Previsão de Geração de Energia em Usinas Fotovoltaicas utilizando Redes Neurais Artificiais e Aprendizado por Transferência

Cristiano G. M. Camandaroba * **Camille V. M. B. de Oliveira** *
Caian D. de Jesus ** **Matheus A. M. Ferreira** ***
Guilherme A. N. Pussente *** **Geraldo F. Neto** ***
Eduardo P. de Aguiar ****

* *Depto. de Circuitos Elétricos, Universidade Federal de Juiz de Fora. (e-mail: {camandaroba.gregory, camille.mota}@engenharia.ufjf.br)*
** *Programa de Pós-Graduação em Modelagem Computacional, Universidade Federal de Juiz de Fora. (e-mail: caian.jesus@engenharia.ufjf.br)*
*** *Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora.(e-mail: {matheus.malta, guilherme.pussente}@engenharia.ufjf.br,geraldo.furtado@estudante.ufjf.br)*
**** *Depto. de Engenharia Mecânica, Universidade Federal de Juiz de Fora.(e-mail: eduardo.aguiar@engenharia.ufjf.br)*

Abstract: The global energy demand is constantly rising, driven by population growth, changes in consumption patterns, and technological advancements. However, concerns about climate change and the limited availability of fossil fuels are driving the search for renewable sources, with solar energy standing out. Solar production, while abundant, is sensitive to weather conditions, making its prediction challenging. New photovoltaic plants present an additional challenge due to their lack of historical data. This work proposes to address the challenge of energy generation forecast in photovoltaic plants using Transfer Learning and Artificial Neural Networks (ANNs), aiming to improve predictions through previous knowledge. Transfer Learning strategies, the benefits of using pre-trained models, and their effectiveness are discussed and compared to traditional approaches. The results indicate that Transfer Learning in ANNs shows promise in improving energy generation forecasting from photovoltaic plants.

Resumo: A demanda global por energia está em constante ascensão, devido ao crescimento populacional, mudança nos padrões de consumo e avanços tecnológicos. No entanto, preocupações com mudanças climáticas e a disponibilidade limitada de combustíveis fósseis impulsionam a busca por fontes renováveis, destacando-se a energia solar. A produção solar, embora abundante, é sensível às condições meteorológicas, dificultando sua previsão. Além disso, novas usinas fotovoltaicas apresentam um desafio adicional devido à falta de dados históricos. Para abordar o desafio da previsão de geração de energia em usinas fotovoltaicas este trabalho propõe métodos baseados em Aprendizado por Transferência e Redes Neurais Artificiais (RNAs), adaptando os modelos por meio de conhecimentos anteriores. Estratégias de Aprendizado por Transferência, benefícios da utilização de modelos pré-treinados e sua eficácia são avaliados em relação a abordagens tradicionais. Os resultados indicam que o Aprendizado por Transferência em RNAs é promissor para melhorar as previsões de geração de energia de usinas fotovoltaicas.

Keywords: Forecasting; Power Generation; Machine Learning; Artificial Neural Networks; Transfer Learning.

Palavras-chaves: Previsão; Geração de Energia; Aprendizado de Máquina; Redes Neurais Artificiais; Aprendizado por Transferência.

1. INTRODUÇÃO

A crescente demanda mundial por energia, impulsionada por fatores como o aumento da população, mudanças no estilo de vida e avanços tecnológicos têm levado os países a diversificarem as suas matrizes energéticas, somando-se a recente preocupação com acentuamento das mudanças climáticas causadas, sobretudo, pela queima de combustíveis fósseis e com a disponibilidade limitada destes recursos, decorrente de conflitos geopolíticos. Devido a esse fato, a energia solar, em particular, tem ganhado destaque pela sua abundância e potencial em diversas regiões do mundo, oferecendo uma fonte limpa e inesgotável de energia. Contudo, a produção de energia solar é altamente sensível às condições meteorológicas imprevisíveis, como a intensidade do sol, velocidade do vento e outros fatores atmosféricos, o que torna a sua previsão um desafio.

De acordo com dados do Energy Transition Investment Trends 2024, um relatório, publicado pela BloombergNEF, os investimentos em energia solar alcançaram a marca de US$ 1,8 trilhão em 2023, representando um aumento significativo em relação aos anos anteriores. Além disso, o relatório prevê que os investimentos em energia solar continuarão a crescer nos próximos anos, impulsionados pela redução dos custos dos painéis solares e pelo aumento da conscientização sobre os benefícios ambientais e econômicos das energias renováveis. Esses investimentos têm sido essenciais para impulsionar o desenvolvimento de tecnologias de previsão e para melhorar a integração de sistemas de energia solar na rede elétrica global (BloombergNEF, 2024).

Nesse contexto, a utilização de tecnologias avançadas de previsão, como modelos baseados em Aprendizado de Máquina (AM), pode ser útil, uma vez que operadores de centrais elétricas podem utilizar a energia prevista para o planejamento, a tomada de decisões e a gestão da distribuição (Tuohy et al., 2015). Um exemplo de utilização de modelos robustos para previsão é apresentado em (Alves et al., 2024), em que a combinação de Inteligência Artificial e Sistema Fuzzy é empregada para prever séries temporais e a produção de energia solar. Além desse trabalho, em (Ahmed et al., 2020) é feito estudos e análise de diversos modelos para previsão de energia solar fotovoltaica, comparando a performace de modelagens estatísticas, como ARIMA, até modelos de AM com *Deep Learning*.

Tendo em vista que a predição de séries temporais por modelos de AM, como Redes Neurais Artificiais (RNAs), enfrenta desafios quanto à quantidade limitada de dados disponíveis, uma estratégia usual é a utilização do Aprendizado por Transferência. Neste tipo de abordagem, o processo inicia-se com o treinamento de uma rede com um conjunto de dados e tarefa primários. Em seguida, as características aprendidas são redirecionadas ou transferidas para uma segunda rede alvo, a qual será treinada em um conjunto de dados e tarefa secundários. Este método demonstra eficácia quando as características são amplas e adequadas tanto para a tarefa inicial quanto para a posterior, ao invés de serem específicas apenas da tarefa primária.

Com base nessas informações, este estudo propõe abordar o desafio da previsão da geração de energia solar e aprimorar o processo de AM por meio da aplicação dos princípios de Aprendizado por Transferência em RNAs.

Nesse contexto, as principais contribuições deste trabalho podem ser listadas como:

- Introdução dos conceitos de Aprendizado por Transferência em RNAs para otimizar a previsão de séries temporais na geração de energia solar;
- Exploração das estratégias de Aprendizado por Transferência para adaptar características aprendidas em conjuntos de dados e tarefas anteriores para melhorar a precisão das previsões em novos conjuntos de dados e tarefas;
- Discussão sobre os benefícios de utilizar modelos de RNAs pré-treinados em tarefas relacionadas para capturar padrões relevantes na previsão da geração de energia solar;
- Avaliação da eficácia das técnicas de Aprendizado por Transferência em comparação com abordagens tradicionais de previsão de séries temporais na indústria de energia solar;
- Análise dos resultados obtidos e considerações sobre as potenciais aplicações práticas e avanços futuros no campo da previsão de séries temporais com o uso do Aprendizado por Tranferência em outros modelos.

E as principais conclusões são:

- A aplicação do Aprendizado por Transferência em modelos de RNAs demonstrou ser uma abordagem promissora para melhorar a precisão das previsões de séries temporais na geração de energia solar;
- A capacidade de transferir conhecimentos de tarefas anteriores para novos conjuntos de dados e tarefas na previsão de energia solar resultou em ganhos significativos de desempenho;
- A utilização de modelos de RNAs pré-treinados em tarefas relacionadas mostrou-se benéfica para capturar padrões complexos e variáveis na geração de energia solar;
- Os resultados obtidos indicam que o uso do Aprendizado por Tranferência pode ser uma ferramenta eficaz para lidar com conjuntos de dados limitados e melhorar a estabilidade e confiabilidade dos sistemas de previsão de energia solar.

Este artigo está organizado da seguinte forma: A Seção 2 apresenta a formulação do problema. A Seção 3 aborda os métodos adotados no modelo proposto. Em seguida, a Seção 4 discute os resultados numéricos. Por fim, a Seção 5 encerra o trabalho e apresenta as conclusões com relação às proposições declaradas.

2. FORMULAÇÃO DO PROBLEMA

A geração de energia elétrica por meio da irradiação solar tem se tornado cada vez mais relevante como uma fonte limpa e sustentável de energia, principalmente diante da necessidade de diversificação da matriz energética e redução das emissões de gases de efeito estufa.

De acordo com dados do Relatório de Tendências Globais em Investimentos em Energia Renovável 2021, publicado pela Agência Internacional de Energia Renovável (IRENA), os investimentos globais em energia solar atin-

giram um recorde de US$ 160,8 bilhões em 2020 (REN21, 2021), representando um aumento significativo em relação aos anos anteriores. Esse crescimento exponencial dos investimentos na energia solar reflete o reconhecimento crescente de seu potencial como uma fonte de energia confiável, acessível e sustentável, capaz de desempenhar um papel fundamental na transição para um futuro energético mais limpo e resiliente.

Contudo, a natureza variável e intermitente da energia solar, influenciada por fatores como condições climáticas, sazonalidade e localização geográfica, apresenta um desafio significativo para a previsão confiável (Sperati et al., 2015). A falta de sincronia entre a oferta e a demanda de energia resulta em custos adicionais associados à ativação de usinas termelétricas de reserva e à compra de energia no mercado a preços mais elevados. Além disso, a operação ineficiente da rede elétrica devido à falta de previsão pode levar a problemas de qualidade de energia, interrupções no fornecimento e perdas financeiras para as concessionárias.

Em 2020, o California Independent System Operator (CAISO), operador da rede elétrica da Califórnia, implementou medidas de emergência para prevenir um colapso no sistema elétrico devido a flutuações na geração de energia resultantes de condições climáticas adversas (California Independent System Operator, 2020). Como parte dessas medidas, foram necessários cortes programados de energia, conhecidos como *rolling blackouts*, afetando os residentes e resultando em perdas financeiras significativas. Essa intervenção destacou a vulnerabilidade do sistema elétrico diante de eventos climáticos extremos e ressaltou a importância da previsão da geração de energia para garantir a estabilidade e a confiabilidade do fornecimento de energia elétrica.

Em síntese, a capacidade de antecipar flutuações na produção de energia é fundamental para garantir a estabilidade e a confiabilidade do sistema elétrico. A implementação eficaz de modelos de previsão avançados pode permitir aos operadores de rede tomarem medidas proativas para mitigar impactos negativos, como cortes de energia, e assegurar um fornecimento contínuo e seguro de eletricidade para consumidores e empresas.

Nessa perspectiva, é fundamental aplicar a previsão de geração de energia solar, uma vez que isso implica em:

- Aumento da confiabilidade da usina;
- Tomada de decisão informada;
- Otimização de recursos;
- Redução de custos;
- Auxílio na manutenção preventiva;
- Sustentabilidade ambiental.

Dessa maneira, o presente trabalho utiliza dados de duas usinas solares fotovoltaicas. A primeira, localizada no estado de São Paulo, Brasil, conforme a Figura 1. A mesma possui uma área de aproximadamente 15 hectares e capacidade instalada de 6,5 MWp, 12.062 módulos fotovoltaicos e 163 rastreadores solares. A segunda está localizada em Alice Springs, Austrália, conforme visto na Figura 2. Sua capacidade instalada é de 23 kWp, com 120 módulos fotovoltaicos e 4 rastreadores solares.

Fig. 1. Usina Solar de São Paulo.

Fig. 2. Usina Solar da Austrália.

3. MODELO PROPOSTO

A metodologia proposta para o desenvolvimento do modelo de previsão, objeto de estudo deste trabalho, tem como base o conceito de Aprendizado por Transferência e sua aplicação conjunta com RNAs. O Aprendizado por Transferência será apresentado de forma detalhada nesta seção, assim como as demais metodologias que foram aplicadas para a criação do modelo.

3.1 Modelo de previsão proposto

A estrutura do modelo é apresentada na Figura 3. No estudo em questão, são empregadas duas bases de dados essenciais, denominadas matriz **Q** e matriz **R**. A matriz **Q** (3259 x 2) representa o conjunto de dados da usina da Austrália apresentada na Seção 4, enquanto a matriz **R** (124 x 2) representa o conjunto de dados da usina de São Paulo, foco de estudo, apresentada de forma detalhada na Seção 3.

Ao iniciar a etapa de Pré-treinamento é realizada a normalização da base de dados **Q**, este processo é detalhado na subseção 3.2, gerando assim a matriz **G**, que é utilizada na etapa de Tratamento, na qual a matriz de entrada do modelo é estruturada. Tal matriz, representada por **S**, possui dimensões 3254 x 5, em que as amostras de entrada são agrupadas nos vetores de tamanho cinco que representam os dados de geração de dias anteriores ao que será previsto. Nesta mesma etapa, o vetor de rótulos **k** é construído a partir das amostras seguintes à 5ª amostra de cada vetor de entrada da matriz **S**. A escolha da janela de previsão, cinco dias, foi realizada através de uma análise de autocorrelação parcial, detalhada na Subseção 3.3.

Ao final da etapa de Tratamento, as matrizes de entrada e saída são utilizadas na Busca em Grade, que visa realizar uma busca de hiperparâmetros, representados por **t**, para serem adotados no Pré-Modelo. Nesta etapa foi utilizada a técnica de Janela Deslizante, que é apresentada de forma

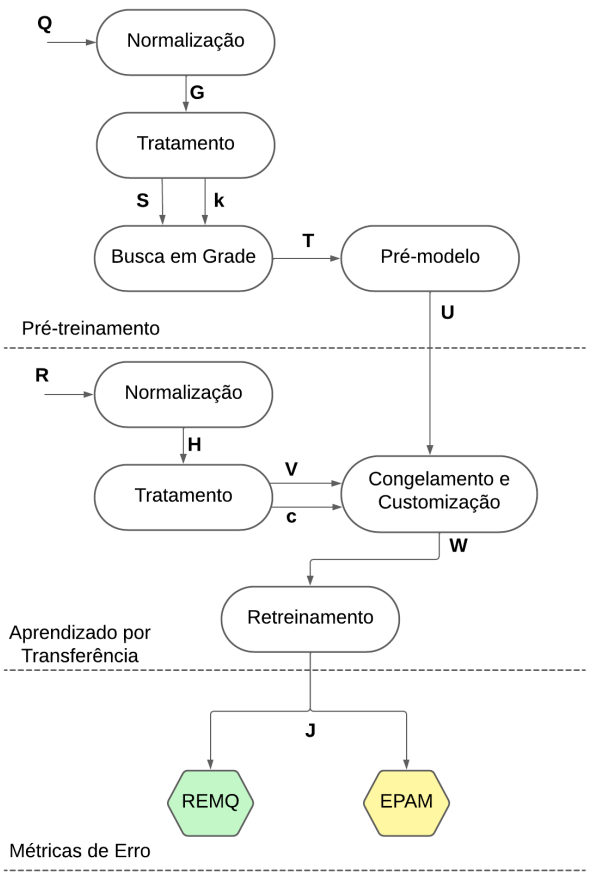

Fig. 3. Modelo Proposto.

detalhada na Subseção 3.6, para o treinamento do modelo durante a busca dos hiperparâmetros. A metodologia utilizada na Busca de Grade está detalhada na Subseção 3.5. Utilizando os hiperparamêtros **T**, é realizado o treinamento do pré-modelo com as entradas **S** e rótulos **k**.

Finalizada a etapa de Pré-treinamento, deu-se início a preparação da base de dados representada pela matriz **Q**, em que esta foi normalizada e tratada de maneira idêntica à base de dados anterior. Dessa maneira, a matriz de entrada **V** e o vetor de rótulos **c** foram estruturados a partir da matriz de dados normalizados **H**. Para o retreinamento do modelo, o Pré-modelo resultante da etapa anterior, **U**, passou pelas etapas de Congelamento e Customização, que são tratadas na Subseção 3.7. Nestas, os pesos e camadas de **U** são congelados e há a substituição da camada de saída, resultando em um novo modelo representado por **W**.

Após o retreinamento do modelo, utilizando as entrada **V** e o vetor de rótulos **c**, foram utilizadas as métricas Raiz do Erro Quadrático Médio (REMQ) e Erro Percentual Absoluto Médio (EPAM) para qualificar a performance do modelo de previsão adotado, representados por **J**.

3.2 Normalização

A normalização dos dados foi feita levando-se em consideração os valores máximo e mínimo das amostras. Definindo **Q** uma série temporal, em que $\mathbf{Q} = \{q_1, q_2, ..., q_j\}$, a partir deste pode-se definir $q_{\max}$ e $q_{\min}$ como os valores máximo e mínimo que compõem os dados de **Q**. Além disso, é definido q_k como k-ésima amostra e $\bar{q}_k$ como o valor de q_k normalizado. Com isso, a seguinte equação é obtida:

$$\bar{q}_k = \frac{q_k - q_{\min}}{q_{\max} - q_{\min}} \tag{1}$$

3.3 Janela de Previsão

A escolha da janela de previsão se faz necessária uma vez que este estudo abrange o tema de previsão de séries temporais. Para a escolha do número de amostras de entrada, analisou-se a autocorrelação parcial entre as amostras (Costa, 2020).

Como pode ser observado no gráfico de Autocorrelação Parcial, apresentado na Figura 4, as amostras com atraso de ordem 1 e de ordem 4 possuem um coeficiente de correlação maior em módulo em comparação com as amostras de ordem superior. Além disso, é observado que a partir da quinta amostra o coeficiente de correlação passa a ser negativo. Sendo assim, a escolha da ordem 5 ao invés de 4 garante uma janela maior de amostras que possuem uma correlação direta.

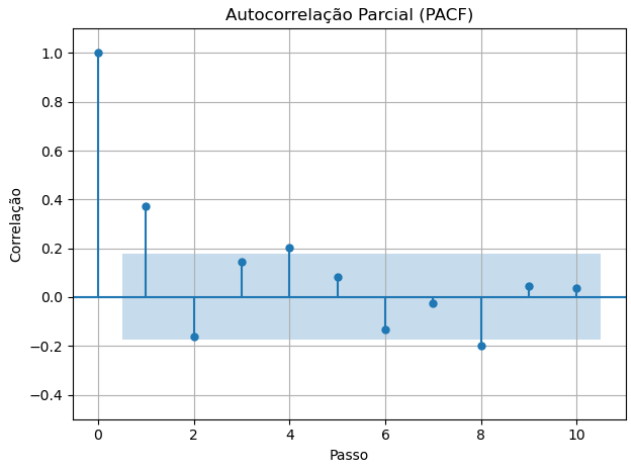

Fig. 4. Autocorrelação Parcial.

3.4 Tratamento

A etapa de tratamento dos dados tem como objetivo criar a matrizes com os vetores de entrada e o vetor de rótulos da matriz de entrada a partir das bases de dados que são utilizadas para treinamento dos modelos. Os vetores de entrada são representados no formato de uma série temporal, conforme ilustrado na Figura 5.

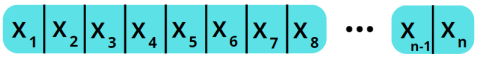

Fig. 5. Exemplo de Série Temporal.

Para fins de exemplo, considera-se n o número de termos de uma série temporal e l o número de amostras da janela de previsão a serem analisadas como entrada do modelo. O vetor que representa as amostras da série temporal é deslocado em seus índices e concatenado consecutivamente, conforme ilustrado na Figura 6, até que o número

de colunas seja igual ao tamanho da janela de previsão especificada.

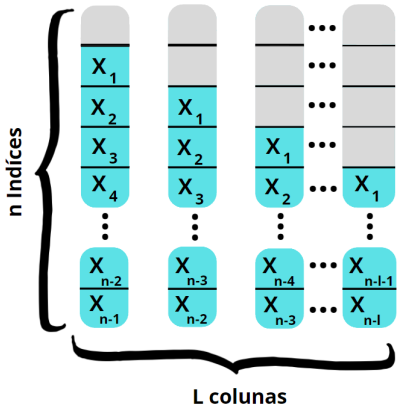

Fig. 6. Matriz do Tratamento.

Em seguida, elimina-se todas as linhas que contenham pelo menos um valor vazio. Como resultado, obtemos uma matriz na qual os vetores presentes em cada linha contêm os valores da série temporal agrupados com suas respectivas amostras atrasadas em l valores.

Para concluir o tratamento, utiliza-se de uma lógica parecida para desenvolver o vetor de valores de rótulos ao deslocar l indíces no sentido contrário, como mostrado na Figura 7.

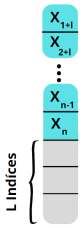

Fig. 7. Vetor de saída do Tratamento.

3.5 Busca em Grade

A Busca em Grade é um dos algoritmos utilizados para se otimizar modelos de AM. Nesse método, uma grade de combinações possíveis de hiperparâmetros é definida e o modelo é treinado e avaliado - com uma função de perda pré-estabelecida - para cada combinação na grade.

Supondo a existência de um modelo M e uma base de teste *X(te)*, a função de perda estabelecida *L (M / X(te))* é calculada em um algoritmo no qual uma base de treinamento *X(tr)* é utilizada para solucionar o problema de otimização. Considerando como o conjunto de hiperparâmetros pertencentes ao modelo, o algoritmo citado visa achar uma combinação dos possíveis parâmetros λ^* que resultam em uma perda mínima $L_{\min}(M/X(te))$.

3.6 Janela Deslizante

A técnica da janela deslizante é um método de iteração sobre uma sequência de dados, normalmente utilizado no contexto da aprendizagem automática. Envolve a divisão dos dados em janelas sobrepostas de um tamanho fixo e o processamento de cada janela de forma independente (DataOverload, 2022). Este método pode ser útil em situações em que o contexto ou a relação entre pontos de dados adjacentes é importante, uma vez que a sobreposição entre janelas permite que o contexto entre eles seja preservado.

As amostras de cada janela são divididas em treino e teste para a aplicação do modelo de AM, com um passo predefinido. Um exemplo de divisão utilizando esse método pode ser observado na Figura 8.

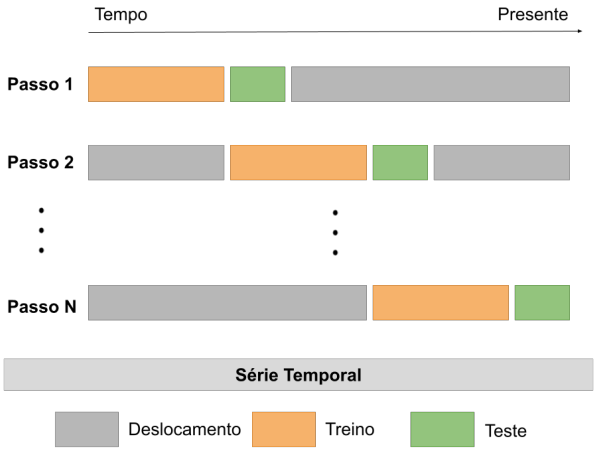

Fig. 8. Janela Deslizante

Através das predições com as amostras de teste de cada janela é possível aplicar um método de avaliação de desempenho. É comum a utilização de parâmetros de erro que são escolhidas de acordo com o contexto do problema.

Para exemplificar o critério de avaliação adotado, consideraremos um vetor de amostras de teste de uma janela w igual a

$$x_w = \{x_i, x_{i+1}, \ldots, x_n\}$$

em que x_i é a primeira amostra de teste e $(n-i)$ representa o número de amostras presentes na janela e um vetor

$$y_w = \{y_i, y_{i+1}, \ldots, y_n\}$$

referente aos rótulos dos dados do vetor x_w.

Utilizando os vetores x_w e y_w obtém-se o vetor de amostras preditas para a mesma janela:

$$p_w = \{p_i, p_{i+1}, \ldots, p_n\}$$

Com esses vetores, é possível calcular o erro absoluto para todos os dados da janela como:

$$E_w = \{|y_i - p_i|, |y_{i+1} - p_{i+1}|, \ldots, |y_n - p_n|\}$$

A partir disso, um erro global é calculado a fim de ser comparado em diferentes combinações de hiperparâmetros na Busca em Grade. Para isso, os erros locais de cada janela são concatenados em um único vetor no qual o erro global é calculado:

$$E_G = \frac{E_1 + E_2 + \ldots + E_m}{m}$$

em que m é a quantidade total de janelas deslizantes. O erro global (E_G) será utilizado como função de perda para a Busca em Grade.

3.7 Aprendizado por Transferência

O Aprendizado por Transferência, no contexto das RNAs, envolve o aproveitamento de um modelo previamente treinado como ponto de partida para inicializar os pesos de outra RNA que realizará uma tarefa similar, como é ilustrado na Figura 9.

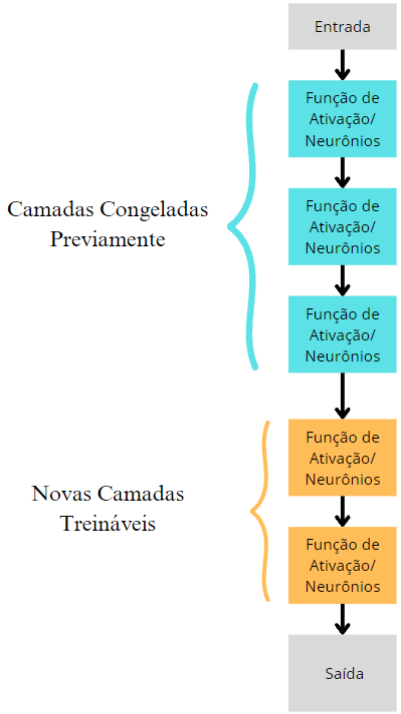

Fig. 9. Ilustração do Aprendizado por Transferência

A principal limitação da base de dados empregada na previsão da geração de energia na usina solar do Brasil é a escassez de amostras. Diante desse desafio, surge a estratégia de adotar o Aprendizado por Transferência, utilizado para aprimorar a construção do modelo (Hosna et al., 2022).

Neste trabalho adotou-se uma RNA Perceptron Multicamadas (PMC) como base para aplicação do AM. O PMC apresenta diversas configurações a serem exploradas e estudadas, sendo uma dessas configurações suas múltiplas camadas ocultas. Cada camada é composta por neurônios - também denominados de perceptrons - que trabalham em conjunto para extrair e refinar características dos dados de entrada. Outro componente crucial para o PMC são os pesos associados à conexão entre cada camada. Esses pesos são ajustados repetidamente, através da retropropagação, de modo a destacar características importantes e ignorar àquelas consideradas irrelevantes.

No contexto do Aprendizado por Transferência, o congelamento de camadas emerge como uma estratégia fundamental para otimizar o desempenho de modelos pré-treinados quando aplicados em novas tarefas. Essa técnica consiste em fixar os parâmetros das camadas pré-treinadas de uma RNA, preservando assim o conhecimento adquirido durante o treinamento em um domínio ou conjunto de dados inicial. Ao restringir as atualizações para apenas as camadas adicionadas, dedicadas à tarefa específica em questão, maximizamos a eficácia da adaptação do modelo aos novos dados, ao mesmo tempo que minimizamos a introdução de ruídos indesejados. Esta abordagem, além de acelerar o processo de treinamento, promove uma melhor generalização e desempenho preditivo do modelo para a nova tarefa proposta (Hosna et al., 2022).

4. RESULTADOS EXPERIMENTAIS

Para obtenção dos resultados apresentados nesta Seção, os algoritmos foram implementados em um computador com processador Intel Core i5-12450H com uma frequência de clock de 4.40 GHz e 16 GB de RAM.

No desenvolvimento deste trabalho foram utilizadas duas base de dados, a que é objeto final do estudo e a base de dados que foi utilizada no proceso de pré-treinamento do modelo final.

A base de dados objeto de estudo é proveniente da medição de geração de um inversor instalado em uma usina solar fotovoltaica de 6,5 MWp. Esta possui rastreadores solares e está localizada no estado de São Paulo. Os dados são tratados de maneira a compor uma série temporal com intervalo de tempo de 1 dia. No total, a base de dados possui 124 amostras, as quais os valores correspondem à geração de energia diária do inversor em quilowatt-hora (kWh). A base de dados citada acima pode ser acessada através `https://github.com/TrackerIC/Database_CBA2024.git`.

A outra base de dados foi utilizada para realizar o pré-treinamento do modelo, etapa do Aprendizado por Tranferência. Tal base é pertencente à usina de geração solar fotovoltaica de 24,3 kWp localizada em Alice Springs, Austrália. Esta base de dados também é tratada de maneira a compor uma série temporal com laço de 1 dia. No total, esta base contém 3259 amostras da produção diária de energia em kWh. Os dados desta usina estão disponíveis em `https://dkasolarcentre.com.au/source/alice-springs/dka-m9-a-c-phases`.

4.1 Estudo Preliminar - Preceptron Multicamadas (PMC)

Tendo em vista que as RNAs têm sido amplamente estudadas e aplicadas na previsão de séries temporais (Zhang, 2003), foi realizada uma análise preliminar utilizando o Perceptron Multicamadas (PMC) para investigar seu desempenho na previsão da série temporal em estudo. Exploramos o comportamento do PMC em relação aos padrões temporais da série, visando compreender sua eficácia e capacidade de modelagem nesse contexto específico.

Neste estudo preliminar foi utilizada a base de dados da usina solar brasileira. Realizou-se a Busca em Grade, conforme explicado na Subseção 3.5, em conjunto com a técnica de Janela Deslizante, com tamanho das janelas sendo 30% do tamanho total das amostras. Dessa maneira, as amostras de cada janela foram divididas em 80% para treino e 20% para teste. O método utilizado para avaliação é descrito na Subseção 3.6, em que o conceito de Erro Global foi apresentado. Por fim, a combinação de hiperparâmetros que apresentou o melhor desempenho foram:

- Camadas Ocultas: duas camadas com 16 neurônios cada;
- Função de Ativação: função Sigmóide;

- Tamanho de Lote : 32 amostras;
- Parada Antecipada: 10 iterações;
- Passo de Adaptação: 0,001;
- Função de Saída: Função ELU.

Ao fim deste estudo preliminar, o modelo com os hiperparâmetros citados foi treinado utilizando as amostras da base de dados da usina brasileira, divididas em 80% para treino e 20% para teste. Assim, os resultados obtidos podem ser visualizados na Figura 10, na qual é realizada a comparação entre os valores previstos e os reais para o subconjunto de teste. Para uma melhor visualização da performance do modelo, um sombreamento foi feito ao longo das amostras preditas. Esse sombreamento foi feito demilitando como margem superior o valor da predição com acréscimo do valor do REMQ e a margem inferior com o decréscimo do valor da REMQ do valor predito.

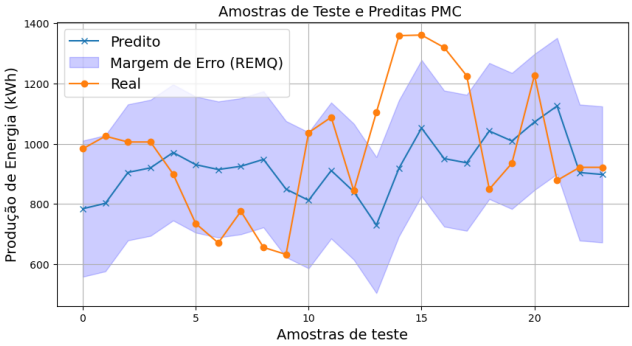

Fig. 10. Previsão com amostras de teste do modelo PMC.

Para avaliar este modelo foram utilizadas o EPAM e a REMQ como métricas, que obtiveram valores de 225,572 e 0,201 respectivamente.

4.2 Modelo com Aprendizado por Transferência

Visando melhorar o desempenho do modelo de RNAs apresentado no estudo preliminar, optou-se por utilizar a técnica de Aprendizado por Transferência, conforme descrito na Subseção 3.7. Para a construção do modelo pré-treinado, foi utilizada a base de dados proveniente da Austrália, contendo 3259 amostras de geração diária de energia. Utilizando essa base de dados foi realizada a Busca em Grade, seguindo a mesma metodologia aplicada no estudo preliminar (Subseção 4.1). Através desta busca, os hiperparâmetros que apresentam melhor desempenho foram:

- Camadas Ocultas: duas camadas com 32 neurônios cada;
- Função de Ativação: Função Tangente;
- Tamanho de Lote: 32 amostras;
- Parada Antecipada: 10 iterações;
- Passo de A daptação: 0,001;
- Função de Saída: Função Linear.

Definidos os hiperparâmetros da rede, foi realizado o treinamento da rede utilizando a base de dados da Austrália, essa etapa foi definida como pré-treinamento. O modelo obtido foi utilizado para a construção do modelo final.

Na estruturação do modelo final, os pesos das camadas ocultas do pré-modelo foram congelados, ou seja, foram mantidos inalterados. Para adaptar o modelo à base de dados da usina brasileira, uma nova camada de saída foi adicionada, com pesos treináveis. No treinamento do modelo final, as amostras da base de dados foram divididas em 80% para treino e 20% para teste. O resultado da previsão para as amostras de teste pode ser observado na Figura 11, na qual os parâmetros REMQ e EPMA foram utilizados como métricas de avaliação. O sombreamento foi utilizado para auxiliar na avaliação do modelo, assim como realizado na Figura 10.

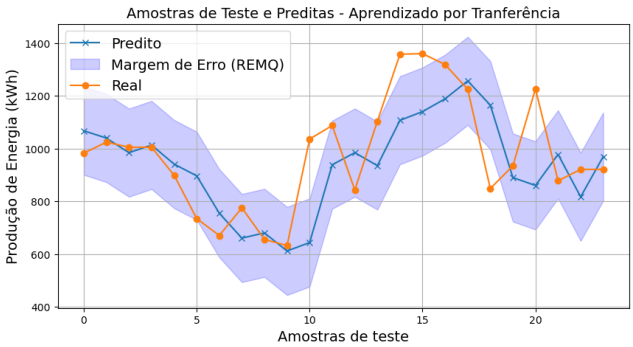

Fig. 11. Previsão com amostras de teste do modelo PMC com Aprendizado por Transferência

Observando a Figura 10 e a Figura 11 é possível notar que, para uma mesma estrutura de rede neural RNAs, utilizando um pré-treinamento com uma base de dados com um maior número de dados, é possível obter um melhor resultado quanto a qualidade de previsão do modelo, em que os dados preditos se aproximam mais dos rótulos.

Conforme evidenciado na Tabela 1, o modelo final, no qual são empregandas as técnicas de Aprendizado por Transferência, exibe um REMQ de $167,070$, enquanto a rede PMC, apresentado no estudo preliminar, demonstra um REMQ de $225,572$. Dessa forma, observa-se que o modelo final com a transferência de aprendizado registrou uma melhoria de cerca de 26% em comparação com o modelo de rede que não incorpora tal técnica. Melhora semelhante é percebida quando se compara o EPAM.

Tabela 1. Resultados dos Modelos

Regressor	REMQ	EPAM
Modelo Final - PMC	**167,70**	**0,141**
Estudo Preliminar - PMC	225,572	0,201
Gradient Boosting	272,482	0,247
Elastic Net	220,060	0,219
SVR	240,587	0,231
Bayesian Ridge	225,804	0,223
Regressão Linear	220,058	0,219
Kernel Ridge	233,581	0,226
Árvore de Decisão	315,039	0,305
RandomForest Regressor	233,778	0,225
ExtraTrees Regressor	226,729	0,224
AdaBoost Regressor	238,800	0,224
Ridge	220,058	0,219
Quantile Regressor	217,547	0,227

4.3 Comparação com outros métodos de regressão

Buscando comparar o desempenho do PMC com outros modelos de regressão que aparecem comumente na

literatura, utilizou-se a biblioteca de AM scikit-learn (Pedregosa et al., 2011), que possui código aberto em Python. A estrutura de código utilizada para obter os resultados são inspiradas no exemplo presente em `https://scikit-learn.org/stable/auto_examples/classification/plot_classification_probability.html`. As configurações adotadas para cada modelo são as padrões apresentadas pela biblioteca citada. Os resultados obtidos por cada modelo de previsão podem ser analisados na Tabela 1, na qual as métricas utilizadas de critério foram a REMQ e o EPAM.

5. CONCLUSÃO

A aplicação da Aprendizagem por Transferência em RNAs para prever a geração de energia em uma usina solar revelou-se uma abordagem altamente promissora, especialmente quando lidamos com conjuntos de dados limitados. Esta técnica não apenas demonstrou sua eficácia na otimização das métricas de erro das previsões, mas também ofereceu uma solução viável para lidar com a escassez de dados em cenários reais de operação. Ao transferir conhecimento de modelos pré-treinados para a tarefa específica de previsão de energia solar, foram obtidas melhorias significativas na capacidade de predição, proporcionando uma base sólida para tomada de decisões estratégicas e planejamento operacional. Esta abordagem é particularmente relevante em ambientes os quais a coleta de dados é desafiadora ou limitada, como é frequentemente o caso em instalações de energia solar descentralizadas ou em áreas remotas. Além disso, os resultados obtidos destacam o potencial da Aprendizagem por Transferência como uma ferramenta versátil e adaptável, capaz de ser integrada em diferentes contextos e expandir suas aplicações para além da previsão de energia solar.

Em futuros trabalhos, pretende-se aprofundar essa investigação, explorando ainda mais a flexibilidade e eficácia da Aprendizagem por Transferência em cenários operacionais diversos e considerando sua combinação com outras técnicas avançadas de análise de dados. Essa abordagem ampla e holística não apenas impulsionará o desenvolvimento de sistemas de previsão mais precisos e robustos, mas também contribuirá para o avanço da sustentabilidade energética e a adoção de fontes renováveis em larga escala.

6. AGRADECIMENTOS

Os autores gostariam de agradecer à Tecsci Ltda., Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001 e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) - Processos 310625/2022-0, 163963/2023-1 e 163969/2023-0.

REFERÊNCIAS

Ahmed, R., Sreeram, V., Mishra, Y., and Arif, M. (2020). A review and evaluation of the state-of-the-art in pv solar power forecasting: Techniques and optimization. Renewable and Sustainable Energy Reviews, 124, 109792. doi:https://doi.org/10.1016/j.rser.2020.109792. URL `https://www.sciencedirect.com/science/article/pii/S1364032120300885`.

Alves, K.S.T.R., de Jesus, C.D., and de Aguiar, E.P. (2024). A new takagi–sugeno–kang model for time series forecasting. Engineering Applications of Artificial Intelligence, 133, 108155. doi:https://doi.org/10.1016/j.engappai.2024.108155. URL `https://www.sciencedirect.com/science/article/pii/S0952197624003130`.

BloombergNEF (2024). Investimento global em energia limpa salta 17 URL `https://www.bloomberg.com.br/blog/bloombergnef-investimento-global-em-energia-limpa-salta-17-e-atinge-us-18-trilhao-em-2023/`. Acesso em: 2024-04-01.

California Independent System Operator (2020). Mid-august 2020 extreme heat wave. Final Root Cause Analysis. URL `https://www.caiso.com/Documents/Final-Root-Cause-Analysis-Mid-August-2020-Extreme-Heat-Wave.pdf`. Acesso em: 2024-03-13.

Costa, H.C. (2020). Correlação, autocorrelação e autocorrelação parcial. RPubs By RStudio. URL `https://rpubs.com/hudsonchavs/fac_facp`. Acesso em: 2024-03-17.

DataOverload (2022). Sliding window technique: Reduce the complexity of your algorithm. URL `https://medium.com/@data-overload/sliding-window-technique-reduce-the-complexity-of-your-algorithm-5badb2cf432f`. Acesso em: 2024-03-12.

Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z., and Azim, Mohammad, A. (2022). Transfer learning: a friendly introduction. Journal of Big Data, 9(1), 102. doi:https://doi.org/10.1186/s40537-022-00652-w.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in python. J. Mach. Learn. Res., 12, 2825–2830.

REN21 (2021). Global status report. URL `https://www.ren21.net/reports/global-status-report/`. Acesso em: 2024-04-01.

Sperati, S., Alessandrini, S., Pinson, P., and Kariniotakis, G. (2015). The "weather intelligence for renewable energies" benchmarking exercise on short-term forecasting of wind and solar power generation. Energies, 8(9), 9594–9619. doi:10.3390/en8099594. URL `https://doi.org/10.3390/en8099594`.

Tuohy, A., Zack, J., Haupt, S.E., Sharp, J., Ahlstrom, M., Dise, S., Grimit, E., Mohrlen, C., Lange, M., Casado, M.G., Black, J., Marquis, M., and Collier, C. (2015). Solar forecasting: Methods, challenges, and performance. IEEE Power and Energy Magazine, 13(6), 50–59. doi:10.1109/MPE.2015.2461351.

Zhang, G. (2003). Time series forecasting using a hybrid arima and neural network model. Neurocomputing, 50, 159–175. doi:https://doi.org/10.1016/S0925-2312(01)00702-0. URL `https://www.sciencedirect.com/science/article/pii/S0925231201007020`.