

ANÁLISE WAVELET E REDES NEURAS ARTIFICIAIS NA PREVISÃO DA VELOCIDADE DE VENTO

Luiz Albino Teixeira Júnior

PUC-RJ – Pontifícia Universidade Católica do Rio de Janeiro
Departamento de Engenharia Elétrica
Rua Marquês de São Vicente 225, Gávea 22451-041, Rio de Janeiro - RJ
joniorg3@hotmail.com

José Francisco Moreira Pessanha

UERJ – Universidade do Estado do Rio de Janeiro
Departamento de Estatística – Instituto de Matemática e Estatística Sala 6028-B
Rua São Francisco Xavier, 524 – Maracanã 20550-900, Rio de Janeiro – RJ
professorjfm@hotmail.com

Reinaldo Castro Souza

PUC-RJ – Pontifícia Universidade Católica do Rio de Janeiro
Departamento de Engenharia Elétrica
Rua Marquês de São Vicente 225, Gávea 22451-041, Rio de Janeiro - RJ
reinaldo@ele.puc-rio.br

RESUMO

A integração econômica e segura dos aproveitamentos eólicos ao sistema elétrico requer que o operador do sistema disponha de modelos capazes de fornecer previsões precisas da disponibilidade de recursos eólicos em um horizonte de curto prazo. Entre as principais técnicas de previsão que podem ser empregadas com este propósito, destacam-se as técnicas de inteligência artificial, em particular as redes neurais artificiais. Apesar dos bons resultados alcançados, a capacidade preditiva de uma rede neural pode ser melhorada com a aplicação da análise *wavelet* à série temporal que se deseja prever. Dado que a potência gerada em uma turbina eólica guarda uma relação cúbica com a velocidade do vento, neste artigo investiga-se o benefício da aplicação da análise *wavelet* para o desempenho de um previsor neural da velocidade do vento. A investigação é conduzida a partir de medições anemométricas disponibilizadas pelo Sistema de Organização Nacional de Dados Ambientais.

PALAVRAS CHAVE. Séries de Vento, Previsão, *Wavelet*.

ABSTRACT

In order to provide an economic and safe integration of the wind farms to the power grid, the operator agent should have short-term forecasting models of the wind resources. Among the several forecasting methods, the artificial neural networks are the main techniques employed with this purpose. Despite the good results achieved, the predictive ability of an artificial neural network can be improved through the application of *wavelet* analysis to the time series. The power generated in a wind turbine hold a cubic relationship with the wind speed. So, the objective of this article is to investigate the usefulness of applying the *wavelet* analysis for the performance of a neural predictor of wind speed. The research is conducted from wind speed measurements provided by National Organization System of Environment Data.

KEYWORDS. Wind Power Series, Forecasting, *Wavelet*.

1. Introdução

As estatísticas apresentadas no *World Wind Energy Report 2009* (WWEA, 2010) mostram a rápida expansão da capacidade instalada da geração eólica no mundo, passando de 24.322 MW em 2001 para 159.213 MW em 2009, sendo a maior parte na Europa (76.218 MW), nos Estados Unidos (35.159 MW) e na China (26 GW).

O potencial eólico brasileiro é avaliado em 143 GW a cinquenta metros do solo, de acordo com AMARANTE *et al* (2001). A capacidade de geração eólica instalada no País era aproximadamente de 709 MW em dezembro de 2009, porém, a partir de 1º de julho de 2012, espera-se a entrada em operação de 71 usinas eólicas contratadas no primeiro leilão de energia eólica realizado no final de 2009, de forma que devem agregar 1.805 MW ao Sistema Interligado Nacional (SIN). A integração segura e econômica dos aproveitamentos eólicos ao SIN requer que o operador do sistema elétrico disponha de previsões de curto prazo da disponibilidade dos recursos eólicos.

A conversão de energia eólica em energia elétrica se dá a partir de uma velocidade mínima denominada velocidade de partida v_p . A potência da turbina é limitada ao valor nominal à velocidade nominal v_n . Para velocidades entre v_p e v_n a potência elétrica P gerada por uma turbina eólica cresce com o cubo da velocidade do vento v transversal à área A varrida pelo seu rotor (CUSTÓDIO, 2009):

$$P = 0,5 \cdot C_p \cdot \eta_m \cdot \eta_g \cdot \rho \cdot A \cdot v^3 \quad (1)$$

onde η_m é o rendimento mecânico da caixa de transmissão, η_g é o rendimento do gerador, ρ é a densidade do ar e C_p é o coeficiente de potência da turbina (que expressa a parcela da potência disponível no vento que é extraída pela turbina).

Assim, para prever a potência eólica gerada, pode-se começar pela previsão da velocidade do vento. Usualmente, tais modelos são classificados em duas categorias: modelos físicos e modelos de séries temporais (PINSON & KARIONATAKIS, 2003).

A categoria dos modelos físicos abrange métodos numéricos para previsão climática (*numeric weather prediction* - NWP). Estes modelos ainda demandam grande esforço computacional e, por este motivo, a sua utilização na previsão de curto prazo é bastante limitada. Por sua vez, a modelagem de séries temporais envolve a análise dos valores passados de variáveis explicativas e da própria variável que se pretende prever. A análise de séries temporais conta com uma ampla variedade de métodos estatísticos e métodos de inteligência artificial. Esta abordagem tem a vantagem de fornecer e atualizar as previsões na escala de tempo em que são tomadas as decisões operativas do sistema elétrico. Seja qual for a abordagem utilizada, a qualidade dos registros anemométricos é um requisito fundamental para a precisão das previsões.

Os registros de velocidade de vento são, em geral, acompanhados de ruídos e *outliers*, ambos decorrentes de falhas no processo de medição ou decorrentes de flutuações aleatórias. Assim, torna-se interessante dispor de uma metodologia capaz de atenuar o ruído na série de registros de velocidade, antes da sua modelagem preditiva.

AQUINO *et al* (2009), FARIA *et al* (2009), KHAN & SHAHIDEHPOUR (2009) e DEJUN *et al* (2010) exploram a propriedade de multirresolução da análise *wavelet* (OGDEN, 1997), como estratégia para aumentar a capacidade de generalização de um preditor da velocidade do vento baseado em redes neurais artificiais - RNA (HAYKIN, 2001). A análise *wavelet* permite decompor uma série temporal em diferentes componentes (ou camadas), o que contribui para a aprendizagem durante o processo de treinamento e validação das redes neurais artificiais. (ROCHA REIS & ALVES DA SILVA, 2004)

Este trabalho tem como objetivo investigar o ganho no processo preditivo ao se aplicar a análise *wavelet* na previsão de velocidade de vento por meio de uma RNA tipo *perceptron* multicamadas. Para ilustrar a aplicação da metodologia proposta considerou-se a série temporal de velocidade do vento no município de São Martinho da Serra, situado na região central do

Estado do Rio Grande do Sul, onde está localizada uma das estações anemométricas do projeto SONDA - Sistema de Organização Nacional de Dados Ambientais (<http://sonda.ccst.inpe.br/>).

O artigo está organizado em seis seções. Na seção 2, são apresentadas algumas definições subjacentes aos Espaços de *Hilbert*, base ortonormal e série de *Fourier*. A teoria das *Wavelets* é descrita na seção 3. Na seção 4, encontra-se uma breve descrição das RNA. Os principais resultados dos experimentos computacionais são apresentados na seção 5. Por fim, na seção 6, são expostas as conclusões do trabalho.

2. Espaços de *Hilbert*, Base Ortonormal e Série de *Fourier*

De acordo com KUBRUSLY (2001), os espaços de *Hilbert* são definidos como espaços lineares completos munidos com um produto interno. Em KUBRUSLY (2001), mostra-se que um espaço de *Hilbert* H é separável se e somente inclui uma base (ortonormal ou ortogonal) contável.

Assim, de acordo com KUBRUSLY (2001), o espaço de funções reais quadraticamente integráveis (à *Lebague*) sobre \mathbb{R} , denotado por $L^2(\mathbb{R})$, munido de um produto interno, denotado por $\langle ; \rangle$, - isto é, o par ordenado $(L^2(\mathbb{R}), \langle ; \rangle)$ - é um exemplo de espaços de *Hilbert* separáveis. De outra forma, o espaço de *Hilbert* $L^2(\mathbb{R})$ é a coleção de todas as funções reais definidas em \mathbb{R} de energia finita. Isto é:

$$L^2(\mathbb{R}) = \left\{ f : X \rightarrow \mathbb{R} : \int_{\mathbb{R}} |f(\cdot)|^2 \partial(\cdot) < \infty \right\} \quad (2)$$

Um subconjunto $\{h_n\}_{n \in \mathbb{Z}}$ de um espaço de *Hilbert* H (separável) é uma base ortonormal (contável) de H se e somente se satisfaz às seguintes condições: (i) ortogonalidade: $\langle h_n, h_m \rangle = 0, \forall n \neq m, \forall n, m \in \mathbb{Z}$; (ii) normalização: $\|h_n\| = 1, \forall n \in \mathbb{Z}$; e (iii) completamento: $\langle x, h_m \rangle = 0$ se e somente se $x = 0, \forall n \in \mathbb{Z}$.

Com efeito, tomando-se arbitrariamente um subconjunto $\{h_n\}_{n \in \mathbb{Z}} \subset H$, sendo H um espaço de *Hilbert* separável, tem-se que, se:

(i) $\{h_n\}_{n \in \mathbb{Z}} \subset H$ for uma base ortonormal contável para H ; e

(ii) Para todo vetor $x \in H$, existir uma expansão única em relação a $\{h_n\}_{n \in \mathbb{Z}}$, tal que

$$x = \sum_{n \in \mathbb{Z}} \frac{\langle x, h_n \rangle}{\|h_n\|} h_n \quad (3)$$

Então, de acordo com o Teorema da Série de *Fourier* (KUBRUSLY, 2001), a expansão de cada vetor x em H é nominada como série de *Fourier*.

Em particular, se o espaço de *Hilbert* considerado for o espaço de funções de energia finita $L^2(\mathbb{R})$ - onde sua base é dada pelo conjunto ortonormal de funções $\{f_n(\cdot)\}_{n \in \mathbb{Z}}$ - cada função $f(\cdot)$ acampada em $L^2(\mathbb{R})$ terá uma expansão única por série de *Fourier*, em termos de $\{f_n(\cdot)\}_{n \in \mathbb{Z}}$, dada por:

$$f(\cdot) = \sum_{n \in \mathbb{Z}} \langle f(\cdot), f_n(\cdot) \rangle f_n(\cdot) \quad (4)$$

3. Teoria Wavelet

3.1 Função Wavelet

Um elemento $\omega(\cdot) \in L^2(\mathbb{R})$ é nominado como função *wavelet* se e somente se a sequência de funções $\left\{ \omega_{m,n}(\cdot) = 2^{\frac{m}{2}} \omega[2^m(\cdot) - n] \right\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, gerada a partir $\omega(\cdot) \in L^2(\mathbb{R})$ por meio de operações (veja LEVAN & KUBRUSLY, 2003), constitui uma base ortonormal para o espaço de Hilbert $L^2(\mathbb{R})$. De outra forma, uma $L^2(\mathbb{R})$ -*wavelet* é uma função $\omega(\cdot) \in L^2(\mathbb{R})$ que gera uma base ortonormal *wavelet* duplamente indexada $\{\omega_{m,n}(\cdot)\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$ para o espaço de funções $L^2(\mathbb{R})$. Por conseguinte, admite-se a qualquer função $f(\cdot)$ em $L^2(\mathbb{R})$ sua expansão por série de *Fourier*:

$$f(\cdot) = \sum_{m \in \mathbb{Z}} \sum_{n \in \mathbb{Z}} \langle f(\cdot), \omega_{m,n}(\cdot) \rangle \omega_{m,n}(\cdot) \quad (5)$$

A projeção de $f(\cdot)$ sobre $\omega_{m,n}(\cdot)$ pode ser interpretada como uma variação de detalhes de $f(\cdot)$ - na escala $2^m(\cdot)$ e translação unitária n . Por outro lado, para cada $m \in \mathbb{Z}$, tem-se que a projeção de $f(\cdot)$ no subespaço de detalhes $W_m(\omega) \subset L^2(\mathbb{R})$ - definido como $W_m(\omega) = span\{\omega_{m,n}(\cdot)\}_{n \in \mathbb{Z}}$ - é definida uma soma parcial da expansão de *Fourier* em (5) na escala m . Isto é:

$$f_{W_m(\omega)}(\cdot) = \sum_{n \in \mathbb{Z}} \langle f(\cdot), \omega_{m,n}(\cdot) \rangle \omega_{m,n}(\cdot) \quad (6)$$

Dessa forma, (6) pode ser referida como uma camada (ou componente) de detalhes de $f(\cdot)$ na escala 2^m . Com efeito, alguma função $f(\cdot) \in L^2(\mathbb{R})$ pode ser interpretada como a soma de todas suas camadas de detalhes em todas as escalas. Um caso especial de funções *wavelets* é a função escala $\phi(\cdot) \in L^2(\mathbb{R})$. Por simetria à *wavelet* $\omega(\cdot)$, assumamos a dilatação diádica 2^{m_0} e a translação unitária n para a função escala $\phi(\cdot) \in L^2(\mathbb{R})$, de forma que:

$$\phi_{m_0,n}(\cdot) = 2^{\frac{m_0}{2}} \phi[2^{m_0}(\cdot) - n], \forall n \in \mathbb{Z}. \quad (7)$$

Assim sendo, considerando algum valor fixo $m_0 \in \mathbb{Z}$, a projeção de $f(\cdot)$ sobre o subespaço de aproximação $V_{m_0}(\phi) \subset L^2(\mathbb{R})$ - definido como $V_{m_0}(\phi) = span\{\phi_{m_0,n}(\cdot)\}_{n \in \mathbb{Z}}$ - é dada por:

$$f_{V_{m_0}(\phi)}(\cdot) = \sum_{n \in \mathbb{Z}} \langle f(\cdot), \phi_{m_0,n}(\cdot) \rangle \phi_{m_0,n}(\cdot) \quad (8)$$

Em síntese, para qualquer função $f(\cdot) \in L^2(\mathbb{R})$, as projeções dos espaços de detalhes, em (6), realizam o mapeamento de suas camadas de detalhes, nos níveis $m_0 \leq m \leq +\infty$, e a projeção do espaço de aproximação, em (8), realiza o mapeamento da camada de aproximação de nível m_0 .

3.2 Transformada Wavelet

Defini-se transformada *wavelet* (TW) como sendo o produto interno entre uma função $f(\cdot) \in L^2(\mathbb{R})$ e uma *wavelet* $\omega_{m,n}(\cdot) \in W_m(\omega) \subset L^2(\mathbb{R})$ - ou uma escala $\phi_{m_0,n}(\cdot) \in V_{m_0}(\phi) \subset L^2(\mathbb{R})$. Dado que os parâmetros n e m são discretos (inteiros), as transformadas *wavelets*, a seguir, são classificadas como discretas (TWD). As transformadas *wavelets* são nominadas como coeficientes de detalhes e de aproximação, sendo calculados (supondo que o suporte de $f(\cdot) \in L^2(\mathbb{R})$ seja igual a \mathbb{R}), respectivamente, como:

$$d_{m,n} = TW_{\omega}(m,n) = \left\langle f(\cdot), \omega_{m,n}(\cdot) \right\rangle = \int_{\mathbb{R}} f(\cdot) \omega_{m,n}(\cdot) \partial(\cdot), \quad \forall (m,n) \in \mathbb{Z} \times \mathbb{Z} \quad (9)$$

$$a_{m_0,n} = TW_{\phi}(m_0,n) = \left\langle f(\cdot), \phi_{m_0,n}(\cdot) \right\rangle = \int_{\mathbb{R}} f(\cdot) \phi_{m_0,n}(\cdot) \partial(\cdot), \quad \forall n \in \mathbb{Z} \quad (10)$$

As famílias $\left\{ d_{m,n} \right\}_{\substack{(m,n) \in \mathbb{Z} \times \mathbb{Z} \\ m \geq m_0}}$ e $\left\{ a_{m_0,n} \right\}_{n \in \mathbb{Z}}$ podem ser denotadas, de forma alternativa, como coeficientes *wavelets* (ou coeficientes de *Fourier*) e quantificam a associação linear entre alguma função $f(\cdot)$ e alguma $\omega_{m,n}(\cdot)$ - ou $\phi_{m_0,n}(\cdot)$ - para cada $(m,n) \in \mathbb{Z} \times \mathbb{Z}$ e $m_0 \in \mathbb{Z}$ (fixo).

3.3 Decomposição Wavelet

De acordo com LEVAN & KUBRUSLY (2003), a sequência de subespaços $\left\{ V_m(\phi), m \in \mathbb{Z} \right\}$ de $L^2(\mathbb{R})$ é definida como Análise Multirresolução *Wavelet*, com relação à função escala $\phi(\cdot) \in L^2(\mathbb{R})$, se as condições seguintes são mantidas:

- (i) $V_m(\phi) \subset V_{m+1}(\phi), \forall m \in \mathbb{Z}$;
- (ii) $\bigcap_{m \in \mathbb{Z}} V_m(\phi) = \{0\}$;
- (iii) $\bigcup_{m \in \mathbb{Z}} V_m(\phi) = L^2(\mathbb{R})$;
- (iv) $v(\cdot) \in V_m(\phi) \Leftrightarrow v[2(\cdot)] \in V_{m+1}(\phi)$, para algum $m \in \mathbb{Z}$; e
- (v) $\left\{ \phi[(\cdot) - n], n \in \mathbb{Z} \right\}$, é uma base ortonormal do subespaço $V_0(\phi) \subset L^2(\mathbb{R})$.

LEVAN & KUBRUSLY (2003) mostram que um espaço de aproximação $V_m(\phi)$ pode ser expandido em termos de subespaços de detalhes $W_k(\omega)$, sendo $-\infty \leq k \leq m-1$:

$$V_m(\phi) = \bigoplus_{k=-\infty}^{m-1} W_k(\omega) \quad (11)$$

KUBRUSLY & LEVAN (2002) mostram que, considerando o resultado da equação (11), o espaço $L^2(\mathbb{R})$ pode ser decomposto em termos dos subespaços de detalhes $W_k(\omega)$, para os níveis no intervalo $m_0 \leq k \leq +\infty$, e de aproximação $V_{m_0}(\phi)$, para o nível m_0 , conforme em (12).

$$L^2(\mathbb{R}) = \left[\bigoplus_{k=-\infty}^{m_0-1} W_k(\omega) \right] \oplus \left[\bigoplus_{k=m_0}^{+\infty} W_k(\omega) \right]$$

$$L^2(\mathbb{R}) = V_{m_0}(\phi) \oplus \left[\bigoplus_{k=m_0}^{+\infty} W_k(\omega) \right] \quad (12)$$

Segundo LEVAN & KUBRUSLY (2003), os subespaços de aproximação e detalhes de $L^2(\mathbb{R})$ são disjuntos e ortogonais entre si. Por consequência, conforme KUBRUSLY (2001), cada função $f(\cdot)$ em $L^2(\mathbb{R})$ possui representação única sob forma de decomposição ortogonal, em termos de projeções ortogonais, dada por:

$$f(\cdot) = f_{V_{m_0}(\phi)}(\cdot) + f_{W_{m_0}(\omega)}(\cdot) + f_{W_{m_0+1}(\omega)}(\cdot) + \dots + f_{W_{+\infty}(\omega)}(\cdot) \quad (13)$$

Assim, considere a decomposição ortogonal descrita em (13) e a família ortonormal *wavelet* $\{\phi_{m_0,n}(\cdot), \omega_{m,n}(\cdot)\}_{\substack{(m,n) \in \mathbb{Z} \times \mathbb{Z} \\ m \geq m_0}}$, base de espaço $L^2(\mathbb{R})$. De acordo com KUBRUSLY

(2001), cada projeção ortogonal em (13) possui uma representação única sob a forma de série de *Fourier* com base *wavelet* ortonormal, uma vez que a ortonormalidade implica independência linear e esta é condição necessária e suficiente para garanti-la. Com isso, tem-se que:

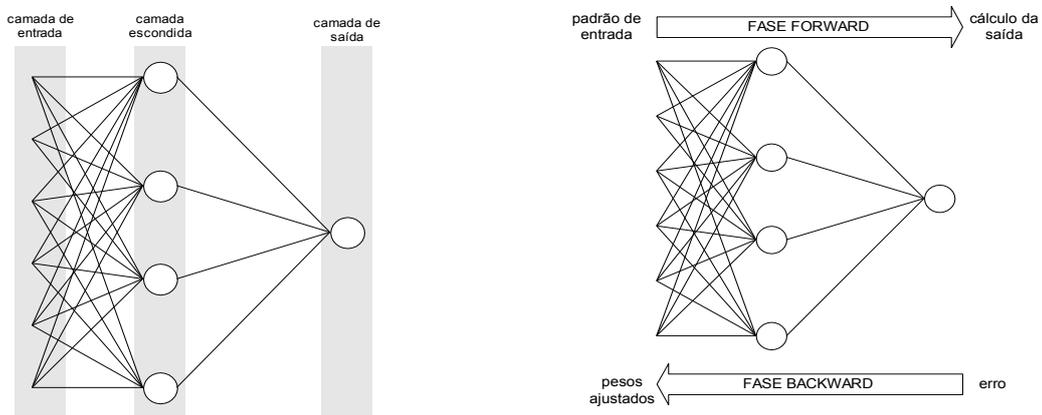
$$f(\cdot) = \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n}(\cdot) + \sum_{n \in \mathbb{Z}} d_{m_0,n} \omega_{m_0,n}(\cdot) + \sum_{n \in \mathbb{Z}} d_{m_0+1,n} \omega_{m_0+1,n}(\cdot) + \dots + \sum_{n \in \mathbb{Z}} d_{+\infty,n} \omega_{+\infty,n}(\cdot) \quad (14)$$

$$f(\cdot) = \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n}(\cdot) + \sum_{m=m_0}^{+\infty} \sum_{n \in \mathbb{Z}} d_{m,n} \omega_{m,n}(\cdot) \quad (15)$$

Sendo as famílias $\{d_{m,n}\}_{\substack{(m,n) \in \mathbb{Z} \times \mathbb{Z} \\ m \geq m_0}}$ e $\{a_{m_0,n}\}_{n \in \mathbb{Z}}$ conhecidas, respectivamente, como coeficientes de detalhes (9) e de aproximação (10).

4. Redes Neurais Artificiais

As redes neurais artificiais (RNA) são sistemas paralelos distribuídos, compostos por unidades de processamento simples (denominadas neurônios) e dispostas em uma ou mais camadas interligadas por um grande número de conexões (sinapses) geralmente unidirecionais e com pesos para ponderar as entradas recebidas por cada neurônio. A arquitetura mais usual é a rede neural artificial multicamadas *perceptron* (MLP) com três camadas, conforme ilustra a Figura 1(a).



(a) Arquitetura da rede neural artificial (b) Fases do algoritmo *backpropagation*

Figura 1 - Rede neural artificial multicamadas *perceptron*.

De forma análoga ao processamento no cérebro humano (onde as sinapses são reforçadas ou enfraquecidas) os pesos nas conexões entre as camadas são ajustados durante o processo de aprendizagem de uma rede neural artificial. A primeira camada da rede neural artificial é a camada de entrada, sendo a única exposta às variáveis de entrada. Esta camada

transmite os valores das variáveis de entrada para os neurônios da camada escondida para que estes extraiam as características relevantes (ou padrões) dos sinais de entrada e transmitam os resultados para a camada de saída, que consiste na última camada da rede. A definição do número de neurônios em cada camada é realizada de forma empírica. O treinamento (ajuste) de uma rede neural consiste em um processo iterativo de obtenção dos pesos das conexões entre as unidades de processamento.

O principal algoritmo de treinamento é o *backpropagation* cujo ajuste dos pesos ocorre mediante um processo de otimização realizado em duas fases: *forward* e *backward*, conforme ilustrado na Figura 1(b). Na fase *forward*, é calculada a resposta fornecida pela rede para um dado padrão de entrada. Na fase *backward*, o desvio (erro) entre a resposta desejada (alvo) e a resposta fornecida pela RNA é utilizado para o ajuste de pesos das conexões. Ao longo do treinamento da rede neural os vários padrões de entrada e as respectivas saídas desejadas são apresentados à RNA, de forma que os pesos das sinapses sejam corrigidos, de forma iterativa, pelo algoritmo do gradiente descendente, com a finalidade de minimizar a soma dos erros quadráticos (HAYKIN, 2001).

5. Experimento Computacional

No experimento computacional, considerou-se a série temporal de velocidade de vento (m/s), a 50 metros de altura, durante o mês de dezembro de 2005. A série tem 4.464 observações (medidas em intervalos de 10 minutos). O *software* utilizado no experimento é o MATLAB. A amostra de treinamento possui 3572 observações e as amostras de validação e teste, 446 observações cada uma. A finalidade do experimento é avaliar o ganho preditivo que é promovido pela utilização da decomposição *wavelet* nos padrões de entrada de uma RNA.

Na primeira etapa (seção 5.1), o treinamento da RNA foi realizado com base nos 4.464 registros da velocidade de vento. A rede neural artificial foi desenhada para fornecer previsões um passo à frente, apresentando a seguinte configuração: 3 valores de entrada (velocidade do vento nos instantes $t-1$, $t-2$ e $t-3$); uma camada escondida com 4 neurônios (função de ativação *tansig*); e 1 neurônio na camada de saída (função de ativação *purelin*). O ajuste da RNA foi realizado utilizando-se o algoritmo de treinamento *backpropagation* (disponível no MATLAB), aplicado aos dados normalizados ao intervalo $[-1,1]$, através da normalização *premnmx*. (veja HAYKIN, 2001).

Na segunda etapa (seção 5.2), foi realizada a decomposição *wavelet* de nível dois (que fornece três componentes, ou subséries) da série temporal de velocidade de vento. Cada componente foi modelada separadamente com uma rede neural artificial de três camadas, de forma a gerar previsões um passo à frente. Em seguida, as previsões de cada componente, em cada instante t , foram somadas, obtendo-se as previsões (um passo à frente) da velocidade de vento. Os resultados obtidos em cada etapa do experimento são comparados em termos das estatísticas de desempenho: MAPE (erro médio percentual absoluto), MAE (erro médio absoluto) e R^2 (coeficiente de determinação).

Assim, sejam $s(t)$ a observação e $\hat{s}(t)$, a previsão, ambos para o instante t , onde $1 \leq t \leq T$. O desvio $e(t) = s(t) - \hat{s}(t)$ entre estes dois valores é denominado como erro de previsão em t . Desse modo, dada uma série histórica com T observações, ou seja, $[s(1), \dots, s(T)]$, tem-se que as estatísticas MAPE, MAE e R^2 são definidos, a seguir, como:

$$MAPE = \sum_{t=1}^T \left[\frac{|s(t) - \hat{s}(t)|}{s(t)} \right] \times \frac{1}{T}$$

$$MAE = \sum_{t=1}^T [|s(t) - \hat{s}(t)|] \times \frac{1}{T}$$

$$R^2 = 1 - \left(\frac{\sum_{t=1}^T (s(t) - \hat{s}(t))^2}{\sum_{t=1}^T (s(t))^2} \right)$$

5.1 Redes Neurais Artificiais sem Decomposição Wavelet

Na Figura 2 têm-se os diagramas de dispersão dos valores observados e as respectivas previsões nas amostras de validação (Figura 2a) e de teste (Figura 2b), obtidos sem a aplicação da decomposição *wavelet* aos padrões de treinamento. Salienta-se que quanto maior a proximidade dos pontos em relação à reta, maior a correlação entre a série temporal observada e as previsões.

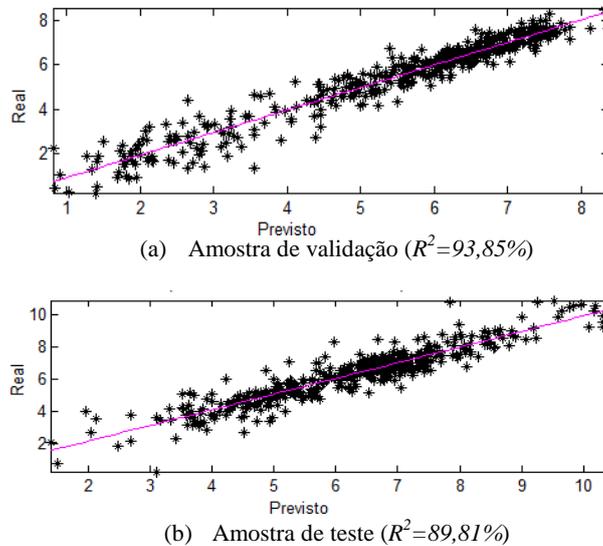


Figura 2 - Valores observados e previstos nas amostras de validação e teste.

5.2 Redes Neurais Artificiais com Decomposição Wavelet

Como qualquer série de tempo finita $[s(1), \dots, s(T)]_{1 \times T}$, para $T \geq 1$, é quadraticamente somável, tem-se que existe algum mapeamento (isto é, uma função) de energia finita tal que $S : \{1, \dots, T\} \rightarrow \mathbb{R}$. Com efeito, cada ponto conjunto imagem (isto é, uma observação no instante t) pode ser expandido por série de *Fourier* com base *wavelet*. Assim tem-se, na Figura 3, uma ilustração do processo de decomposição *wavelet* de nível n , seguido pela previsão por RNA.

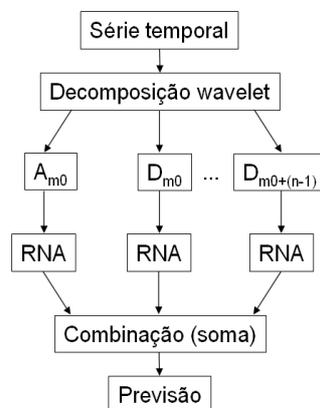


Figura 3 - Decomposição *wavelet* de nível n e previsão.

No experimento, em particular, foi utilizada a decomposição *wavelet* de nível 2 e a base ortonormal de Daubechies d10 (DAUBECHIES, 1988). No figura 4, encontram-se as curvas teóricas das funções escala e wavelet da família de Daubechies com momento igual a 10 (db10).

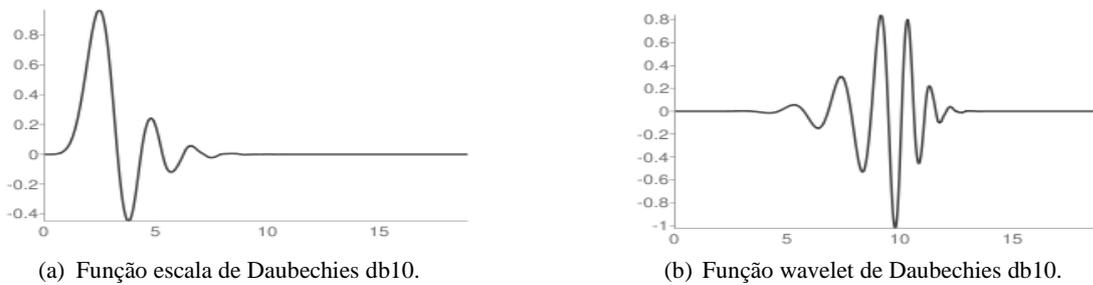


Figura 4 - Funções de Daubechies dB 10 (fonte: <http://wavelets.pybytes.com/wavelet/db10/>).

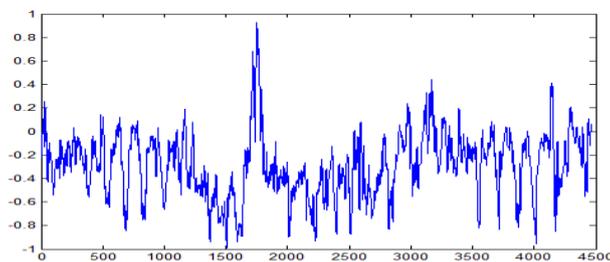
Assim, a série temporal de velocidade de vento foi decomposta em três componentes (subséries) - duas de detalhes e uma de aproximação-, de forma que, em cada instante t , tem-se a equação: $s(t) = A_{m_0,t} + D_{m_0,t} + D_{m_0+1,t}$. Em termos de série de *Fourier*, tem-se que:

$$s(t) = \sum_{n=1}^{n_{m_0}} a_{m_0,n} \phi_{m_0,n}(t) + \sum_{m=m_0+1}^{m_0+1} \sum_{n=1}^{n_m} d_{m,n} \omega_{m,n}(t) \quad (16)$$

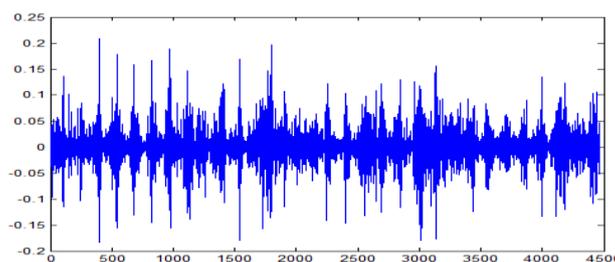
onde

$$a_{m_0,n} = \langle s(t), \phi_{m_0,n}(t) \rangle = \sum_{t=1}^T s(t) \phi_{m_0,n}(t) \text{ e } d_{m,n} = \langle s(t), \omega_{m,n}(t) \rangle = \sum_{t=1}^T s(t) \omega_{m,n}(t) \quad (17)$$

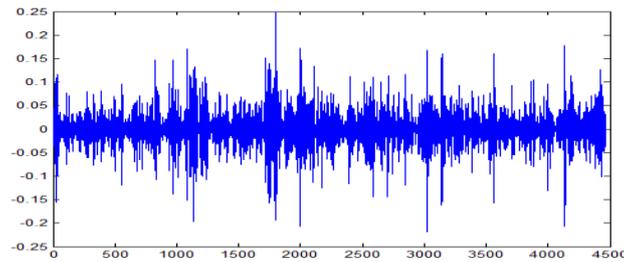
Como os parâmetros m e n são discretos, têm-se, em (17), os coeficientes de detalhes e aproximação que são as transformadas *wavelet* discretas (TWD) de alguma série temporal $[s(1), \dots, s(T)]_{1 \times T}$, para $T \geq 1$, utilizadas como coeficientes na equação (16). O valor de escala ótimo m_0 é obtido, automaticamente, no *software* MATLAB, utilizando-se como critério a minimização da soma dos erros quadráticos. Em relação ao valor de n_m , o *software* MATLAB utiliza o método *down-sampling* para obtê-lo (veja MALLAT, 1998). Na Figura 5, tem-se o gráfico de cada componente (ou subsérie) *wavelet* resultante da decomposição de nível 2 da série temporal $s(t)$ de velocidade de vento.



(a) Componente de aproximação de nível 2 - A_{m_0}



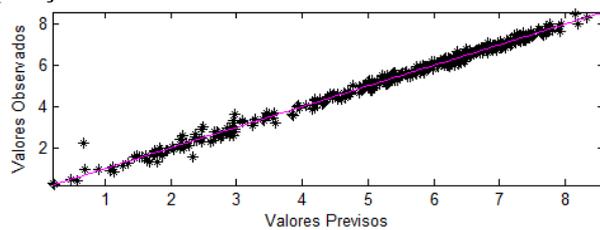
(b) Componente de detalhes de nível 2 - D_{m_0}



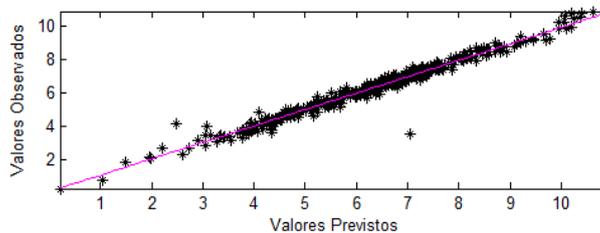
(c) Componente de detalhes de nível 1 - D_{m_0+1}

Figura 5 - Componentes *wavelets* da série temporal de velocidade de vento.

Na sequência, têm-se os diagramas de dispersão dos valores observados em relação às respectivas previsões nas amostras de validação (Figura 6a) e de teste (Figura 6b), obtidos pela utilizando-se a decomposição *wavelet*.



(a) Amostra de validação ($R^2=99,32\%$).



(b) Amostra de teste ($R^2=98,71\%$).

Figura 6 - Correlação entre valores observados e previstos.

A comparação das Figuras 2 e 6 revela que as previsões obtidas com a utilização da decomposição *wavelet* possuem maior correlação com a série temporal observada, tanto na amostra de validação quanto na de teste, o que é um indicativo do ganho de preditivo.

5.3 Comparação dos Resultados Estatísticos

Nas Tabelas 1 e 2, são apresentadas as estatísticas MAPE, MAE e R^2 das amostra de treinamento, validação e teste, obtidas nas duas situações propostas: sem e com decomposição *wavelets*, respectivamente.

Tabela 1 – Qualidade do ajuste sem a decomposição *wavelet*.

Amostra de Treino			Amostra de Validação			Amostra de Teste		
MAPE	MAE	R^2	MAPE	MAE	R^2	MAPE	MAE	R^2
11,69%	0,4340	91,48%	12,30%	0,3449	93,85%	11,46%	0,4908	89,81%

Tabela 2 – Qualidade do ajuste com a decomposição *wavelet*.

Amostra de Treino			Amostra de Validação			Amostra de Teste		
MAPE	MAE	R^2	MAPE	MAE	R^2	MAPE	MAE	R^2
3,68%	0,1462	99,06%	3,82%	0,1153	99,32%	3,94%	0,1788	98,71%

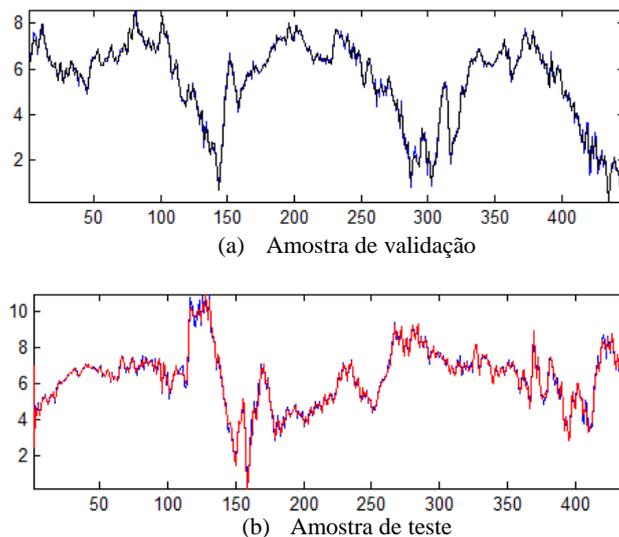


Figura 7 – Valores observados e previstos com a utilização da decomposição *wavelets*.

Conforme explicitado na Figura 7, os valores de velocidade do vento previstos com o auxílio da decomposição *wavelets* aderem bem aos valores observados, refletindo o bom desempenho retratado nas estatísticas apresentadas na Tabela 2.

6. Conclusões

Com a disseminação em larga escala de novos parques eólicos, os responsáveis pela operação de sistemas elétricos necessitam de ferramentas capazes de prever a disponibilidade de recursos eólicos em horizontes de curto prazo. Para tal finalidade, destacam-se as técnicas de inteligência computacional, em particular as redes neurais artificiais (RNA). Os resultados apresentados no artigo mostram que a decomposição da série temporal utilizando funções *wavelets* contribuiu substancialmente para o aumento da capacidade preditiva da rede neural utilizada, conforme verificado nas estatísticas de desempenho (MAPE, MAE e R^2).

O motivo principal do ganho se deve ao fato de que, ao se decompor a série de velocidade de vento em subséries de diferentes escalas de frequência, melhores padrões de comportamento são obtidos. Sob outra ótica, tem-se que a série temporal original está “contaminada” com ruído, porém as subséries são, evidentemente, menos ruidosas que a série original, na medida em que o ruído também é decomposto, o que favoreceu seu mapeamento no tempo pelo predictor neuronal. Portanto, as previsões geradas pelo predictor neuronal com a utilização da decomposição *wavelet* foram mais acuradas em todas as estatísticas de aderência para previsão pontual (um passo à frente) de velocidade de vento.

Referências

- Amarante, O.A.C., Brower, M., Zack, J. e Sá, A.L.** (2001), Atlas do Potencial Eólico Brasileiro, Centro de Pesquisas de Energia Elétrica, Brasília.
- Aquino, R.R.B., Lira, M.M.S., Oliveira, J.B., Carvalho Jr., M.A., Neto, O.N., Almeida, G.J.,** (2009), Application of *Wavelet* and Neural Network Models for Wind Speed and Power Generation Forecasting in a Brazilian Experimental Wind Park, International Joint Conference on Neural Networks, Atlanta, USA.
- Custódio, R. S.** (2009), Energia Eólica para a Produção de Energia Elétrica. Eletrobrás, Rio de Janeiro.
- Daubechies, I.** (1988) Orthonormal Bases of Compactly Supported *Wavelets*. *Comm. Pure and Applied Math.*, 41, pp.909-996.

- Dejun, L., Hui, L., Zhonghua, M.** (2010), One Hour Ahead Prediction of Wind Speed Based on Data Mining, International Conference on Advanced Computer Control (ICACC), Shenyang, China.
- Faria, D.L., Castro, R., Philippart, C., Gusmão, A.** (2009), *Wavelets* Pre-Filtering in Wind Speed Prediction, International Conference on Power Engineering, Energy and Electrical Drives, POWERENG, Lisboa, Portugal.
- Haykin, S.** (2001), *Redes Neurais Princípios e Aplicações*, segunda edição, Porto Alegre.
- Khan, A.A., Shahidehpour, M.**, (2009), One Day Ahead Wind Speed Forecasting using *Wavelets*, Power Systems Conference and Exposition, IEEE/PES, Seattle, USA.
- Levan N., Kubrusly, C. S.**, (2003), A *Wavelet* “Time-Shift-Detail” Decomposition. *Mathematics and Computers in Simulation* 63, 73-78.
- Kubrusly, C. S.** (2001), *Elements of Operator Theory*. Birkhäuser, Boston.
- Kubrusly, C. S., Levan N.** (2002), Dual-Shift Decomposition of Hilbert Space. *Semigroups of Operators: Theory and Application* 2, 145-157.
- Lei, C. & Ran, L.** (2008), Short-term wind speed forecasting model for wind farm based on wavelet decomposition DRPT, Nanjing, China, pp 2525-2529
- Mallat S.** (1998), *A Wavelet Tour of Signal Processing*, Academic Press, San Diego.
- Ogden, R.T.** (1997), *Essential wavelets* for statistical applications and data analysis, Birkhäuser, Boston.
- Pinson, P., Kariniotakis, G.N.** (2003), Wind Power Forecasting using Fuzzy Neural Networks Enhanced with On-line Prediction Risk Assessment, IEEE Bologna Power Tech Conference, Bologna, Italy.
- Rocha Reis, A. J. & Alves da Silva, A. P.** (2004), Aplicação da transformada wavelet discreta na previsão de carga de curto prazo via redes neurais, *Sba Controle & Automação* vol.15 n°1, Campinas Jan. / Mar.
- WWEA - World Wind Energy Association** (2010), *World Wind Energy Report 2009*, Bonn, Germany, February.