

REDES NEURAS ARTIFICIAIS E DECOMPOSIÇÃO WAVELET NA PREVISÃO DA RADIAÇÃO SOLAR DIRETA

Luiz Albino Teixeira Júnior

Departamento de Engenharia Elétrica
Pontifícia Universidade Católica do Rio de Janeiro - PUC-RIO
joniorg3@hotmail.com

José Francisco Moreira Pessanha

Instituto de Matemática e Estatística
Universidade do Estado do Rio de Janeiro - UERJ
professorjfm@hotmail.com

Moisés Lima de Menezes

Departamento de Estatística
Universidade Federal Fluminense - UFF
moises_lima@msn.com

Keila Mara Cassiano

Departamento de Estatística
Universidade Federal Fluminense - UFF
keilamath@hotmail.com

Reinaldo Castro Souza

Departamento de Engenharia Elétrica
Pontifícia Universidade Católica do Rio de Janeiro - PUC-RIO
reinaldo@ele.puc-rio.br

RESUMO

Este artigo propõe um método que combina Redes Neurais Artificiais (RNA) e Decomposição *Wavelet* (DW) na previsão da radiação solar direta. O método, denominado RNA-DW, consiste de dois passos básicos: decomposição da série temporal de interesse em $p+1$ componentes ortonormais *wavelet* e previsão da série temporal por uma RNA em que as variáveis de entrada são as componentes ortonormais *wavelet*. O método proposto apresentou um desempenho superior ao alcançado pela RNA convencional.

PALAVRAS CHAVE. Decomposição *Wavelet*, Redes Neurais Artificiais, Previsão de Séries Temporais, Energia Solar.

ABSTRACT

This paper proposes a method which combines Artificial Neural Networks (ANN) and Wavelet Decomposition (WD) in the direct solar radiation forecasting. The ANN-WD method consists of two basic steps: the decomposition of the time series in $p+1$ wavelet orthonormal components and the time series forecasting by ANN whose input variables are the wavelet orthonormal components. The results showed that the performance of the proposed method is better than the conventional ANN forecaster.

KEYWORDS. Wavelet Decomposition, Artificial Neural Networks, Time Series Forecasting, Solar Power.

1. Introdução

A conversão da energia solar em energia elétrica é uma das alternativas mais promissoras na geração de eletricidade de forma limpa e renovável, seja por meio de grandes centrais geradoras conectadas ao sistema de transmissão ou por pequenas unidades de geração para o atendimento de sistemas isolados.

O Sol fornece anualmente à atmosfera terrestre, aproximadamente, $1,5 \times 10^{18}$ kWh de energia (Grupo de Trabalho de Energia Solar - GTES, 2004), porém apenas uma fração desta energia atinge à superfície terrestre, em função da reflexão e absorção dos raios solares pela atmosfera. A parcela da energia solar que chega à superfície do planeta possui uma componente direta e uma componente difusa, sendo que apenas a componente direta pode ser aproveitada no processo de geração de energia elétrica, por meio de painéis fotovoltaicos e coletores concentradores de energia (Reis, 2003).

Uma tecnologia proeminente na conversão da energia solar em energia elétrica é a usina solar térmica (usina termossolar), cujo funcionamento é esquematizado no diagrama da Figura 1.

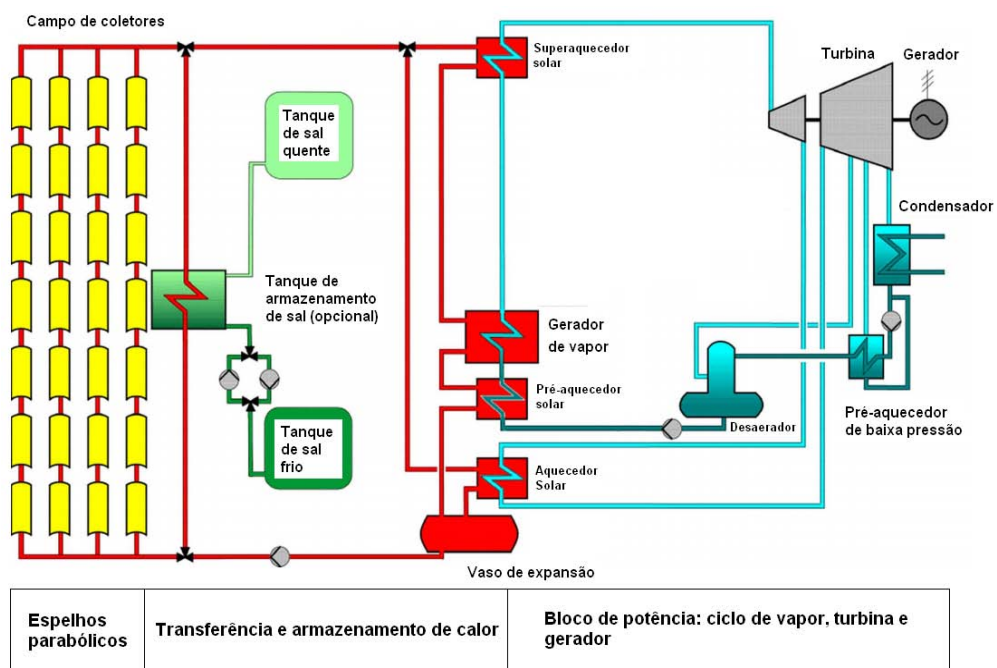


Figura 1 – Esquema de uma usina solar térmica, adaptado de Wittmann et al. (2008).

Conforme esquematizado na Figura 1, a usina solar térmica consiste de uma unidade geradora de eletricidade convencional e de um sistema de coletores solares ou heliostatos (espejos parabólicos) que captam a energia solar e que fornecem calor ao gerador de vapor, com a finalidade de acionar uma turbina. Os espelhos parabólicos coletam a energia solar direta e aquecem um fluido térmico que circula entre os coletores solares e a unidade de produção de vapor com o objetivo de produzir eletricidade (Reis, 2003).

Um problema das fontes renováveis de energia, como, por exemplo, a eólica e a solar, reside no fato da produção destas fontes serem dependentes de fatores meteorológicos. No caso da energia solar, em particular, a alternância de dias e noites, as estações do ano, a passagem de nuvens e os períodos chuvosos acarretam grande variabilidade e descontinuidades na produção de energia elétrica. Ainda neste caso, existe a necessidade de se contar com dispositivos capazes de armazenar energia durante o dia, a fim de disponibilizá-la no período da noite, como, por exemplo, banco de baterias ou tanques de sal, conforme ilustrado na Figura 1.

Desta forma, a integração econômica e segura das fontes alternativas na operação do sistema elétrico depende de previsões acuradas da produção energética (Wittmann et al, 2008), de

forma que os operadores possam tomar decisões sobre a manutenção e o despacho das unidades geradoras que alimentam o sistema.

Dentre as técnicas empregadas na previsão da radiação solar destacam-se os modelos ARIMA (Perdomo et al., 2010), as redes neurais artificiais (RNA) (Yanling et al., 2012), a rede neuro-fuzzy (ANFIS) (Chaabene et al., 2008) e Filtro de Kalman (Yona et al., 2009) e as diferentes formas de combinar bases ortonormais *wavelet* e redes neurais artificiais (Cao et al., 2009 e Zhou et al., 2011).

Neste artigo é proposto o uso combinado da decomposição *wavelet* com a RNA (denominado por RNA-DW) para gerar previsões de curto-prazo da radiação solar direta, uma informação fundamental para a avaliação da potência elétrica gerada a partir da conversão da energia solar em energia elétrica. Mais especificamente, inicia-se com a decomposição *wavelet* de nível p (Faria et al., 2009, Júnior et al., 2011 e Perdomo et al., 2010) da série temporal de radiação solar direta, gerando $p+1$ componentes ortonormais *wavelet*. Em seguida, as componentes *wavelet* são utilizadas como padrões de entrada de uma RNA, cujo objetivo consiste em fornecer previsões da radiação solar direta.

O desempenho do método proposto foi avaliado por meio de um experimento computacional, no qual foi considerada a série temporal horária de radiação solar direta média (W/m^2) na estação Solarimétrica do Projeto Sonda do INPE/CPTEC (<http://sonda.ccst.inpe.br/infos/index.html>) localizada na cidade de Cuiabá ($15^{\circ}33'19''S$ e $56^{\circ}04'12''O$). A série considerada cobre o período de janeiro até dezembro de 2010.

O artigo está organizado em seis seções. Nas seções 2 e 3 são introduzidos os aspectos teóricos da Teoria *Wavelet* e das Redes Neurais Artificiais, respectivamente. O método proposto é detalhado na seção 4. O experimento computacional, bem como os seus principais resultados, são apresentados na seção 5. Por fim, na seção 6 são apresentadas as conclusões.

2. Teoria Wavelet

2.1 Espaços de Hilbert, Base Ortonormal e Série de Fourier

De acordo com Kubrusly (2001), um espaço de Hilbert H é qualquer espaço linear munido de um produto interno e completo. A coleção de todas as sequências infinitas de números complexos e quadraticamente somáveis, denotada por $l^2 := \{f: \mathbb{Z} \rightarrow \mathbb{C}: \sum_{t \in \mathbb{Z}} |f(t)|^2 < \infty\}$, munida de um produto interno, denotado por $\langle ; \rangle: l^2 \rightarrow \mathbb{C}$, isto é, $(l^2, \langle ; \rangle)$, é um caso particular de espaços de Hilbert (Kubrusly, 2001). De acordo com Kubrusly & Levan (2002), um subconjunto $\{h_n\}_{n \in \mathbb{Z}}$ de um espaço de Hilbert H é uma base ortonormal de H se, e somente se, satisfaz aos seguintes axiomas:

- (i) ortogonalidade: $\langle h_{n'}, h_m \rangle = 0, \forall n' \neq m$ e $\forall n', m \in \mathbb{Z}$;
- (ii) normalização: $\|h_{n'}\| = 1, \forall n' \in \mathbb{Z}$;
- (iii) completamento: $\langle x, h_{n'} \rangle = 0$ se, e somente se, $x = 0$.

De acordo com o Teorema da Série de Fourier (Kubrusly, 2001), se o subconjunto $\{h_n\}_{n \in \mathbb{Z}}$ é uma base ortonormal, então a identidade em (1) é uma expansão única x sobre H em termos da base ortonormal $\{h_n\}_{n \in \mathbb{Z}}$. A expansão em (1) é chamada de *Série de Fourier*.

$$x = \sum_{n \in \mathbb{Z}} \frac{\langle x, h_n \rangle}{\|h_n\|} h_n. \quad (1)$$

2.2 Função Wavelet

Considere um espaço de *Hilbert* $(l^2, \langle ; \rangle)$. Um elemento $\omega(\cdot) \in l^2$ - com um produto interno $\langle ; \rangle: l^2 \rightarrow \mathbb{C}$ - é chamado de função *wavelet* se, e somente se, as funções $\omega_{m,n}(\cdot) := \frac{m}{2^{\frac{m}{2}}} \omega(2^m(\cdot) - n)$, onde $n, m \in \mathbb{Z}$, formam uma base ortonormal para o espaço de *Hilbert* $(l^2, \langle ; \rangle)$. De acordo com Levan & Kubrusly (2003), qualquer função $f(\cdot)$ em $(l^2, \langle ; \rangle)$ admite a

expansão via Série de *Fourier*, em termos de uma base ortonormal *wavelet* $\{\omega_{m,n}(\cdot)\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$ de l^2 , conforme em (2).

$$f(\cdot) = \sum_{m \in \mathbb{Z}} \sum_{n \in \mathbb{Z}} \langle f(\cdot), \omega_{m,n}(\cdot) \rangle \omega_{m,n}(\cdot) \quad (2)$$

onde m é chamado de *parâmetro de escala* e n , de *parâmetro de translação* (Ogden, 1997).

De acordo com Levan & Kubrusly (2003), a projeção de $f(\cdot)$ sobre $\omega_{m,n}(\cdot)$ pode ser interpretada como uma *variação de detalhes* de $f(\cdot)$, na escala m e translação n . De acordo com Mallat (1998), o subespaço fechado (Kubrusly, 2001) $W_m(\omega) := \left(\text{span}\{\omega_{m,n}(\cdot)\}_{n \in \mathbb{Z}} \right)^-$ de $(l^2, \langle ; \rangle)$ é chamado de *subespaço de detalhes* (na escala m). Por sua vez, a projeção de $f(\cdot)$ sobre o subespaço (fechado) de detalhes $W_m(\omega)$, denotada por $f_{W_m(\omega)}(\cdot)$, é definida pela soma parcial descrita em (3).

$$f_{W_m(\omega)}(\cdot) := \sum_{n \in \mathbb{Z}} \langle f(\cdot), \omega_{m,n}(\cdot) \rangle \omega_{m,n}(\cdot) \quad (3)$$

De acordo com Levan & Kubrusly (2003), a projeção $f_{W_m(\omega)}(\cdot)$ pode ser referida como uma *componente de detalhes* de $f(\cdot)$, na escala m , sobre $(W_m(\omega), \langle ; \rangle)$. Como consequência, dada a identidade em (1), segue que $f(\cdot)$ pode ser interpretada como a soma de todas suas componentes de detalhes $f_{W_m(\omega)}(\cdot)$, em todas as escalas inteiras m sobre o subespaço fechado $((\sum_{n \in \mathbb{Z}} W_m(\omega))^- , \langle ; \rangle)$ de $(l^2, \langle ; \rangle)$. Tautologicamente, tem-se que $((\sum_{n \in \mathbb{Z}} W_m(\omega))^- , \langle ; \rangle) = (l^2, \langle ; \rangle)$.

Por sua vez, um elemento $\phi(\cdot) \in l^2$ - com um produto interno $\langle ; \rangle: l^2 \rightarrow \mathbb{C}$ - é chamado de função *wavelet* escala (ou função escala) se, e somente se, as funções $\phi_{m,n}(\cdot) := 2^{\frac{m}{2}} \phi(2^m(\cdot) - n)$, onde $n, m \in \mathbb{Z}$, são tais que $\langle \phi_{m',n'}(\cdot), \phi_{j,k}(\cdot) \rangle = 0$ sempre que $m' = j$ e $n' \neq k$, e $\langle \phi_{m',n'}(\cdot), \phi_{j,k}(\cdot) \rangle \neq 0$, caso contrário. De acordo com Mallat (1998), o subespaço fechado $V_m(\phi) := \left(\text{span}\{\phi_{m,n}(\cdot)\}_{n \in \mathbb{Z}} \right)^-$ de $(l^2, \langle ; \rangle)$ é chamado de *subespaço de aproximação* (na escala m). A projeção de $f(\cdot)$ sobre o subespaço fechado de aproximação $V_m(\phi)$ é definida pela soma parcial descrita em (4).

$$f_{V_m(\phi)}(\cdot) := \sum_{n \in \mathbb{Z}} \langle f(\cdot), \phi_{m,n}(\cdot) \rangle \phi_{m,n}(\cdot) \quad (4)$$

De acordo com Mallat (1998), $f_{V_m(\phi)}(\cdot)$ pode ser interpretada como uma *componente de aproximação* de $f(\cdot)$, na escala m , sobre o subespaço $(V_m(\phi), \langle ; \rangle)$ de $(l^2, \langle ; \rangle)$.

2.3 Transformada Wavelet

Por *transformada wavelet* sobre $(l^2, \langle ; \rangle)$, entende-se como sendo o produto interno $\langle ; \rangle: l^2 \rightarrow \mathbb{C}$ entre uma função $f(\cdot) \in l^2$ e uma função *wavelet* $\omega_{m,n}(\cdot) \in W_m(\omega)$ ou uma função escala $\phi_{m,n}(\cdot) \in V_m(\phi)$, $(m, n) \in \mathbb{Z} \times \mathbb{Z}$. De acordo com Mallat (1998), as transformadas *wavelet* podem ser classificadas e agrupadas em dois conjuntos disjuntos: *coeficientes de detalhes*, denotado por $\{d_{m,n}\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$, e *coeficientes de aproximação*, denotado por $\{a_{m,n}\}_{(m,n) \in \mathbb{Z} \times \mathbb{Z}}$. Para cada par ordenado $(m, n) \in \mathbb{Z} \times \mathbb{Z}$, tem-se que as transformadas *wavelet* $d_{m,n}$ e $a_{m,n}$ são definidas, respectivamente, por $d_{m,n} := \langle f(\cdot), \omega_{m,n}(\cdot) \rangle = \sum_{t \in \mathbb{Z}} f(t) \omega_{m,n}(t)$ e $a_{m,n} := \langle f(\cdot), \phi_{m,n}(\cdot) \rangle = \sum_{t \in \mathbb{Z}} f(t) \phi_{m,n}(t)$.

2.4 Expansão Wavelet

De acordo com Levan & Kubrusly (2003), uma cadeia de *subespaços de aproximação* $\{V_m(\phi)\}_{m \in \mathbb{Z}}$ em $(l^2, \langle \cdot, \cdot \rangle)$ é uma Análise Multirresolução Wavelet (ou AMR wavelet), com vetor escala $\phi(\cdot) \in l^2$, se, e somente se, os seguintes axiomas são satisfeitos.

- (a) $V_m(\phi) \subset V_{m+1}(\phi), \forall m \in \mathbb{Z}$;
- (b) $\bigcap_{m \in \mathbb{Z}} V_m(\phi) = \{0\}$;
- (c) $\left(\bigcup_{m \in \mathbb{Z}} V_m(\phi) \right)^- = H$;
- (d) $v \in V_m(\phi) \Leftrightarrow Dv \in V_{m-1}(\phi), m \in \mathbb{Z}$;
- (e) $\left\{ 2^{\frac{m}{2}} \phi(2^m(\cdot) - n) \right\}_{n \in \mathbb{Z}}$ é uma base ortonormal de $V_m(\phi), m \in \mathbb{Z}$.

Em Kubrusly & Levan (2002), mostra-se que um espaço de Hilbert l^2 pode ser expandido ortogonalmente tal como $l^2 = \left(\sum_{m \in \mathbb{Z}} W_m(\omega) \right)^-$ e, em Levan & Kubrusly (2003), mostra-se, utilizando-se os axiomas de uma AMR wavelet $\{V_m(\phi)\}_{m \in \mathbb{Z}}$, que a identidade $V_{m_0}(\phi) = \left(\sum_{-\infty}^{m_0-1} W_m(\omega) \right)^-$, para todo $m_0 \in \mathbb{Z}$, é verdadeira. Com base nas identidades $l^2 = \left(\sum_{m \in \mathbb{Z}} W_m(\omega) \right)^-$ e $V_{m_0}(\phi) = \left(\sum_{-\infty}^{m_0-1} W_m(\omega) \right)^-$, bem como no Teorema da Estrutura Ortogonal (Kubrusly, 2001), mostra-se, em Kubrusly & Levan (2002), que o espaço l^2 pode ser ortogonalmente expandido conforme em (5).

$$l^2 = V_{m_0}(\phi) + \left(\sum_{m=m_0+1}^{+\infty} W_m(\omega) \right)^- \quad (5)$$

Por consequência, segue que $f(\cdot)$ possui decomposição ortogonal (única), sobre o espaço de Hilbert $(l^2, \langle \cdot, \cdot \rangle)$, descrita em (6).

$$f(\cdot) = f_{V_{m_0}(\phi)}(\cdot) + \sum_{m=m_0+1}^{+\infty} f_{W_m(\omega)}(\cdot) \quad (6)$$

Dadas as definições das componentes wavelet $f_{V_{m_0}(\phi)}(\cdot)$ e $f_{W_m(\omega)}(\cdot)$ e as identidades (1) e (6), segue que a Série de Fourier da função $f(\cdot)$, sobre o espaço de Hilbert $(l^2, \langle \cdot, \cdot \rangle)$, em termos da base ortonormal wavelet $\left\{ \phi_{m_0,n}(\cdot) \right\}_{n \in \mathbb{Z}} \cup \left\{ \omega_{m,n}(\cdot) \right\}_{(m,n) \in \{m\}_{m_0}^{+\infty} \times \mathbb{Z}}$, é dada por:

$$f(\cdot) = \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n}(\cdot) + \sum_{m \geq m_0} \sum_{n \in \mathbb{Z}} d_{m,n} \omega_{m,n}(\cdot) \quad (7)$$

onde: $a_{m,n} := \sum_{t \in \mathbb{Z}} f(t) \phi_{m,n}(t)$, $d_{m,n} := \sum_{t \in \mathbb{Z}} f(t) \omega_{m,n}(t)$, onde $m_0 \leq m < +\infty$ e $m_0 \in \mathbb{Z}$.

3. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são sistemas paralelos distribuídos e compostos por unidades de processamento simples, denominadas neurônios artificiais, e dispostas em uma ou mais camadas interligadas por um grande número de conexões (sinapses), geralmente, unidirecionais (*feedforward*) e com pesos sinápticos para ponderação das entradas recebidas por cada neurônio. Na Figura 2(a), tem-se uma ilustração da arquitetura mais comum de uma RNA (*feedforward*) multicamadas *perceptron* (MLP) com três camadas: *camada de entrada (input)*, *camada escondida* (ou *intermediária*) e *camada de saída (output)*.

A primeira camada da rede neural artificial é a camada de entrada, sendo a única exposta aos padrões de entrada. A camada de entrada transmite os valores dos padrões de entrada para os neurônios da camada intermediária para que estes extraiam padrões e transmitam os resultados para a camada de saída (última camada da RNA). A definição do número de neurônios na camada intermediária é realizada de forma empírica (Haykin, 2001).

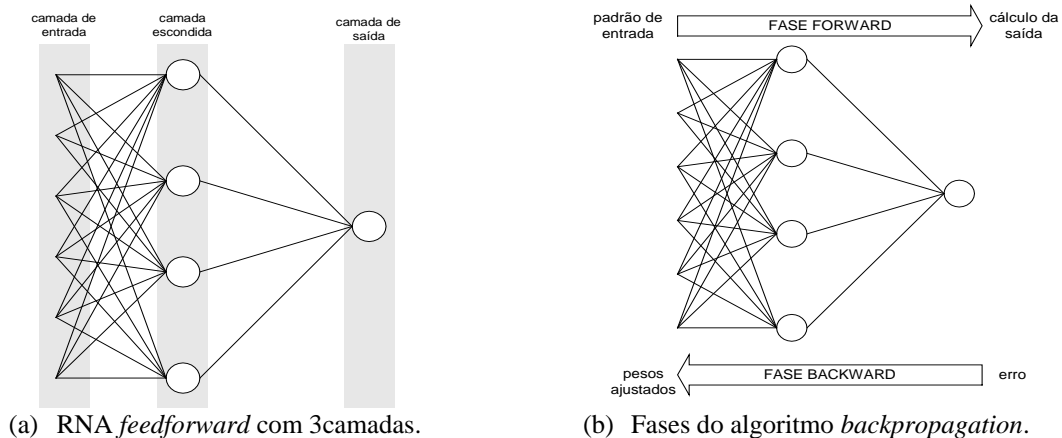


Figura 2 – Rede neural artificial *feedforward* MLP e algoritmo *backpropagation*.

O principal algoritmo de treinamento de redes neurais artificiais é o *backpropagation* (Haykin, 2001), cujo ajuste dos pesos sinápticos ocorre por meio de um processo de otimização realizado em duas fases: *forward* e *backward*, conforme ilustrado na Figura 2(b). Na fase *forward*, é calculada a resposta fornecida pela RNA para determinado padrão de entrada. Na fase *backward*, o desvio (ou *erro*) entre a *resposta da RNA* e a *resposta desejada* é utilizado no processo de ajuste dos pesos sinápticos. Ao longo do treinamento da RNA, os vários padrões de entrada e as respectivas respostas desejadas são apresentados à RNA, de forma que os pesos sinápticos sejam tais que minimizem a soma dos erros quadráticos (MSE).

A previsão de valores futuros de uma série temporal, por meio de uma RNA, inicia-se com a montagem do conjunto de padrões de treinamento (pares entrada/saída), o qual depende da definição do tamanho da janela L de tempo (para os valores passados da própria série temporal que se deseja prever e para as variáveis explicativas) e do horizonte de previsão h . Em um processo autoregressivo o padrão de entrada é formado pelos valores passados da própria série que se deseja prever.

Por sua vez, o padrão de saída desejada é o valor da observação da série temporal no horizonte de previsão. Na Figura 3 tem-se uma ilustração de como é construído o conjunto de treinamento para a previsão com RNA, em particular, é ilustrado o caso da previsão 1 passo à frente com base nos 4 últimos valores passados da série temporal. Note que a construção dos padrões de treinamento da rede consiste em mover as janelas de entrada e saída ao longo da série temporal, de modo que cada par de janelas (entrada/saída) é um padrão de treinamento.




Figura 3 – Obtenção do conjunto de treinamento a partir da série temporal

4. Combinação Redes Neurais Artificiais e Decomposição Wavelet

A combinação de Redes Neurais Artificiais (RNA) e Decomposição Wavelet (DW) pode ser realizada de diferentes maneiras. Por exemplo, pode-se aplicar a decomposição wavelet em uma série temporal de interesse e utilizar uma RNA para projetar cada componente wavelet, separadamente, e, ao final, somar suas previsões, a fim de obter a previsão da série temporal (Júnior et al., 2011). Outra opção consiste em usar as funções wavelet (normalizadas no intervalo [0,1]) como funções de ativação dos neurônios de uma RNA (Righeto et al, 2004).

Neste artigo, todavia, optou-se por um método de combinação em que as componentes wavelet de uma série temporal constituem os padrões de entrada de uma RNA feedforward MLP, cuja saída fornece a previsão da série temporal. O esquema proposto encontra-se ilustrado na Figura 4, no qual duas etapas podem ser destacadas:

- (1) decomposição wavelet de nível p (Júnior et al., 2011, Lei & Ran, 2008, Rocha & Alves da Silva, 2004) de uma série temporal $f(\cdot)$; e
- (2) apresentação das componentes wavelet de $f(\cdot)$ (oriundas da etapa 1) como entradas de uma RNA para a previsão da série temporal de interesse.

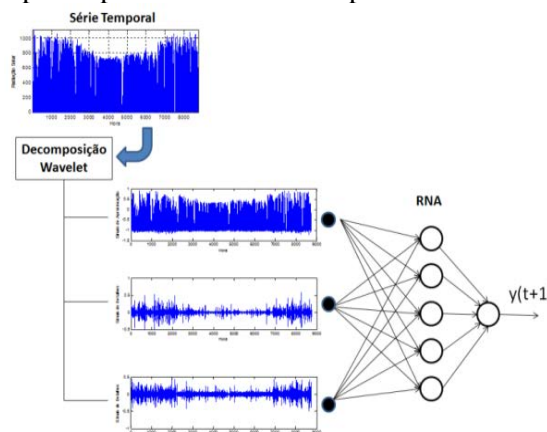


Figura 4 – Combinação da RNA com decomposição wavelet.

4.1 Decomposição Wavelet de Nível p

Seja $f(\cdot)$ uma série temporal em $(l^2, \langle \cdot, \cdot \rangle)$ e $\{\phi_{m_0, n}(\cdot)\}_{n \in \mathbb{Z}} \cup \{\omega_{n, m}(\cdot)\}_{(m, n) \in \{m_0\}^+ \times \mathbb{Z}}$ uma base ortonormal wavelet do espaço de Hilbert $(l^2, \langle \cdot, \cdot \rangle)$. De acordo com a identidade em (7), a decomposição wavelet de nível p (Júnior et al., 2011) de $f(\cdot)$, onde p é um número natural no intervalo $1 \leq p < \infty$, é representada pela série de Fourier (aproximada) descrita em (8).

$$f(\cdot) \simeq \tilde{f}(\cdot) = \sum_{n=1}^{n_{m_0}} a_{m_0, n} \phi_{m_0, n}(\cdot) + \sum_{n=1}^{n_m} \sum_{m=m_0}^{m_0+(p-1)} d_{m, n} \omega_{m, n}(\cdot). \quad (8)$$

Os valores ótimos dos parâmetros m_0 , n_{m_0} e $\{n_m\}_{m=m_0}^{m_0+(p-1)}$ são tais que minimizam a métrica euclidiana (Kubrusly, 2001) entre a série temporal $f(\cdot)$ e sua aproximação $\tilde{f}(\cdot)$. As componentes wavelet $f_{V_{m_0}(\phi)}(\cdot) := \sum_{n \in \mathbb{Z}} a_{m_0, n} \phi_{m_0, n}(\cdot)$ e $f_{W_m(\omega)}(\cdot) := \sum_{n \in \mathbb{Z}} d_{m, n} \omega_{m, n}(\cdot)$ são classificadas, respectivamente, como *componente de aproximação* (na escala m_0) e *componente de detalhe* (na escala m) da série temporal $f(\cdot)$ em $(l^2, \langle \cdot, \cdot \rangle)$. Dada a expansão em (8), segue que a série temporal $f(\cdot)$ pode ser expandido ortogonalmente sobre $(l^2, \langle \cdot, \cdot \rangle)$, conforme em (9).

$$f(\cdot) \simeq f_{V_{m_0}(\phi)}(\cdot) + \sum_{m=m_0}^{m_0+(p-1)} f_{W_m(\omega)}(\cdot). \quad (9)$$

onde $f_{V_{m_0}(\phi)}(\cdot) = \{f_{V_{m_0}(\phi)}(t)\}_{t \in \mathbb{Z}}$, para um inteiro fixo m_0 , e $f_{W_m(\omega)} = \{f_{W_m(\omega)}(t)\}_{t \in \mathbb{Z}}$, onde m é um inteiro no intervalo $m_0 \leq m \leq m_0 + (p - 1)$, sendo p o nível de decomposição *wavelet*.

4.2 Introdução das Componentes *Wavelets* na RNA

Considere uma RNA *feedforward* MLP. O conjunto de sinais temporais *wavelet* $\left\{ \left\{ f_{V_{m_0}(\phi)}(t) \right\}_{t=1}^T \right\} \cup \left\{ \left\{ f_{W_m(\omega)}(t) \right\}_{t=1}^T \right\}_{m=m_0}^{m_0+(p-1)}$, oriundos de $p+1$ componentes *wavelet* de uma série temporal de interesse $\{f(t)\}_{t=1}^T$ [seção 4.1] são tais que constituem o conjunto de padrões de entrada de uma RNA *feedforward* MLP para realização do processo de treinamento.

Considerando uma janela de tamanho igual a L valores passados, a previsão da série temporal (saída de RNA) para cada instante t' (nas amostras de treino, validação e de teste) é obtida a partir do conjunto de padrões de entrada descrito em (10).

$$\left\{ f_{V_{m_0}(\phi)}(t) \right\}_{t=t'-L}^{t'-1} \cup \left\{ \left\{ f_{W_m(\omega)}(t) \right\}_{t=t'-L}^{t'-1} \right\}_{m=m_0}^{m_0+(p-1)} \quad (10)$$

5. Experimento Computacional

No experimento computacional, considerou-se a série temporal horária de radiação solar direta durante o período de janeiro até dezembro de 2010 (Figura 5). A amostra considerada no treinamento da RNA contém as 7.008 primeiras observações de radiação solar, enquanto as 876 observações restantes pertencem às amostras de validação e de teste. O treinamento das redes neurais artificiais foi realizado no *software* MATLAB. Em todas as simulações, os padrões de entrada foram normalizados por meio da transformação *premnmx* e o algoritmo de treinamento utilizado foi o *Levenberg & Marquardt*.

Inicialmente, buscou-se a RNA (*feedforward* MLP) com o melhor ajuste à série de radiação solar direta. Os resultados são apresentados na seção 5.1. A melhor RNA identificada tem a seguinte estrutura topológica: tamanho de janela de entrada igual a 3, uma (1) camada escondida composta por 4 neurônios artificiais com função de ativação *tansig* e um (1) neurônio na camada de saída com função de ativação *purelin* (Haykin, 2001).

Na sequência, a série de radiação solar direta passou por uma decomposição *wavelet* de nível 2 (i.e., 3 componentes *wavelet*), na qual foi considerada a base ortonormal *wavelet* de Daubechies, com momento igual a 15 (ou, simplesmente, db15) (Daubechies, 1998). Os resultados são apresentados na seção 5.2. Após o pré-processamento da série temporal de radiação solar direta, a melhor RNA com entrada *wavelet* possui a seguinte estrutura topológica: tamanho de janela de entrada igual a 8 (isto é, cada padrão de entrada da RNA tem $3 \times 8 = 24$ sinais temporais *wavelet* defasados), uma (1) camada escondida composta por 5 neurônios artificiais com função de ativação *tansig* e um (1) neurônio na camada de saída com função de ativação *purelin* (Haykin, 2001).




Figura 5– Série temporal horária de radiação solar direta.

5.1 Resultados da RNA MLP

Na Figura 6 são apresentados os diagramas de dispersão entre os valores observados e previstos da radiação solar direta nas amostras de validação e de teste. Salienta-se que quanto

maior a proximidade dos pontos em relação à reta com 45° de inclinação, maior a correlação entre os valores observados da série temporal de radiação solar e suas respectivas previsões, logo, melhor a qualidade das previsões.

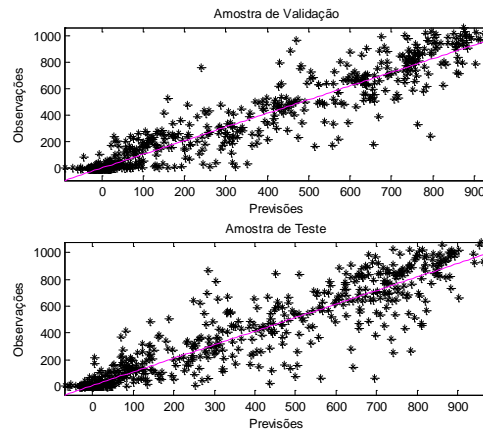


Figura 6– Diagrama de dispersão entre os valores observados e as previsões do método RNA.

5.2 Resultados da RNA com entrada *wavelet*

Na Figura 7 tem-se as componentes *wavelet* db15 resultantes da decomposição *wavelet* de nível 2 da série temporal de radiação solar direta.

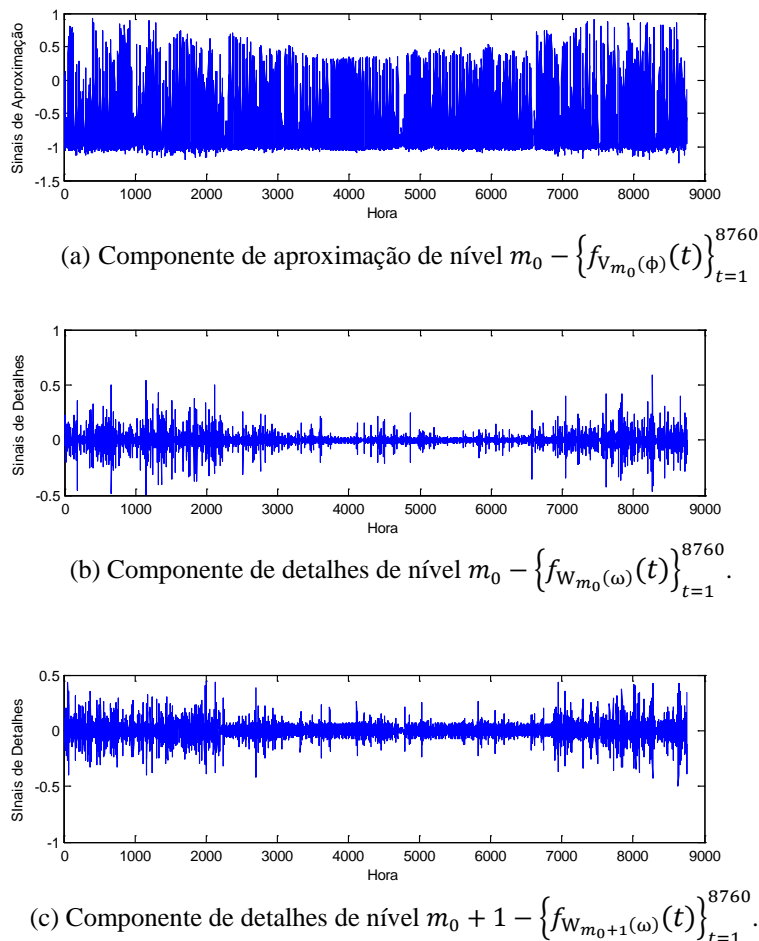


Figura 7 - Componentes *wavelet* da série temporal normalizada da radiação solar direta.

Na Figura 8, são apresentados os diagramas de dispersão das observações da série temporal de radiação solar direta e as respectivas previsões da RNA (com entrada *wavelet*), nas amostras de validação e de teste.

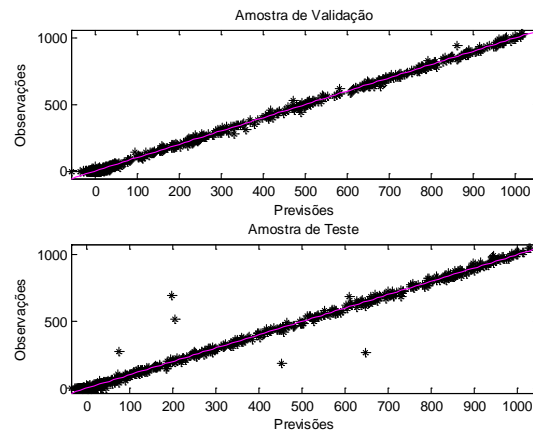


Figura 8 - Diagrama de dispersão entre os valores observados e previstos pelo método RNA-DW.

Na Figura 9, são mostrados os gráficos dos valores observados da série temporal de radiação solar direta e suas respectivas previsões geradas pelo método RNA-DW.

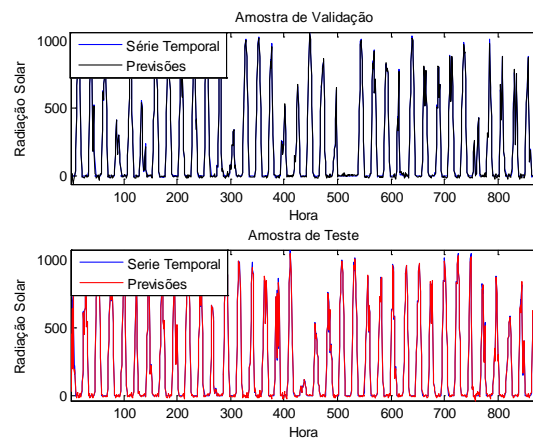


Figura 9 – Série temporal e as previsões do método RNA-DW.

6. Conclusões

Neste artigo foi proposta a combinação de Redes Neurais Artificiais (RNA), em particular a rede *feedforward* MLP, com a Decomposição *Wavelet* (DW) na previsão da radiação solar direta.

A partir da comparação das Figuras 6 e 8, verifica-se que as previsões oriundas do método RNA-DW possuem uma correlação significativamente maior com as observações da série temporal de radiação solar direta, quando comparado com as previsões oriundas da RNA convencional (isto é, sem considerar os sinais *wavelet* como padrões de entrada).

Por fim, convém salientar que, para se realizar de uma modelagem adequada e eficiente, é importante considerar a forma como uma série temporal é apresentada ao método preditivo. Em outras palavras, a escolha do pré-processamento dos dados de entrada de predictor (como, por exemplo, a decomposição *wavelet*) é tão importante quanto à escolha deste. Nesta perspectiva, a combinação de Redes Neurais Artificiais com a Decomposição *Wavelet* contempla estes dois aspectos. Destaca-se ainda que a aplicação do método proposto não se restringe ao caso das séries temporais de radiação solar direta, mas pode ser aplicado na previsão de qualquer série temporal.

Referências

- Cao, S., Weng, W., Chen, J., Liu, W., Yu, G., Cao, J.** (2009), Forecast of Solar Irradiance Using Chaos Optimization Neural Networks, Power and Energy Engineering Conference, Wuhan, March.
- Chaabene, M., Ben Ammar, M.** (2008), Neuro-fuzzy dynamic model with Kalmanfilter to forecast irradiance and temperature for solar energy systems, *Renewable Energy*, 33, pp. 1435-1443.
- Daubechies, I.** (1988), Orthonormal Bases of Compactly Supported Wavelet *s*. Comm. Pure and Applied Math., 41, pp.909-996.
- Deng, F., Su, G., Liu, C., Wang, Z.** (2010), Global Solar Radiation Modeling Using TheArtificial Neural Network Technique, *Power and Energy Engineering Conference*, Chengdu, March.
- Faria, D.L., Castro, R., Philippart, C., Gusmão, A.** (2009), Wavelet *s* Pre-Filtering in Wind Speed Prediction, *International Conference on Power Engineering, Energy and Electrical Drives, POWERENG*, Lisboa, Portugal.
- Grupo de Trabalho de Energia Solar – GTES**, *Manual de Engenharia para Sistemas Fotovoltaicos*, Centro de Pesquisas de Energia Elétrica – Cepel, Centro de Referência para Energia Solar e Eólica Sérgio de Salvo Brito – Cresesb, Rio de Janeiro, 2004.
- Haykin, S.**, *Redes Neurais Princípios e Aplicações*, segunda edição, Porto Alegre, 2001.
- Júnior, L.A.T., Pessanha, J.F.M., Souza, R.C.** (2011), Análise wavelet e redes neurais artificiais na previsão da velocidade de vento. In: *XLIII Simpósio Brasileiro de Pesquisa Operacional*, Ubatuba.
- Kubrusly, C.S.**, *Elements of Operator Theory*. Birkhäuser, Boston, 2001.
- 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
- Levan N., Kubrusly, C. S.** (2003), A Wavelet “Time-Shift-Detail” Decomposition. *Mathematics and Computers in Simulation* 63, 73-78.
- Mallat S.**, *A Wavelet Tour of Signal Processing*, Academic Press, San Diego, 1998.
- Ogden, R.T.**, *Essential wavelet *s* for statistical applications and data analysis*, Birkhäuser, Boston, 1997.
- Perdomo, R., Banguero, E., Gordillo, G.** (2010), Statistical modeling for global solar radiation forecasting in Bogotá, *Photovoltaic Specialists Conference*, Honolulu, June.
- Reis, L.B.**, Geração de Energia Elétrica: tecnologia, inserção ambiental, planejamento, operação e análise de viabilidade, Editora Manole, Barueri-SP, 2003.
- Righeto, E., Grassi, L.H.M., Pereira, J.A.** (2004), Wavenets and nonlinear plant identification, 59º Seminário Brasileiro de Análise, Ribeirão Preto-SP.
- 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.
- Wittmann, M., Breitkreuz, H., Schroedter-Homscheidt, S., Eck, M.** (2008), Case studies on the use of solar irradiance forecast for optimized operation strategies of solar thermal power plants, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 1, no 1, march, pp-18-27.
- Yanling, G., Changzheng, C., Bo, Z.** (2012), Blind source separation for forecast of solar irradiance, *Intelligent System Design and Engineering Application*, Sanya, China, January.
- Yona, A., Senjyu, T.** (2009), One-Day-Ahead 24-Hours Thermal Energy Collection Forecasting Based on Time Series Analysis Technique for Solar Heat Energy Utilization System, *Transmission & Distribution Conference & Exposition*, Seoul, October.

Zervas, P.L., Sarimveis, H., Palyvos, J.A., Markatos, N.C.G. (2008), Prediction of daily global solar irradiance on horizontal surfaces based on neural-network techniques, *Renewable Energy*, 33, pp 1796-1803.

Zhang, N., Behera, P.K. (2012), Solar radiation prediction based on recurrent neural networks trained by Levenberg-Marquardt backpropagation learning algorithm, *Innovative Smart Grid Technologies*, Washington, January.

Zhou, H., Sun, W., Liu, D., Zhao, J., Yang, N. (2011), The research of daily total solar-radiation and prediction method of photovoltaic generation based on wavelet-neural network, *Power and Energy Engineering Conference*, Wuhan, March.