

## WAVELETS E REDES NEURAI APLICADAS A PREVISÃO DE RECURSO EÓLICO

TIAGO MALAVAZI DE CHRISTO; TARCISIO PREST BERNABÉ; JUSSARA FARIAS FARDIN; DOMINGOS SÁVIO LYRIO  
SIMONETTI.

*Laboratório de Eletrônica de Potência, Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo*

*E-mail:* tmalavazi@ifes.edu.br

**Abstract**— This work investigates the use of artificial neural networks for day ahead wind power forecasts, with the differential of the of wavelet decomposition. The advantages of using wavelet decomposition are addressed, the edge distortion problem are investigated and a comparison of traditional methods for minimizing the edge effect is presented. At the end is presented the results obtained with a forecast model using Wavelet Packet and a NAR neural network with time delay.

**Keywords**— Wind Power Forecasting, Energy Management, Wavelet, Neural Networks

**Resumo**— Este trabalho investiga a utilização redes neurais artificiais para a previsão de potência eólica dia a frente, com o diferencial da decomposição Wavelet. São abordadas as vantagens do uso de decomposições Wavelet, o problema da distorção de borda e um comparativo dos métodos tradicionais para minimização do efeito de borda. Ao final é apresentado os resultados obtidos por um modelo de previsão com o uso de Wavelet Packet e uma rede neural NAR com atraso de tempo.

**Palavras-chave**— Previsão de Potência Eólica, Gerenciamento de Energia, Wavelet, Redes Neurais

### 1 Introdução

A integração de fontes renováveis ao sistema elétrico, seja de forma centralizada, distribuída ou mesmo em sistemas isolados, apresenta-se como uma alternativa para o atendimento demanda de energia de forma mais sustentável, contribui para a diversificação da matriz, para a redução da necessidade de acionamento das termelétricas ou do uso de combustíveis fósseis em ambientes isolados (Tin, et al., 2010; ABEEólica, 2016; Christo, et al., 2016). Porém, lidar com a característica intermitente dessas fontes é um fator determinante para a segurança do sistema e para a gestão técnico-econômica da rede (Ye Ren, 2015).

Estudos realizados pelo Laboratório de Energias Renováveis dos Estados Unidos (NREL), em uma planta eólica de 1920 MW, localizada no estado do Arizona, mostraram que um aumento de 20% no índice de acerto do sistema de previsão poderia reduzir os custos de operação em até 195 milhões de dólares, considerando uma penetração média anual de 24% (Lew, et al., 2011).

Em sistemas híbridos isolados, onde não há a presença de uma rede elétrica externa capaz de sustentar variações abruptas de oferta e demanda, a previsão da produção renovável também pode elevar a estabilidade do sistema, permitir o gerenciamento da planta de energia e a gestão da demanda. Dessa forma, prever-se com precisão a expectativa de produção de energia renováveis, horas ou dias a frente, demonstra-se fundamental para que seja possível um gerenciamento seguro e eficiente de um sistema elétrico moderno.

Segundo Ye Ren, 2005, os modelos de previsão de recursos renováveis como vento e incidência solar, podem ser diferenciados entre: Numéricos ou físicos;

Estatísticos; de Inteligência Computacional; e Híbridos (Ye Ren, 2015).

Os métodos numéricos se baseiam em equações físicas, exigem elevado grau de compreensão da dinâmica regional associada e tem maior custo computacional, comparado aos demais, sendo necessário computadores dedicados para que os cálculos sejam realizados em tempo hábil. Os modelos numéricos possuem precisão superior aos demais em simulações de longo prazo (dias ou semanas), porém, inferior em curto prazo (horas) (Wang, et al., 2011). Já os modelos estatísticos utilizam técnicas de regressão linear e de análise estatística das características do recurso para previsão. Esses modelos possuem maior simplicidade matemática e menor custo computacional (Wang, et al., 2011). Os modelos baseados em inteligência computacional utilizam conceitos matemáticos modernos, como redes neurais e lógica difusa, a fim de identificar e aprender a dinâmica não linear do recurso. Os modelos baseados em inteligência computacional têm demonstrado resultados superiores aos demais métodos quando aplicados a previsão de curto prazo e extremo curto prazo (minutos) (Wang, et al., 2011). Por fim, os modelos híbridos apresentam-se como os mais completos e avançados. Os modelos híbridos unem as características de diversos modelos citados para alcançar precisão máxima (Wang, et al., 2011).

Este trabalho investiga a utilização redes neurais artificiais para a previsão de vento 24 horas a frente com a aplicação da decomposição Wavelet na série temporal. São abordadas as vantagens do uso de decomposições Wavelet, o problema da distorção de borda e um comparativo dos métodos tradicionais para minimização do efeito de borda. Ao final é apresentado os resultados obtidos por um modelo de previsão com o uso de Wavelet Packet em uma rede neural não linear auto regressiva.

## 2 Materiais e Métodos

O modelo investigado utiliza três técnicas independentes associadas em série, conforme mostra a Figura 1. As etapas envolvem o tratamento dos dados, a decomposição wavelet e análise separadamente das componentes por redes neurais (RNA). A previsão final é obtida pela soma das previsões parciais calculadas pelas RNAs.

A validação dos registros segundo critérios de identificação de dados suspeitos por mau funcionamento e intempéries, necessária a fim de evitar que o modelo de previsão venha a aprender inconsistências, foi atendida com uso de dados validados do Sistema de Organização Nacional de Dados Ambientais (SONDA), mantido pelo Instituto Nacional de Pesquisas Espaciais (INPE) (INPE, 2015). Para as simulações foram utilizados dados anemométricos da Estação de Petrolina (PTR), referente ao ano de 2010. Foram utilizados os registros do anemômetro posicionado a 25 metros de altura e velocidade média registrada a cada 6 minutos. Salienta-se que a escolha da estação PTR e ano 2010, se justifica exclusivamente pela integridade dos dados.

A fim de ajustar os dados a resolução adequada a uma previsão 24h a frente, os dados foram integralizados a cada uma hora. Dessa forma, foi obtida uma série com 8760 pontos (365 dias x 24 horas). A Figura 2 apresenta as 8760 médias horárias obtidas ao longo do ano de 2010.




Figure 1. Modelo de previsão baseado em decomposição wavelet do sinal e aplicação de redes neurais artificiais.




Figure 2. Série dos ventos, em média horária, medidos a 25 metros, em 2010, na região de Petrolina. Calculado com base nos dados coletados pelo projeto SONDA (INPE, 2015).

Após o tratamento dos dados os mesmos foram subdivididos em 16 faixas de frequência pela aplicação da decomposição Wavelet Packet, treinamento de 16 redes neurais independentes e combinação das saídas para construção do sinal previsto.

## 3 A Decomposição Wavelet

A decomposição Wavelet é uma transformação matemática capaz de representar uma série em diferentes escalas de frequência e de tempo, decompondo-se o sinal entre aproximações (componentes de menores frequências) e detalhes (componentes de maiores frequências) (Mallat, 1987). Mais níveis permitem a decomposição do sinal em mais faixas de frequência. Uma vez somadas ponto a ponto, a aproximação e os detalhes, o sinal é reconstruído ponto a ponto. Dessa forma, é possível aplicar uma rede neural específica para cada banda de frequência. Permitindo a rede melhor ajuste a dinâmica do sinal. A Figura 3 representa uma comparação entre dois tipos de decomposição em três níveis, Wavelet (WD) e Wavelet Packet (WPD).




Figure 3. Estruturas de decomposição wavelet em três níveis. Decomposição Wavelet (WD), na parte superior, e Decomposição Wavelet Packet (WPD), na parte inferior.

Para a decomposição da série de velocidade dos ventos foi escolhida a decomposição Wavelet Packet de 4 níveis, resultando em um total de 16 decomposições. A decomposição Wavelet Packet foi escolhida por permitir maior quantidade separação de frequências ( $2^n$ ) quando comparado a Wavelet simples ( $n+1$ ). Onde "n" refere-se ao número de níveis estabelecido. A escolha do nível foi realizada com base na análise da decomposição AAAA<sub>4</sub>, de forma que a mesma concentrasse as componentes de frequência diária e inferiores ( $T > 24h$ ). A wavelet utilizada para decomposição foi a DMeyer (aproximação discreta da wavelet da família Meyer).

### 3.1 Efeito de borda da decomposição wavelet

Efeitos de borda são comuns no processamento de sinais de comprimento finito. Quando a wavelet chega próximo ao limite do sinal, o cálculo da convolução requer valores inexistentes, que estariam além da fronteira (HANG SU, 2012). Isso cria uma distorção conhecida como efeito de borda, fruto de informação desconhecida além da fronteira do sinal. Para lidar com o efeito de borda diversos métodos de extensão de borda tem sido discutidos na literatura (HANG SU, 2012; Rana & Koprinska, 2016).

A fim de avaliar os métodos tradicionais quanto a distorção na decomposição do sinal de velocidade do vento, foram comparados 11 métodos tradicionais de extensão de sinal disponíveis no Matlab. São eles: Preenchimento com zeros ('zpd'); Extensão simétrica ('sym', 'symh' e 'symw'); Extensão Anti-simétrica ('asym', 'asymh' e 'asymw'); Preenchimento com derivada de primeira ordem ('spd' ou 'sp1'); Preenchimento com derivada de ordem zero ('sp0'); Preenchimento periódico ('ppd' e 'per').

Os métodos foram aplicados em cinco seguimentos do sinal, com espaçamento de 20 passos (horas) entre eles. A Figura 5, apresenta em forma de gráfico de barras o erro quadrático médio obtido para cada dos 11 métodos, considerando os últimos 20 elementos da borda, em cada um dos cinco sinais testados.




Figure 4. Erro médio quadrático na borda dos cinco sinais, para diferentes tipos de preenchimento.

O método que na maioria dos casos apresentou a menor distorção foi o preenchimento com derivada de ordem zero ('sp0'), o qual estende o sinal com seu último valor. No entanto, os resultados mostram que nenhum dos métodos tradicionais permite eliminar o efeito de borda. Assim, é necessário recorrer a métodos alternativos, como os abordados por Hang (HANG SU, 2012), e por Rana (Rana & Koprinska, 2016), ou ainda descartar parte da borda da decomposição. Este efeito é um dos principais limitantes para a aplicação da decomposição de wavelet.

## 4 A Escolha da Rede Neural

O elemento processador básico de uma rede neural artificial é o neurônio artificial. Como mostra a Figura 5, o modelo apresenta os seguintes componentes

principais: Um conjunto de sinapses ou conexões de entrada, sendo cada entrada ponderada por um peso sináptico, que indica a sua influência na saída da unidade; Uma junção de soma, responsável pela combinação aditiva das entradas ponderadas pelos pesos sinápticos, que produz um nível de atividade responsável por ativar ou não a função de ativação; A função de ativação, geralmente não linear, responsável pela ativação da saída ou resposta do elemento processador é ativada se o nível de atividade exceder um certo limite (threshold). Se ativada a unidade produz uma determinada resposta de saída.




Figure 5. Modelo de neurônio artificial (Dorffner, 1996).

Visando identificar a rede de topologia mais simples capaz de permitir a previsão do vento 24 horas a frente, partiu-se de uma rede neural com atraso de tempo e apenas um neurônio. Essa configuração pode ser entendida como um aproximador de séries similar aos modelos autorregressivo AR(p), porém, substituindo a função linear de aproximação por uma não linear, determinada através de um método de aprendizado, como a retropropagação de erros (Dorffner, 1996).

Para definição da quantidade de passos anteriores a serem considerados pela RNA, foram avaliados os gráficos de autocorrelação do sinal global e da decomposição A4(0,0). A Figura 6 e 7 apresentam respectivamente os gráficos de autocorrelação dos dados para 8760 horas (um ano) e 192 horas (oito dias). Pelos gráficos de autocorrelação pode-se observar picos de correlação em frequência diária (24, 48, 72, 96 horas, ...), sendo que o pico de correlação diária torna-se menor do 40% a partir do quinto dia.

A fim de avaliar a influência do tamanho do histórico de dados a priori (entrada da rede) no grau de acerto da rede, foi estabelecido como ponto de partida a utilização de 24 passos anteriores, e realizados testes aumentando-se de 24 em 24 até a consideração de 192 passos anteriores (oito dias). O treinamento foi realizado com as decomposições dos meses de janeiro a março de 2010 e os testes realizados de abril a dezembro do mesmo ano. As bordas das decomposições foram descartadas e a divisão dos dados para o treinamento e teste foi randômica. O algoritmo de treino adotado foi o *Bayesian regulation backpropagation*, o qual ajusta os pesos e o *Bias* de acordo com a otimização *Levenberg-Marquardt*. Sob essas condições, foram simulados a previsão de 24 horas a frente e 36 horas a frente.

A Figura 8 apresenta o  $R^2$  obtido para cada uma das 16 decomposições, na fase de treino (janeiro a

março) da rede de previsão de 24 horas a frente. A Figura 9 apresenta o resultado na fase de teste (abril a dezembro).

Observa-se nas Figuras 8 e 9 que as redes com observação de mais de 48 passos anteriores apresentaram resultados semelhantes na fase de teste e de treino, indicando elevado grau de aprendizado e generalização, para a previsão 24 horas a frente.




Figure 5. Gráfico de autocorrelação dos dados, ano de 2010.




Figure 6. Gráfico de autocorrelação dos dados, 200 horas.




Figure 7. Resultado da regressão entre saída e alvo, na fase de treino (janeiro a março de 2010), para a rede de um neurônio, prevendo 24h a frente, com base na observação de 24 a 192 passos anteriores.




Figure 8. Resultado da regressão entre saída e alvo, na fase de teste (abril a dezembro de 2010), para a rede de um neurônio, prevendo 24h a frente, com base na observação de 24 a 192 passos anteriores.

Considerando os resultados apresentados, escolhe-se a rede que observa 168 passos anteriores para previsão de 24 passos à frente, como a de melhor performance. Essa rede apresentou todos os  $R^2$  superiores a 0,999 em todas as decomposições.

Após a previsão das decomposições é realizado o somatório das mesmas. Esse somatório constrói a série prevista. A Figura 10 apresenta de forma sobreposta, os valores previstos, reais e os valores de erro, em um intervalo de 4 dias, na fase de teste.




Figure 9. Valores previstos, reais e os valores de erro, em um intervalo de 4 dias, na fase de teste. Previsão 24 horas a frente com base em 168 passos anteriores.

A Figura 11 apresenta o  $R^2$  obtido para cada uma das 16 decomposições, na fase de treino (janeiro a março) da rede de previsão de 36 horas a frente. A Figura 12 apresenta o resultado na fase de teste (abril a dezembro).

Observa-se nas Figuras 11 e 12 que as redes apresentaram resultados semelhantes na fase de teste e de treino, indicando bom grau de generalização, para a previsão 36 horas a frente, porém, a rede apresentou resultados significativamente piores comparados a previsão de 24 horas.

A Figura 13 apresenta de forma sobreposta, os valores previstos, reais e os valores de erro, em um intervalo de 4 dias, na fase de teste, da rede de previsão 36 horas a frente alimentada por 144 passos anteriores.




Figure 10.  $R^2$  obtido para cada uma das 16 decomposições, na fase de treino (janeiro a março) da rede de previsão de 36 horas a frente.




Figure 11.  $R^2$  obtido para cada uma das 16 decomposições, na fase de teste (abril a dezembro) da rede de previsão de 36 horas a frente.




Figure 12. Valores previstos, reais e os valores de erro, em um intervalo de 4 dias, na fase de teste, da rede de previsão 36 horas a frente alimentada por 144 passos anteriores.

Redes NAR com maior quantidade de neurônios também foram simuladas, mas houve piora e ou perda de capacidade de generalização. Assim o estudo de outras topologias de redes e o uso de variáveis exógenas apresentam-se como alternativas para se elevar o horizonte de previsão e ou grau de acerto.

Considerando que testes com redes NAR diretamente a série de tempo, apresentaram  $R^2$  de 86% para apenas um passo à frente, entende-se que o ganho de performance dado a aplicação da decomposição wavelet relevante. Dessa forma, investigações no sentido da minimização da distorção de borda e topologias de redes, aplicados ao problema da previsão dias a frente, justificam-se.

## 5 Estimação da Potência elétrica

Para que o sistema de gerenciamento de energia possa tomar decisões deve ser entregue ao mesmo a curva de expectativa de geração ao longo do dia. Dessa forma, uma vez previsto a curva diária dos ventos, é necessário convertê-la na curva expectativa de potência que será produzida pela turbina eólica.

Primeiramente deve-se verificar se há diferença entre a altura onde foram medidos os ventos e a altura do rotor da turbina eólica. Caso exista diferença, a série prevista deverá ser corrigida utilizando-se a equação 1 (Patel, 1999). Onde  $V$  é a velocidade,  $H$  a altura e  $R_{terreno}$  a rugosidade do terreno.

$$V_{rotor} = V_{anem} \cdot \frac{\ln\left(\frac{H_{rotor}}{R_{terreno}}\right)}{\ln\left(\frac{H_{anem}}{R_{terreno}}\right)} \quad (1)$$

A equação 2 calcula a potência fornecida por uma turbina eólica, onde  $A$  refere-se a área circular coberta pelas hélices ( $m^2$ ),  $\rho$  refere-se a densidade do ar ( $Kg/m^3$ ),  $v$  refere-se a velocidade do vento ( $m/s$ ), o  $C_p$  refere-se ao produto dos rendimentos aerodinâmicos ( $C_a$ ), mecânicos ( $C_m$ ) e elétricos ( $C_e$ ) (REN, 2015). É importante observar que esses rendimentos variam em função da velocidade do vento incidente, velocidade de giro da turbina e ângulo das pás.

$$P(t) = \frac{1}{2} \cdot \rho(t) \cdot A \cdot v(t)^3 \cdot C_p(t) \quad (2)$$

A Figura 14 mostra uma curva estática de potência em função da velocidade do vento incidente, de uma turbina com controle ativo de ângulo de passo. Nela pode-se observar o comportamento do  $C_p$ .




Figure 13. Curva estática de Potência da turbina ENERCON, modelo E-33, de 330 kW (ENERCON, 2016).

Em séries de vento com resolução em horas, a aproximação pode ser obtida diretamente pela curva estática de potência da turbina.

A figura 15 apresenta de forma sobreposta a curva de vento e a potência real e prevista 24 horas a frente.




Figure 14. Vento e a potência real e prevista 24 horas a frente

Nas Figuras 14 e 15, pode-se observar que a relação entre a velocidade do vento e a potência elétrica produzida pela turbina não é diretamente proporcional. Assim, salienta-se a importância de se considerar a curva potência da turbina prevista e não apenas curva do vento, no gerenciamento de sistemas de energia. Caso a velocidade do vento atinja valores superiores a velocidade nominal da turbina (12 m/s), diferenças ainda maiores serão observadas, uma vez que sob essa condição a turbina manterá sua potência constante até seu limite de operação.

## 6 Conclusões

O uso de previsão para o gerenciamento do sistema elétrico moderno, apresenta-se como solução para elevação da segurança e eficiência (ABEEólica, 2016) (Lew, et al., 2011). Nesse sentido, modelos de previsão baseados em inteligência computacional se destacam na previsão 24 horas a frente (Ye Ren, 2015) (Wang, et al., 2011). Para isso a aplicação de wavelet permite melhor grau de aprendizado da rede e simplicidade de projeto, sendo um neurônio capaz de prever 24 passos à frente com  $R^2$  maior que 0,99, com treino de apenas 3 meses e teste em 9 meses seguintes. Isso ocorre devido a separação do sinal em faixas de frequências. Porém, o problema da distorção de borda torna necessário o tratamento da decomposição antes do treino da rede, sendo o preenchimento  $sp0$  o qual em geral apresentou menor distorção dentre os métodos tradicionais. Dessa forma, investigações no sentido da minimização da distorção de borda e topologias de redes, aplicados ao problema da previsão dos ventos, podem permitir previsão expectativa de produção potência eólica em horizontes ainda maiores.

## Agradecimentos

Agradecemos a Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES), pelo apoio a pesquisa.

## Referências Bibliográficas

- ABEEólica, 2016. Tempos de rediscutir a Matriz Energética Nacional?. [Online]  
Available at: <http://www.portalabeeolica.org.br>
- Christo, T. M. d. et al., 2016. Design and analysis of hybrid energy systems: The Brazilian Antarctic Station case. *Renewable Energy*, pp. 236-246.
- Dorffner, G., 1996. Neural Networks for Time Series Processing. *Neural Network World*, pp. 447--468.
- ENERCON, 2016. ENERCON\_Product\_Overview. [Online]  
Available at: <http://www.enercon.com>
- HANG SU, Q. L. J. L., 2012. Boundary Effects Reduction in Wavelet Transform for Time-frequency Analysis. *WSEAS TRANSACTIONS on SIGNAL PROCESSING*, pp. 169-179.
- INPE, 2015. Instituto Nacional de Pesquisas Espaciais. [Online]  
Available at: <http://sonda.ccst.inpe.br>
- Lew, D., Milligan, M., Jordan, G. & Piwko, R., 2011. The Value of Wind Power Forecasting - NREL - National Renewable Energy Laboratory of the U.S. Department of Energy. Washington, DC: NREL/CP-5500-50814.
- Mallat, S. G., 1987. A Theory for Multiresolution Signal Decomposition: The Wavelet Representation. *University of Pennsylvania ScholarlyCommons*, Issue MS-CIS-87-22, pp. 1-27.
- Patel, M. R., 1999. *Wind and Solar Power System*. New York: CRC Press.
- Rana, M. & Koprinska, I., 2016. Forecasting electricity load with advanced wavelet neural networks. *Neurocomputing*, Volume 182, pp. 118-132.
- Tin, T. et al., 2010. Energy efficiency and renewable energy under extreme conditions: case studies from Antarctica. *Renewable Energy*, pp. 1715-1723.
- Wang, X., Guo, P. & Huang, X., 2011. A Review of Wind Power Forecasting Models. *Energy Procedia*, pp. 770-778.
- Ye Ren, P. N., 2015. Ensemble methods for wind and solar power forecasting - A state-of-the-art review. *RenewableandSustainableEnergyReviews*, pp. 82-91.