

Modelo Inteligente Utilizando Grafos para Previsão da Potência Gerada por Módulos de Painéis Fotovoltaicos[★]

Bruna Rodrigues Vidigal^{*} Marcia Helena Moreira Paiva^{**}
Helder Roberto de Oliveira Rocha^{***}
Marcelo Eduardo Vieira Segatto^{****} Vanessa Batista Boone[†]

^{*} Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: bruna.vidigal@edu.ufes.br)

^{**} Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: marcia.paiva@ufes.br)

^{***} Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: helder.rocha@ufes.br)

^{****} Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: marcelo.segatto@ufes.br)

[†] Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, (e-mail: vanessa.boone@edu.ufes.br)

Abstract: The growth in demand for electricity in the world has intensified the alternative use of renewable energy sources such as solar energy. Solar panels are structures composed of photovoltaic cells, responsible for absorbing solar radiation and transforming it into electrical current. Photovoltaic Systems (PV system) performance analysis mainly helps to reduce energy loss and maintenance costs. However, most existing solutions for performance analysis need technical knowledge and often neglect spatial and temporal dependencies. In this paper, it is proposed a spatial-temporal graph neural network with the objective of automating the analysis of the PV system functioning. The classic technique using statistical models of time series is used for comparison purposes. The model adjustment was performed to predict future values, and performance metrics considering the model error were used to define the best fitted model. The model using neural networks and graphs presented better performance than the classic one, showing that considering the structure of the system is very relevant in the performance analysis.

Resumo: O crescimento da demanda de energia elétrica no mundo tem intensificado o uso alternativo de fontes de energia renováveis como a energia solar. Os painéis solares são estruturas construídas utilizando células fotovoltaicas, responsáveis por absorver a irradiação solar e transformá-la em corrente elétrica. A análise do desempenho do painel auxilia principalmente na redução de perda de energia gerada e redução dos custos de manutenção. No entanto, a maioria das soluções existentes para a análise de desempenho necessitam de conhecimento técnico para interpretação, além de desprezar a lógica temporal e a topologia física do sistema como informação relevante no desenvolvimento dos métodos. Neste artigo, uma técnica utilizando redes neurais convolucionais espaço-temporal de grafo é proposta com o objetivo de automatizar a análise do funcionamento do sistema de painéis fotovoltaicos. A técnica clássica utilizando modelos estatísticos de séries temporais é utilizada para fins de comparação. O ajuste dos modelos foi realizado para previsão de valores futuros, e métricas de desempenho considerando o erro dos modelos foram utilizadas para definir o melhor modelo ajustado. O modelo utilizando redes neurais e grafos apresentou melhor desempenho com relação ao clássico, mostrando que considerar a estrutura do sistema é muito relevante na análise de desempenho.

Keywords: Photovoltaic System; Forecasting; Graph; Convolutional; Neural Network.

Palavras-chaves: Sistemas Fotovoltaicos; Previsões; Grafos; Convolução; Rede Neural.

1. INTRODUÇÃO

Um painel fotovoltaico consiste em um equipamento composto por materiais semicondutores, capaz de transformar a radiação solar em energia elétrica. O sistema de energia solar é o sistema mais vantajoso em termos de facilidade de utilização, considerando que a radiação não necessita de uma estrutura complexa para ser consumida, tornando possível a utilização desse recurso tanto na área industrial/comercial quanto na residencial.

O desenvolvimento de novas tecnologias que ajudam a monitorar o desempenho do sistema é de grande importância para auxiliar na identificação e redução de perda da energia gerada e redução com custos de manutenção. A análise de atributos como corrente, tensão e potência facilita a detecção de irregularidades no funcionamento e o diagnóstico do estado do sistema. No entanto, a implementação de aplicações de avaliação automatizada em um sistema de painéis fotovoltaicos ainda está em processo de estudo, em consequência da grande quantidade de variáveis que influenciam as condições de funcionamento (Basnet et al., 2020).

Técnicas de análise gráfica utilizando medições de corrente, tensão e potência, juntamente com a análise visual da estrutura dos painéis, são normalmente utilizadas para avaliar o desempenho dos módulos (Meyer and Van Dyk, 2004). O método é bastante eficaz para detectar anomalias nas condições físicas e ambientais do painel. No entanto, esses mecanismos de análise não conseguem abranger de forma eficiente as falhas no sistema elétrico. Além disso, é necessário um conhecimento técnico para avaliar as informações gráficas, tornando o uso complexo no âmbito doméstico.

O aprendizado de máquina é uma área da inteligência artificial que utiliza técnicas computacionais para habilitar computadores a aprender sozinhos como realizar tarefas específicas adquirindo conhecimento de forma automática (Kim, 2020), e sua aplicação na resolução do problema de monitoramento de desempenho de sistemas de painéis fotovoltaicos é explorado em vários estudos (Fan et al., 2020; Basnet et al., 2020; Silva, 2020). A utilização do aprendizado de máquina supervisionado e semi-supervisionado também fornece resultados satisfatórios na classificação de falhas nos módulos (Fan et al., 2020; Basnet et al., 2020; Silva, 2020).

Modelos de previsão de séries temporais são explorados e considerados essenciais para um sistema de painéis fotovoltaicos (Sharadga et al., 2020). Diferentemente dos modelos classificadores, definido um limite de variação, é possível detectar o momento em que o comportamento das métricas de avaliação foi alterado e se a alteração é um sinal de mau funcionamento do sistema. A desvantagem de utilizar a análise temporal é que ainda não é possível identificar qual

a falha está impactando o sistema. Esse problema pode ser solucionado realizando um estudo para categorizar os dados de série temporal do modelo. A aplicação de análise de séries temporais baseada em métodos estatísticos e inteligência artificial é explorado com o objetivo de encontrar um modelo ótimo para previsão dos valores de potência do sistema (Sharadga et al., 2020). A referida pesquisa também obteve resultados satisfatórios, contudo, ainda que seja possível detectar irregularidades no desempenho do sistema com o modelo, não seria possível identificar o módulo onde surgiu a inconsistência dos dados.

A estrutura lógica ou física de um sistema de painéis fotovoltaicos pode ser bastante útil na resolução de um problema de análise de desempenho do sistema, visto que o sistema é composto por células fotovoltaicas agregadas, que formam estruturas denominadas módulos, que são conectados em série ou em paralelo com o objetivo de aumentar a tensão e a corrente gerada, respectivamente.

No presente estudo, um modelo inteligente utilizando redes neurais convolucionais espaço-temporal de grafos é proposto para analisar o conjunto de dados de medições de potência de um sistema de painéis fotovoltaicos. O ajuste de um modelo estatístico de previsão de séries temporais foi utilizado para fins de comparação. Os resultados foram comparados utilizando métricas de desempenho baseadas nos erros de cada modelo. O objetivo é explorar modelos que consigam capturar o comportamento espacial e temporal do conjunto de dados e entender a contribuição da relação de dependência dos módulos dentro da análise.

2. MATERIAL E MÉTODOS

Neste artigo, serão utilizadas letras maiúsculas em negrito para definir matrizes e letras minúsculas em negrito para definir vetores.

2.1 Modelo Estatístico

Análise de Série Temporal: Uma série temporal é um conjunto de observações no tempo, sendo a ordem cronológica essencial para análise e interpretação dos dados. Um série pode ser decomposta de forma aditiva como a soma de três componentes não observáveis, da forma apresentada pela equação (1), com ϵ_t sendo uma componente aleatória, usualmente conhecida como ruído branco, isto é, estacionária com média zero e variância σ_ϵ^2 e \mathbf{t}_t e \mathbf{s}_t representando a tendência e a sazonalidade, respectivamente.

$$\mathbf{z}_t = \mathbf{t}_t + \mathbf{s}_t + \epsilon_t \quad (1)$$

A análise gráfica da série temporal é importante para identificar possíveis padrões de comportamento dos dados.

Box Cox Transformation: Não são raros os casos em que a variância da série é função da sua média μ_t , como apresentado na equação (2), onde c um valor constante e $f(\cdot)$ a função de transformação. Uma série que aparenta ser estacionária em um nível até certo instante e sofre uma mudança inesperada na média implica não estacionariedade da matriz de autocovariância.

$$Var(\mathbf{z}_t) = c \times f(\mu_t) \quad (2)$$

* O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Projetos 3090822020 - 0 e 3097372021 - 4, da Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) e da Secretaria da Ciência, Tecnologia, Inovação, Educação Profissional e Desenvolvimento Econômico do Espírito Santo (SECTIDES).

O teste CUSUM (Brown et al., 1975) é aplicado para confirmar a existência ou não de quebras na média e tem como hipótese nula que não há mudança estrutural no conjunto de dados. No cenário onde a mudança estrutural se confirma, é necessário realizar uma transformação para estabilizar a variância.

$$T(\mathbf{z}_t) = \frac{z_t^\lambda - 1}{\lambda} \quad (3)$$

A transformação deve ser aplicada antes de qualquer outra análise e só faz sentido em dados positivos. O valor de λ da equação (3) pode ser estimado utilizando um otimizador de estimação de máxima verossimilhança, sendo o critério maximizar o coeficiente de correlação do gráfico de quantis da probabilidade normal (Box and Cox, 1964).

Tendência Estocástica e Diferenciação: Um série é estacionária nos momentos de 2ª ordem quando a média μ_t e a variância σ_t^2 são invariantes ao longo do tempo e a covariância entre valores defasados $\gamma(t, t - k)$ da série depende apenas da defasagem k (Wei, 2006), como apresentado nas equações (4) e (5).

$$\mu_t = \mu, \quad \forall t \in \mathbb{Z} \quad (4)$$

$$\gamma(t, t - k) = \gamma_k, \quad \forall k \in \mathbb{Z} \quad (5)$$

Modelos estatísticos de série temporal necessitam que o conjunto de dados seja estacionário, para garantir que as previsões sejam precisas. A verificação da estacionariedade dos dados pode ser avaliada utilizando o teste Dickey Fuller Aprimorado (ADF) e o teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS) (Seabold and Perktold, 2010).

O teste ADF é utilizado e tem como hipótese nula a presença de raízes unitárias na série, indicando não estacionariedade. O teste KPSS em contrapartida, possui hipótese nula e alternativa oposta ao teste ADF, sendo a hipótese nula a estacionariedade da série. A rejeição da hipótese nula de ambos os testes indica que a diferenciação deverá ser utilizada para tornar a série estacionária.

Processos sazonais autoregressivos integrados de médias móveis (SARIMA): Uma metodologia bastante utilizada na análise de modelos paramétricos é conhecida como abordagem de Box e Jenkins (Jere et al., 2017). Tal metodologia consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA ao conjunto de dados, atentando para as informações descritivas exploradas.

No caso em que se identifique a presença de sazonalidade no conjunto de dados o mais indicado é o ajuste de modelos SARIMA(p, d, q) \times (P, D, Q) $_s$, onde p refere-se a ordem autoregressiva do modelo, d o grau de diferenciações, q a ordem da parte de média móveis do modelo. Os valores (P, D, Q) tem a mesma interpretação dos valores (p, d, q) aplicados a parte sazonal do modelo, sendo s a ordem de sazonalidade.

Diagnóstico do Ajuste: Uma das suposições do modelo SARIMA é a de que os resíduos $\hat{\varepsilon}_t$ sejam um ruído branco (RB), ou seja, o comportamento de $\hat{\varepsilon}_t$ deve ser semelhante ao comportamento de um processo não correlacionado, estacionário com média zero e desvio padrão σ_ε^2 .

O procedimento de Portmanteau (Pankratz, 2012) é utilizado para verificar se as correlações e autocorrelações dos resíduos do modelo são significativamente iguais a zero. Para o teste utiliza-se a estatística de Ljung-Box Portmanteau (Ljung and Box, 1978) definida na equação (6), onde n é o tamanho do conjunto de dados, $r_{\varepsilon\varepsilon}^2(h)$ a correlação dos resíduos com defasagem h . Quando o modelo explica adequadamente a média e a variabilidade presente nos dados, $\mathcal{Q}(\mathcal{H})$ converge para uma variável com distribuição Qui-Quadrado com $(\mathcal{H} - p - q)$ graus de liberdade. A hipótese nula de correlação igual a zero será rejeitada quando $\mathcal{Q}(\mathcal{H})$ assumir valores altos.

$$\mathcal{Q}(\mathcal{H}) = n(n + 2) \sum_{h=1}^{\mathcal{H}} \frac{r_{\varepsilon\varepsilon}^2(h)}{n - h} \quad (6)$$

Além da verificação da hipótese de autocorrelação nula, uma outra suposição deve ser verificada, a de que os dados sejam normalmente distribuídos. Existem ferramentas gráficas de verificação da distribuição dos dados tais como o histograma, o box-plot e o gráfico de quantis, no entanto são úteis apenas numa análise descritiva. É necessário verificar a normalidade dos dados por meio de um teste de hipóteses. Neste artigo, optou-se pelo uso do teste Jarque-Bera (Jarque and Bera, 1987), a estatística de teste é apresentada na equação (7).

$$JB = n \left(\frac{(\sqrt{b_1})^2}{6} + \frac{(b_2 - 3)^2}{24} \right), \quad (7)$$

Na equação (7), $\sqrt{b_1}$ é o coeficiente de assimetria e b_2 , a curtose que, sob a hipótese nula devem ser significativamente iguais a 0 e 3, respectivamente. A hipótese alternativa de que os dados não possuem distribuição normal será aceita para valores altos de JB . Sob a hipótese de normalidade dos dados a estatística do teste converge para uma variável aleatória com distribuição Qui-Quadrado com dois graus de liberdade.

2.2 Rede Neural Espaço-Temporal de Grafos

Teoria de Grafos: Grafo é um estrutura matemática utilizada para modelar relações entre objetos de determinado conjunto e é representado como $G = (V, E)$, onde V é o conjunto finito e não vazio de nós/vértices, e E o conjunto de subconjuntos, $e_{ij} = \{v_i, v_j\}$ com $v_i, v_j \in V$, de arestas. A vizinhança de um nó v é definida como $N(v) = \{u \in V | (v, u) \in E\}$ (Benjamin et al., 2015).

Uma das formas de se representar um grafo é utilizando a matriz de adjacência $\mathbf{A}^{n \times n}$, onde n é a quantidade de nós do grafo e as componentes da matriz são preenchidas conforme a equação (8).

$$\begin{cases} \mathbf{A}_{ij} = 1, & \text{se } e_{ij} \in E \\ \mathbf{A}_{ij} = 0, & \text{se } e_{ij} \notin E \end{cases} \quad (8)$$

Um grafo pode ter informações relacionadas ao seus nós, essas informações podem ser representadas em uma matriz de atributos \mathbf{Z} , onde $\mathbf{Z} \in \mathbb{R}^{n \times d}$ com $\mathbf{z}_v \in \mathbb{R}^d$ representando o vetor de característica do nó v . No contexto onde há mudança dinâmica dos valores dos atributos dos nós ao

longo do tempo, ao grafo atribuído é dado o nome de grafo espaço-temporal e é definido como $G^{(t)} = (\mathbf{V}, \mathbf{E}, \mathbf{Z}^{(t)})$ com $\mathbf{Z}^{(t)} \in \mathbb{R}^{n \times d}$.

Rede Neural Espaço-Temporal Convolutacional de Grafos: Redes neurais convolucionais (CNN) são definidas como algoritmos de aprendizado profundo, que geralmente tem como dados de entrada um conjunto de imagens categorizadas, capazes de atribuir importância a vários aspectos da figura e, com base na significância definida para cada aspecto, diferenciar suas distintas categorias (Kim, 2020). Os algoritmos CNN possuem duas propriedades interessantes: os padrões aprendidos pelo algoritmo são invariantes a translação e o modelo é capaz de aprender padrões espaciais hierárquicos. Invariância a translação é equivalente a identificar os padrões aprendidos pela rede, independente do local onde a característica se encontra na imagem. O aprendizado de maneira hierárquica consiste no fato que a primeira camada, geralmente, aprende pequenos padrões locais, como bordas, a segunda compreende padrões maiores construídos com as características da primeira camada e assim sucessivamente. Generalizando a convolução para grafos, considera-se que uma rede neural convolutacional de grafo é composta por filtros de grafos com não-linearidade pontual, similares aos filtros de imagem utilizados em categorização de imagens.

Na teoria de grafos, estabelecido o conceito de convolução espectral de grafos (Wu et al., 2020), as camadas convolucionais podem ser interpretadas como multiplicadores do sinal $x \in \mathbb{R}^n$ no espaço Θ , como apresentado na equação (9).

$$\Theta_{*G}x = \Theta(\mathbf{L})x = \Theta(\mathbf{U}\mathbf{\Lambda}\mathbf{U}^T)x = \mathbf{U}\Theta(\mathbf{\Lambda})\mathbf{U}^T x \quad (9)$$

Na equação (9), \mathbf{U} é a matriz de autovetores da transformada laplaciana do grafo $\mathbf{L} = \mathbf{I}_n - \mathbf{D}^{-\frac{1}{2}}\mathbf{W}\mathbf{D}^{-\frac{1}{2}} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T$, com \mathbf{W} igual a matriz de adjacência do grafo, \mathbf{I}_n matriz identidade e $\mathbf{D} \in \mathbb{R}^{n \times n}$ matriz diagonal de graus dos nós do grafo ($\sum_j \mathbf{W}_{ij}$).

Os grafos são dinâmicos tanto em sua estrutura quanto em suas informações de entrada na matriz de atributos dos nós. As redes neurais espaço-temporal convolutacional de grafo (STGCN) tem o objetivo de modelar as informações presente na matriz de atributos dos nós considerando a interdependência entre os nós conectados.

Pré-processamento de Dados para uma Rede Neural: O pré-processamento de dados é necessário porque não é seguro alimentar uma rede com valores muito grandes ou que são heterogêneos. Tipicamente, as variáveis de entrada da rede devem ter duas características, ser um valor entre zero e um, e serem homogêneas entre si (Haykin, 2007).

A normalização tem o objetivo reduzir a escala e variação dos dados z_t , e a transformação é realizada utilizando a equação (10).

$$Z_{std} = \frac{\mathbf{z}_t - \min(\mathbf{z}_t)}{\max(\mathbf{z}_t) - \min(\mathbf{z}_t)} \quad (10)$$

Avaliação do desempenho de uma Rede Neural: O treinamento de uma rede neural é realizada através da divisão do conjunto de dados em três subconjuntos: treino, validação

e teste. A rede é treinada no conjunto de treino e avaliada no conjunto de validação. Definido o modelo, é realizado um exame final do seu desempenho no conjunto de dados de teste.

Desenvolver um modelo sempre envolve “afinação” (*tuning*) na configuração (Kim, 2020). A afinação do modelo consiste na escolha dos parâmetros e hiperparâmetros, e é realizada utilizando o sinal de *feedback* do desempenho do algoritmo nos dados de validação. No entanto, afinar a configuração com base na performance do modelo nos dados de validação pode resultar em um sobreajuste nesse conjunto, mesmo que o modelo não esteja sendo treinado diretamente nele. O centro desse fenômeno consiste no vazamento de informação. Garantir uma boa performance em dados nunca visto pelo modelo antes é essencial. Dessa forma, após definidos os parâmetros, é realizada uma avaliação em um conjunto totalmente desconhecido para o modelo: o conjunto de teste.

2.3 Métrica de Desempenho dos Modelos

A qualidade de ajuste dos diferentes modelos é determinada pelas métricas de desempenho, que compreende métodos que medem quantitativamente o rendimento acerto de cada estrutura. O erro médio absoluto (MAE), o erro percentual absoluto médio (MAPE) e a raiz do erro quadrático médio (RMSE) foram as métricas adotadas para medir a performance de cada modelo, distinguindo os melhores modelos quando apresentados valores baixos ou próximos de zero.

2.4 Descrição do Conjunto de Dados

A usina fotovoltaica do Centro de Pesquisa, Inovação e Desenvolvimento do Espírito Santo (CPID) forneceu os dados para o desenvolvimento desta pesquisa, sendo o acesso ao conjunto de dados restrito aos colaboradores. A Figura 1 apresenta a estrutura física da usina solar do CPID. A usina tem uma potência instalada de $264kWp$ e gera em média $35MWh$ /mês, por meio de placas solares que armazenam a energia solar e a convertem em energia para uso no empreendimento SECTIDES (2020). O funcionamento da usina foi iniciado em janeiro de 2021, no entanto os dados começaram a ser armazenados no início de fevereiro do mesmo ano. O sistema utilizado para armazenamento e monitoramento dos dados é o SolarEdge Monitoring Platform (Leite, 2020).

Os modelos foram testados no conjunto de dados composto por medições de potência, efetuadas por sensores, presentes no sistema de painéis fotovoltaicos, e informações sobre a estrutura física do respectivo sistema. Os sensores são dispositivos de eletrônica de potência no nível do módulo (MLPE), denominados otimizadores de potência P730/P850, e tem a função de monitorar de forma contínua a energia gerada em cada módulo buscando seu respectivo ponto de máxima potência (Leite, 2020).

O sistema fotovoltaico é composto por 840 módulos, sendo eles representados em um modelo de grafo espaço temporal com 420 vértices, correspondentes aos otimizadores de potência. As medições de potência, que compõem a matriz de atributos dos vértices, foram coletadas no período entre 12/02/2021 e 20/06/2021, sendo os dados agregados por



Figura 1. Usina experimental de geração de energia alternativa - CPID.

hora. Durante esse período, a potência apresentou valores muito próximos de zero ou zero entre os horários de 05h - 07h e após as 17h. Por isso, foram considerados apenas os dados no intervalo das 07h às 17h.

3. RESULTADOS E DISCUSSÕES

A matriz de atributos dos vértices possui 1419 observações, correspondentes às medições de potência, realizadas pelos 420 otimizadores (cada otimizador é representado por uma coluna na matriz), agregadas por hora em um período de 129 dias (12/02/2021 e 20/06/2021). A finalidade do experimento é realizar a previsão de potência no decorrer do dia, sendo assim, o conjunto de dados foi dividido nos subconjuntos de treino, validação e teste, cada um contendo 90, 19 e 20 dias, respectivamente.

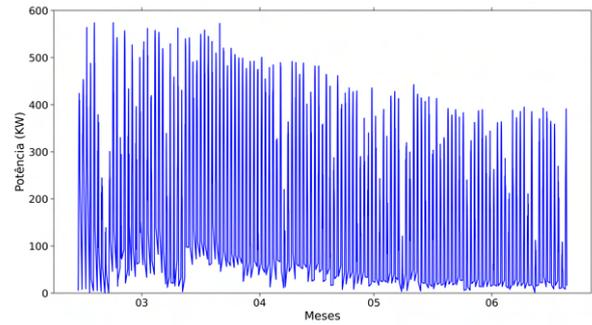
O desenvolvimento do modelo estatístico foi realizado considerando os conjuntos de treino e validação, sendo o desempenho do modelo final avaliado no conjunto teste. No desenvolvimento do modelo de rede neural, o modelo foi determinado utilizando os dados de treino, baseado no desempenho avaliado no conjunto de validação, análogo ao modelo estatístico, o desempenho do modelo final foi avaliado utilizando os dados do conjunto teste.

É importante destacar que o modelo estatístico não utiliza nem uma informação do grafo, enquanto que o modelo de rede neural utiliza a informação do grafo através da sua representação matemática dada pela matriz de adjacência.

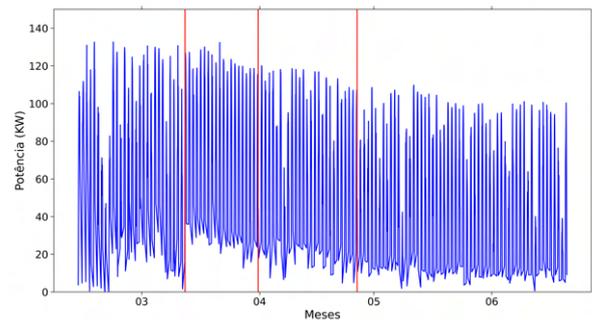
3.1 Modelo Estatístico

A análise descritiva da matriz de atributos dos vértices foi realizada com o objetivo de identificar as principais características das séries, considerando os módulos de forma individual. A Figura 2(a) apresenta o gráfico da série original de potência de um módulo do sistema fotovoltaico, onde é possível identificar uma provável quebra na média indicando a não estacionariedade da variância e autocovariância da série. O teste CUSUM (Brown et al., 1975) foi aplicado e o valor- p obtido para o teste foi igual a $5,132 \times 10^{-9}$. Logo, rejeitou-se a hipótese nula de que a série não possuía mudanças de níveis com 95% de confiança.

A transformação Box-Cox, utilizando $\lambda = 0,5126$, foi aplicada no conjunto de dados para tratar a não estacionariedade da matriz de autocovariância e os pontos



(a) Original.



(b) Transformação Box-Cox.

Figura 2. Séries temporais de potência do otimizador P730/P850.

de quebra de média foram identificados no conjunto de dados transformados, Figura 2(b). O gráfico para definir o valor do λ da transformação Box Cox, apresentada na equação (3), é exibido na Figura 3, no qual o eixo y representa o valor de ajuste da linha do gráfico de quantis de probabilidade normal para os diferentes valores λ . Por outra forma, o valor do λ utilizado na transformação Box Cox foi definido com base no coeficiente de correlação do gráfico de quantis de probabilidade normal (Box and Cox, 1964).

As quebras de média foram identificadas nos dias 12, 31 de março e 26 de abril de 2021. Houve um crescimento na energia gerada na primeira quebra, que se manteve durante o período entre a primeira e segunda quebra, que pode ser atribuída à maior incidência de radiação solar que ocorre no fim do verão. A segunda quebra foi um decréscimo da energia gerada, também podendo ser explicada pela mudança de estação, que ocorre dia 21/03/2021, data que marca o encerramento do verão e início do outono no Brasil. A confirmação das suposições a cerca da mudança de níveis do conjunto de dados necessita de uma análise mais crítica, considerando um período maior de observação dos dados e a identificação das diferentes estações dentro do modelo ajustado.

A decomposição da série temporal transformada, como demonstrado na equação (1), é realizada e os gráficos de tendência e sazonalidade são apresentados na Figura 4. O gráfico de tendência apresenta um padrão de crescimento no início da série até atingir seu ponto máximo no final do mês de março. O comportamento da série após o mês

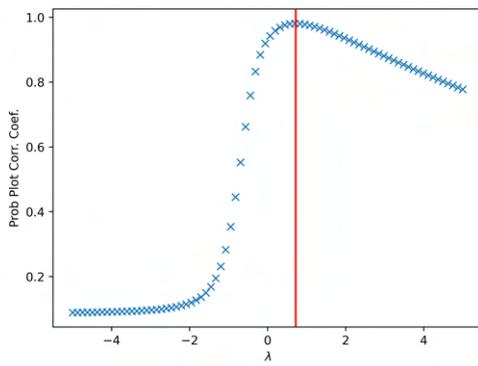
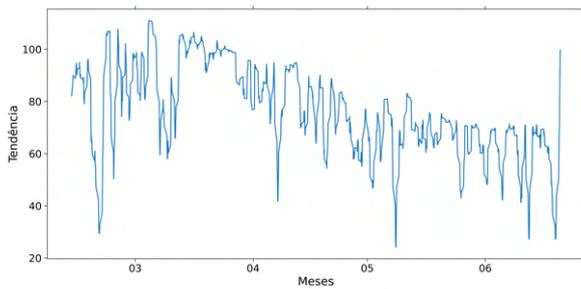
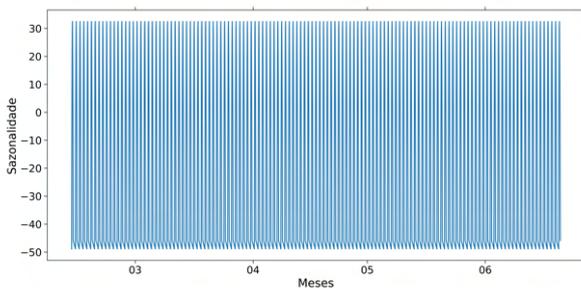


Figura 3. Gráfico de normalidade Box-Cox.



(a) Gráfico de tendência da série.



(b) Gráfico de sazonalidade da série.

Figura 4. Decomposição da série temporal.

de março muda e começa a apresentar um padrão de decréscimo. A mudança de padrão identificada sugere que a média do conjunto de dados não seja estacionária.

Os testes ADF e KPSS foram realizados para testar a estacionariedade dos dados e apresentaram valores- p igual 0,00085892 e 0,01, respectivamente. Considerando o nível de confiança de 95%, a hipótese nula de ambos os testes é rejeitada, indicando que a diferenciação deve ser usada para tornar a série estacionária. No entanto, como identificado na análise gráfica do gráfico de tendência da série, o conjunto de dados aparenta estar sujeito a distúrbios estocásticos. Dessa forma, a diferenciação dos dados é implementada no modelo de ajuste.

Tabela 1. Blocos espaço-temporal

Blocos	Configuração dos canais
1	[1, 32, 64]
2	[64, 32, 128]

Ajustes dos modelos $SARIMA(p, d, q) \times (P, D, Q)_{11}$, com $0 \leq p \leq q \leq d \leq P \leq Q \leq D \leq 2$ foram realizados. A decisão a favor do melhor modelo foi baseada no Critério de *AKAIKE* (AIC) e o Critério de Informação Bayesiano (BIC). O modelo $SARIMA(1, 1, 1) \times (1, 0, 1)_{11}$ apresentou o menor valor em ambos os critérios, sendo então definido para o ajuste dos dados.

Os resíduos do modelo ajustado foram calculados e os gráficos de diagnóstico analisados para verificar se o modelo atendia as suposições iniciais. O diagnóstico do modelo indicou que a suposição que os resíduos são não correlacionados e seguem uma distribuição normal padrão com média 0 e variância σ^2 é verdadeira. A fim de confirmar os resultados encontrados nos gráficos de diagnóstico, avaliaremos se os resíduos do modelo ajustado atendem as hipóteses de ruído branco e normalidade, aplicando o teste de normalidade de *Jarque-Bera* e o teste de autocorrelação de *Ljung-Box* com nível de significância $\alpha = 0,05$.

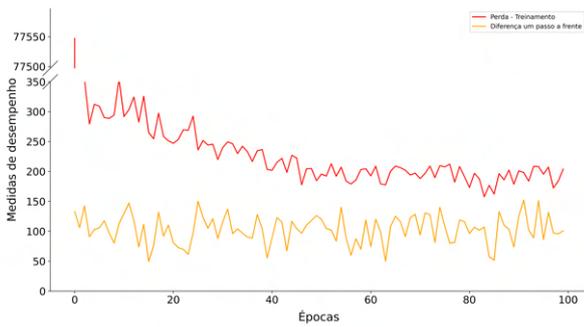
O teste de *Ljung-Box*, com valor- p igual a 0,301335, não rejeita a hipótese de ruído branco. No entanto, o teste de *Jarque-Bera* resultou em um valor- $p \leq 0$, rejeitando a hipótese de normalidade dos resíduos. Nesse cenário, a previsão dos valores foi realizada utilizando o método de reamostragem *sieve bootstrap*.

A ideia do intervalo *sieve bootstrap* (Andre'es et al., 2002) é aproximar o processo observado por um modelo autoregressivo de alta ordem ($AR(\infty)$) e então gerar “novas” realizações a partir de reamostras dos próprios resíduos do ajuste. As previsões foram calculadas para os dias separados no conjunto teste, uma hora à frente, sendo o valor predito relativo à hora 16 de cada dia. A análise temporal foi replicada para cada série presente na matriz de atributos dos vértices e o desempenho médio dos modelos ajustados é apresentado na Tabela 2. Na Tabela 2 a primeira coluna se refere a identificação dos modelos ajustados, as colunas dois a quatro apresentam as métricas de desempenho baseadas nos erros, e a última coluna apresenta o tempo de processamento utilizado por cada modelo.

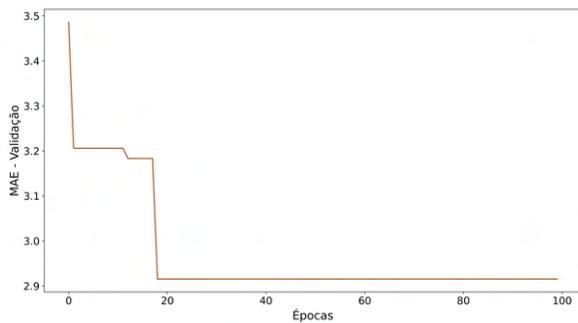
3.2 Rede Neural Espaço Temporal de Grafos

A transformação Box-Cox foi utilizada nos dados assim como no ajuste do modelo estatístico. No entanto, a transformação não reduziu os valores dos dados de modo a alimentar de forma eficiente a rede neural, por esse motivo os dados transformados foram submetidos a normalização descrita pela Equação 10.

A arquitetura base da rede foi construída conforme modelo desenvolvido para previsão de tráfego em rodovias (Yu et al., 2017), em consequência da similaridade das séries presentes na matriz de atributos dos vértices. A configuração dos blocos convolucionais espaço-temporal são apresentadas na Tabela 1.



(a) Conjunto treinamento.



(b) Conjunto validação.

Figura 5. Desempenho do modelo de Rede Neural.

O treinamento foi executado com número de épocas e tamanho do lote igual a 100 e 50, respectivamente. A taxa inicial de treinamento definida foi 10^{-3} com taxa de decaimento igual 0,7 a cada 5 épocas. Análogo as previsões realizadas no modelo de série temporal, os valores preditos são calculados uma hora à frente e são relativos à hora 16 de cada dia.

O valor de perda foi calculado em cada iteração do modelo considerando o conjunto de treino e validação e os resultados são apresentados na Figura 5. No conjunto de validação o valor de perda do conjunto decresce significativamente antes da iteração 20 e depois permanece constante. A imutabilidade do erro após a iteração 20 ocorre devido a lógica criada para armazenar somente os modelos que apresentassem o menor erro. A previsão foi calculada para o conjunto teste, estabelecido o modelo com melhor desempenho no conjunto validação e o resultado é apresentado na Tabela 2.

3.3 Modelos Ajustados

Estabelecido a configuração final do modelo de série temporal e rede neural, a próxima etapa é a avaliação do desempenho dos modelos no que diz respeito à previsão de valores futuros.

A comparação dos modelos apresentados na Tabela 2, mostra que o modelo de rede neural espaço-temporal de grafos apresentou melhor resultado que o estimador construído com base no modelo estatístico SARIMA. O resultado foi melhor tanto na qualidade do ajuste do modelo quanto no tempo de processamento, apresentando

Tabela 2. Desempenho dos modelos

Modelos	MAPE	MAE	RMSE	Tempo
SARIMA	18,830%	17,258	15,689	4832,788s
STGCN(Cheb)	6,634%	4,198	4,386	23,085s
STGCN(1st)	6,615%	4,189	4,349	21,994s

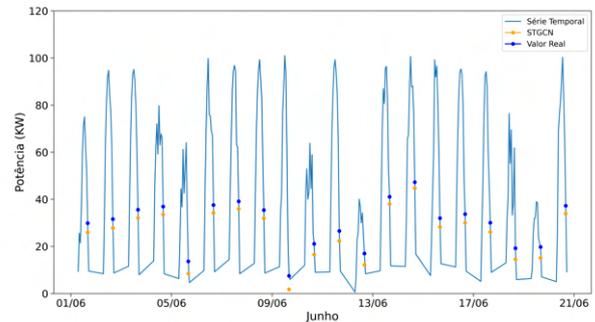


Figura 6. Comparação dos valores reais *versus* previsões um passo à frente da série temporal.

desempenho cerca de três vezes melhor que o desempenho do modelo estatístico, e um tempo de processamento com enorme diferença visto que o modelo SARIMA levou mais de uma hora para finalizar o ajuste. O gráfico comparativo dos valores preditos pelo modelo rede neural espaço-temporal de grafos e os valores reais é apresentado na Figura 6.

4. CONCLUSÃO E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Explorar o comportamento espacial e temporal de dados referentes a potência gerada por sistemas de painéis fotovoltaicos oferece grandes benefícios em modelos de previsão. Neste estudo, foram considerados dois tipos de modelos para realizar a tarefa e os resultados apresentados foram satisfatoriamente a favor da utilização do modelo que explora a estrutura espaço-temporal. Mesmo complexa, a estrutura do modelo de redes neurais convolucionais espaço-temporal de grafos se mostrou mais eficaz na previsão e no desempenho computacional. O desempenho computacional é influenciado principalmente pelo processamento paralelo das informações de todos os módulos realizado pela rede neural.

A definição de modelos utilizando redes neurais é um trabalho que exige uma análise detalhada do comportamento dos dados. O trabalho é baseado em explorar as estruturas do modelo e utilizar o conhecimento obtido pelos resultados de estudos similares. Uma sugestão para trabalho futuros é determinar diferentes arquiteturas bases para manipular os dados e construir um estrutura ideal. O estudo da influência de variáveis como temperatura, estação do ano, entre outras, também pode ser uma boa opção de tratativa.

REFERÊNCIAS

- Andre'es, M.A., Pena, D., and Romo, J. (2002). Forecasting time series with sieve bootstrap. *Journal of Statistical Planning and Inference*, 100(1), 1–11.

- Basnet, B., Chun, H., and Bang, J. (2020). An intelligent fault detection model for fault detection in photovoltaic systems. *Journal of Sensors*, 2020.
- Benjamin, A., Chartrand, G., and Zhang, P. (2015). *The fascinating world of graph theory*. Princeton University Press.
- Box, G.E. and Cox, D.R. (1964). An analysis of transformations. *Journal of the Royal Statistical Society: Series B (Methodological)*, 26(2), 211–243.
- Brown, R.L., Durbin, J., and Evans, J.M. (1975). Techniques for testing the constancy of regression relationships over time. *Journal of the Royal Statistical Society. Series B (Methodological)*, 149–192.
- Fan, J., Rao, S., Muniraju, G., Tepedelenlioglu, C., and Spanias, A. (2020). Fault classification in photovoltaic arrays using graph signal processing. In *2020 IEEE Conference on Industrial Cyberphysical Systems (ICPS)*, volume 1, 315–319. IEEE.
- Haykin, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.
- Jarque, C.M. and Bera, A.K. (1987). A test for normality of observations and regression residuals. *International Statistical Review/Revue Internationale de Statistique*, 163–172.
- Jere, S., Kasense, B., and Bwalya, B.B. (2017). Univariate time-series analysis of second-hand car importation in zambia. *Open Journal of Statistics*, 7(4), 718–730.
- Kim, S. (2020). Deep learning with r, François Chollet, Joseph J. Allaire, Shelter Island, NY: Manning.
- Leite, N.M. (2020). A diferença entre a solução SolarEdge e outras topologias de inversores solares. <https://www.solaredge.com/br/solaredge-blog/solaredge-tipos-de-inversor-solar>. [Online; accessed 19-November-2021].
- Ljung, G.M. and Box, G.E. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303.
- Meyer, E.L. and Van Dyk, E.E. (2004). Assessing the reliability and degradation of photovoltaic module performance parameters. *IEEE Transactions on Reliability*, 53(1), 83–92.
- Pankratz, A. (2012). *Forecasting with dynamic regression models*, volume 935. John Wiley & Sons.
- Seabold, S. and Perktold, J. (2010). Statsmodels: Econometric and statistical modeling with python. In *Proceedings of the 9th Python in Science Conference*, volume 57, 61. Austin, TX.
- SECTIDES (2020). Centro de Pesquisa, Inovação e Desenvolvimento (Cpid). <https://inovacaoedesenvolvimento.es.gov.br/centro-de-pesquisa-inovacao-e-desenvolvimento-cpid>. [Online; accessed 19-November-2021].
- Sharadga, H., Hajimirza, S., and Balog, R.S. (2020). Time series forecasting of solar power generation for large-scale photovoltaic plants. *Renewable Energy*, 150, 797–807.
- Silva, A. (2020). Identificação de funcionamento atípico de painel fotovoltaico.
- Wei, W.W. (2006). Time series analysis. In *The Oxford Handbook of Quantitative Methods in Psychology: Vol. 2*.
- Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., and Philip, S.Y. (2020). A comprehensive survey on graph neural networks. *IEEE transactions on neural networks and learning systems*, 32(1), 4–24.
- Yu, B., Yin, H., and Zhu, Z. (2017). Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. *arXiv preprint arXiv:1709.04875*.