônio artificial garante sua capacidade de aprender padrões relevantes que relacionam os dados de entrada e saída. A divisão entre o treino e teste é feita antes do treinamento da rede, enquanto o conjunto de validação é gerado durante o treinamento. Primeiramente, o conjunto inicial de treino é utilizado para ajustar os pesos internos da rede, em que a rede vai entender a influência independente de cada variável dentro da arquitetura da rede. Já o conjunto de validação é gerado automaticamente pela rede durante o treinamento, a partir de uma pequena parcela dos dados de treino. Esse conjunto é empregado para monitorar e verificar a capacidade do modelo em generalizar os dados que não estão na fase de treinamento, o que ajuda na detecção de *overfitting*, que ocorre quando o modelo aprende demais os detalhes dos dados de treinamento, ao ponto de memorizar os exemplos, em vez de aprender padrões gerais que possam ser aplicados a novos dados.

Para a construção e treinamento de estruturas de redes neurais, foi utilizada a biblioteca Keras, com *backend* Tensor Flow. Através dessa ferramenta, é possível interagir por meio de interfaces que possibilitam o desenvolvimento de arquiteturas, como o modelo LSTM. Com a estrutura desse modelo, é possível realizar cálculos de otimização numérica, derivadas parciais (gradientes) e paralelização em GPU/CPU, o que garante um alto desempenho mesmo em conjunto com grandes volumes de dados.

Após a realização do treino e validação da estrutura do neurônio artificial, é gerado, por fim, o conjunto de teste, o qual é responsável por aplicar outros novos dados (que não foram usados no treino e validação) e avaliar a capacidade de previsão da rede. Sendo assim, a divisão e análise de cada conjunto dentro da rede torna-se essencial para evitar problemas como o *overfitting*.

No contexto de previsão de potência em sistemas fotovoltaicos, a separação entre esses conjuntos possibilita avaliar a capacidade da rede neural ao lidar com variações climáticas e comportamentos sazonais. Por meio de bibliotecas da linguagem Python, como o Scikit-learn e o Pandas, é possível realizar a separação das variáveis independentes, como temperatura, umidade e irradiância, e da variável dependente, que representa a potência gerada, de forma eficiente e estruturada, facilitando a preparação dos dados para a aplicação do modelo.

2.6.5. Treinamento da Rede Neural Recorrente

Em relação ao treinamento de redes neurais, seja ela uma rede neural recorrente ou uma estrutura perceptron, é possível destacar alguns critérios que são fundamentais para realização desse processo. Nesse sentido, é possível destacar como os parâmetros *Epochs* e *Batch size* desempenham papéis importantes no processo de ajuste dos pesos do modelo. O parâmetro *Epochs* indica o número de vezes que o algoritmo irá percorrer todo o conjunto de dados durante o treinamento, ou seja, para cada época é realizado um ciclo completo de alimentação do modelo com os dados que estão disponíveis, com o objetivo de ajustar melhor os pesos internos da rede e melhorar a capacidade preditiva.

Já o *batch size* define a quantidade de amostras que serão processadas antes que seja feita uma atualização dos pesos do modelo. Desse modo, ao invés de atualizar os parâmetros a cada amostra ou apenas ao final do ciclo de uma época, com o uso de lotes (*batches*) é possível estabelecer uma maior estabilidade do desempenho computacional. Segundo Goodfellow, Bengio e Courville (2016), a escolha adequada desses parâmetros pode influenciar diretamente a taxa de convergência e a capacidade de generalização do modelo, sendo necessário adequá-los com base na complexidade dos dados e na arquitetura da rede.

2.6.6. Avaliação de Resultados

Através da análise comparativa entre os valores de potência previstos pela estrutura de rede neural artificial e os

valores reais medidos do conjunto de dados ao longo do tempo, foi possível avaliar a eficiência e desempenho da rede neural desenvolvida. Essa comparação foi representada por meio da geração de gráficos, os quais foram desenvolvidos através da biblioteca Matplotlib do Python, a qual é amplamente empregada em aplicações científicas que possibilitam a criação de gráficos bidimensionais com alta flexibilidade e qualidade visual (HUNTER, 2007). Por meio dessa etapa foi possível a verificação visual da acurácia do modelo construído, o que possibilitou e facilitou a visualização de possíveis padrões de erro ao longo do tempo.

Ao analisar o desempenho de diferentes estruturas de rede neural (alterando o seu número de camadas, quantidade de neurônios entre outros parâmetros) foi possível estabelecer o seguinte modelo de rede neural LSTM: 4 camadas, sendo duas delas LSTM compostas por 100 neurônios, uma terceira camada densa de regressão linear e uma camada final densa de apenas um neurônio para disparar o resultado final. Essa estrutura foi capaz de oferecer um erro quadrático médio de, aproximadamente, 2% e 3% durante o seu treino e validação, respectivamente, o que indica valores de erros significativamente baixos, sugerindo que a rede está aprendendo e generalizando bem. Além disso, também é importante citar um fator importante para a modelagem da ferramenta, o "Day step". Esse parâmetro indica quantos dados serão passados na rede para que ela possa fazer a projeção do próximo valor.

Neste estudo, foi utilizado 30 para o valor de "Day step", o que indica que a rede analisa as 30 leituras anteriores para calcular a previsão seguinte. Dessa forma, isso possibilita que o modelo LSTM aprenda com a ordem sequencial dos dados, o que é de suma importância para séries temporais climáticas e produção de energia. Essa experimentação contínua possibilitou que o modelo fosse continuamente aprimorado, selecionando a configuração que melhor se adequa aos dados coletados.

Para avaliar o desempenho do modelo de arquitetura finalizado, uma curva de potência prevista será traçada em cima da curva de potência real dentro dos índices do intervalo de dados separados para o teste. Desse modo, é possível notar que a curva gerada prevista pelo modelo consegue se aproximar bastante à curva dos dados que realmente foi coletada, como é mostrado na Figura 6, o que evidencia a importância da rede neural desenvolvida para estimar a potência de geração e, posteriormente, avaliar o desempenho do sistema FV. Na Figura 7 também é possível verificar as diferenças entre os valores reais e previstos, evidenciando uma linha de perfeição, que sugere que o modelo é mais eficiente quando o conjunto de pontos está mais próximo dessa linha.

Além da visualização e análise das curvas geradas para os valores previstos e reais, existem outras formas alternativas para verificar as métricas do desempenho das redes, como o RMSE (*Root Mean Squared Error*), o qual quantifica o erro quadrático médio em modelos de regressão, que sugere o erro médio que a rede está tendo nas suas previsões, e o R^2 (Coeficiente de Determinação), que indica a proporção da variabilidade dos dados que o modelo é capaz de explicar.

Nesse sentido, tais métricas foram calculadas diretamente com o Python no conjunto de dados de teste, as quais tem o objetivo de avaliar o desempenho da rede. Os resultados obtidos indicaram o RMSE com o valor de 0,38, que indica que, em média, o modelo apresentou um erro de previsão de 0,38 kW em relação aos valores reais. Já o valor do coeficiente de determinação apresentou um valor de 0,51 o que significa que o modelo conseguiu abranger cerca de 51% da variabilidade dos dados, refletindo uma capacidade moderada de ajuste aos dados observados.




Figura 6 - Comparação entre potência real e potência prevista com o modelo LSTM. (Fonte: Autoria própria)




Figura 7 - Dispersão de dados de potência predita e potência real com o modelo LSTM (Fonte: Autoria própria)

Além disso, a análise do erro de treinamento e validação, que é um parâmetro gerado pela própria rede durante o processo de treinamento, é fundamental para avaliar o desempenho e a capacidade de generalização do modelo para novos dados. Por meio da Figura 8, a qual duas curvas são mostradas: uma vermelha, que representa o erro no conjunto de treinamento, e uma azul, que indica o erro no conjunto de validação. É possível destacar como as curvas se comportam, em que as duas curvas, que diminuem ao longo das épocas, o que indica que o modelo está aprendendo e generalizando bem.

Tais erros são calculados utilizando a função de perda, a qual geralmente também usa o erro quadrático médio (MSE), que mede a diferença entre os valores previstos e reais. Nesse contexto, ao verificar que o erro de validação começa a aumentar enquanto o erro de treinamento continua a diminuir, isso pode estar sinalizando que está ocorrendo um sobreajuste da rede com o conjunto de dados (*overfitting*), que indica que o modelo não está conseguindo melhorar suas previsões para o conjunto de validação. No modelo desenvolvido embora a curva de validação permaneça oscilando, o intervalo de valores é pequeno, o que sugere que a rede está conseguindo generalizar relativamente bem. Desse modo, a análise gráfica torna-se essencial para monitoramento e ajuste do treinamento do modelo, garantindo um melhor desempenho em dados não vistos.



Figura 8 - Comparação entre os erros de treinamento e validação com o modelo LSTM (Fonte: Autoria própria)

2.7. Implementação de Rede neural MLP

O Perceptron Multicamadas é uma estrutura de rede neural composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, sendo cada camada formada por unidades ou células de neurônios artificiais. Essas arquiteturas também têm um papel importante em tarefas como classificação e regressão de problemas não lineares. Assim, para otimizar os parâmetros que fundamentam sua estrutura e evitar o sobreajuste (*overfitting*), são realizadas algumas técnicas, uma delas é o *Grid Search*.

Através dessa técnica, é possível realizar diferentes combinações de hiper parâmetros, como valores de *epochs* e *batch size* diferentes, como também otimizadores. Dessa forma, é possível encontrar a configuração mais eficiente. Essa abordagem, associada à capacidade de aprendizado do MLP, torna -o um modelo robusto e amplamente aplicado em diversas áreas, como reconhecimento de padrões, previsão de séries temporais e análise de dados complexos. Dessa forma, o modelo MLP com *grid search* se torna mais eficaz para problemas gerais de classificação e regressão em dados não sequenciais, enquanto o LSTM é a escolha ideal para dados temporais ou sequenciais, como séries temporais e análise de texto.

Para realizar análises e comparações, uma rede neural MLP com *grid search* foi treinada utilizando as mesmas etapas de treinamento e os mesmos conjuntos de dados, e os seguintes resultados podem ser destacados: uma de acurácia de 47%, com os melhores parâmetros, estabelecidos pelo Grid Search, com o valor para épocas igual a 50, *batch size* igual a 64 e o *adam* como melhor otimizador. Para avaliar o desempenho do modelo de previsão, foram gerados três gráficos, semelhante aos gráficos gerados anteriormente para o modelo LSTM. Na Figura 9, é possível analisar como a linha temporal compara a evolução dos valores reais e preditos ao longo do tempo com índices de treinamento, o que possibilita o acompanhamento de tendências e padrões dos dados.




Figura 9 - Comparação entre potência real e potência prevista durante o teste com o modelo MLP e *Grid Search* (Fonte: Autoria própria)

Já a Figura 10 exibe compara os valores reais com os valores preditos pelo modelo, o qual utiliza uma linha vermelha, que representa a linha de perfeição, em que os valores preditos pelo modelo são iguais aos reais dos dados coletados. Desse modo, quanto mais próximos os pontos azuis estiverem dessa linha, melhor o modelo está em prever os valores.




Figura 10 - Dispersão de dados de potência predita e potência real com o modelo MLP e Grid Search (Fonte: Autoria própria)

A análise do desempenho e eficiência do modelo utilizando o gráfico de erro de treino e validação não é diretamente possível quando se utiliza o modelo MLP com o *grid search*, tendo em vista que o *grid search* ajusta seus hiperparâmetros e treina o modelo de uma forma que não há exposição do histórico de treinamento de forma acessível como o modelo desenvolvido com o LSTM. Como solução, o desempenho do processo de aprendizagem da rede foi avaliado por meio do RMSE e R^2 , outro parâmetro utilizado para avaliar o modelo LSTM. Outras formas de analisar desempenho são RMSE e R^2 . As métricas obtidas para o modelo MLP indicaram o RMSE com um valor de 0,42 e um R^2 de 0,41, o que sugere uma capacidade moderada de ajuste aos dados observados.

2.8. Comparando modelos desenvolvidos

Nesta seção, será realizado o comparativo do desempenho de cada um dos dois modelos desenvolvidos e testados para as redes neurais artificiais: o MLP e o LSTM, ambas estruturas sendo aplicadas para o mesmo contexto de previsão da produção energética fotovoltaica. Dessa forma, ambos os modelos foram treinados e testados aplicando o mesmo conjunto de dados reais, e para análise de desempenho foi realizada por meio de várias métricas, como a acurácia, RMSE, R^2 e o erro de validação.

As duas estruturas de redes neurais foram aplicadas em diferentes condições de funcionamento do sistema, considerando cenários de dias nublados e ensolarados. Através da Figura 11, é possível mostrar uma clara distinção entre as condições de céu nublado e ensolarado, evidenciada pelas flutuações de irradiação, que são significativamente mais baixas durante os períodos de nuvens e aumentam consideravelmente em condições ensolaradas. Além disso, a temperatura também segue um padrão diferente, apresentando menores variações durante os dias nublados e maiores picos nos dias ensolarados.




Figura 11 – Comportamento da Irradiância e Temperatura entre 10/06/2025 e 12/06/2025 (Fonte: Autoria própria)

O modelo MLP, com os parâmetros definidos pelo Grid Search, foi testado em diferentes condições climáticas, utilizando 50 épocas, batch size de 64 e Adam como otimizador. Embora o modelo tenha alcançado uma acurácia de 47% de treinamento, o desempenho foi moderado, com algumas limitações para captar relações temporais mais complexas. A análise da Figura 12 revela o comportamento do modelo em três condições distintas: dias nublados, dias nublados com maior variabilidade e dias ensolarados. Nas condições de dias nublados (Região Verde e Amarela), o modelo teve um desempenho mais equilibrado e previsões mais precisas, com menores variações na irradiação e temperatura. Porém, ao lidar com sequências de variáveis climáticas mais bem definidas, como em dias ensolarados (Região Azul), o modelo enfrentou maiores dificuldades, apresentando maiores erros nas previsões devido às rápidas flutuações das variáveis. Assim, a estrutura multicamadas teve certas limitações em construir relações temporais mais complexas, mas ainda conseguiu apresentar previsões razoáveis, apresentando um RMSE de 0,46 e o R^2 de 0,41, que indica que o modelo tem um erro quadrático médio expressivo e uma capacidade de enxergar a variabilidade dos dados moderada, mas ainda baixa.




Figura 12 – Comparação entre potência real e potência prevista em três condições ambientais diferentes com o modelo MLP e *Grid Search* (Fonte: Autoria própria)

Por outro lado, o modelo LSTM, o qual foi configurado com 100 épocas, um *batch size* de 16, otimizador Adam e um “*Day step*” de 30, teve um desempenho significativamente superior. Ao analisar o valor de RMSE, o qual foi de 0,15, é possível interpretar que as previsões estão mais próximas em relação aos valores reais. Já R^2 com o valor de 0,51 demonstra uma certa capacidade de explicação da variabilidade dos dados, quando comparado ao modelo MLP. Além disso, os erros de validação e de treinamento foram relativamente baixos, o que sugere a capacidade do modelo de generalizar a partir dos dados de treinamento e sua eficácia para capturar as relações temporais mais complexas dos dados.

Por outro lado, o modelo LSTM, configurado com 100 épocas, um *batch size* de 16, o otimizador Adam e um “*Day step*” de 30, obteve um desempenho significativamente superior em comparação ao modelo MLP. Ao analisar o valor de RMSE, que foi de 0,38,, é possível interpretar que as previsões feitas pelo LSTM estão muito mais próximas dos valores reais. Além disso, o R^2 , com valor de 0,51, demonstra uma maior capacidade do modelo de explicar a variabilidade dos dados, o que é um indicativo de um desempenho mais eficiente na modelagem das relações temporais. A análise da Figura 13 ilustra o comportamento do modelo em três diferentes condições climáticas, como mostrado nas regiões da figura: Condição 1 - Dias Nublados (Região Verde), Condição 2 - Dias Nublados com maior variabilidade (Região Amarela) e Condição 3 - Dias Ensolarados (Região Azul). Na Região Verde e Amarela (Dias Nublados), o modelo LSTM, embora tenha se saído melhor do que o MLP em termos gerais, apresentou um desempenho inferior devido à tentativa de estabelecer uma curva nas previsões. Durante os dias nublados, a irradiação e a temperatura exibiam mais variações, o que gerou uma previsão mais 'curvada' por parte do modelo LSTM, tentando seguir uma tendência onde não havia grandes flutuações.

Na Região Azul (Dias Ensolarados), o modelo LSTM se destacou em relação ao modelo MLP, mostrando um desempenho superior. Durante os dias ensolarados, as variáveis climáticas apresentaram flutuações acentuadas mas com sequências bem estabelecidas. O modelo LSTM foi capaz de capturar essas variações mais complexas, ajustando-se de maneira mais eficiente ao comportamento dinâmico dos dados.




Figura 13 – Comparação entre potência real e potência prevista em três condições ambientais diferentes com o modelo LSTM (Fonte: Autoria própria)

Tabela 1 - Comparação entre parâmetros RMSE e R^2 dos modelos MPL e LSTM (Fonte: Autoria própria)

Métrica	MPL	LSTM
RMSE (Erro quadrático médio)	0,46	0,38
R^2 (Coeficiente de determinação)	0,41	0,51




Figura 14 – Distribuição de erros quadráticos dos modelos LSTM e MLP (Fonte: Autoria própria)

Com base nas métricas RMSE e R^2 exibidas na tabela 1 e na observação do comportamento dos erros quadrático dos dois modelos mostrado na Figura 14, é possível destacar que o modelo LSTM apresentou um desempenho relativamente superior em relação ao MLP. Com um valor de RMSE da estrutura LSTM significativamente baixo (0,38), principalmente quando comparado com o mesmo parâmetro do MLP, indica uma maior precisão nas previsões, o qual demonstrou ser o modelo mais eficaz, com menor erro e boa capacidade de explicação da variabilidade dos dados.

Além disso, também é possível analisar o desempenho dos modelos desenvolvidos através do comportamento dos erros médios dos dois modelos em três regiões com condições ambientais diferentes, o qual pode ser observado na Figura 14. Na região verde (dia nublado 1), a média de erro da estrutura MLP consegue ser inferior em relação ao LSTM, pois o modelo LSTM demora mais para conseguir entender o comportamento da curva enquanto a arquitetura do MLP consegue captar melhor as previsões que possuem grandes variações, como dias nublados. Nesse sentido, o modelo LSTM, apesar de indicar um erro maior na primeira região, apresenta um RMSE mais baixo e estável, sugerindo uma capacidade de previsão mais precisa nos dados com pouca variação. Já o MLP, embora também tenha um desempenho moderado, apresenta erros um pouco mais altos e uma variação maior, indicando uma menor capacidade de generalização para esses dados.

À medida que os dados se aproximam das regiões roxa e azul, o comportamento dos modelos se torna mais divergente. O MLP sofreu um aumento considerável nos seus erros de previsão, com os picos de erro se ampliando consideravelmente. Em contrapartida, o modelo LSTM mantém uma transição mais gradual e menos volátil, com picos de erro menores, indicando sua maior capacidade de lidar com dados de comportamento mais complexo ou imprevisível. Essas diferenças sugerem que o LSTM se comporta de maneira mais robusta em condições de dados mais complexos, enquanto o MLP pode ser mais suscetível a erros mais elevados em certos cenários.

3. CONCLUSÕES

Por meio do estudo apresentado foi possível entender os benefícios acerca das aplicações de redes neurais artificiais a partir dos modelos LSTM (*Long Short-Term Memory*) e MLP (*Multilayer Perceptron*) no contexto de geração fotovoltaica. Nesse sentido, através da interpretação e análise dos erros gerados pelos modelos, observou-se que a estrutura LSTM, com sua capacidade de lidar melhor com sequências temporais e dependências de longo prazo, apresentou resultados superiores em relação ao modelo MLP.

Desse modo, o modelo LSTM foi capaz de prever com uma precisão significativa, apresentando erros de treinamento e validação pequenos. Já o MLP, o qual é mais adequado para problemas não sequenciais, teve um desempenho relativamente moderado, com uma acurácia de 47%. Embora sua acurácia tenha apresentado um valor razoavelmente moderado, seus coeficientes de RMSE (0,46) e R^2 (0,41) indicam que o MLP tem uma capacidade de explicação da variabilidade dos dados bastante limitada. Ainda nesse viés, mesmo com os parâmetros do LSTM de RMSE (0,38) e R^2 (0,51), o quais foram de certa forma não tão diferentes do modelo MLP, a estrutura conseguiu capturar melhor as relações temporais dos dados climáticos estabelecendo sequências temporais. Diante disso, a comparação entre os dois modelos evidenciou que o LSTM é o mais adequado para séries temporais para o contexto do problema aplicado, uma vez que sua estrutura pode processar informações sequenciais de forma mais eficiente. Já o MLP demonstrou desempenho

inferior, uma vez que o modelo possui uma limitação em tratar dependências temporais. Apesar disso, há sempre oportunidades para aprimorar ainda mais o desempenho do modelo LSTM destacado, que pode ocorrer de várias formas, que podem acontecer desde a otimização de seus hiperparâmetros, como a possibilidade de inserção de novas variáveis de entrada no modelo para melhorar ainda mais a eficiência da estrutura neural.

Além disso, também é possível citar como a estrutura do modelo LSTM se mostrou particularmente eficaz para dias ensolarados ou dias com poucas variações climáticas, em que a consistência nas suas previsões foi consideravelmente mais eficiente. Isso ocorre porque o LSTM consegue identificar e manter padrões temporais estáveis, fazendo previsões mais precisas nessas situações. Por outro lado, o MLP, apesar de suas limitações em lidar com sequências temporais complexas, se mostrou mais eficaz em dias com variações mais altas, como dias nublados, tendo em vista que nessa situação o modelo MLP teve um desempenho mais razoável, adaptando-se bem a mudanças rápidas nas condições climáticas, onde a previsão exigia uma adaptação mais flexível às mudanças mais abruptas.

Nesse contexto, o desenvolvimento do estudo se destaca pela sua contribuição ao aprimoramento da operação, eficiência e planejamento de usinas fotovoltaicas, o qual verificou como a inteligência artificial, como redes neurais, especialmente o modelo LSTM, pode contribuir para melhorar as previsões de energia de uma usina FV. Com isso, através dessas ferramentas possibilitam a análise de dados climáticos históricos ao longo de uma sequência temporal e suas influências na produção de energia.

Dessa forma, é possível destacar como o estudo tem grande relevância para a otimização e eficiência dos sistemas fotovoltaicos, tendo em vista que ele visa melhorar o uso da energia solar, a qual é uma das fontes renováveis que vem ganhando ênfase na transição energética global. Assim, com capacidade de prever a produção energética de maneira mais precisa e ajustada às condições climáticas no contexto em que está sendo analisado, isso pode significar ganhos operacionais bastante significativos, os quais contribuem para uma matriz energética mais sustentável e confiável.

Além disso, para dar seguimento à linha de estudo em possíveis análises posteriores, é notável destacar a exploração da integração de outras variáveis climáticas adicionais nos modelos, como pressão atmosférica, velocidade do vento e entre outras, o que torna possível aprimorar ainda mais a precisão na previsão de energia gerada. Portanto, o estudo reforça como a inteligência artificial pode ser uma ótima ferramenta para gerenciar e otimizar a geração de energia solar, o que favorece cada vez mais a transição para fontes de energia mais limpas e eficientes.

4. REFERÊNCIAS

- CUNHA, H.; SOBEL, L. Aplicação de Redes Neurais Artificiais na Predição de Geração de Energia Fotovoltaica no Nordeste do Brasil. *Revista de Engenharia e Pesquisa Aplicada*, v. 6, n. 5, p. 73-80, 19 nov. 2021.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep learning*. 1. ed. Cambridge: MIT Press, 2016.
- HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. *Neural Computation*, v. 9, n. 8, p. 1735-1780, 1997. DOI: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- HUNTER, J. D. Matplotlib: a 2D graphics environment. *Computing in Science & Engineering*, v. 9, n. 3, p. 90-95, 2007.
- KINGMA, D. P.; BA, J. Adam: a method for stochastic optimization. In: *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, 2015.
- LIU, Y.; et al. Aplicação de redes neurais LSTM na previsão de energia fotovoltaica. *Revista de Engenharia Elétrica*, v. 10, n. 2, p. 123-134, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9265470>.
- PONRAJ, Ram Prakash et al. *Previsão da energia solar fotovoltaica com base na aprendizagem automática*. In: Segunda Conferência Internacional sobre Inteligência Aumentada e Sistemas Sustentáveis (ICAIS 2023). Anais [...]. IEEE, 2023. ISBN 979-8-3503-2579-9. Disponível em: <https://ieeexplore.ieee.org>. Acesso em: 25 jul. 2025.
- 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.
- SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. *Redes neurais artificiais: para engenharia e ciências aplicadas: fundamentos teóricos e aspectos práticos*. 2. ed. São Paulo: Artliber, 2016.
- VAN ROSSUM, Guido; DRAKE, Fred L. *Python tutorial*. 2. ed. Python Software Foundation, 2009.