

Predição Solar e Eólica Utilizando Redes com Neurônios de Histerese L^2P para Aplicações em *Smart Grids*

Daniel F. de Jesus* Richelly D. F. Pontes**
 Moisés A. P. Borges*** Felipe S. O. Costa****
 Omar A. C. vilcanqui† Luiz A. L. de Almeida‡

* Pós Graduação em Engenharia da Informação, Universidade Federal do ABC, Santo André, SP, (e-mail: daniel.jesus@ufabc.edu.br)

** Pós Graduação em Engenharia Elétrica, Universidade Federal do ABC, Santo André, SP, (e-mail: richelly.dayenne@ufabc.edu.br)

*** Pós Graduação em Engenharia Elétrica, Universidade Federal do ABC, Santo André, SP, (e-mail: moises.borges@ufabc.edu.br)

**** Pós Graduação em Engenharia da Informação, Universidade Federal do ABC, Santo André, SP, (e-mail: oiwa.costa@ufabc.edu.br)

† Centro de Ciências Exatas e Tecnológicas, Universidade Federal do Acre, Rio Branco, AC, (e-mail: omarchu@ufac.br)

‡ Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas, Universidade Federal do ABC, Santo André, SP, (e-mail: luiz.almeida@ufabc.edu.br)

Abstract: This paper focuses on the study of the strategic prediction of renewable sources of intermittent energy, using bio-inspired computational models, developed in Python, with the aim of providing mechanisms that help in the monitoring and control of smart grids. To perform the learning of the neural network, we used the Backpropagation and Feedforward algorithms. This neural network makes use of hysteresis neurons through the L^2P model that, therefore, iterates the data to reproduce the prediction curves. To evaluate the model, real data obtained from the National Institute of Meteorology (INMET) was used. Results are presented through the application of the L^2P model as a neural network and compared to existing structures in neural networks such as the ARIMA method, showing the good performance of the L^2P neural network.

Resumo: Este artigo concentra-se no estudo da predição estratégica de fontes renováveis de energia intermitente, utilizando modelos computacionais baseados em redes neurais artificiais (RNAs), desenvolvidos em linguagem *Python*, com o intuito de fornecer mecanismos que auxiliem no monitoramento e controle das redes elétricas inteligentes. Para a realização do aprendizado da rede neural, utilizou-se os algoritmos *Backpropagation* e *Feedforward*. A rede neural em questão, faz o uso de neurônios de histerese por meio do modelo L^2P (*Limity Loop Proximity*) que, portanto, realiza a iteração dos dados para reproduzir as curvas de previsão de radiação solar e velocidade do vento. Para avaliar o modelo, empregou-se dados reais obtidos no Instituto Nacional de Meteorologia (INMET). Resultados são apresentados por meio da aplicação do modelo L^2P como rede neural e comparado a estruturas já existentes em redes neurais como o método ARIMA, evidenciando o bom desempenho da rede L^2P .

Keywords: Neural networks; Energy prediction; Smart grids; Renewable energy.

Palavras-chave: Redes neurais; Histerese; Predição; Redes inteligentes; Energias renováveis.

1. INTRODUÇÃO

O constante crescimento e desenvolvimento populacional acarreta no aumento do consumo e na complexidade da matriz energética, que precisa diversificar seus sistemas de distribuição de energia elétrica, para atender demandas de consumidores com cargas variantes - indústrias, mercados *spots*, residências, entre outros (Valdés Cambero et al., 2019). Portanto, existe a preocupação com a economia dos recursos naturais, pois o uso exacerbado de tais recursos

gera escassez e poluição. Devido a necessidade de atender ao aumento da demanda por energia elétrica, de maneira confiável, faz-se necessária uma busca por tecnologias renováveis.

Na busca por melhorias das condições operativas do sistema elétrico, desenvolve-se a rede inteligente (*Smart Grid*). Essas redes elétricas baseiam-se em uma acentuada utilização de tecnologia de automação, computação e comunicação para realizar monitoramento e o controle

de forma eficaz (Hilal et al., 2018). A importância da utilização de mecanismos computacionais para o controle e gestão é significativa, pois promove o desenvolvimento e aplicação do conceito de *Smart Grids*, sendo também necessária para melhorar o atual cenário energético.

A previsão de recursos para a utilização em geração de energia é importante para a viabilidade de colheita (*harvesting*) de energia (Wang et al., 2019). Uma rede neural artificial (RNA) é um modelo bioinspirado capaz de identificar padrões e validar por meio de uma base de dados se os mesmos são significativos Gebben et al. (2015). Assim, a criação de RNAs que possibilite na previsão de geração de energia por meio de fontes renováveis é interessante para um correto manejo da demanda de energia.

De acordo com experiências realizadas na neurobiologia, evidenciou-se que existe resposta não linear histerética em sistemas de neurônio natural (Kashef et al., 2018). Desta forma, a histerese tem um efeito considerável no armazenamento, memória e retenção de estado (de Araujo et al., 2019).

O intuito é criar e aperfeiçoar as características de uma RNA fazendo uso do fenômeno de histerese. Nesse sentido a combinação com a histerese é realizada para obtenção em diversas vertentes do processamento de informações para realização da previsão (Seo et al., 2018).

Em concordância com Di Piazza et al. (2014), a previsão satisfatória das condições climáticas, melhora efetivamente a eficiência global e o funcionamento das centrais elétricas renováveis conectadas à rede. Para alcançar uma sondagem ótima dos recursos disponíveis, a análise da potencialidade das energias renováveis é imprescindível. Isto é favorável no âmbito de *Smart Grids*, pois é possível alcançar a gestão ótima de energia por meio de um conjunto de dados e a previsão de dados futuros. Todavia, a previsão é fundamentada em amostragem de dados de longo prazo, e nesse conjunto, existe a possibilidade de serem corrompidos, devido a erros ocorridos em algum intervalo, ausência de dados, flutuações e um componente de caos na formação da série.

O estudo de obtenção de dados de previsão de energias renováveis é descrito por diversos autores como Lukhyswara et al. (2019) e Makhoulfi et al. (2018), que descrevem técnicas de previsão baseadas em séries temporais para previsão Solar e eólica. A diferença desta abordagem em relação as anteriores está na inclusão do neurônio baseado no modelo de histerese como é abordado em de Araujo et al. (2019). , com a diferença que nesta abordagem é utilizado todo o modelo L^2P descrito por Almeida et al. (2004).

A contribuição deste trabalho é a construção de um método de previsão de energia eólica e solar utilizando modelos computacionais formulados por RNA, fundamentado na curva de histerese de uma série não linear baseada no modelo L^2P (*Limiting Loop Proximity*), implementados no *software Python*, a fim de contribuir com os sistemas de monitoramento, e o controle das redes inteligentes.

A abordagem para realização da previsão utiliza os algoritmos de aprendizagem da rede neural *Backpropagation*, o

qual realiza treinamento em camadas e é fundamentado no aprendizado supervisionado por correção e erro de previsões baseadas em dados meteorológicos fornecidos, e *Feedforward*, com descida de gradiente, que considera o mínimo de uma função de perda (*loss function*).

Para prever os recursos pretendidos, velocidade do vento e radiação solar, o modelo apresentado opera com variáveis de entrada, relacionando as condições meteorológicas em faixas de tempo, hora, dia, mês e ano, ou seja, utiliza-se os dados reais para fazer o treinamento da rede neural e, com isso, ocorrer a previsão dos recursos futuros. Os dados reais adquiridos do Instituto Nacional de Meteorologia (INMET) foram obtidos de 2014 até 2018 e são utilizados para realizar a experimentação para curto, médio e longo prazo. Tais dados abrangem as condições meteorológicas aferidas por estações na cidade de Bauru no interior do Estado de São Paulo.

2. MODELO DE HISTERESE L^2P

Modelos de histerese são avaliadores completos de projeções de perdas ou de fluxo de corrente induzida em campos magnéticos (Borges et al., 2019). As vantagens da histerese é destacada em modelos como o de Almeida et al. (2004) que atribuem parâmetros básicos para a geração de curvas de histerese. Uma ilustração da forma de magnetização é abordada na Figura 1, apresentando parâmetros desejados pelo modelo, a medida que se desenvolve a curva de histerese.

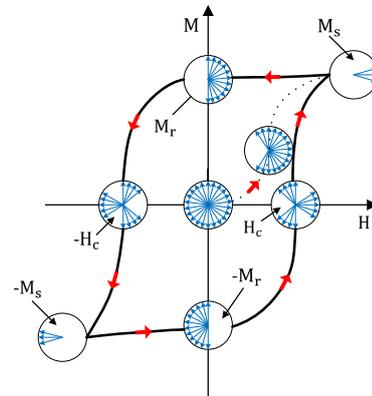


Figura 1. Representação de modelo de histerese com base em parâmetros importantes.

A geração da curva no modelo de Almeida et al. (2004) é representada, basicamente pelos parâmetros observados na Figura 1, em que M é magnetização; M_r representa magnetização remanescente ou remanência; M_s indica magnetização de saturação; H é o campo elétrico e H_c apresenta os valores de campo coercitivo, ou coercividade.

A análise matemática é estabelecida por uma função principal a partir de considerações apresentadas na equação (1). Em que, δ é uma constante arbitrária, com a característica de determinar a aderência dos laços menores em relação ao laço principal, a partir de pontos x , para gerar a dinâmica de acordo com as condições que serão apresentadas em $P(x)$.

$$P(x) = \begin{cases} 1 - \sin(\delta x), & \text{se } \delta x < \frac{\pi}{2} \\ 0, & \text{se } \delta x > \frac{\pi}{2} \end{cases} \quad (1)$$

Considerando que a histerese independe da taxa de variação temporal do sinal de excitação, propõem-se que sua taxa de variação seja insignificante ao ponto de ser desprezada, de maneira que o laço principal seja considerado invariante, qualquer que seja o campo aplicado.

Tendo em vista a Figura 1, por meio de configurações geométricas, obtém-se a estrutura do modelo proposto por Almeida et al. (2004). O que resulta na equação (2), onde a $M(H)$ representa a magnetização, H_p o ponto proximal, H_c o campo coercitivo e h_0 a relação de dependência do material:

$$M(H) = \frac{2M_s}{\pi} \arctan\left(\frac{H_p + H - \delta H_c}{h_0}\right) \quad (2)$$

$$H_{pr} = h_0 \tan\left(\frac{\pi M_r}{2M_s}\right) + \delta H_c - H_r \quad (3)$$

Uma equação em função H_{pr} facilita a representação do modelo, devido ser a representação do campo de proximidade no ponto de reversão, que é a distância entre o ponto do laço principal e o ponto de reversão. O laço principal tem o mesmo valor de magnetização M do ponto final de reversão e, pertence a curva em que δ tem seu valor representado na equação (3) em função de H_{pr} .

A expressão matemática vista em (3) e otimizada como equação principal por meio de (2), devido a correspondência $H_p = P(x) * H_{pr}$. Desta forma, pode ser modelado materiais ferrites. Para a apresentação de outros materiais devem ser realizadas adequações para a obtenção da curva de histerese ou treinamentos, com o uso de computação, baseadas em rotinas de adequação. A histerese possui a capacidade de preservar as propriedades obtidas por um estímulo. Ela está presente na natureza, biologia, física, entre outras. Seu modelo pode ser usado para filtrar sinais de forma que a saída reaja de maneira retardada ao histórico deste sinal.

3. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são mecanismos computacionais, que exibem um modelo matemático baseado na estrutura neural de corpos inteligentes e são capazes de obter conhecimento por meio de treinamentos. É composta por diversas unidades de processamento, as quais, comumente, são interligadas por canais de comunicação, que estão associados a determinados pesos (Fan et al., 2019). Ao receber os sinais apresentados na entrada, o neurônio faz com que cada sinal seja multiplicado por uma variável, ou peso, que irá apontar a sua influência na saída da unidade, em seguida, faz-se um somatório ponderado dos sinais, que geram um grau de atividade, e por fim, se este grau de atividade ultrapassar uma certa fronteira (*threshold*), o neurônio gera um dado retorno de saída.

A Figura 2 representa o modelo de neurônio utilizado para a realização do estudo deste artigo. O neurônio artificial

pode ser comparado ao neurônio biológico nas seguintes características:

- Cada conexão de entrada é interligada (dendritos) a função objetivo, Σ é o núcleo de processamento, a função de ativação é o mapeamento de histerese (nódulo de ranvier e a bainha de mielina) e por fim, a saída é gerada (terminais do axônio).

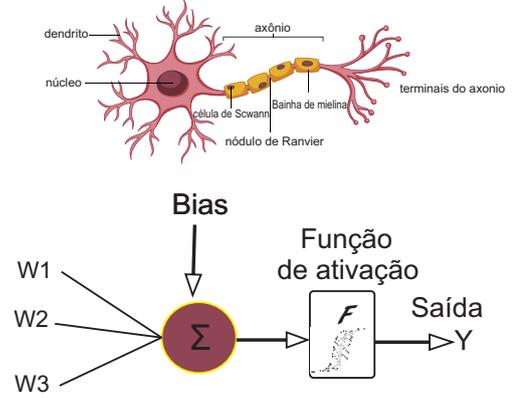


Figura 2. Estrutura do Neurônio Artificial

- A informação é o impulso nervoso. As entradas são as conexões sinápticas (conexão do axônio com o dendrito de outros neurônios), seu nível de eficácia (plasticidade sináptica), influencia diretamente o aprendizado dos neurônios na rede. Os erros na aprendizagem são tratados pelo ajuste sináptico entre cada neurônio que compõe a informação apresentada. O viés (ou vies) é utilizado externamente para aumentar ou diminuir a entrada efetiva na função de ativação. Cada peso dentro do neurônio pode estar positivo (excitado), ou negativo (inibido).

O neurônio possui dois estados distintos: um estado de ativação, na qual combina todos os sinais obtidos pelos neurônios, somando-os ao viés, e um estado onde a função de ativação calcula a saída convertida pelo nível de atividade de cada frequência, baseado na função utilizada (são exemplos: sigmoide, RELU, Tangente hiperbólica, e o mapeamento de histerese). A função de ativação (também conhecida como função de transferência), é a responsável pela amplitude do sinal, pois trabalha como um neurotransmissor, excitando ou inibindo o potencial de ação de um neurônio. Os modelos de redes neurais dispõem de algum princípio de treinamento, no qual os pesos de suas conexões são estabelecidos de acordo com os padrões apresentados, ou seja, eles aprendem por meio de exemplos. Particularmente, as redes neurais são estruturadas em camadas (entrada, intermediárias e saída), onde as unidades podem estar interconectadas, observadas na Figura 3, que é a arquitetura neural com 4 camadas ocultas, um exemplo de parâmetros utilizados para avaliação do modelo proposto no trabalho.

Cada entrada corresponde a um valor na série temporal. O treinamento recebe as entradas e um vetor de aprendizado é gerado. Na predição, a rede recebe os últimos valores com janela temporal (curto, médio e longo prazo) para prever um horizonte a frente, baseando-se apenas na amostra dos dias anteriores (por exemplo, treino de 3 dias, ou uma semana).

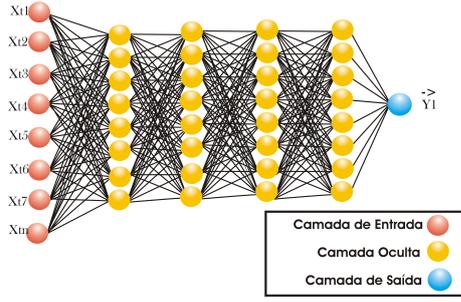


Figura 3. Rede neural artificial de 4 camadas ocultas

Os tipos de aprendizados são determinados de acordo com o relacionamento da rede neural com o ambiente, podendo ser aprendizado supervisionado, não supervisionado e por reforço.

4. MODELO E AVALIAÇÃO EXPERIMENTAL

Séries temporais possuem como característica o sequenciamento de valores dependentes no tempo. Ao contrário de alguns modelos de regressão, onde a ordem temporal não afeta o resultado esperado, em séries temporais de ventos e radiação solar tem dependência direta com o tempo (Lukhyswara et al., 2019). O trabalho feito por Mitkov et al. (2019) utiliza o modelo ARIMA para realizar previsão da demanda de energia. o Modelo L^2P comparado com o ARIMA é a base para observação do tratamento de dados realizados nas próximas seções deste trabalho

4.1 Formulação aplicada para o neurônio de histerese

O primeiro passo a ser desenvolvido no neurônio é em relação aos valores de entrada, que são transformados em uma histerese. Os parâmetros que foram utilizados no desenvolvimento da histerese são: $M_s=0.2$, $h_0=90$ e $H_c=280$ conforme a equação (2). Estes valores representam uma histerese específica baseada na forma dos dados L^2P , sua amplitude torna acomodativo para os casos eólicos, e para dados solares. Nesses parâmetros foi observado que o modelo L^2P que é não linear desenvolve curvas adaptativas e o ponto aplicado correspondente a x da equação (1) muda de forma mais suave na aplicação de intervalos de tempo, aplicando a equação (2) resulta na obtenção das curvas de previsão ao longo do tempo com melhores indicadores para previsão.

Após gerar a histerese, os valores foram classificados e retro-propagados conforme as equações (4) e (5) em Bielecki (2019), onde valores acima do limite superior receberam o valor 1, e valores que estão entre os limiares superior e inferior, receberam o valor anterior. Se o valor a ser calculado for menor que o limite inferior, o valor a ser recebido é o valor zero. Após este passo, os valores podem ser ativados ou não, dependendo do seu valor e transformados em uma derivada binária, gerando assim o valor final.

$$\begin{aligned} y(0) &= y(s(0)) \\ y(k+1) &= f(s(k+1), s(k), y(k)) \end{aligned} \quad (4)$$

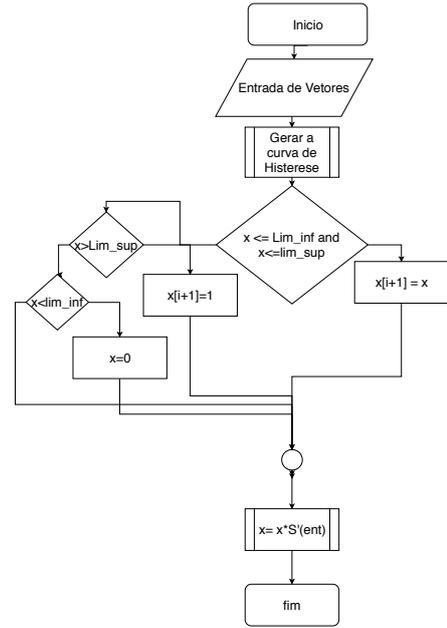


Figura 4. Fluxograma da função de ativação do modelo de neurônio L^2P

$$P_x = \begin{cases} 1, & \text{se } dla \ s(K+1) > p_g \\ y(k), & \text{se } p_d \leq s(K+1) \leq p_g \\ 0 & \text{dla } s(K+1) < p_d \end{cases} \quad (5)$$

Para o desenvolvimento do algoritmo de função de ativação por histerese, conforme apresentado na Figura 4, foram utilizados os seguintes procedimentos: a resposta final é dada pela multiplicação da aritmética do fluxograma pela derivada S' do sinal de entrada, dadas as condições apresentadas na equação (5) (Bielecki, 2019).

4.2 Métodos de aprendizagem

O aprendizado da rede neural utilizado é supervisionado, através da verificação da saída obtida com a saída esperada, pelo erro quadrático, utilizando *backpropagation* e a regra delta com descida de gradiente. O número de elementos anteriores ao horizonte de previsão, recebe o nome de janela, a qual é utilizada para realizar o treinamento e teste, para a obtenção de valores futuros. O horizonte de previsão corresponde aos elementos previstos a partir da rede já treinada. A execução dos estudos experimentais, ocorreu, primeiramente, com o treinamento dos dados, por meio dos valores de velocidade de vento e radiação solar, em 72 horas sequenciais, conforme mostra a Figura 5. O período de amostragem foi de 1 mês para o treinamento, com uma janela de 6 dias a frente, e com um total de 10 janelas para o treinamento.

A média de erros (MSE- *Mean Square Error*) realizada por meio de cálculos da saída da rede neural para o modelo L^2P é apresentada como modelo L^2P e ARIMA, conforme mostra a Figura 6.

O modelo L^2P com 8 camadas ocultas de neurônios e 20 épocas, obteve uma quantidade de erro médio quadrático, entre o previsto e o esperado abaixo de 0.1, enquanto que o resultado do ARIMA [3,1,1] (obtido pela estimação de parâmetros do modelo), foi acima de 0.5, conforme mostra a Figura 6.

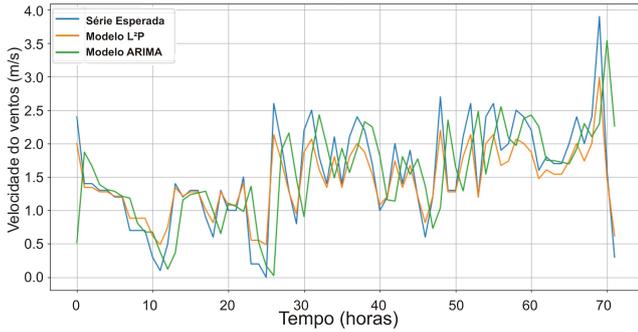


Figura 5. Comparativo de predição no treinamento L^2P e ARIMA

A divergência observada na Figura 6 ocorre nas diferenças de características do modelo L^2P quando comparado com o modelo ARIMA.

O modelo L^2P faz uso do método de histerese, considerando a não linearidade do modelo e também da função objetivo, mesmo que aproximada, as condições meteorológicas sofrem mudanças, e busca-se encontrar a melhor solução para não ficar nos mínimos locais. Uma abordagem já realizada envolvendo modelos de histerese é a de Shukla and Sinha (1994) que cria uma RNA baseada no modelo de Preisach (1935) para aproximação do comportamento de um material. O modelo ARIMA utiliza uma filtragem linear para detectar influências ocorridas na previsão (Mikhailov et al., 2019).

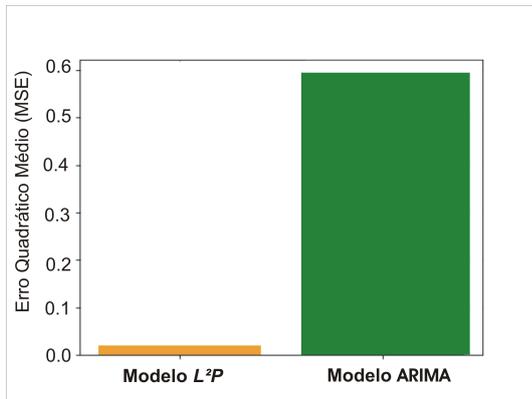


Figura 6. Média de erros

O modelo para a ativação do neurônio sigmoide em comparação ao modelo de histerese foi escolhido por apresentar não linearidade e por constar entre os mais utilizados pela literatura em redes neurais.

A quantidade de épocas e quantidade de neurônios foram variados no período de treinamento da rede neural. A importância da variação destes dados está relacionada ao tamanho da janela, pois está influência na oscilação e na suavização da curva de previsão.

A Figura 7, apresenta o treinamento obtido por cada modelo estudado em dados de radiação solar, representando os modelos sigmoide, ARIMA e L^2P . A série esperada e o L^2P estão sobrepostos. A Figura 8 representa o treinamento para predição eólica. A cidade avaliada é Bauru SP em 2017, no mês de janeiro. Valores acima da curva foram obtidos pelo modelo sigmoide. A sazonalidade em

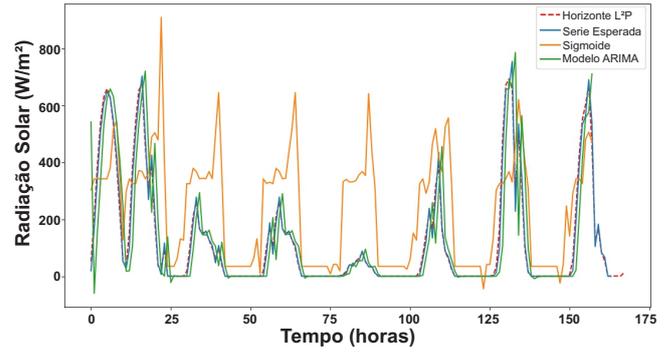


Figura 7. Resultados do treino da rede em radiação solar

relação a noite e o padrão dia foi mantida por cada modelo, porém uma amplitude maior no caso do modelo sigmoide evidencia que os parâmetros de taxa de aprendizagem de 0.4, 60 épocas e 28 camadas ocultas de neurônios não foram o suficiente para acompanhar o acerto feito pelo modelo L^2P . O aumento de épocas e camadas ocultas de neurônios representou em menor precisão ao método de sigmoide em comparação ao modelo proposto, sendo o melhor ajuste com a redução da taxa de aprendizado (mesmo assim ficando com uma taxa de erro maior que o modelo L^2P). Como o resultado do teste é a comparação entre o L^2P e a sigmoide partindo dos mesmos parâmetros de épocas, taxa de aprendizagem, e camadas de neurônios ocultos, manteve-se os resultados.

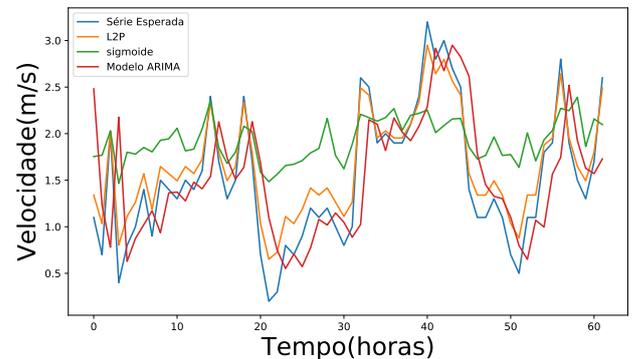


Figura 8. Resultados da rede com o uso do modelo L^2P

4.3 Especificação da base de dados

A base de dados obtida foi particionada com 60 % das amostras para o treinamento, e 40 % para validação e teste. Os dados são os mesmos para todos os modelos. Para a determinação do número de neurônios na camada oculta e o número de épocas, foram feitos testes até a minimização do erro médio, buscando assim uma rede mínima, ao mesmo tempo evitando o ajuste a apenas aos dados de treinamento. Na tabela 1 é apresentado o número de épocas e de camadas ocultas em cada modelo.

A metodologia utilizada foi simular todas as RNAs apresentadas e comparar com a série esperada. Desta forma, seguindo os critérios de cada função de ativação que são respectivamente a sigmoide e L^2P pelo fluxo de entrada na RNA é encontrado o número de neurônios.

Tabela 1. Parâmetros utilizados nas RNAs.

Modelos	Janela de uma semana frente	Janela de um dia frente
Modelo L2P Solar	40 Épocas	50 Épocas
	25 Camadas	18 Camadas
Sigmoide Solar	50 Épocas	60 Épocas
	16 Camadas	14 Camadas
Modelo L2P Eólica	60 Épocas	60 Épocas
	15 Camadas	15 Camadas
Sigmoide Eólica	60 Épocas	60 Épocas
	28 Camadas	40 Camadas

4.4 Resultados baseados em janelas de previsão

De acordo com Soman et al. (2010), a classificação da escala temporal para técnicas de previsão foi separada em previsão de curto prazo (6 horas de antecedência), previsão de médio prazo (1 dia de antecedência) e previsão a longo prazo (1 semana à frente).

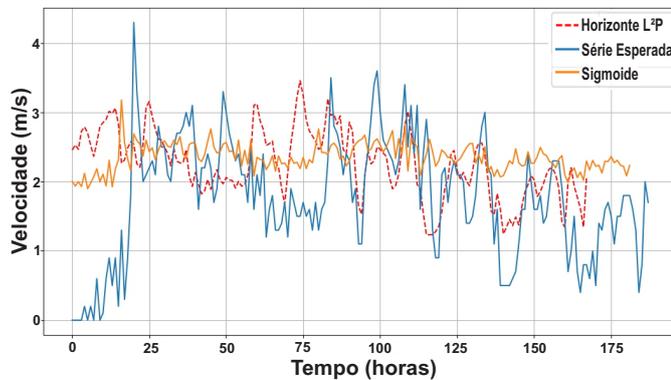


Figura 9. Resultados da janela temporal 1 semana a frente, série eólica

A Figura 9 apresenta o resultado da série ventos, que possui um horizonte de 1 semana a frente e uma janela de 1 semana. É possível observar a fidelidade obtida na resposta com o ajuste de treinamento, apesar do erro em alguns momentos de picos (uma perturbação que interfere no aprendizado da rede neural), o desempenho em prever o comportamento da série foi obtido.

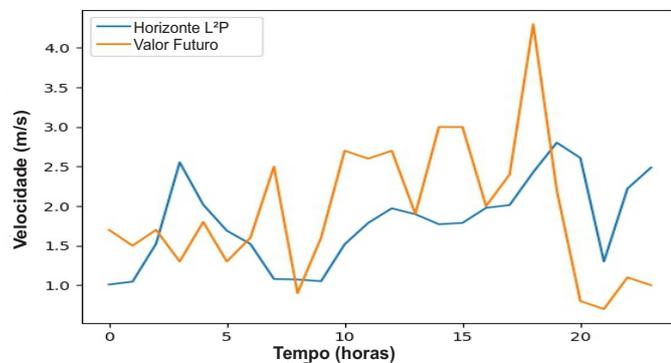


Figura 10. Resultados da janela 24 horas a frente, série eólica

A Figura 10 é o resultado de 3 dias de treino e um horizonte de 24 horas a frente. Semelhante ao horizonte de 1 semana, a predição estimada apresenta concordância,

com a capacidade de produzir a evolução da série, e sua tendência, mesmo apesar de um treino reduzido, o que é fundamental para a previsão a curto prazo, e quando não tem disponível um histórico maior. Cada vez que a rede possui mais dados para aprendizagem, melhor será o reconhecimento da rede neural para valores futuros. Apesar de uma diferença acentuada em um prazo de 24 horas, o treinamento segue os 3 dias anteriores, para que demonstre que a rede realmente está aprendendo.

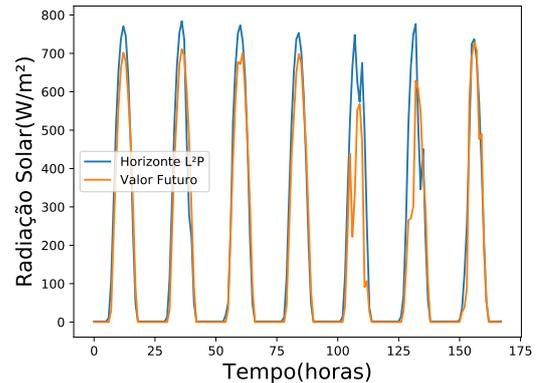


Figura 11. Resultados da janela 1 semana a frente, série solar

A Figura 11 é o resultado do horizonte de 1 semana a frente com a série solar. A aproximação do horizonte para o valor futuro mostra que as sazonalidades foram igualmente aprendidas, junto com as amplitudes de valores e crescimento de cada dia medido.

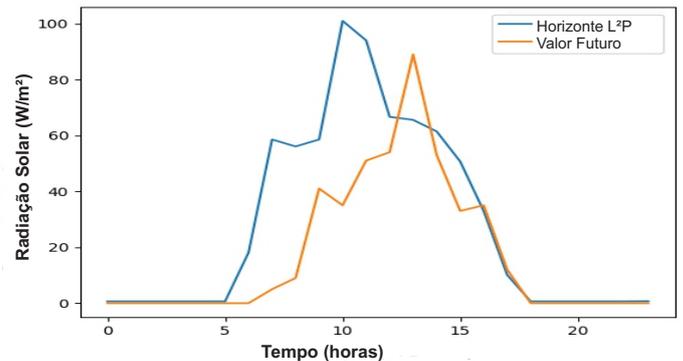


Figura 12. Resultados da janela 24 horas a frente, série solar

A Figura 12 mostra o horizonte de predição de 24 horas à frente da série solar. O resultado obtido possui uma perceptível aproximação ao valor futuro real. O comportamento não linear possui um grau de precisão determinado pelo treinamento de 3 dias. É perceptível a influência na amplitude e no atraso obtido no modelo L^2P . A taxa de aprendizagem utilizada é em 0.5. O resultado é coerente com a forma geométrica do valor futuro, com um avanço em 3 horas no erro de maiores valores, devido ao curto prazo de 3 dias de antecedência.

5. CONCLUSÃO

Predição de séries temporais é um assunto de extrema importância dentro do contexto da engenharia de energia e de setores estratégicos de operação da matriz energética. O presente trabalho demonstrou um método experimental, baseado na histerese, utilizando o modelo L^2P . O modelo vem sendo estudado pela literatura, pois possui um melhor ajuste, tendo a vista que consegue trabalhar em séries caóticas. O presente modelo experimental, obteve um comportamento adequado em referência à quantidade de erro quadrático médio.

O modelo proposto possui uma melhoria para a função de ativação da rede de previsão, onde a não linearidade produz efeitos diretamente na janela temporal. Comparando-se com os trabalhos feitos por Liu and Lu (2011), Makhouloufi et al. (2018), Mitkov et al. (2019) e Lukhyswara et al. (2019), a estimação dos parâmetros de histerese na metodologia realizada neste trabalho é feita diretamente nos dados. Desta forma, é apresentado uma sensibilidade no aprendizado, o que beneficia o reconhecimento das amplitudes de dados, com exceção de picos.

As previsões realizadas mostram o ajuste da rede neural idealizada para comportamentos a nível de curva de histerese para medição de recurso disponível. Os levantamentos feitos são consistentes com os gráficos apresentados. O trabalho apresenta uma abordagem teórica que alcança em forma de representação, dados significativos. Logo, a implementação destes modelos podem ser de grande valia para a avaliação de sistemas elétricos inteligentes.

REFERÊNCIAS

- Almeida, L.A.L., Deep, G.S., Lima, A.M.N., Khrebtov, I.A., Malyarov, V.G., and Neff, H. (2004). Modeling and performance of vanadium-oxide transition edge microbolometers. *Applied Physics Letters*, 85(16), 3605–3607.
- Bielecki, A. (2019). *Models of Neurons and Perceptrons: Selected Problems and Challenges*. Springer International Publishing.
- Borges, M.A.P., Vilcanqui, O.A.C., and Almeida, L.A.L. (2019). Amplificador acoplado em modelo de histerese para análise de altas frequências. *Encontro Regional de Matemática Aplicada (IV-ERMAC)*, 28–33.
- de Araujo, R.S., de Almeida, L.A.L., and da Costa, F.S.O. (2019). Modelo de neurônio memristivo de dióxido de vanádio com codificação de impulsos prbs-pwm. *14º Simpósio Brasileiro de Automação Inteligente*.
- Di Piazza, A., Di Piazza, M., and Vitale, G. (2014). Estimation and forecast of wind power generation by ftdnn and narx-net based models for energy management purpose in smart grids. *algorithms*, 8, 10.
- Fan, L., Li, J., Pan, Y., Wang, S., Yan, C., and Yao, D. (2019). Research and application of smart grid early warning decision platform based on big data analysis. In *2019 4th International Conference on Intelligent Green Building and Smart Grid (IGBSG)*, 645–648.
- Gebben, F., Bader, S., and Oelmann, B. (2015). Configuring artificial neural networks for the prediction of available energy in solar-powered sensor nodes. In *2015 IEEE SENSORS*, 1–4.
- Hilal, H., Riza, Prastawa, A., and Matsumura, T. (2018). Turning renewable energy be a dispatchable electric generation through energy management system technology: Sumba smart micro grid case. In *2018 Conference on Power Engineering and Renewable Energy (ICPERE)*, 1–4.
- Kashef, H., Mahmoud, K., and Abdel-Nasser, M. (2018). Power loss estimation in smart grids using a neural network model. In *2018 International Conference on Innovative Trends in Computer Engineering (ITCE)*, 258–263.
- Liu, W. and Lu, L. (2011). Hysteretic neural network and its applications in associative memory. In *2011 International Conference on Control, Automation and Systems Engineering (CASE)*, 1–3. IEEE.
- Lukhyswara, P., Putranto, L.M., and Ariananda, D.D. (2019). Solar irradiation forecasting uses time series analysis. In *2019 11th International Conference on Information Technology and Electrical Engineering (ICI-TEE)*, 1–6.
- Makhouloufi, S., Debbache, M., and Boulahchiche, S. (2018). Long-term forecasting of intermittent wind and photovoltaic resources by using adaptive neuro fuzzy inference system (anfis). In *2018 International Conference on Wind Energy and Applications in Algeria (ICWEAA)*, 1–4.
- Mitkov, A., Noorzad, N., Gabrovska-Evstatieva, K., and Mihailov, N. (2019). Forecasting the energy consumption in afghanistan with the arima model. In *2019 16th Conference on Electrical Machines, Drives and Power Systems (ELMA)*, 1–4.
- Preisach, F. (1935). Über die magnetische nachwirkung. *Zeitschrift für Physik*, 94, 277–302.
- Seo, Y., Yu, H., Yu, M., and Lee, S.J. (2018). Compensation method of gyroscope bias hysteresis error with temperature and rate of temperature using deep neural networks. In *2018 18th International Conference on Control, Automation and Systems (ICCAS)*, 1072–1076.
- Shukla, P. and Sinha, T.K. (1994). Hysteresis in neural networks. *Phys. Rev. E*, 49, R4811–R4814. doi:10.1103/PhysRevE.49.R4811. URL <https://link.aps.org/doi/10.1103/PhysRevE.49.R4811>.
- Soman, S.S., Zareipour, H., Malik, O., and Mandal, P. (2010). A review of wind power and wind speed forecasting methods with different time horizons. In *North American Power Symposium 2010*, 1–8.
- Valdés Cambero, E.V., Paz, H.P., Silva, V.S., Araujo, H.X., Casella, I.R.S., and Capovilla, C.E. (2019). A 2.4 ghz rectenna based on a solar cell antenna array. *IEEE Antennas and Wireless Propagation Letters*, 1–4.
- Wang, Y., Luo, P., Zeng, X., Peng, D., Zhen, S., Qin, Y., and Zhang, B. (2019). A new design method for solar energy harvesting system based on neural network. In *2019 IEEE International Symposium on Circuits and Systems (ISCAS)*, 1–4.