

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

VICTOR HUGO CHIMILOVSKI RIBEIRO

**ANÁLISE DE SÉRIES TEMPORAIS UTILIZANDO APRENDIZADO DE
MÁQUINA AO EXTREMO (ELM) PARA PREVISÃO DE POTÊNCIA EM PAINÉIS
SOLARES**

PATO BRANCO

2022

VICTOR HUGO CHIMILOVSKI RIBEIRO

**ANÁLISE DE SÉRIES TEMPORAIS UTILIZANDO APRENDIZADO DE
MÁQUINA AO EXTREMO (ELM) PARA PREVISÃO DE POTÊNCIA EM PAINÉIS
SOLARES**

**TIME SERIES ANALYSIS USING EXTREME LEARNING MACHINE (ELM) FOR
POWER FORECASTING IN SOLAR PANELS**

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia da Computação do Curso de Bacharelado em Engenharia da Computação da Universidade Tecnológica Federal do Paraná.

Orientador: Prof^a. Dr^a. Viviane Dal Molin

PATO BRANCO

2022



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

VICTOR HUGO CHIMILOVSKI RIBEIRO

**ANÁLISE DE SÉRIES TEMPORAIS UTILIZANDO APRENDIZADO DE
MÁQUINA AO EXTREMO (ELM) PARA PREVISÃO DE POTÊNCIA EM PAINÉIS
SOLARES**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção
do título de Bacharel em Engenharia da
Computação do Curso de Bacharelado em
Engenharia da Computação da Universidade
Tecnológica Federal do Paraná.

Data de aprovação: 07/Dezembro/2022

Dalcimar Casanova
Doutorado em Física
Universidade Tecnológica Federal do Paraná - Campus Pato Branco

Ives Renê Venturini Pola
Doutorado em Ciências da Computação e Matemática Computacional
Universidade Tecnológica Federal do Paraná - Campus Pato Branco

Viviane Dal Molin
Doutorado em Informática
Universidade Tecnológica Federal do Paraná - Campus Pato Branco

PATO BRANCO
2022

RESUMO

Pensando na importância das energias renováveis e seus desenvolvimentos tecnológicos, o uso de ferramentas computacionais e estatísticas para auxiliar na sua administração e manejo, pode ser um próximo passo para um crescimento e incentivo no uso dessas fontes energéticas sustentáveis, como usinas fotovoltaicas. Utilizando séries temporais e seus métodos de análise para descrever o conjunto amostral, pode-se realizar previsões estatísticas estocásticas com as mesmas e ao aplicar o modelo inteligente de Aprendizado de Máquina ao Extremo (ELM) têm-se uma melhora na acurácia dessas previsões. Aproveitando para encontrar os melhores hiperparâmetros na inicialização do ELM, o uso de meta-heurísticas de otimização como: *Coyote Optimization Algorithm*(COA), *Differential Evolution* (DE) e *Particle Swarm Optimization* (PSO), refinam os resultados de previsões e também é possível realizar um comparativo entre elas, indicando a melhor para aplicação em questão com o uso da minimização de erro de previsão como métrica de comparação. Com isso é possível notar resultados promissores numa acurácia próxima a 98% com a meta-heurística do PSO.

Palavras-chave: ELM; Usina fotovoltaica; Algoritmos de otimização; Série temporal; Técnicas de previsão.

ABSTRACT

Thinking about the importance of renewable energies and their technological developments, the use of computational and statistical tools to assist in their administration and management, can be a next step towards growth and encouragement in the use of these sustainable energy sources, such as photovoltaic plants. Using time series and their analysis methods to describe the sample set, stochastic statistical forecasts can be made with them and by applying the intelligent model of Extreme Learning Machine (ELM) there is an improvement in the accuracy of these forecasts. Taking advantage of finding the best hyperparameters at ELM initialization, the use of optimization meta-heuristics such as: *Coyote Optimization Algorithm*(COA), *Differential Evolution* (DE) and *Particle Swarm Optimization* (PSO), refine the forecast results and it is also possible to make a comparison between them, indicating the best one for the application in question with the use of forecast error minimization as a comparison metric. With this, it is possible to notice promising results in an accuracy close to 98% with the PSO meta-heuristic.

Keywords: ELM; Photovoltaic plant; Optimization algorithm; Timeseries; Forecasting techniques.

LISTA DE ALGORITMOS

Algoritmo 1 – Algoritmo do PSO	20
Algoritmo 2 – Algoritmo do DE	21
Algoritmo 3 – Algoritmo do COA	22

LISTA DE FIGURAS

Figura 1 – Pipeline do processamento de dados.	14
Figura 2 – Exemplo da previsão utilizando SEHW com sazonalidade.	18
Figura 3 – Estrutura de uma SLFN.	23
Figura 4 – Diagrama de metodologia aplicada na pesquisa.	29
Figura 5 – Dashboard de aquisição de dados.	30
Figura 6 – Variação da Temperatura em um dia.	30
Figura 7 – Variação da Tensão em um dia.	31
Figura 8 – Variação da Corrente em um dia.	31
Figura 9 – Variação da Potência em um dia.	32
Figura 10 – Método de previsão retroalimentada.	33
Figura 11 – Decomposição da série temporal observada: Tendência.	35
Figura 12 – Decomposição da série temporal observada: Sazonalidade.	35
Figura 13 – Previsão de Potência Verão.	36
Figura 14 – Previsão de Potência Outono.	37
Figura 15 – Previsão de Potência Inverno.	38
Figura 16 – Previsão de Potência Primavera.	39

LISTA DE TABELAS

Tabela 1 – Comparação das tecnologias abordadas nos trabalhos da seção	27
Tabela 2 – Melhores parâmetros encontrados por modelo no Verão	36
Tabela 3 – Resultado da acurácia por modelo no Verão	36
Tabela 4 – Melhores parâmetros encontrados por modelo no Outono	37
Tabela 5 – Resultado da acurácia por modelo no Outono	37
Tabela 6 – Melhores parâmetros encontrados por modelo no Inverno	38
Tabela 7 – Resultado da acurácia por modelo no Inverno	38
Tabela 8 – Melhores parâmetros encontrados por modelo no Primavera	39
Tabela 9 – Resultado da acurácia por modelo no Primavera	39

LISTA DE ABREVIATURAS E SIGLAS

Siglas

ANN	Rede Neural Artificial, do inglês <i>Artificial Neural Network</i>
ARIMA	Média Móvel Auto-regressiva Integrada, do inglês <i>Autoregressive Integrated Moving Average</i>
CGSA	Algoritmo de Busca Gravitacional Caótica, do inglês <i>Chaotic Gravitational Search Algorithm</i>
COA	Algoritmo de otimização Coyote, do inglês <i>Coyote Optimization Algorithm</i>
DE	Evolução Diferencial, do inglês <i>Differential Evolution</i>
DKASC	Centro de Conhecimento Solar do Deserto da Austrália, do inglês <i>Desert Knowledge Australia Solar Center</i>
ELM	Aprendizado de Máquina ao Extremo, do inglês <i>Extreme Learning Machine</i>
FOS	Sequência de Esquecimento Online, do inglês <i>Forgetting Online Sequential</i>
GA	Algoritmo Genético, do inglês <i>Genetic Algorithm</i>
GP	Programação Genética, do inglês <i>Genetic Programation</i>
HGSR	Radiação Solar Global Horizontal, do inglês <i>Horizontal Global Solar Radiation</i>
IA	Inteligência Artificial
ICSO	Otimizador de Enxame de Frango Melhorado, do inglês <i>Improved Chicken Swarm Optimizer</i>
IDE	Ambiente de Desenvolvimento Integrado, do inglês <i>Integrated Development Environment</i>
MAE	Erro Médio Absoluto, do inglês <i>Mean Absolute Error</i>
MAPE	Erro Percentual Médio Absoluto, do inglês <i>Mean Absolute Percentual Error</i>
MSE	Erro Quadrático Médio, do inglês <i>Mean Square Error</i>
PNE	Plano Nacional de Energia
PSO	Otimização por enxame de partículas, do inglês <i>Particles Swarm Optimization</i>
RMSE	Erro de Raiz Quadrática Média, do inglês <i>Root Mean Squared Error</i>

SDA	Análise de Dias Similares, do inglês <i>Similar Day Analysis</i>
SEH	Suavização de Exponencial de Holt
SEHW	Suavização de Exponencial de Holt-Winters
SES	Suavização de Exponencial Simples
SLFN	Rede Neural com Alimentação Direta de Camada Única Oculta , do inglês <i>Single Hidden Layer Feedforward Neural Network</i>
UTFPR	Universidade Tecnológica Federal do Paraná

SUMÁRIO

1	INTRODUÇÃO	11
2	REFERENCIAL TEÓRICO	14
2.1	Preparação dos dados	14
2.2	Séries temporais	15
2.2.1	Tendência e Sazonalidade	15
2.2.2	Modelo de Suavização de Exponencial	16
2.2.3	Procedimentos da Suavização exponencial <i>Holt-Winters</i>	17
2.3	Meta-heurísticas de otimização	19
2.3.1	<i>Particle Swarm Optimization</i> (PSO)	19
2.3.2	<i>Differential Evolution</i> (DE)	20
2.3.3	<i>Coyote Optimization Algorithm</i> (COA)	21
2.4	Aprendizado de Máquina ao Extremo (ELM)	22
2.5	Trabalhos correlatos	24
2.5.1	<i>Global Solar Radiation Prediction Using Hybrid Online Sequential Extreme Learning Machine Model</i>	25
2.5.2	<i>A comparative evaluation for identifying the suitability of extreme learning machine to predict horizontal global solar radiation</i>	25
2.5.3	<i>Prediction short-term photovoltaic power using improved chicken swarm optimizer - Extreme learning machine model</i>	26
2.5.4	<i>Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine</i>	26
2.5.5	<i>Forecasting Solar Irradiance with Weather Classification and Chaotic Gravitational Search Algorithm Based Wavelet Kernel Extreme Learning Machine</i>	27
3	MATERIAIS E MÉTODO	28
3.1	Materiais	28
3.2	Método	29
3.2.1	Aquisição de dados	29
3.2.2	Pré-processamento de Dados	29
3.2.3	Análise de série temporal	32
3.2.4	Utilizando meta-heurísticas de otimização	33

3.2.5	Previsão com ELM	33
3.2.6	Testes estatísticos	33
4	RESULTADOS E DISCUSSÃO	35
5	CONCLUSÃO	40
	REFERÊNCIAS	42

1 INTRODUÇÃO

Ao passar dos anos a energia elétrica tornou-se algo fundamental para a humanidade, pois possibilitou muitos avanços tecnológicos nas mais diversas áreas, além de trazer conforto, autonomia e melhor desempenho para tarefas manuais. Com esses avanços, a sociedade teve evoluções dentre meios sociais e econômicos, pois alavancou a geração de empregos, conectividade entre pessoas e a globalização. Mas por outro lado, também criou-se uma dependência energética das fontes de geração de energias, as quais em sua maioria são não renováveis, assim a busca pela eficiência energética e fontes renováveis de geração de energia cresceu com a preocupação de manter toda essa cadeia de avanços tecnológicos, confortos e meios econômicos. Com isso foi criado o Programa Nacional de Energia (PNE 2050), que tem o objetivo de explorar alternativas de futuro de modo a aprimorar o processo de tomada de decisão em políticas energéticas até 2050. Jannuzzi e de Melo (2013) afirmam que "À medida que a produção de energia renovável no local se torna viável, deve haver menos perdas nos sistemas de transmissão e distribuição, e essas tecnologias ajudam a mitigar o CO_2 das emissões que de outra forma seriam produzidas por novas usinas de energia baseadas em gás natural, petróleo e carvão, conforme planejado."

Logo as soluções de fontes renováveis de geração de energia como a eólica, nuclear, hídrica, oceânica, biomassa e energia solar tem ganhado espaço, apesar de suas dificuldades e por conta de sua relevância destacada em Carstens e Cunha (2019), no qual são mapeados os desafios e oportunidades para que este setor tenha um crescimento esperado nos próximos anos. Relata também que incentivos fiscais e financeiros criam uma boa visão para investidores nesta tecnologia, conseqüentemente tornando os preços mais atraentes para os consumidores especialmente na desenvoltura de uma indústria doméstica de energia fotovoltaica, aumentando o crescimento econômico nacional, e conseqüentemente o desenvolvimento local e regional, os quais são fatores responsáveis para a disseminação da energia fotovoltaica.

Diante deste cenário com todos estes ganhos apresentados, o uso da energia solar se mostra cada vez mais atraente para todos os tipos de consumidores, assim como a busca por inovações dos mesmos. Instigando pesquisas que utilizam todos os tipos de tecnologias, principalmente meios computacionais de previsão como aprendizagem de máquina que agregam nesse mundo de possibilidades e oportunidades que têm uma relevância mundial.

Apesar da tarefa de medição, predição e até redução de custos com o monitoramento da geração de energia em painéis solares ser um desafio, os artigos de Liu *et al.* (2020) e Pani e Nayak (2019), tem o objetivo em comum de realizar uma previsão sobre a geração de energia elétrica nos painéis solares adotados sob as diferentes condições climáticas, chegando à um resultado consideravelmente bom após o uso de séries temporais, ferramentas computacionais com inteligência artificial e meta-heurísticas de otimização.

Assim como é possível descrever uma sequência de valores relacionados por um meio observável com séries temporais e realizar uma previsão estatística com modelos de análise,

também pode-se realizar previsões com modelos computacionais como de aprendizado de máquina através de regressão linear, correlação de características e entre outros. Seguindo nesta linha de conhecimento, consegue-se ver uma aplicação muito interessante para este trabalho, no qual os dados coletados com o monitoramento da conversão de energia gerada de painéis solares por um período de tempo, podem ser utilizados para previsões de potência com modelos computacionais de inteligência artificial, onde a justificativa de emprego destes métodos é explicada logo abaixo.

"O processo de radiação solar é de natureza complexa, onde vários outros elementos climatológicos e atmosféricos como velocidade do vento, evaporação, umidade, temperatura, entre outros estão associados à sua magnitude. Assim, quantificar a radiação solar é um problema de natureza altamente difícil de resolver, e esta questão tem preocupado os estudiosos por cinco décadas. Tradicionalmente, a radiação solar é calculada por múltiplas formulações manuais e empíricas. No entanto, as formulações empíricas estão associadas a várias limitações, como comportamento particular do estudo de caso e variação nos resultados devido à alta estocasticidade incorporada aos dados reais. Assim, a motivação dos cientistas é incentivada a encontrar novas estratégias alternativas de modelagem para resolver esse problema."(HOU *et al.*, 2018)

Deste modo, os modelos artificiais conquistaram seu espaço com a exatidão desejada graças a obtenção de resultados mais precisos a partir de uma quantidade massiva de dados de entrada, e deixando de lado os problemas encontrados anteriormente de comportamento particular de estudo e cálculos estocásticos massivos. Considerando a acurácia e consistência apresentado no modelo de predição baseada em regressão linear nos trabalhos abordados na Seção 2.5, o aprendizado de máquina ao extremo (ELM) torna-se um modelo muito interessante para a aplicação no manejo de energia elétrica a partir das previsões realizadas em dados obtidos de painéis solares, pois com sua capacidade de receber inúmeros parâmetros de entrada e uma resposta razoavelmente rápida, ainda permitindo uma abrangência maior do período observado com uma precisão esperada próxima de 90% segundo os artigos de Hosain *et al.* (2017), Pani e Nayak (2019), Liu *et al.* (2020), Hou *et al.* (2018), Zhou *et al.* (2020), Shamshirband *et al.* (2015) que utilizam este modelo inteligente.

Tendo em vista que a previsão de potência de dias característicos de cada estação do ano, a partir de dados vindos de painéis solares e aplicando um modelo inteligente do ELM ainda não realizada na região de Pato Branco - PR, foram coletados os dados no período de 2 anos, com taxa de amostragem de 5 minutos totalizando em 151.608 amostras, a partir da usina fotovoltaica da UTFPR - Pato Branco, dados os quais tem a abrangência de variações climáticas e de índice de incidência solar durante o período. Após os tratamentos e testes iniciais de refinamento foram selecionados apenas amostras no período de 1 ano referente à 2021, pois algumas falhas de coletas nos inversores ocorreram até que fossem instalados e regulados. E também por conta de que já foi possível descrever e identificar as características necessárias

para o desenvolvimento da pesquisa, as quais são denotadas essencialmente na variação da temperatura da placa fotovoltaica e índices climáticos e elétricos como horas de incidência solar, variação da tensão, variação da corrente e energia acumulada, durante as 4 estações do ano, que de forma cíclica se repetem, totalizando o novo conjunto amostral suficiente com o 75.804 amostras.

Com os dados já pré-processados e parâmetros de treino e teste selecionados para o modelo de inteligência artificial ELM, foi possível realizar uma previsão da variação de potência do dia subsequente ao selecionado como característico de cada estação, comparando assim o comportamento observado com o previsto. E afim de refinar esta estimativa de dados que descrevem as variações de amostras observadas no período de um dia, é proposta uma comparação de métodos híbridos de aprendizado de máquina ao extremo, que fazem uso meta-heurísticas de otimização evolutivas, como *Particle Swarm Optimization (PSO)*, *Differential Evolution (DE)* e *Coyote Optimization Algorithm (COA)*, os quais são empregados na seleção de parâmetros mais adequados da inicialização do aprendizado de máquina ao extremo. Podendo assim realizar uma estimativa do desempenho de cada meta-heurística nesta aplicação particular através da minimização do erro como métrica principal, comprovando a sua eficiência no auxílio da busca por uma solução adequada para o problema em questão.

A aproximação metodológica deste trabalho pode ser dada pela contextualização da importância do desenvolvimento da geração de energia sustentável, propondo uma comparação de solução com previsão fazendo uso de um modelo inteligente do aprendizado de máquina ao extremo (ELM) híbrido, o qual tem a tarefa de melhorar a precisão, reduzindo a instabilidade de solução e com tempo computacional hábil no Capítulo 1. São definidos os conceitos necessários de mineração de dados, séries temporais, meta-heurísticas, aprendizado de máquina ao extremo (ELM) e é feita uma comparação de trabalhos correlatos no Capítulo 2. Seguindo, são comentados os materiais necessários para o desenvolvimento do mesmo, e a metodologia empregada no trabalho no Capítulo 3. Continuando com o detalhamento dos resultados obtidos, valores de erros e gráficos de previsões encontradas no Capítulo 4. E por fim, são apresentados como os objetivos deste trabalho foram atingidos e suas conclusões no Capítulo 5

2 REFERENCIAL TEÓRICO

Neste capítulo são apresentados os conceitos teóricos necessários para o embasamento deste trabalho, abordando todos os passos do seu desenvolvimento, desde o pré-processamento dos dados citados na Seção 2.1, os conceitos estatísticos e matemáticos do método utilizado para a análise de série temporal na Seção 2.2, explicando sobre as meta-heurísticas utilizadas para a seleção de hiperparâmetros do ELM na Seção 2.3, definindo o modelo inteligente proposto para a solução do problema na Seção 2.4, e finalizando com uma discussão e comparação de trabalhos correlatos na Seção 2.5.

2.1 Preparação dos dados

Para realizar a análise de algum problema real, é necessário possuir os dados que descrevem o que está sendo observado, apesar da coleta dos mesmos não sendo sempre como esperado. Desta maneira é introduzida a necessidade dos conceitos de mineração de dados, definido por Charu, C. Aggarwal logo abaixo:

A mineração de dados é o estudo da coleta, limpeza, processamento, análise e obtenção de percepções de dados. Existe uma grande variação em termos de domínios de problemas, aplicativos, formulações e representações de dados que são encontradas em aplicações reais. Portanto, "Mineração de dados" é um termo amplo que é usado para descrever esses diferentes aspectos de processamento de dados. (CHARU, 2015, p. 1)

Assim a aplicação dessa sequência de métodos se torna a peça inicial neste trabalho, fazendo parte desde a coleta dos dados obtidos, tratamento dos mesmos com a extração de características e limpeza de *outliers* ou valores faltantes. Até mesmo no bloco de construção na área classificada como processamento analítico ilustrado pela Figura 1, que são selecionadas as correlações de parâmetros do *dataset* inicial, ou mesmo se necessário, utilizando mais análises de padrões, representado pelo segundo bloco de construção na figura citada, com o objetivo de aplicar mais métodos de análise e lógica para o *dataset* tratado em questão.

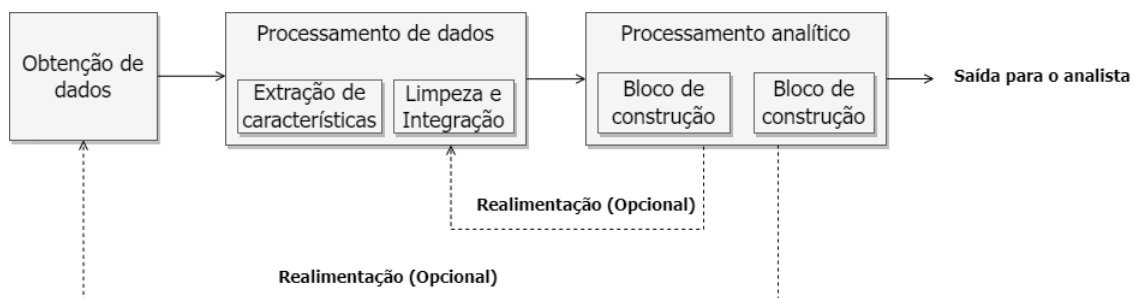


Figura 1 – Pipeline do processamento de dados.
Adaptado de Charu (2015).

Explorando a segunda etapa da preparação de dados no *pipeline* da mineração, é possível verificar a relevância da mesma, pois cada um de seus passos e fases melhoram o conjunto amostral da sua maneira, auxiliando conseqüentemente em uma melhor análise do conjunto amostral observado. Esta fase é o pré-processamento, definidor por Charu (2015) como: [1] Extração de características e portabilidade, fase qual o analista se depara com uma grande quantidade de dados crus, e faz uso de um roteiro para visualizar a transformação destes dados heterogêneos em homogênicos na base de dados de características no processamento. [2] Limpeza de dados, qual a entrada pode conter dados errados ou faltantes, logo o tratamento pode ser de remoção para as inconsistências e estimativa para os faltantes como por exemplo, uma média de valores anteriores. [3] Redução, seleção, e transformação de dados, é a fase em que as características irrelevantes são descartadas, tornando a base de dados menor com o objetivo de alcançar uma mineração mais eficiente, aproximando da solução para o problema específico.

Desta maneira, estes passos do pré-processamento foram aplicados nos dados adquiridos afim de auxiliar a análise comportamental dos mesmos, e otimizar a base de dados que é descrita por uma série temporal no trabalho.

2.2 Séries temporais

Para definir o que é esta representação de comportamento para uma sequência de pontos, Morettin Pedro A. (2006) conceitua: "Uma série temporal é qualquer conjunto de observações ordenada no tempo." Da mesma forma, é possível chamar uma parte de uma trajetória de pontos, com variação no tempo, de série temporal, ou função amostral. O objetivo de descrever o comportamento dessa sequência de pontos com uma série temporal, é tanto poder analisar a geração dos mesmos, quanto realizar previsões futuras, evidenciando suas características como tendência, sazonalidade, ciclos e variações, além de sua periodicidade.

Como o enfoque desta pesquisa é na previsão de pontos através de séries temporais, são abordados os procedimentos e modelos para a previsão, mais especificamente os modelos de suavização de exponencial na seção 2.2.2. Outro ponto muito importante a ser comentado para as séries temporais e estudos probabilísticos, é o modelo auto-regressivo integrado de médias móveis (ARIMA), definido por um ciclo de procedimentos, o qual auxilia o entendimento da série temporal, resultando em uma previsão de pontos seguintes.

2.2.1 Tendência e Sazonalidade

Ao se analisar uma série temporal, deve-se observar as características de tendência e sazonalidade. Pois para se decompor uma série temporal Z_t , são necessários três componentes

não observáveis,

$$Z_t = T_t + S_t + a_t \quad (1)$$

onde T_t e S_t correspondem a tendência e sazonalidade, e a_t representa o ruído branco, como um processo estacionário. Sabendo que este erro é a diferença entre a tendência e sazonalidade.

Tendência pode ser conceituada como uma componente de comportamento estimado da série, que descreve qual a variação esperada durante o período observado. Ao supor que a constante S_t da Equação 1 não esteja presente, segundo Morettin Pedro A. (2006), podemos estimar através dos seguintes métodos:

- Ajustar a função do tempo, como uma função suave de t ;
- Suavizar valores da série ao redor de um ponto;
- Suavizar valores da séries através de sucessivos ajustes de retas mínimos quadrados ponderados.

Por outro lado, se há a sazonalidade, que descreve quando ocorrem as variações específicas durante o período observado. É estimada por um procedimento de ajuste sazonal, dado por obter as estimativas de S_t e \hat{S}_t e calcular

$$Z_t^{SA} = Z_t - \hat{S}_t \quad (2)$$

onde Z_t é a série temporal decomposta e \hat{S}_t é a sazonalidade estimada. Além destas características, ainda podem estar classificadas como sazonalidades determinísticas, ou seja, que através de regressões, a previsão baseada apenas nos pontos anteriores tem uma alta precisão. Ou ainda como sazonalidade estocástica, quando a componente sazonal não é estável, variando com o tempo, neste modo é utilizado o método de médias móveis. Apesar de fenômenos como *El Nino* e *La Nina* poderem se classificar nessas definições de sazonalidade, os mesmos foram considerados nesta pesquisa, mas suas consequências de variações climáticas específicas podem sim afetar as previsões, onde novamente, foram consideradas como *OUTLIERS* por conta do modelo de previsão escolhida com apenas um dia caracterizando a estação do ano.

2.2.2 Modelo de Suavização de Exponencial

A maioria dos métodos de previsão com séries temporais são baseados em observar pontos passados, para definir um comportamento da série. "Uma grande classe de métodos de previsão, que tenta tratar ambas as causas de flutuações em séries de tempo, é a das suavizações". Morettin Pedro A. (2006)

Estes modelos são divididos por suas aplicações a partir das características das séries temporais observadas, assim resultando em vantagens de cada modelo, abordados pelo livro Morettin Pedro A. (2006), o modelo Suavização Exponencial Simples (SES), o qual é uma média ponderada que dá pesos maiores a observações recentes. Seguindo para os modelos para séries que apresentam tendência, é apresentada a Suavização Exponencial de *Holt* (SEH), com base no método anterior SES, mas invés de suavizar apenas seu nível, faz uso a constante de suavização para modelar a tendência da série, resultando em uma previsão com menor ruído. Para finalizar os modelos de suavização de exponencial descritos por Morettin Pedro A. (2006), é introduzido o modelo de Suavização Exponencial de *Holt-Winters* (SEHW), o qual é indicado para séries temporais sazonais e com tendência, ou seja, que possuem um comportamento esperado e com uma variação específica em um dado período. Para definir este modelo, que se encaixa melhor nesta pesquisa, sabendo que os dados obtidos para decompor a série temporal esperada, tem sua periodicidade de um ano, e com variações durante os meses e estações do ano. Logo é explicada uma aplicação do algoritmo de uma melhor forma na subseção 2.2.3, para que fique mais claro seus resultados e o porque da escolha.

2.2.3 Procedimentos da Suavização exponencial *Holt-Winters*

Seguindo os passos do algoritmo de Brockwell e Davis (2016), que define a sequência de passos para se realizar previsões com o modelo de suavização exponencial escolhido.

Dada a série exponencial observada como Y_1, Y_2, \dots, Y_n com tendência, sazonalidade e de período d , a função para a previsão generalizada é dada por

$$P_n Y_{n+h} = \hat{a}_n + \hat{b}_n h + \hat{c}_{n+h}, h = 1, 2, \dots, \quad (3)$$

onde \hat{a}_n , \hat{b}_n e \hat{c}_n respectivamente estimativas de tendência de subida a_n , tendência de queda b_n e componente sazonal c_n , durante o tempo n . Se k é um número inteiro, que satisfaz $n + h - kd \leq n$, então

$$\hat{c}_{n+h} = \hat{c}_{n+h-kd}, h = 1, 2, \dots, \quad (4)$$

enquanto os valores de \hat{a}_i , \hat{b}_i e \hat{c}_i , $i = d + 2, \dots, n$ são encontrados de forma recursiva em

$$\hat{a}_{n+1} = \alpha(Y_{n+1} - \hat{c}_{n+1-d}) + (1 - \alpha)(\hat{a}_n + \hat{b}_n) \quad (5)$$

$$\hat{b}_{n+1} = \beta(\hat{a}_{n+1} - \hat{a}_n) + (1 - \beta)\hat{b}_n, \quad (6)$$

e

$$\hat{c}_{n+1} = \gamma(Y_{n+1} - \hat{a}_{n+1}) + (1 - \gamma)\hat{c}_{n+1-d}, \quad (7)$$

com as condições iniciais

$$\hat{a}_{d+1} = Y_{d+1} \quad (8)$$


$$\hat{b}_{d+1} = (Y_{d+1} - Y_1)/d \quad (9)$$

e

$$\hat{c}_i = Y_i - (Y_1 + \hat{b}_{d+1}(i - 1)), i = 1, \dots, d + 1 \quad (10)$$

Assim sabendo que a previsão depende dos parâmetros de suavização α , β e γ , com valores arbitrários entre 0 e 1, ou escolhidos sistematicamente através do erro pela soma de quadrados $\sum_{i=d+2}^n (Y_i - P_{i-1}Y_i)^2$.

Ao finalizar o algoritmo, aplicado ao data set *DEATHS.TSM* do livro Brockwell e Davis (2016), é possível verificar a eficácia de sua previsão com 24 pontos na Figura 2, onde a linha azul são os dados observados que compõem a série temporal, e a linha vermelha representa os pontos previstos pela suavização, no gráfico que mostra o número de mortes acidentais, do *Software* de testes ITSM.



**Figura 2 – Exemplo da previsão utilizando SEHW com sazonalidade.
Brockwell e Davis (2016)**

2.3 Meta-heurísticas de otimização

Com o objetivo de otimizar as previsões realizadas pelo métodos de suavização, são aplicadas meta-heurísticas, as quais oferecem uma solução viável para o problema de selecionar um vetor de parâmetros a serem automatizados, com o aprendizado de máquina ao extremo. Desta forma, é introduzida a definição de uma meta-heurística por Glover e Kochenberher (2003) em *Handbook of Metaheuristics* como:

meta-heurísticas, em sua definição original, são métodos de solução que orquestram uma interação entre procedimentos de melhoria local e estratégias de nível superior para criar um processo capaz de escapar de ótimos locais e realizar uma busca robusta de um espaço de solução. Com o tempo, esses métodos também passaram a incluir quaisquer procedimentos que empregam estratégias para superar a armadilha da otimização local em espaços de solução complexos, especialmente aqueles procedimentos que utilizam uma ou mais estruturas de vizinhança como meio de definir movimentos admissíveis para a transição de uma solução para outro, ou para construir ou destruir soluções em processos construtivos e destrutivos. (GLOVER; KOCHENBERHER, 2003)

Durante o processo de aplicação de uma meta-heurística, temos como resultado uma solução para o problema *NP-HARD*, mas não necessariamente é a melhor solução. Mas como todos algoritmos de Meta-heurísticas são equivalentes em sua eficácia, a validação cruzada contorna esta questão de encontrar uma solução viável e de custo computacional aceitável.

A validação cruzada consiste em comparar os resultados dos modelos aplicados, para que se encontre a melhor solução dentre as soluções obtidas. Logo, será possível comparar os algoritmos das subseções seguintes, testados a partir dos dados resultados nas previsões de eficiência energética em painéis solares com a suavização de exponencial.

2.3.1 Particle Swarm Optimization (PSO)

O algoritmo de otimização com nuvem ou enxame de partículas, é baseado no paradigma de cálculos espaciais n-dimensionais. Onde a população responde aos níveis de qualidade P_{melhor} e G_{melhor} , garantindo uma diversidade de soluções possíveis. Para a evolução da população, é necessário a atualização de G_{melhor} , que adapta a população, variável diretamente ligada a velocidade da partícula definida de forma arbitrária. É possível ter um entendimento melhor de seu funcionamento pelo pseudocódigo abaixo.

Algoritmo 1 – Algoritmo do PSO

```

1:  $Max\_it \leftarrow Total\_de\_iteracoes$ 
2:  $n \leftarrow Tamanho\_do\_enxame$ 
3: para  $i = (1 : n)$  faça
4:    $x_i \leftarrow inicia\_posicao\_particula$ 
5:    $P_{melhor}^i = x_i$ 
6:   se  $f(P_{melhor}^i) > f(G_{melhor})$  então
7:      $G_{melhor} = P_{melhor}^i$ 
8:   finaliza se
9: finaliza para
10: enquanto  $t < Max\_it$  faça
11:    $t = t + 1$ 
12:   para  $i = (1 : n)$  faça
13:      $v_i \leftarrow velocidade\_da\_particula$ 
14:      $x_i(t) = x_i(t - 1) + v_i$ 
15:     se  $f(x_i) > f(P_{melhor}^i)$  então
16:        $P_{melhor}^i = x_i$ 
17:       se  $f(P_{melhor}^i) > f(G_{melhor})$  então
18:          $G_{melhor} = P_{melhor}^i$ 
19:       finaliza se
20:     finaliza se
21:   finaliza para
22: finaliza enquanto
23: imprime  $G_{melhor}$ 

```

Fonte: Kennedy e Eberhart (1995a).

2.3.2 Differential Evolution (DE)

Para conceituar o evolução diferencial, Storn e Price (1997b) explica de maneira mais detalhada qual é a ideia por trás desta meta-heurística.

"Como regra, assumiremos uma distribuição de probabilidade uniforme para todas as decisões aleatórias, a menos que seja declarado de outra forma. No caso de uma solução preliminar estar disponível, a população inicial é frequentemente gerada adicionando desvios aleatórios normalmente distribuídos à solução nominal x_{nom} , 0. A ideia crucial por trás de DE é um esquema para gerar vetores de parâmetros de teste. DE gera novos vetores de parâmetro adicionando um vetor de diferença ponderada entre dois membros da população a um terceiro membro. Se o vetor resultante produzir um valor de função objetivo menor do que um membro da população predeterminado, o vetor recém-gerado substituirá o vetor com o qual foi comparado na geração seguinte."(STORN; PRICE, 1997b)

Algoritmo 2 – Algoritmo do DE

```

1: Inicia_populacao
2: enquanto !convergencia faça
3:    $x_i \leftarrow pop\_atual$ 
4:    $y_i \leftarrow nova\_pop$ 
5:   para  $i = (0 : N_p)$  faça
6:      $r1 = rand(N_p)$ 
7:      $r2 = rand(N_p)$ 
8:      $r3 = rand(N_p)$ 
9:      $u_i = x_{r3} + F * (x_{r1} - x_{r2})$ 
10:    se  $f(u_i) \leq f(x_i)$  então
11:       $y_i = u_i$ 
12:    senão,
13:       $y_i = x_i$ 
14:    finaliza se
15:  finaliza para
16: finaliza enquanto
17: imprime  $y_i$ 

```

Fonte: Storn e Price (1997a).

2.3.3 Coyote Optimization Algorithm (COA)

Para definir e explicar o algoritmo de otimização do coyote (COA), que é uma meta-heurística baseada em população Pierozan e Coelho (2018) detalha em *Coyote Optimization Algorithm: A new metaheuristic for global optimization problems*

"No COA, a população de coiotes é dividida em $N_p \in \mathbb{N} \times matilhas$ com $N_c \in \mathbb{N} \times coiotes$ cada. Nesta primeira proposta, o número de coiotes por matilha é estático e semelhante para todas as matilhas. Portanto, a população total no algoritmo é obtida pela multiplicação de N_p e N_c . Para fins de simplificação, os coiotes solitários (ou transitórios) não são considerados nesta primeira versão do algoritmo. Para facilitar a compreensão do leitor, cada coiote é uma possível solução para o problema de otimização e sua condição social é o custo da função objetivo."(PIEREZAN; COELHO, 2018)

Algoritmo 3 – Algoritmo do COA

```

1:  $N_p \leftarrow matilha, N_c \leftarrow coiotes$ 
2: verifica_adaptacao
3: enquanto !convergencia faça
4:   para bando faça
5:     define_alpha
6:     calcula_tendencia
7:     para coiote faça
8:       melhora_pop
9:       calcula_pop
10:      atualiza_pop
11:     finaliza para
12:     verifica_sobreviventes
13:   finaliza para
14:   trocas_de_bando
15:   atualiza_idade_coiotes
16: finaliza enquanto
17: imprime coiote_mais_adaptado

```

Fonte: Pierezan e Coelho (2018).

2.4 Aprendizado de Máquina ao Extremo (ELM)

Ao abordar o aprendizado de máquina ao extremo, inicialmente deve-se introduzir o conceito de redes neurais, definido por Wang *et al.* (2021) em *A review on extreme learning machine* como:

Rede neural, que geralmente se refere a rede neural artificial, foi proposta pela primeira vez na última década para uma história de mais de 70 anos. A rede neural foi inspirada no biológico rede neural e sua estrutura básica imita o sistema nervoso do cérebro humano. Como um tipo de método de aprendizado de máquina, uma rede neural típica consiste em neurônios, conexões e pesos. Na rede neural, um neurônio, também chamado de percepção, recebe sinais de entrada de neurônios anteriores e envia sinais de saída para neurônios posteriores. Neurônios dentro de uma rede neural são frequentemente organizados em camadas diferentes. A conexão foi definida como relação entre neurônios de diferentes camadas. E cada conexão fornece um parâmetro importante chamado peso. Isto é pesos que decidem como um neurônio processa sinais de entrada para emitir sinais de saída. (WANG *et al.*, 2021)

Pois segundo Huang, Zhu e Siew (2006), ELM possui a mesma arquitetura de uma *Single-hidden layer feedforward neural network* (SLFN), ou seja, Rede Neural Realimentada de Camada Única Oculta, mas escolhe aleatoriamente nós ocultos e determina analiticamente os pesos de saída. Porém diferente de uma SLFN comum que utiliza o conhecimento passado linearmente para chegar a uma nova conclusão com o *Back Propagation*, o ELM utiliza a aleatoriedade dos resultados obtidos para selecionar o peso ou relevância de cada neurônio.

A SLFN (*Single Hidden Layer Feedforward Neural Network*) consiste em 3 camadas, a camada de entrada, a oculta e a de saída representados na Figura 3. Sendo x a entrada, e o o vetor de saída, não esquecendo de w , representando o vetor de peso conectando o i -ésimo nó oculto e b é o limite do i -ésimo nó oculto. Já o β é o peso do resultado obtido, pois a rede decide estes parâmetros para alcançar a solução ótima.




Figura 3 – Estrutura de uma SLFN.

Wang *et al.* (2021)

Para o treinamento deste método, considera-se que para qualquer número de amostras de treino N onde $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbb{R}^n$, e $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$ é dado

$$\sum_{i=1}^{\hat{N}} \beta_i g(w_i \cdot x_j + b_i) = o_j, j = 1, \dots, N \quad (11)$$

e para encontrar o vetor objetivo t_i é feito

$$\sum_{i=1}^{\hat{N}} \beta_i g(w_i \cdot x_j + b_i) = t_j, j = 1, \dots, N. \quad (12)$$

As quais podem ser compactadas como $H\beta = T$, onde

$$H(w_1, \dots, w_{\hat{N}}, b_1, \dots, b_{\hat{N}}, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\hat{N}} \cdot x_1 + b_{\hat{N}}) \\ \dots & \dots & \dots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\hat{N}} \cdot x_{\hat{N}} + b_{\hat{N}}) \end{bmatrix}_{N \times \hat{N}} \quad (13)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \cdot \\ \cdot \\ \cdot \\ \beta_{\hat{N}}^T \end{bmatrix}_{\hat{N} \times m}, T = \begin{bmatrix} t_1^T \\ \cdot \\ \cdot \\ \cdot \\ t_N^T \end{bmatrix}_{N \times m} \quad (14)$$

Assim, como o SLFN tem sua solução calculada baseada em um gradiente convencional, dado por

$$\| H(\hat{w}_1, \dots, \hat{w}_{\hat{N}}, \hat{b}_1, \dots, \hat{b}_{\hat{N}}) \hat{\beta} - T \| = \min_{w_i, b_i, \beta} \| H(w_1, \dots, w_{\hat{N}}, b_1, \dots, b_{\hat{N}}) \beta - T \| \quad (15)$$

escrevendo de outra forma

$$E = \sum_{j=1}^N \left(\sum_{i=1}^{\hat{N}} \beta_i g(w_i \cdot x_j + b_i) - t_j \right)^2. \quad (16)$$

Os algoritmos de aprendizado baseados em gradiente, são usados quando o H é desconhecido, com o intuito de encontrar o mínimo de $\| H\beta - T \|$. Neste processo de minimização, o vetor W , cujo representa o conjunto de parâmetros e pesos (w_i, b_i) , e tendência (b_i) , é descrito pela seguinte equação:

$$W_k = W_{k-1} - \eta \frac{\partial E(W)}{\partial W}. \quad (17)$$

Sabendo que η é a proporção de aprendizado. O grande destaque do ELM em comparação aos outros algoritmos baseados em gradientes como *Back-Propagation* (BP) e *Support Vector Machine* (SVM), é sua eficiência e rapidez para o encontrar a solução mesmo utilizando uma função de definição de pesos aleatórios para os neurônios que repassam as soluções obtidas.

2.5 Trabalhos correlatos

Uma ótima maneira de verificar a eficácia dos métodos para previsão de eficiência energética em painéis solares é comparar as diferentes abordagens utilizadas, considerando suas tecnologias empregadas, assim são detalhados trabalhos e pesquisas que fizeram uso de aprendizado de máquina ao extremo para auxiliar na acurácia de seus resultados.

2.5.1 *Global Solar Radiation Prediction Using Hybrid Online Sequential Extreme Learning Machine Model*

No artigo de Hou *et al.* (2018), que propõe *Predição de radiação solar global usando modelo de aprendizado de máquina ao extremo sequencial híbrido online*, é possível verificar que a aplicação de modos híbridos em inteligências artificiais (IAs), como o *Forgetting Online Sequential Extreme Learning Machine* (FOS-ELM), para medir a eficiência energética em painéis solares e realizar previsões, tem resultados promissores, precisão e adaptabilidade em padrões complexos. Anteriormente descritos por séries temporais, estes dados não estacionários, variantes no tempo e em grande quantidade, causam problemas de predição para o modelo clássico do aprendizado ao extremo, já que para seu treino, são necessários os dados atuais e anteriores. A grande vantagem do FOS-ELM é dada pela forma sequencial atualizada, treinada e testada apenas com os dados mais novos extraídos, e esquecendo os antigos.

Os dados desta pesquisa foram extraídos de Dedougou, na região de Burkina Faso (África), os quais foram: velocidade do vento, temperatura (max e min), humidade (max e min), evaporação e deficiência da pressão do vapor, medindo a acurácia com *Root Mean Square Error* (RMSE) e *Mean Absolute Error* (MAE) (68.8 a 79.8%), concluindo uma eficácia de 3% maior comparando FOS-ELM em relação ao ELM

2.5.2 *A comparative evaluation for identifying the suitability of extreme learning machine to predict horizontal global solar radiation*

Com o objetivo de encontrar o método de predição mais preciso para a radiação solar global horizontal (HGSR), Shamshirband *et al.* (2015) realiza comparações entre os modelos de aprendizado de máquina, como o ELM, *Support Vector Machine* (SVM), Programação Genética (GP) e Rede Neural Artificial (ANN). A partir de dados meteorológicos como duração relativa do sol, horas de incidência solar, variação de temperatura no dia, temperatura (média, min e max) do ar e umidade relativa. Extraídos de Shiraz no Iran, durante 120 meses, separados em 84 e 36 meses, respectivamente para o treino e teste do aprendizado de máquina.

Shamshirband *et al.* (2015) conclui com "Para concluir, os resultados do estudo comparativo conduzido indicaram fortemente que o ELM é um método especialmente eficiente para prever o HGSR com a capacidade de fornecer uma precisão muito maior em comparação com muitas técnicas existentes", onde essas comparações de precisão utilizaram RMSE e *Mean Square Error* (MSE).

2.5.3 *Prediction short-term photovoltaic power using improved chicken swarm optimizer - Extreme learning machine model*

Para realizar a Previsão de energia fotovoltaica de curto prazo, Liu *et al.* (2020) faz uso de um otimizador aprimorado de enxame de frango sob o modelo de máquina de aprendizado extremo. Iniciando com a determinação do coeficiente de correlação, aprimorando o enxame de frango, estimulando a convergência do modelo, com o objetivo de balancear os pesos e parâmetros de uma forma melhor para o aprendizado de máquina. Chamado de *Improved Chicken Swarm Optimizer* (ICSO-ELM), ou Otimizador de Enxame de Frango Aprimorado, tem uma melhor aplicação para a previsão de diferentes condições climáticas, pois nesta pesquisa são aplicados super parâmetros de atualização rápida, dados a partir da potência gerada durante 8h as 17h de um dia, com amostras a cada 5 minutos.

Concluindo com Liu *et al.* (2020) afirma que "Os resultados do teste mostram que o erro médio percentual absoluto médio e o erro quadrático médio médio do otimizador de enxame de frango aprimorado - modelo de máquina de aprendizado extremo são 5,54% e 3,08%. O método proposto é de grande importância para o despacho econômico de sistemas de potência e o desenvolvimento de energia limpa."

2.5.4 *Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine*

Nesta pesquisa, que Zhou *et al.* (2020) propõem a "Previsão da produção de energia fotovoltaica com base na análise de dias semelhantes, algoritmo genético e máquina de aprendizado extremo", afirmando que os clássicos algoritmos de aprendizado de máquina não possuem uma precisão estável, dada a aplicação de previsão para energia gerada em usinas fotovoltaicas. Sugerindo um modelo híbrido baseado em ELM, *Genetic Algorithm* (GA) e *Similar Day Analysis* (SDA), prevendo a energia gerada de hora em hora. Porém a SDA é fortemente influenciada pela condição climática, incluindo temperatura ambiente, radiação horizontal, horas de luz solar durante o dia e a velocidade do vento. Desta maneira a aplicação de Algoritmos Genéticos melhora estas condições e parâmetros para o ELM foi de fundamental necessidade.

Os dados empregados neste trabalho foram retirados do *Desert Knowledge Australia Solar Center* (DKASC), em Alice Spring. No período de 14 de Janeiro de 2017 a 15 de Outubro de 2018, com resolução de amostragem de 1h. E concluindo que segundo Zhou *et al.* (2020) o SDA-GA-ELM tem aproximadamente 10% de eficiência a mais comparado ao clássico ELM, na tarefa de realizar previsões para o dia seguinte. Para estas comparações de desempenho foram utilizadas o RMSE e MAE

2.5.5 Forecasting Solar Irradiance with Weather Classification and Chaotic Gravitational Search Algorithm Based Wavelet Kernel Extreme Learning Machine

É possível verificar uma abordagem totalmente diferente por Pani e Nayak (2019), que visa a "Previsão da radiação solar com classificação do tempo e algoritmo de busca gravitacional caótica baseado em Wavelet Kernel Extreme Learning Machine", pois faz uso do *Chaotic Gravitational Search Algorithm* (CGSA), afim de otimizar parâmetros no funcionamento do kernel, o qual ajuda na estabilidade e convergência do ELM, selecionando os pesos para os testes da camada oculta.

Neste trabalho foram coletados dados de um ano para as previsões classificar os diferentes climas, como ensolarado, nublado, nublado e chuvoso, a partir de variáveis como irradiação, temperatura atmosférica, e potência gerada. No período de 1 de Janeiro de 2015 a 31 de Dezembro de 2015, na localidade de Tangi, Odisha, India. Com isso o autor Pani e Nayak (2019) conclui que "O ELM é rápido e simples, mas com um problema de saída instável, este problema é resolvido pelo KELM que mostra um maior desempenho de generalização junto com ser estável, mas tinha uma desvantagem de parâmetro não otimizado que é mitigado por uma técnica de otimização." Resultando em uma eficácia testada de 3% superior comparando o CGSA-ELM com o ELM, comprovadas com as métricas de erro RMSE, MAE e *Mean Absolute Percentage Error* (MAPE).

Tabela 1 – Comparação das tecnologias abordadas nos trabalhos da seção

Painéis solares	Meta-heurística	ELM	Série temporal	Precisão	Trabalho
Sim	FOS	FOS-ELM	15 anos	97%	Hou <i>et al.</i> (2018)
Sim	-	ELM	-	97%	Shamshirband <i>et al.</i> (2015)
Sim	ICSO	ICSO-ELM	27 horas	96%	Liu <i>et al.</i> (2020)
Sim	GA	SDA-GA-ELM	-	90%	Zhou <i>et al.</i> (2020)
Sim	CGSA	CGSA-ELM	365 dias	97%	Pani e Nayak (2019)
Sim	COA, DE e PSO	ELM	24h/estação do ano	98,5%	Presente trabalho

Fonte: Autoria própria.

Como pode-se notar, não é todo trabalho que faz uso de meta-heurísticas, afim de otimizar a precisão do aprendizado de máquina, apesar das semelhanças dos trabalhos apresentados, como o uso de dados de painéis solares para a previsão de energia gerada utilizando ELM. A pesquisa em questão tem também o objetivo de comparar diferentes meta-heurísticas, verificando qual consegue os melhores parâmetros na entrada do ELM, consequentemente obtendo uma melhor acurácia na previsão de energia gerada pelos painéis solares.

3 MATERIAIS E MÉTODO

Afim de detalhar o desenvolvimento deste trabalho, esta seção relata os métodos e ferramentas empregadas para que se possa entender a sequência de decisões tomadas durante a realização do mesmo. Assim definindo as principais características da pesquisa e como foi possível obter o resultado alcançado.

3.1 Materiais

No desenvolvimento desta pesquisa, o *Software* de ambiente de desenvolvimento (IDE) RStudio, se destaca como ferramenta principal para trabalhar com a linguagem de programação R, a qual foi essencial desde o pré-processamento dos dados, destacando as principais características a serem utilizadas, realizando previsões com análises de séries temporais, e até mesmo o uso de algoritmos de meta-heurísticas de otimização previamente implementadas "*Swarm Optimization* (PSO), (Kumar et al., 2019)", "*Differential Evolution* (DE), (Kumar et al., 2019)" e "*Coyote Optimization Algorithm* (COA), (Pierezan e Coelho, 2018)". Além da realização das previsões com os algoritmos de rede neural ELM

Já a base de dados foi adquirida através do serviço de monitoramento *SOLARVIEW*, na usina fotovoltaica da UTFPR - Campus Pato Branco, que permite a extração de tabelas com valores mensurados a partir de inversores fotovoltaicos. Em que essa coleta com taxa de amostragem de 5 minutos no período das 05h da manhã às 21:55h da noite, totalizando 204 amostras por dia, estabelece a base de dados a partir de sensores nos inversores das placas solares, no período de 01 de Janeiro de 2021 até 31 de Dezembro de 2021 com 75.804 linhas de dados coletados, com 43 colunas referentes a dados de de conversão de energia solar em elétrica, como: Data e Hora; Corrente na Fase A (A); Corrente na Fase B (A); Corrente na Fase C (A); Tensão de Linha AB (V); Tensão de Linha BC (V); Tensão de Linha CA (V); Tensão de Fase AN (V); Tensão de Fase BN (V); Tensão de Fase CN (V); Potência CA (W); Frequência CA (Hz); Fator de Potência; Energia CA (kWh); Horas de Injeção (Hs); Potência CC (W); Corrente CC 01 (A); Tensão CC 01 (V); Corrente CC 02 (A); Tensão CC 02 (V); Corrente CC 03 (A); Tensão CC 03 (V); Corrente CC 04 (A); Tensão CC 04 (V); Temperatura (°C); Corrente CC 05 (A); Tensão CC 05 (V); Corrente CC 06 (A); Tensão CC 06 (V); Corrente CC 07 (A); Tensão CC 07 (V); Corrente CC 08 (A); Tensão CC 08 (V); Corrente CC 09 (A); Corrente CC 10 (A); Corrente CC 11 (A); Corrente CC 12 (A); Corrente CC 13 (A); Corrente CC 14 (A); Corrente CC 15 (A); Corrente CC 16 (A); Corrente CC 17 (A); Corrente CC 18 (A)"

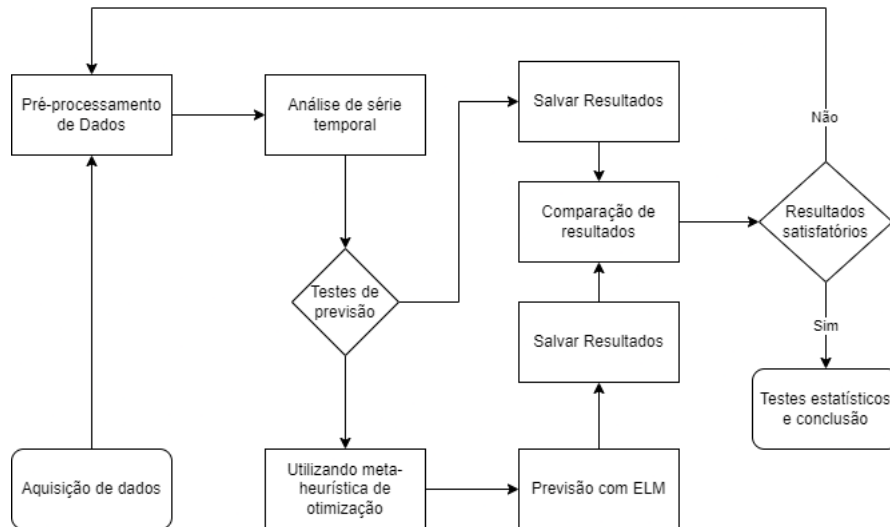


Figura 4 – Diagrama de metodologia aplicada na pesquisa.

Autoria própria.

3.2 Método

Na Figura 4 é possível verificar quais foram os passos de desenvolvimento desta pesquisa, descritos e abordados detalhadamente abaixo. Importante destacar que a metodologia proposta é iterativa e evolutiva, assim sendo, até se obter resultados satisfatórios, as etapas de pré-processamento e demais etapas foram executadas N vezes.

3.2.1 Aquisição de dados

Inicialmente é feita a extração de dados do programa de monitoramento dos painéis solares da UTFPR - Pato Branco, *SOLARVIEW*, o qual possui um *dashboard* interativo com opções de seleção de período de amostragem e parâmetros para uma visualização gráfica das informações de conversão de energia elétrica realizada pelos inversores nos painéis solares como é possível notar na Figura 5.

3.2.2 Pré-processamento de Dados

No *dataset* haviam dados com valores correspondentes a *NA* ou zerados, vindos de falhas nas coletas dos sensores nos inversores ou ainda por conta de dias nublados, que afetam a geração de energia nos painéis solares. Para que essas amostras não atrapalhassem na análise, foram necessários processos como o uso do *replace* que permite substituir o valor *NA* pela mediana dos valores anteriores, e também tratamentos de dados para que os valores se tornassem numéricos, por questões de conversão de arquivos extraídos do site e uso na ferramenta R. Assim utilizando as ferramentas de pré-processamento e mineração de dados como extração de características, categorização para tornar uniforme os dados e redução do *dataset*,




Figura 5 – Dashboard de aquisição de dados.

Autoria própria.

auxiliaram na análise e seleção das características mais relevantes para a previsão dentre os dados coletados através dos sensores de inversores disponíveis, as quais foram selecionadas Temperatura, Corrente, Tensão e Potência, pois a partir desse conjunto de dados correlacionados é possível visualizar a curva de variação de potência durante cada dia ilustradas nas Figuras 6, Figura 7, Figura 8 e Figura 9.

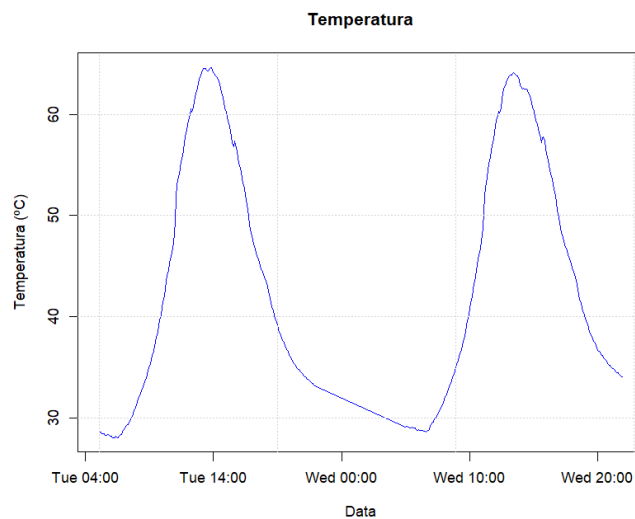
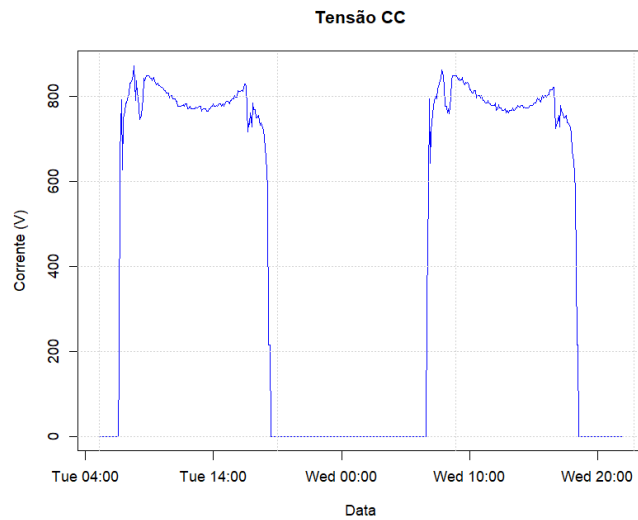



Figura 6 – Variação da Temperatura em um dia.

Autoria própria.

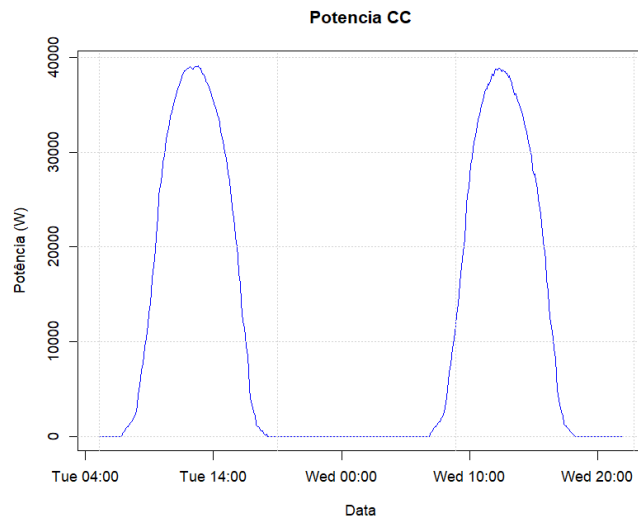


**Figura 7 – Variação da Tensão em um dia.
Autoria própria.**



**Figura 8 – Variação da Corrente em um dia.
Autoria própria.**

Também foi necessário reduzir a base de dados de 2 anos para apenas 1 ano, pois durante os testes iniciais com a base de dados completa, foi perceptível o crescimento do tempo computacional para a execução além de que a acurácia desejada não foi alcançada, por conta de várias falhas detectadas no primeiro ano de coletas e ajustes realizados nos inversores dos painéis solares. Assim essa decisão de redução da base de dados foi tomada para que se pudesse realizar os testes em tempo computacional hábil utilizando as ferramentas propostas neste trabalho, e que os resultados fossem mais satisfatórios. É possível verificar que são observadas tendência e sazonalidade climática nas 4 estações do ano englobadas com esse novo conjunto de dados reduzido, características as quais satisfazem as necessidades da aplicação da análise de série temporal escolhida. Os parâmetros que foram levados em consideração para essa redução do *dataset* na seleção de dias característicos de cada uma das quatro estações



**Figura 9 – Variação da Potência em um dia.
Autoria própria.**

do ano, englobando as variáveis de decomposição da série como a sazonalidade e tendência, foram a incidência solar durante as diferentes épocas do ano notadas, umidade do ar que está muito relacionada a formação de nuvens, temperatura ambiente, velocidade do vento e coletas com menor número de *outliers* ou falhas.

3.2.3 Análise de série temporal

Sabe-se que é possível descrever o conjunto de dados observados através de uma série temporal, e utilizado a suavização exponencial como meio de análise para normalizar os dados, obter-se uma relação entre uma amostra e a outra, e também conseguir uma previsão estatística de um valor futuro. Assim ao utilizarmos o método da Suavização Exponencial de *Holt-Winters*, que é indicada para séries temporais com tendência e sazonalidade identificados na série em questão evidenciadas nas Figura 11 e Figura 12, obtemos uma previsão de valor futuro para a potência gerada nos painéis fotovoltaicos.

Considerando que a suavização é realizada de maneira estocástica, os erros podem acumular causando previsões errôneas, e para contornar esse possível problema utilizamos a técnica de retroalimentação, onde a partir de uma amostra prevista é agregada ao conjunto amostral da série, e primeira amostra do conjunto amostral é removida, continuando com o mesmo número de amostras, porém com valores híbridos, ou seja, valores vindos de observações e valores vindos de previsões, até que todo o conjunto amostral seja composta por valores de previsões da suavização como é possível verificar na Figura 10.




Figura 10 – Método de previsão retroalimentada.
Adaptado de Moreno, Mariani e Coelho (2021)

3.2.4 Utilizando meta-heurísticas de otimização

Com o intuito de realizar uma otimização mono-objetivo de encontrar os melhores hiperparâmetros de inicialização do ELM, como a quantidade de neurônios, função de ativação, peso de cada neurônio e número de neurônios na camada oculta com meta-heurísticas de otimização. Os algoritmos evolutivos foram utilizados com população de 50 indivíduos e 100 gerações, e como métrica de comparação para encontrar os melhores indivíduos de cada geração foi utilizado função objetivo de minimizar a taxa de erro dada pela raiz do erro quadrático médio (RMSE) dadas pelo *fit* e *predict* do conjunto amostral utilizando as soluções obtidas de cada meta-heurística.

3.2.5 Previsão com ELM

Com o conjunto de amostral de características e rótulos selecionados, tratados, categorizadas e separados entre treino 70% e teste com 30%, além dos parâmetros de inicialização do ELM definidos, foi possível realizar a previsão de variação de potência para um dia seguinte com a rede neural em questão, assim como proposto no início do trabalho.

3.2.6 Testes estatísticos

Para analisar a acurácia e assertividade do modelo proposto foram utilizadas as métricas do Erro Absoluto Médio (MAE), dado pela Equação 18 que é muito utilizado em séries temporais por conta de que são medidos apenas a distância do valor real, Raiz do Erro Quadrático Médio (RMSE) demonstrado pela Equação 19 e o Raiz do Erro Quadrático Médio Relativo (RRMSE) dado pela Equação 20, os quais respectivamente destacam a variação do erro quadrático em

sua unidade de medida e o percentual relativo do mesmo, e finalizando com a Média Percentual Absoluta do Erro (MAPE) descrita na Equação 21, que permite ter uma visão geral sobre o erro.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (18)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}. \quad (19)$$

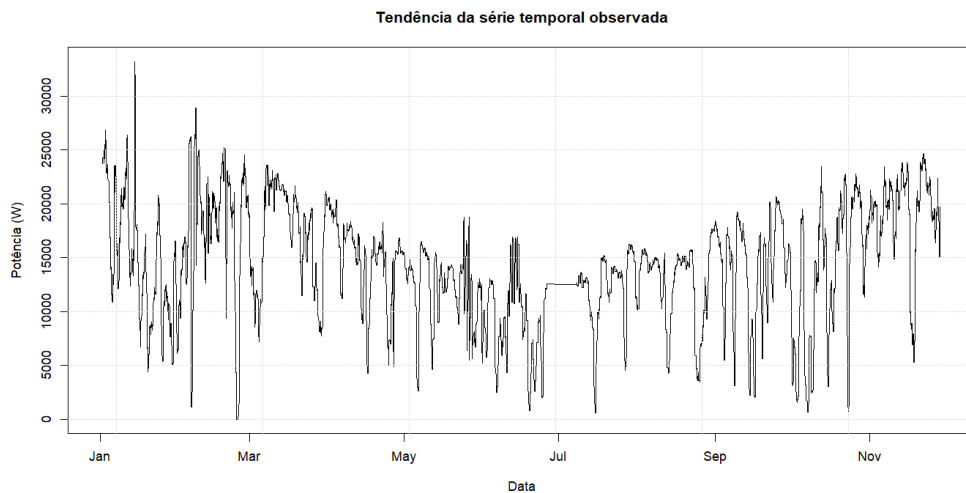
$$RRMSE = 100 \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}}{\sum_{i=1}^N y_i}. \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right|. \quad (21)$$

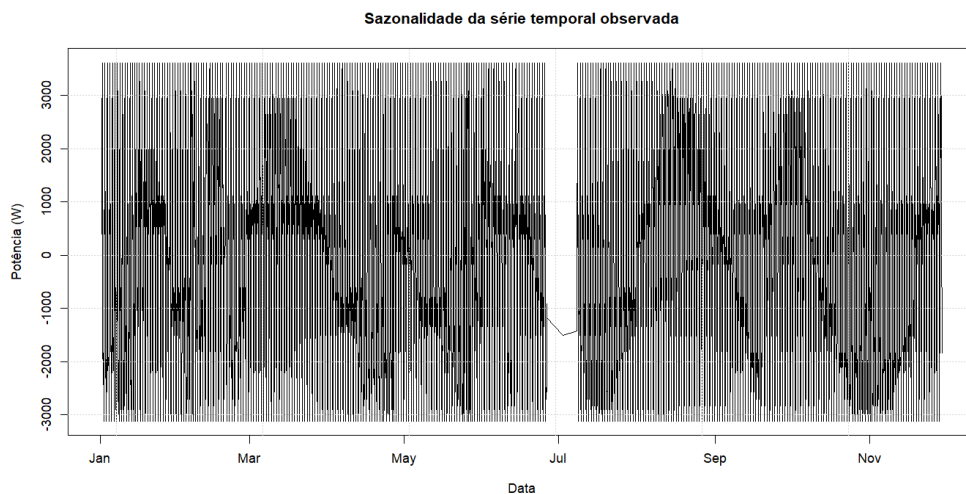
Onde y_i é o valor real e \hat{y}_i é o valor previsto, e como métrica de avaliação é utilizado o RRMSE, que segundo Moreno, Mariani e Coelho (2021), consideramos que $RRMSE < 10\%$ é Excelente, $10\% < RRMSE < 20\%$ é Bom, $20\% < RRMSE < 30\%$ é Justo e $RRMSE > 30\%$ é considerado Ruim.

4 RESULTADOS E DISCUSSÃO

Afim de utilizar o método de análise de série temporal mais adequado, é preciso verificar as características e componentes que descrevem a série observada. Ao selecionar o conjunto amostral e realizados os tratamentos iniciais nos dados, é possível extrair os componentes de Tendência como observado na Figura 11 e Sazonalidade na Figura 12, definindo assim que o método mais indicado é a Suavização Exponencial de *Holt-Winters*.



**Figura 11 – Decomposição da série temporal observada: Tendência.
Autoria própria.**



**Figura 12 – Decomposição da série temporal observada: Sazonalidade.
Autoria própria.**

Com a série decomposta podemos realizar a previsão com o método estatístico do *SEHW* e comparar com os métodos de inteligência artificial do ELM híbridos de parâmetros selecionados a partir das meta-heurísticas propostas nestes trabalho, além verificar a acurácia

que cada modelo alcançou Figura 13 e também na Tabela 3. Iniciando pela primeira estação do ano, o Verão, nos dias característicos selecionados de 07 a 08 de Fevereiro de 2021.

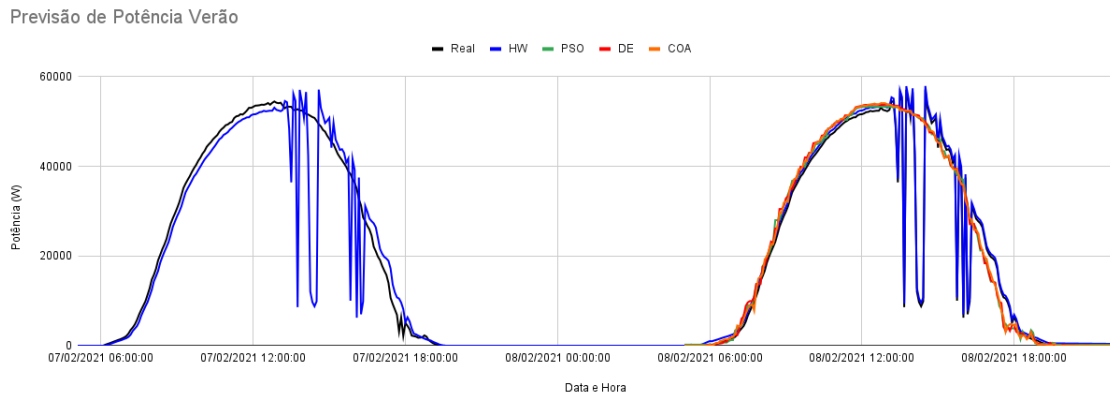


Figura 13 – Previsão de Potência Verão.

Autoria própria.

Tabela 2 – Melhores parâmetros encontrados por modelo no Verão

Meta-heurística	Qtd. de neurônios	beta	w_i	b_i
COA	35	10	0.32	5
PSO	33	3	0.14	10.61
DE	49	10	0.18	12.32

Fonte: Autoria própria.

Tendo em vista que os Trabalhos Correlatos na abordados na Seção 2.5 alcançaram uma acurácia de 90% a 97% e alcançaram seus respectivos objetivos e foram destacados pelos métodos utilizados, nesta primeira tabela de resultados é possível notar que a acurácia alcançada é realmente próxima do esperado. E também definido pelas métricas de testes estatísticos da Subseção 3.2.6, quando o valor de $RRMSE > 10\%$ é considerada Excelente, $10\% < RRMSE < 20\%$ é considerada Boa, $20\% < RRMSE < 30\%$ é considerada Justa e $RRMSE > 30\%$ é considerado uma acurácia Ruim.

Tabela 3 – Resultado da acurácia por modelo no Verão

Modelo	MAE	RMSE	MAPE	RRMSE	Acurácia	Acurácia perc.
HW	782,65	7671,46	55,24%	16,90%	Boa	83,14%
COA-ELM	44,59	524,89	11,45%	1,16%	Excelente	98,84%
PSO-ELM	64,78	687,18	22,75%	1,51%	Excelente	98,53%
DE-ELM	27,99	621,44	33,74%	1,37%	Excelente	98,65%

Fonte: Autoria própria.

Continuando com a estação seguinte ao passar do ano, têm-se o Outono, com dias característicos de uma redução gradativa de temperaturas antecipando o Inverno e com maior incidência de ventos e diminuição de umidade do ar. Onde foram selecionados os dias de 27 e

28 de Abril de 2021 demonstrados no Gráfico 14, também pode-se verificar a acurácia de cada modelo nesta estação através da Tabela 5.




Figura 14 – Previsão de Potência Outono.
Autoria própria.

Tabela 4 – Melhores parâmetros encontrados por modelo no Outono

Meta-heurística	Qtd. de neurônios	beta	w_i	b_i
COA	22	6	0.06	35.12
PSO	14	4	0.31	10.11
DE	22	10	0.46	11.34

Fonte: Autoria própria.

Tabela 5 – Resultado da acurácia por modelo no Outono

Modelo	MAE	RMSE	MAPE	RRMSE	Acurácia	Acurácia perc.
HW	283,40	672,97	6,06%	2,34%	Excelente	97,66%
COA-ELM	12,00	386,88	8,78%	1,35%	Excelente	98,58%
PSO-ELM	43,69	417,02	9,54%	1,45%	Excelente	98,54%
DE-ELM	87,94	590,54	5,95%	2,06%	Excelente	97,95%

Fonte: Autoria própria.

Representando a estação com as menores temperaturas do ano e dias mais curtos, justificando assim a diminuição de potência convertida nos painéis solares, o Inverno. Com os dias selecionados de 24 a 25 de Julho de 2021, é possível analisar e comparar a acurácia das previsões realizadas com a Figura 15 e Tabela 7.




Figura 15 – Previsão de Potência Inverno.
Autoria própria.

Tabela 6 – Melhores parâmetros encontrados por modelo no Inverno

Meta-heurística	Qtd. de neurônios	beta	w_i	b_i
COA	9	9	0.33	1.27
PSO	37	6	0.14	7.42
DE	6	10	0.32	6.53

Fonte: Autoria própria.

Tabela 7 – Resultado da acurácia por modelo no Inverno

Modelo	MAE	RMSE	MAPE	RRMSE	Acurácia	Acurácia perc.
HW	417,40	900,59	6,26%	3,80%	Excelente	96,22%
COA-ELM	24,20	438,89	11,13%	1,85%	Excelente	98,11%
PSO-ELM	0,15	222,64	6,46%	0,94%	Excelente	99,44%
DE-ELM	46,67	901,45	30,29%	3,81%	Excelente	96,26%

Fonte: Autoria própria.

E finalmente com a última estação do ano, a Primavera, temos dias característicos com aumento da umidade do ar por conta das chuvas, temperaturas se elevando para um clima mais agradável e dias mais longos, se preparando para o início do verão. Onde dentre os dias observados, os que demonstraram essas particularidades foram 08 e 09 de Dezembro de 2021, respectivamente, na Figura 16 e Tabela 9.




Figura 16 – Previsão de Potência Primavera.
Autoria própria.

Tabela 8 – Melhores parâmetros encontrados por modelo no Primavera

Meta-heurística	Qtd. de neurônios	beta	w_i	b_i
COA	46	10	0.70	3.78
PSO	21	10	0.28	10.21
DE	46	10	0.29	11.91

Fonte: Autoria própria.

Tabela 9 – Resultado da acurácia por modelo no Primavera

Modelo	MAE	RMSE	MAPE	RRMSE	Acurácia	Acurácia perc.
HW	228,14	3516,00	18,55%	7,82%	Excelente	92,10%
COA-ELM	99,36	1155,75	19,17%	2,57%	Excelente	97,45%
PSO-ELM	37,79	837,03	9,19%	1,86%	Excelente	98,13%
DE-ELM	51,54	910,84	10,20%	2,03%	Excelente	97,94%

Fonte: Autoria própria.

5 CONCLUSÃO

Tendo em vista as necessidades energéticas da humanidade e olhando para o crescimento do desenvolvimento das energias renováveis, painéis solares para a geração de energia elétrica são uma solução relativamente boa e sustentável. E a aplicação de métodos computacionais afim de melhorar a logística e administração de energia gerada em nesses painéis, é de grande ajuda, possibilitando a previsão da potência que será gerada através de características correlacionadas observadas nos inversores elétricos, como Tensão, Corrente e Temperatura de cada amostra coletada. Os conceitos de mineração de dados, como pré-processamento, limpeza e remoção de anomalias, auxiliaram e otimizaram o processo da análise de série temporal, a qual tem o papel de suavizar a curva encontrada a partir do conjunto amostral observado, e assim realizar uma estimativa de maneira estatística baseados em componentes e características extraídas da mesma. Ainda é possível refinar estas previsões obtidas utilizando redes neurais de camada única com meta-heurísticas de otimização, para encontrar os hiperparâmetros de inicialização do modelo inteligente do ELM escolhido, resultando em uma melhora considerável para estas previsões no sentido de precisão e acurácia. Considerando os resultados obtidos com a aplicação do modelo descrito no texto, é denotado pelo percentual de erro encontrado com o RRMSE e MAPE, no qual o algoritmo do PSO encontrou os melhores parâmetros de 37 para a quantidade de neurônios, 7 para a função objetivo de inicialização e distribuição de pesos para os neurônios, 0.14 para o peso de cada neurônio na camada oculta e 7 para o número de neurônios na camada oculta. Alcançando assim a acurácia média de 98.56% para as previsões durante as estações do ano. A justificativa desta meta-heurística alcançar o melhor parâmetro dentre os demais, é dado pelo fato que segundo Kennedy e Eberhart (1995b), a otimização de funções não lineares que o PSO pode realizar com a aplicação de treinamento e classificação em *dataset* é tão eficiente quanto ao método do *Backpropagation* em redes neurais.

Desta maneira pode-se concluir que o trabalho atingiu seus objetivos, utilizando dados selecionados de painéis solares, descrevê-los com séries temporais e realizando uma previsão com o modelo de análise de suavização exponencial de *Holt-Winters*, refiná-la através do modelo inteligente proposto do ELM juntamente com meta-heurísticas de otimização, qual o PSO se sobressaiu diante das outras propostas para o comparativo de melhor seleção de hiperparâmetros e alcançando a acurácia esperada, bem próxima da que a literatura encontra ao utilizar um conjunto de métodos semelhantes.

Para que em trabalhos futuros se possa realizar a previsão de mais dias futuros, seria necessário iniciar uma análise dos fatores climáticos e meteorológicos da região para que os erros não aumentassem de forma crescente, pois com um dia característico é possível ter uma ideia ou estimativa de como serão os próximos dias dentro de cada estação, que tende a se repetir durante o ano. Mas fatores como a variação climática de um ano para o outro deve ser levada em consideração, pois conforme o tempo passa, a previsão do tempo se torna mais complexa, considerando os danos causados ao meio ambiente durante a existência da evolução

industrial e tecnológica humana na Terra. Desta maneira o escopo da pesquisa seria muito mais complexo e com ênfase na melhoria da acurácia com o método inteligente encontrado dentre os propostos neste trabalho.

REFERÊNCIAS

- BROCKWELL, P. J.; DAVIS, R. A. **Introduction to Time Series and Forecasting - 3ed.** Springer International Publisher Switzerland, 2016. ISBN 9783319298528. Disponível em: https://www.google.com.br/books/edition/Introduction_to_Time_Series_and_Forecast/EGkljwEACAAJ?hl=pt-BR.
- CARSTENS, D. D. dos S.; CUNHA, S. K. da. Challenges and opportunities for the growth of solar photovoltaic energy in brazil. **Energy Policy**, v. 125, p. 396–404, 2019. ISSN 0301-4215. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0301421518307183>.
- CHARU, C. A. **Data Mining: The textbook.** Springer International Publisher Switzerland, 2015. ISBN 9783319141411. Disponível em: https://books.google.com.br/books?id=cfNICAAAQBAJ&printsec=copyright&redir_esc=y#v=onepage&q&f=false.
- GLOVER, F.; KOCHENBERHER, G. **Handbook of meta-heuristics.** [S.l.: s.n.], 2003.
- HOSSAIN, M. *et al.* Application of extreme learning machine for short term output power forecasting of three grid-connected pv systems. **Journal of Cleaner Production**, v. 167, p. 395–405, 2017. ISSN 0959-6526. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652617317973>.
- HOU, M. *et al.* Global solar radiation prediction using hybrid online sequential extreme learning machine model. **Energies**, v. 11, n. 12, 2018. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/11/12/3415>.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 70, n. 1, p. 489–501, 2006. ISSN 0925-2312. Neural Networks. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0925231206000385>.
- JANNUZZI, G. de M.; de Melo, C. A. Grid-connected photovoltaic in brazil: Policies and potential impacts for 2030. **Energy for Sustainable Development**, v. 17, n. 1, p. 40–46, 2013. ISSN 0973-0826. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0973082612000798>.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. *In: Proceedings of ICNN'95 - International Conference on Neural Networks.* [S.l.: s.n.], 1995. v. 4, p. 1942–1948 vol.4.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. *In: Proceedings of ICNN'95 - International Conference on Neural Networks.* [S.l.: s.n.], 1995. v. 4, p. 1942–1948 vol.4.
- LIU, Z.-F. *et al.* Prediction short-term photovoltaic power using improved chicken swarm optimizer - extreme learning machine model. **Journal of Cleaner Production**, v. 248, p. 119272, 2020. ISSN 0959-6526. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652619341423>.
- MORENO, S. R.; MARIANI, V. C.; COELHO, L. dos S. Hybrid multi-stage decomposition with parametric model applied to wind speed forecasting in brazilian northeast. **Renewable Energy**, v. 164, p. 1508–1526, 2021. ISSN 0960-1481. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0960148120316980>.
- MORETTIN PEDRO A., C. M. C. T. **Análise de séries temporais - 2ed.** [S.l.]: Edgard Blucher Editora, 2006. ISBN 9788521213512.

PANI, A. K.; NAYAK, N. Forecasting solar irradiance with weather classification and chaotic gravitational search algorithm based wavelet kernel extreme learning machine. **RENEWABLE ENERGY RESEARCH**, v. 9, p. 10, 2019. ISSN 1309-0127. Disponível em: <https://www.ijrer-net.ijrer.org/index.php/ijrer/article/view/10028>.

PIEREZAN, J.; COELHO, L. D. S. Coyote optimization algorithm: A new metaheuristic for global optimization problems. *In: 2018 IEEE Congress on Evolutionary Computation (CEC)*. [S.l.: s.n.], 2018. p. 1–8.

SHAMSHIRBAND, S. *et al.* A comparative evaluation for identifying the suitability of extreme learning machine to predict horizontal global solar radiation. **Renewable and Sustainable Energy Reviews**, v. 52, p. 1031–1042, 2015. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032115008205>.

STORN, R.; PRICE, K. Differential evolution – a simple and efficient heuristic for global optimization over continuous spaces. **Journal of Global Optimization**, v. 11, n. 4, p. 341–359, dez. 1997.

STORN, R.; PRICE, K. Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces. **Journal of Global Optimization**, v. 11, p. 341–359, 01 1997.

WANG, J. *et al.* A review on extreme learning machine. **Multimedia Tools and Applications**, 2021. ISSN 1573-7721. Disponível em: <https://link.springer.com/article/10.1007/s11042-021-11007-7#citeas>.

ZHOU, Y. *et al.* Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine. **Energy**, v. 204, p. 117894, 2020. ISSN 0360-5442. Disponível em: <https://www.sciencedirect.com/science/article/pii/S036054422031001X>.