

PREVISÕES PONTUAIS E INTERVALARES HÍBRIDAS DE DESLOCAMENTO DE BARRAGENS

**Jairo Marlon Corrêa¹, Anselmo Chaves Neto², Luiz Albino Teixeira Júnior³, Edgar
Manuel Carreño Franco⁴, Reinaldo Castro de Souza⁵, Álvaro Eduardo Faria⁶**

1: Departamento de Matemática
Universidade Tecnológica Federal do Paraná – UTFPR
Avenida Brasil, 4232; Medianeira, Paraná, Brasil; CEP: 85884-000
jairocorrea@utfpr.edu.br

2: Departamento de Estatística
Universidade Federal do Paraná – UFPR
Av Cel Francisco H dos Santos, s/n; Foz do Iguaçu, Paraná, Brasil; CEP: 81530-900
anselmo@ufpr.br

3: Departamento de Engenharia Elétrica
Universidade Federal da Integração Latino-Americana – UNILA
Avenida Silvio Américo Sasdelli, 1842; Foz do Iguaçu, Paraná, Brasil; CEP: 85866-000
luiz.a.t.junior@gmail.com

4: Centro de Engenharias e Ciências Exatas
Universidade Estadual do Oeste do Paraná – UNIOESTE
Av. Tarquínio Joslin dos Santos, 1300, Foz do Iguaçu, Paraná, Brasil; CEP: 85870-650
pgesde@unioeste.br

5: Centro de Engenharias e Ciências Exatas
Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio
Rua Marquês de São Vicente, 225, Rio de Janeiro – Rio de Janeiro; CEP: 22451-041
reinaldo@ele.puc-rio.br

6: Departamento de Matemática
The Open University
United Kingdom of Great Britain and Northern Ireland
alvaro.faria@open.ac.uk

Palavras-chave: Previsão, Decomposição Wavelet, Modelos ArimaX-Garch, Redes Neurais Artificiais

Resumo: Neste artigo é proposta uma metodologia híbrida chamada de ArimaX-Garch Wavelet Neural (AXGWN) cujo objetivo é gerar previsões pontuais e intervalares para uma série temporal de medições de deslocamento de um bloco da Usina Hidrelétrica de Itaipu, localizada em Foz do Iguaçu, Paraná, Brasil. Em linhas gerais, o método AXGWN é dividido em quatro passos: (1) faz-se uma decomposição wavelet de nível p da série temporal supracitada, de forma a produzir $p+1$ componentes wavelet (CWs); (2) cada CW do passo (1) é modelada por uma rede neural artificial (RNA), a fim de se gerar previsões fora da amostra; (3) As CWs do passo 1 são completadas pelas respectivas previsões, obtidas em (2), gerando-se as variáveis exógenas artificiais wavelet-neural; e (4) é feita a modelagem da série temporal deslocamento por meio de um modelo ArimaX-Garch cujas variáveis exógenas são as geradas no passo (3). Em todas as análises consideradas, a metodologia AXGWN obteve maior acurácia em termos preditivos fora da amostra.

1. INTRODUÇÃO

Desde os primórdios das civilizações, o uso da energia hidráulica teve importância devido à disponibilidade de recursos, facilidade de aproveitamento e, especialmente, seu caráter renovável. É sabido que a energia hidrelétrica contribuiu efetivamente para o desenvolvimento econômico de forma significativa como em atividades agrícolas, de serviços, comerciais e, também, no aumento do conforto das residências e aumento da qualidade de vida das pessoas. A energia hidráulica representa cerca de 20%, atualmente, de toda a eletricidade gerada no planeta; é utilizada como principal fonte na produção de energia elétrica em mais de 30 países, dentre os quais se destacam como maiores produtores mundiais: Canadá, China, Brasil, Estados Unidos e Rússia. De acordo com [1] estes países foram responsáveis por mais de 52% de toda a produção mundial de energia elétrica e, segundo o Balanço Energético Nacional de 2014 a contribuição da energia elétrica na matriz energética nacional foi de aproximadamente 79,5%. Fato é que a energia elétrica é a principal fonte geradora de energia elétrica no País, e continuará sendo por muitos anos. Somente a bacia do rio Paraná é responsável em quase 50% da capacidade hidrelétrica aqui instalada. Das fontes renováveis é considerada a de maior representatividade na matriz energética mundial por possuir tecnologias aprimoradas em produção de energia elétrica, basta considerar as usinas hidrelétricas já construídas.

Um belo exemplo da obra prima da engenharia, a usina hidrelétrica de Itaipu, é resultado dos esforços e do comprometimento de dois países vizinhos, Brasil e Paraguai, cuja origem das negociações ocorreu a partir de 1966 e na sequência foi criado o “Tratado de Itaipu”. Este tratado foi composto de 25 artigos que regulamentavam o aproveitamento de recursos hídrico do rio Paraná, a participação equilibrada na administração e execução do projeto, fornecimento equivalente de mão-de-obra. A Itaipu binacional é um dos maiores projetos hidrelétricos do mundo, considerando-se a produção anual. Localiza-se no rio Paraná a 14 km à montante da ponte internacional que liga a cidade de Foz do Iguaçu, no Brasil, à Ciudad del Este no Paraguai. O projeto da barragem da Itaipu foi bastante criterioso tanto em termos de investigação da rocha de fundação quanto dos materiais utilizados na construção das barragens, seguindo um minucioso controle de qualidade, além disso foram instalados milhares de instrumentos cujas leituras são feitas desde a época da construção. As campanhas de leituras e medições tem uma periodicidade que varia de semanal até semestral, conforme o tipo de instrumento. Além disso, cerca de 10% dos principais instrumentos foram automatizados para se obter leituras mais frequentes, permitindo estabelecimento de sistemas de alerta. A análise dos dados é feita por especialistas em segurança de barragens que emitem pareceres técnicos semestralmente e cada quatro anos todos os resultados e estudos são apresentados para uma junta de consultores internacionais que avaliam todos os aspectos relacionados à segurança de barragens. Pode-se dizer que a Itaipu mantém um rigoroso controle no que tange a segurança das suas estruturas civis e o desempenho apresentados pelas estruturas é muito bom.

As barragens são obras que requerem atenção às diversas condições de segurança estrutural e operacional, a fim de evitar algum dano em suas estruturas ou até mesmo ao meio ambiente e/ou perdas de vidas humanas. A identificação de problemas e execução de reparos diminui o fator risco, porém, esses estudos requerem muita atenção para a determinação de soluções adequadas. Por isso a usina de Itaipu foi concebida com um plano de auscultação que conta com mais de 2400 instrumentos e um sistema de drenagem com mais de 5000 drenos, instalados em suas estruturas e fundações, formando um banco de dados de mais de 30 anos.

Alguns blocos são designados blocos chave, pois são dotados de maior quantidade de instrumentos devido a sua importância para a região monitorada e características pré-definidas em projeto.

Em 2005, como parte de modernização da usina, foi implantado um sistema de aquisição de dados automáticos (ADAS), onde 10% dos instrumentos mais importantes foram automatizados, passando a ter leituras a cada 30 minutos, além da leitura manual já existente.

A barragem principal da usina de Itaipu é de concreto, do tipo gravidade aliviada. É composta por 18 blocos, onde estão as tomadas d'água de 16 unidades geradoras [2].

A água do reservatório exerce uma pressão na face montante da barragem e também exerce, nas partes inferiores dos blocos, uma subpressão ou empuxo hidrostático que cria um efeito contrário ao que a sua própria massa exerce sobre a fundação. Devido a essas duas forças, a barragem tem uma tendência a apresentar pequenos deslocamentos horizontais, principalmente no sentido montante-jusante. Em contrapartida, as forças estabilizantes ou a favor da segurança são o peso próprio da estrutura e o atrito entre a barragem e a rocha de fundação. De acordo com [1], foram instalados dois tipos de pêndulos instalados em trechos da Usina Hidrelétrica de Itaipu: o pêndulo direto e o invertido. O pêndulo direto é responsável em monitorar os deslocamentos horizontais de pontos dos blocos instrumentados da barragem em determinadas cotas, em relação à fundação da estrutura. Já o pêndulo invertido monitora os deslocamentos da fundação da barragem em relação ao contato concreto/rocha ou a alguma cota determinada no bloco de concreto.

É fato que a barragem acumula um pequeno deslocamento ao longo de 32 anos desde o enchimento do reservatório, porém dentro dos valores previstos em projeto. A análise dos dados dos pêndulos mostra que o deslocamento descreve um movimento que gera uma curva cujo comportamento é cíclico, influenciado pela temperatura ambiente. É observável, por meio do gráfico em planta nos pêndulos, que alguns blocos já se deslocaram cerca de 13mm em relação à fundação considerando o período de tempo desde o enchimento do lago. Esses deslocamentos são considerados pequenos e estão dentro dos limites de segurança estabelecidos no projeto. Mesmo assim, a equipe técnica da Itaipu vem acompanhando periodicamente as leituras de todos os instrumentos e incentivado estudos para aplicação de ferramentas matemáticas para atuar preventivamente ante quaisquer riscos potenciais.

Diante disso, diversos autores afirmam "Os maiores desastres de barragens de gravidade ocorreram por resistência inadequada ao movimento horizontal, isto é, ruptura por cisalhamento na fundação". Uma das grandes forças atuantes na barragem é a subpressão, a qual ocorre no sentido ascendente e que reduz o peso efetivo da estrutura. Tais efeitos podem gerar pequenos deslizamentos existentes no maciço rochoso.

Neste estudo, avalia-se a implementação de um modelo por meio do qual seja possível realizar a análise e a previsão do comportamento da estrutura da barragem. Tais informações permitirão medidas corretivas em planos de execução e/ou tomada de decisões já existentes. De posse destas informações, se abre um caminho de possibilidades de aplicação de técnicas matemáticas e estatísticas na previsão da série temporal que poderão operar em benefício da análise do desempenho estrutural da barragem Usina Hidrelétrica de Itaipu.

Assim sendo, neste artigo, é proposta uma metodologia híbrida chamada de ArimaX-Garch Wavelet Neural (AXGWN) cujo objetivo é gerar previsões pontuais e intervalares para uma série temporal de deslocamento de um bloco da Usina Hidrelétrica de Itaipu, localizada em Foz do Iguaçu, Paraná, Brasil. Em linhas gerais, o método AXGWN é dividido em quatro passos: (1) faz-se uma decomposição wavelet de nível p da série temporal supracitada, de forma a produzir $p+1$ componentes wavelet (CWs); (2) cada CW do passo (1) é modelada por uma rede neural artificial (RNA), a fim de se gerar previsões fora da amostra; (3) As CWs do passo 1 são completadas pelas respectivas previsões, obtidas em (2), gerando-se as variáveis exógenas artificiais wavelet-neural; e (4) é feita a modelagem da série temporal deslocamento por meio de um modelo WARIMAX-GARCH-NEURAL cujas variáveis exógenas são as geradas no passo (3). Em todas as análises consideradas, a metodologia AXGWN obteve maior acurácia em termos preditivos fora da amostra. Além da introdução o artigo está dividido em quatro

outras seções. Na Seção 2, é feita uma revisão sobre a Análise Wavelet e modelos Arima-Garch. Na Seção 3, é detalhada a metodologia proposta (WARIMAX-Garch). Na Seção 4, são apresentados os principais resultado obtidos a partir da modelagem via modelos ARIMA-GARCH e WARIMAX-GARCH-NEURAL de uma série temporal de deslocamento de barragens da Usina de Itaipu. E, por fim, na Seção 5, são tratados comentários finais.

2. REVISÃO DA LITERATURA

2.1 Análise Wavelet

Na Análise de Fourier, uma série temporal (unidimensional) de cardinalidade igual a T , denotada por $f(\cdot) := (f(1), f(2), \dots, f(T))$, é decomposta ortogonalmente, em termos de senos e cossenos definidos em diversas bandas de frequências [3]; enquanto que, na Análise Wavelet, $f(\cdot)$ é, de forma ortogonal, decomposta, simultaneamente, a partir de informações de escala e de translação capturadas a partir de um conjunto $\{\omega_{m,n}(\cdot)\}_{(m,n) \in \mathbb{Z}^2}$ de funções wavelet, onde

$\omega_{m,n}(\cdot) := 2^{\frac{m}{2}} \omega(2^m(\cdot) - n)$ é gerado por meio da dilatação (associada ao parâmetro m) e translação (associada ao parâmetro n) de uma função wavelet $\omega(\cdot)$ original [4-5]. Segundo [6], o parâmetro m é chamado de parâmetro de escala diádica e n , de parâmetro de translação unitária.

Em [5], pode-se verificar, empiricamente, que as funções wavelet $\omega_{m,n}(\cdot)$ estão associadas às componente wavelet de detalhe (isto é, as de alta frequência) de $f(\cdot)$; e, teórico e empiricamente, que a componente wavelet de aproximação (isto é, a de baixa frequência) de $f(\cdot)$ é gerada de uma combinação linear de funções escala em $\{\phi_{m_0,n}(\cdot)\}_{n \in \mathbb{Z}}$, onde: cada mapa $\phi_{m_0,n}(\cdot) := 2^{\frac{m_0}{2}} \phi(2^{m_0}(\cdot) - n)$, sendo que o parâmetro m_0 toma um valor inteiro fixo, é gerado por meio da translação unitária n de uma função escala original $\phi(\cdot)$ [6]. De acordo com [7], por definição, as funções wavelet e as funções escala consistem em ondas de curta duração, geralmente assimétricas, que permitem a sua dilatação diádica m (positiva ou negativa) e translação unitária n (positiva ou negativa) de seu domínio. Não obstante, definições mais formais e gerais, do ponto de vista matemático, podem ser verificadas em [5]. As famílias de bases ortonormais wavelet, em geral, são geradas por convoluções de $\omega(\cdot)$ e $\phi(\cdot)$. Em particular, as bases de Haar, Daubechies, Coifelet e Symelet são exemplos de famílias que, frequentemente, são utilizadas na modelagem de séries temporais, para fins de geração de previsões.

Baseado em [8-6], tem-se que a decomposição wavelet de uma série temporal $f(\cdot)$ é dada, genericamente, em (1).

$$f(\cdot) = f_{A_{m_0}}(\cdot) + \sum_{m=m_0}^{\infty} f_{D_m}(\cdot) \quad (1)$$

Onde: $f_{A_{m_0}}(\cdot) := \sum_{n \in \mathbb{Z}} a_{m_0,n} \phi_{m_0,n}(\cdot)$ é a componente de aproximação de nível m_0 de $f(\cdot)$; $f_{D_m}(\cdot) := \sum_{n \in \mathbb{Z}} d_{m,n} \omega_{m,n}(\cdot)$ é a componente de detalhe de nível m de $f(\cdot)$; $d_{m,n}$ e $a_{m_0,n}$ são, respectivamente, os coeficientes de detalhe e de aproximação e são calculados, ainda nesta ordem, a partir do produto interno usual entre $f(\cdot)$ e $\omega_{m,n}(\cdot)$ (isto é, $d_{m,n} := \sum_{t=1}^T f(t) \omega_{m,n}(t)$) e entre $f(\cdot)$ e $\phi_{m_0,n}(\cdot)$ (isto é, $a_{m_0,n} := \sum_{t=1}^T f(t) \phi_{m_0,n}(t)$), para todo $m_0, m, n \in \mathbb{Z}$.

Na prática, é usual que o parâmetro m_0 tome valor igual ao nível de decomposição r (isto é, truncamento na r -ésima componentes de aproximação). Por exemplo, em uma decomposição wavelet de nível 2 (isto é, $r = 2$) - onde o truncamento, em (1), ocorre na segunda componente de detalhe - se adota $m_0 = 2$. Assim, tem-se que a série temporal $f(\cdot)$ é expandida tal como: $f(\cdot) = f_{A_2}(\cdot) + f_{D_2}(\cdot) + f_{D_3}(\cdot) + \varepsilon$, onde ε é o vetor erro de aproximação. Independente do nível

r de decomposição wavelet, observa-se empiricamente que ε é, em geral, constituído de coordenadas muito próximas a zero, de modo que pode ser desconsiderado, para fins de modelagem, um vetor nulo.

2.3 Redes neurais artificiais

De acordo com [9], as redes neurais artificiais 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 1(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.

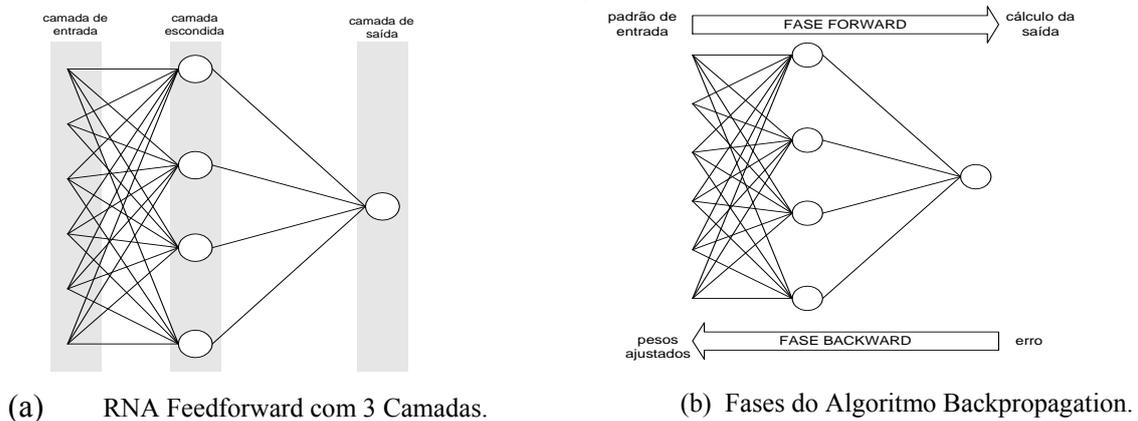


Figura 1 - Rede Neural Artificial Feedforward MLP e Algoritmo Backpropagation.

O principal algoritmo de treinamento de redes neurais artificiais é o backpropagation, cujo ajuste dos pesos sinápticos ocorre por meio de 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 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 [6]. 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 (linear ou não linear), 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 2, ilustra-se como geralmente é construído o conjunto de treinamento no caso da previsão basear-se nos 4 últimos valores passados. Note que a construção dos padrões de treinamento da rede consiste em mover as janelas de entrada e saída ao longo de

toda série temporal, de modo que cada par de janelas (entrada/saída) funciona como um padrão de treinamento e deve ser apresentado repetidas vezes até que o algoritmo de aprendizado convirja.

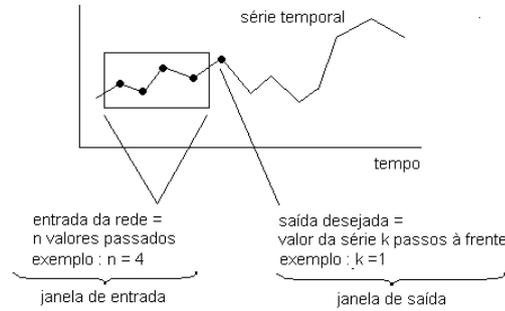


Figura 2 - Montagem do Conjunto de Treinamento.

2.3 Modelos ArimaX-Garch

Seja y_t ($t = 1, \dots, T$) uma série temporal estacionária que exibe estrutura de autodependência linear. Também, assuma que $\left((x_{1,t})_t^T, \dots, (x_{(r+1),t})_t^T \right)$ denote uma lista de $(r+1)$ vetores de realizações de $(r+1)$ variáveis exógenas (estacionárias) da série temporal y_t ($t = 1, \dots, T$). Com base em [10-11], cada realização y_t pode ser representada por um modelo ArimaX (p, d, q), de acordo com (2).

$$\nabla^d y_t = \phi_0 + \sum_{j=1}^p \phi_j y_{t-j} + \sum_{i=1}^q \theta_i e_{t-i} + \sum_{i=1}^{r+1} \sum_{l_i=0}^{L_i} \alpha_{il_i} x_{i,t-l_i} + e_t \quad (2)$$

Onde: B é o operador de atraso definido por $B^k y_t := y_{t-k}$, onde k pertence a \mathbb{Z} ; $\nabla^d := (1 - B)^d$ é o operador diferença, onde d é a ordem da diferenciação; $(\phi_i)_{i=0}^p$ e $(\theta_j)_{j=1}^q$ são listas ordenadas de parâmetros complexos do modelo, com $\phi_p \neq 0$ e $\theta_q \neq 0$, e $(\alpha_{il_i})_{l_i=0}^{L_i}$ é o i -ésimo vetor de parâmetros complexo associado à componente causal (onde estes três vetores de parâmetros precisam satisfazer tanto as condições de invertibilidade e quanto as de estacionariedade de segunda ordem) [11-12]; e_t é uma inovação no tempo t que consiste em uma realização de uma variável aleatória ε_t , onde ε_t ($t = 1, \dots, T$) é um processo estocástico com média zero e covariância constante; e p e q são, respectivamente, as ordens da parte auto-regressivas $\sum_{j=1}^p \phi_j y_{t-j}$ (notação: AR(p)) e da parte de médias móveis $\sum_{j=1}^q \theta_j e_{t-j}$ (notação: MA(q)). L_i é a ordem máxima do lag em $\sum_{l_i=0}^{L_i} \alpha_{il_i} x_{i,t-l_i}$ da variável exógena $x_{i,t}$, onde $i = 1, \dots, (r + 1)$. Por sua vez, um modelo estocástico SARIMA de ordem $(p,d,q) \times (P,D,Q)_S$, também conhecido como modelo multiplicativo ARIMA $(p,d,q) \times (P,D,Q)_S$ - o qual é constituído por uma componente sazonal da série de tempo subjacente [11] e consistem, em termos ferais, de um modelo ARIMA com componentes sazonais.

Note que o termo do erro e_t , em t , é a realização de uma variável randômica ε_t , com média zero e variância constante, isto é, $\sigma_{\varepsilon_t}^2 = \sigma^2$. Em alguns casos a heteroscedasticidade pode depender dos valores observados do passado da série temporal ou de valores passados da sua variância, de tal modo que um modelo AR, bem como suas extensões, pode ser adaptado para projetar a variação temporal. Desta forma, incondicionalmente, a variância é constante, mas condicionada a esses valores passados, poderá mudar temporalmente. Um modelo vastamente utilizado em sua modelagem é o chamado o Heteroscedasticidade Condicional Autorregressiva (GARCH). Segundo [13], O modelo geral GARCH (P,Q) para a variância condicional σ_t^2 de inovações ε_t é dado por:

$$h(\sigma_t^2) = \gamma_0 + \sum_{j=1}^P \gamma_j \sigma_{t-j}^2 + \sum_{i=1}^Q \delta_i e_t^2, \quad (3)$$

com as seguintes restrições: $\sum_{j=1}^P \gamma_j + \sum_{i=1}^Q \delta_i < 1$; $\gamma_0 > 0$; e $\gamma_j \geq 0$ ($j=1, \dots, P$) e $\delta_i \geq 0$ ($i=1, \dots, Q$). A função $h(\cdot)$ pode ser uma transformação identidade, a raiz quadrada ou uma função de logaritmo, dependendo de como a variância se comporta no tempo. Essa função é usada pelo método WARIMAX-GARCH para gerar previsões dentro e fora da amostra para a variância da série temporal y_t ($t = 1, \dots, T$).

Um modelo composto por (2) e (3), que representa as restrições acima mencionadas, é chamado de modelo ArimaX-Garch Wavelet Neural (AXGWN). Assim, para se obter o melhor modelo Arimax-Garch Wavelet Neural possível, três passos básicos deverão ser levadas em conta: (i) testar os valores dos parâmetros plausíveis p, d, q, I, L_i , em (2), bem como os parâmetros P e Q , em (3) (que pode ser obtido por meio da análise do gráfica das funções de autocorrelação simples e parcial das inovações padronizadas z_t ($t = 1, \dots, T$) e as inovações padronizadas quadráticas z_t^2 ($t = 1, \dots, T$), como descrito por [13-14]; (ii) definir o método para ser usado na estimação dos parâmetros do modelo ARIMAX-GARCH (o método mais comum é o da Máxima Verossimilhança) (MLE); e, (iii) Faça um teste de diagnóstico para escolher o modelo mais parcimonioso e adequado a ser usado para gerar t previsões de nível de y_t ($t = 1, \dots, T$), bem como de sua variância.

3. EXPERIMENTO COMPUTACIONAL

Nesta seção, os principais resultados de uma aplicação do método WARIMAX-GARCH Wavelet Neural a uma série temporal medida a cada meia hora de uma série de medidas de deslocamento de um bloco de barragem é descrita. Para fins de comparação, o modelo ARIMA-GARCH convencional também foi aplicado ao mesmo conjunto de dados. Na seção 3.1, os dados são descritos uma análise estatística inicial para justificar os modelos selecionados. Na seção 3.2, os modelos ARIMA-GARCH aplicados aos dados são identificados. Na seção 3.3 são apresentados os cinco passos básicos do método WARIMAX-GARCH Wavelet Neural aplicados ao conjunto de dados com os principais testes estatísticos utilizados para a sua validação. Na seção 3.4 é feita a conclusão com uma análise comparativa que mostra a eficácia da abordagem em termos de performances de previsão em relação aos modelos ARIMA-GARCH.

3.1 Série temporal do deslocamento

Uma série temporal de deslocamento físico de um bloco da barragem que abastece a Usina Hidrelétrica de Itaipu é modelada devido às suas propriedades de relevância e estatísticas. Na Figura 1, o gráfico mostra o comportamento temporal das 2.554 observações em intervalos diários, os quais foram coletados do sistema automatizado. Os dados correspondem a observações que datam de 28 de outubro de 2005 à 24 de outubro de 2012. As 2506 observações iniciais são usadas para treinamento dentro da amostra e as últimas 48 observações são usadas para testes fora da amostra para o modelo testado.

O teste de raiz unitária *Dikey-Fuller* Aumentado, ou teste ADF (*Augmented Dickey-Fuller*), não rejeita a hipótese de não estacionariedade da série a nível de 1% de significância. Não obstante, o ADF rejeitou fortemente a não estacionariedade, ao nível de 1% de significância, para a série transformada com a aplicação do logaritmo, bem como para a segunda diferença desta última.

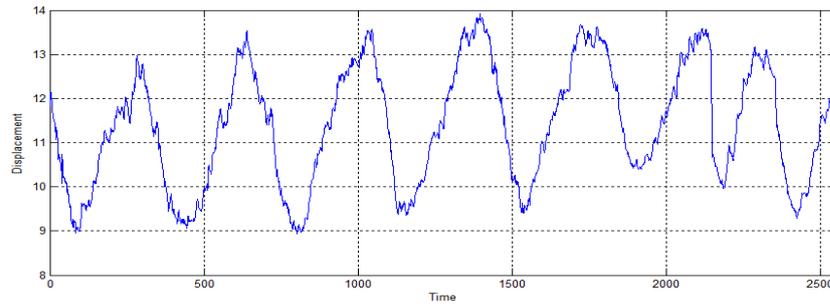


Figura 1 - Série Temporal de Descolamento.

O teste destaca a segunda diferença que aqui foi usada para a obtenção de melhor performance. As funções de autocorrelação da segunda diferença da série temporal de deslocamento do bloco da barragem mostrou valores significativamente, a 1%. Por conseguinte, uma vez que não houve variáveis exógenas, com correlação linear entre a série do deslocamento, disponíveis para serem usados num sistema convencional ARIMAX-GARCH. Isso sugere que um modelo ARIMA-GARCH pode ser um modelo plausível a ser adotado. A investigação conduzida nesta secção é a geração de múltiplos passos dentro e fora da amostra (pontual e intervalar) previstos por ambos os modelos ARIMA-GRACH (usado como modelo referência) e o método WARIMAX-GARCH-NEURAL. O diagnóstico dos resíduos para a validação estatística foram realizados o teste da raiz unitária com *Dickey-Fuller* aumentado, testes de Ljung-Box e Durbin-Watson para autocorrelações de primeira ordem, bem como os gráficos da ACF e FACP, teste BDS para detectar correlações não lineares da série e testes ARCH para a variância residual incondicionalmente constante [11]. Todos esses testes estatísticos foram realizados utilizando o software EViews 8.

3.2 O modelo ARIMA-GARCH

Dada a amostra de treinamento y_t ($t = 1, \dots, 2506$) da série temporal subjacente, o modelo ARIMA-GARCH que melhor se adéqua aos dados é o modelo ARIMA-GARCH (3,2,4) (2,1).. Como mencionado acima, a série temporal original foi transformada por uma aplicação de logaritmo seguido por uma dupla diferenciação. Todas as estimativas de seus parâmetros foram estatisticamente significativos. O método da máxima verossimilhança foi usado na estimação dos parâmetros do modelo ARIMA-GARCH (3, 2, 4) (2,1). Nas figuras 2 e 3, o teste Ljung-Box (Q-Stat) sugeriram que não havia nenhuma estrutura autodependência linear, dentro da amostra, para os resíduos quadráticos padronizados, a 1% de significância, até o lag 36. Além disso, o teste ARCH confirmou que não havia nenhuma estrutura heteroscedástica, a 1% de significância, até o lag 36. Além disso, a estatística Durbin-Watson de 2.092367 que sugere que não há autocorrelação de primeira ordem entre os resíduos ordinários padronizados.

Baseado nos p-valores da Tabela 1, é possível concluir que não há evidência, para todas as seis dimensões [15], de estruturas de autodependência linear e não linear nos resíduos de previsão dentro da amostra, ao nível de 1% de significância. Particularmente, a autodependência linear e quadrática, presente anteriormente nos resíduos de previsão, foram modeladas adequadamente pelo modelo ARIMA-GARCH especificado a seguir. Portanto, o resíduo de previsão dentro da amostra pode ser considerado como um processo ruído branco. Por fim, vale ressaltar que a seleção do modelo entre todos os modelos ARIMA-GARCH plausíveis identificados foi determinada pela comparação dos desempenhos de previsão de cada modelo candidato medida por: erro absoluto percentual (APE), *Erro Absoluto Médio Percentual* (MAPE), Média do erro absoluto (MAE) e R^2 . O modelo melhor selecionado, aquele com menor APE, MAPE e MAE e com o maior valor de R^2 , é descrito na seção seguinte.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.021	-0.021	1.0781	
		2 0.013	0.013	1.5119	
		3 0.001	0.002	1.5164	
		4 0.025	0.025	3.1276	
		5 0.027	0.028	5.0089	0.025
		6 0.033	0.033	7.7102	0.021
		7 0.021	0.022	8.8475	0.031
		8 0.007	0.006	8.9698	0.062
		9 0.026	0.025	10.707	0.058
		10 0.020	0.019	11.760	0.068
		11 0.034	0.031	14.587	0.042
		12 0.021	0.020	15.748	0.046
		13 0.013	0.011	16.201	0.063
		14 0.025	0.022	17.754	0.059
		15 0.012	0.009	18.124	0.079
		16 0.012	0.007	18.483	0.102
		17 0.029	0.025	20.638	0.080
		18 0.037	0.033	24.051	0.045
		19 0.032	0.029	26.669	0.032
		20 0.013	0.010	27.129	0.040
		21 0.026	0.021	28.873	0.036
		22 0.026	0.021	30.529	0.033
		23 0.010	0.003	30.781	0.043
		24 0.029	0.021	32.842	0.035
		25 0.005	-0.002	32.895	0.047
		26 0.018	0.011	33.746	0.052
		27 0.031	0.024	36.139	0.040
		28 0.028	0.021	38.154	0.033
		29 0.020	0.014	39.200	0.035
		30 0.027	0.020	41.042	0.031
		31 0.033	0.026	43.726	0.022
		32 0.015	0.008	44.288	0.026
		33 0.036	0.027	47.617	0.016
		34 0.010	0.003	47.871	0.020
		35 0.001	-0.009	47.872	0.027
		36 0.007	-0.003	48.004	0.034

Figura 2 – FAC e FACP dos Resíduos ordinários padronizados.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.001	-0.001	0.0019	0.965
		2 -0.001	-0.001	0.0044	0.998
		3 -0.001	-0.001	0.0074	1.000
		4 -0.001	-0.001	0.0093	1.000
		5 -0.001	-0.001	0.0118	1.000
		6 -0.001	-0.001	0.0125	1.000
		7 -0.001	-0.001	0.0143	1.000
		8 -0.001	-0.001	0.0172	1.000
		9 -0.001	-0.001	0.0199	1.000
		10 -0.001	-0.001	0.0230	1.000
		11 -0.001	-0.001	0.0252	1.000
		12 -0.000	-0.000	0.0255	1.000
		13 -0.001	-0.001	0.0283	1.000
		14 -0.001	-0.001	0.0314	1.000
		15 -0.000	-0.000	0.0317	1.000
		16 -0.001	-0.001	0.0345	1.000
		17 -0.001	-0.001	0.0357	1.000
		18 -0.000	-0.000	0.0361	1.000
		19 -0.001	-0.001	0.0381	1.000
		20 -0.001	-0.001	0.0402	1.000
		21 -0.001	-0.001	0.0434	1.000
		22 -0.001	-0.001	0.0463	1.000
		23 -0.001	-0.001	0.0491	1.000
		24 -0.001	-0.001	0.0504	1.000
		25 -0.001	-0.001	0.0527	1.000
		26 -0.001	-0.001	0.0552	1.000
		27 -0.001	-0.001	0.0577	1.000
		28 -0.001	-0.001	0.0602	1.000
		29 -0.001	-0.001	0.0627	1.000
		30 -0.001	-0.001	0.0646	1.000
		31 -0.001	-0.001	0.0657	1.000
		32 -0.001	-0.001	0.0685	1.000
		33 -0.001	-0.001	0.0709	1.000
		34 -0.001	-0.001	0.0737	1.000
		35 -0.001	-0.001	0.0762	1.000
		36 -0.000	-0.000	0.0767	1.000

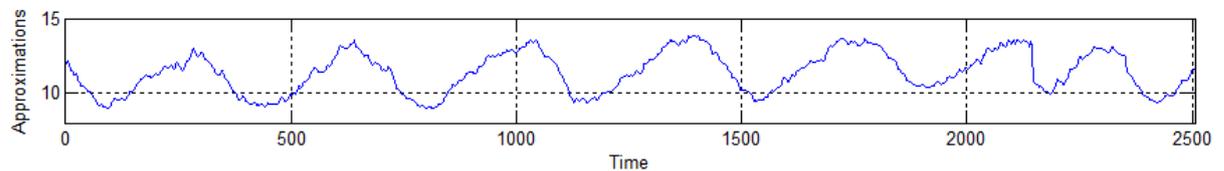
Figura 3 – FAC e FACP dos resíduos quadráticos padronizados.

Dimensão	Estatística BDS	p-valoers
2	-3.22E-07	0.9840
3	-9.65E-07	0.9785
4	-1.93E-06	0.9743
5	-3.22E-06	0.9707
6	-4.83E-06	0.9675

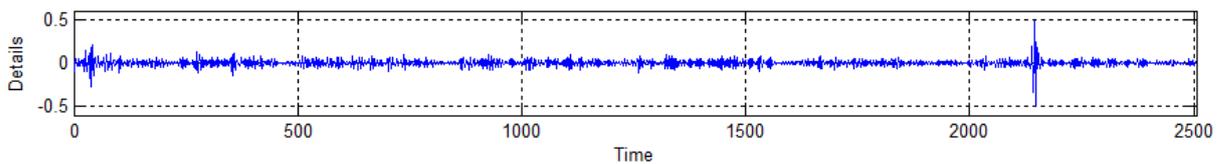
Tabela 1 –Teste BDS dentro da amostra dos resíduos ordinários padronizados.

3.3 O modelo WARIMAX-GARCH

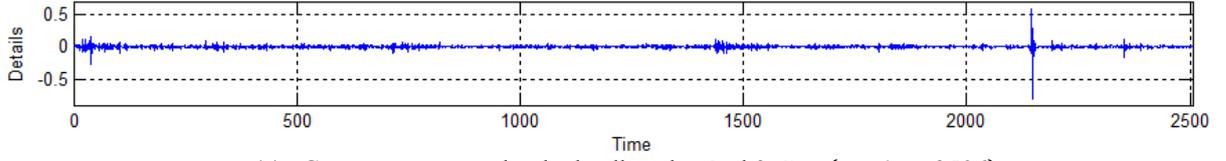
O primeiro passo para o método WARIMAX-GARCH é sua implementação no MATLAB (versão 2013a). A decomposição wavelet de nível 2 foi obtida pela amostra de treino da série do deslocamento horizontal do bloco. A componente wavelet com a base ortonormal db40 (onde, db40 é descrito em [7]) pode ser visto na Figura 4.



(a) Componente wavelet de aproximação de nível 2, $\tilde{y}_{A_2,t}(t = 1, \dots, 2506)$.



(b) Componente wavelet de detalhes de nível 2, $\tilde{y}_{D_2,t}(t = 1, \dots, 2506)$.



(c) Componente wavelet de detalhes de nível 3, $\tilde{y}_{D3,t}$ ($t = 1, \dots, 2506$).

Figura 4 – Componentes wavelet da série de deslocamento de um bloco de barragem

Sabe-se que $y_t = \tilde{y}_{A2,t} + \tilde{y}_{D2,t} + \tilde{y}_{D3,t} + \varepsilon$ ($t = 1, \dots, 2506$), onde: ε é um visto como um vetor nulo (i.e., $\varepsilon = 0$). No passo 2 do método WARIMAX-GARCH, cada uma das três componentes $\tilde{y}_{A2,t}$, $\tilde{y}_{D2,t}$ e $\tilde{y}_{D3,t}$ foram modeladas usando uma RNA, gerando as sequências de previsões para o seu nível, denotas por: $\hat{y}_{A2,t}$, $\hat{y}_{D2,t}$ e $\hat{y}_{D3,t}$ ($t = 2507, \dots, 2554$). Adotou-se um horizonte de previsão $h=48$, com 48 passos a frente (isso equivale a 48 instantes de previsão). Todos os parâmetros estimados pelos três modelos foram estatisticamente significativos, ao nível de 1%.

No passo 3, As três componentes wavelet completadas (denotadas por $\tilde{y}_{A2,t,C}$, $\tilde{y}_{D2,t,C}$ e $\tilde{y}_{D3,t,C}$ ou, equivalentemente, x_1 , x_2 e x_3) consistem de variáveis exógenas wavelet geradas a partir da própria série temporal. Conforme mencionado, as referidas são facilmente obtidas pelo completamento das componentes wavelet com previsões geradas fora da amostra no passo 2. Algebricamente, isso significa que:

- I. $x_{1,t} = \tilde{y}_{A2,t,C} := \left(\left(\tilde{y}_{A2,t} \right)_{t=1}^{2506} ; \left(\hat{y}_{A2,t} \right)_{t=2507}^{2554} \right)$;
- II. $x_{2,t} = \tilde{y}_{D2,t,C} := \left(\left(\tilde{y}_{D2,t} \right)_{t=1}^{2506} ; \left(\hat{y}_{D2,t} \right)_{t=2507}^{2554} \right)$; e
- III. $x_{3,t} = \tilde{y}_{D3,t,C} := \left(\left(\tilde{y}_{D3,t} \right)_{t=1}^{2506} ; \left(\hat{y}_{D3,t} \right)_{t=2507}^{2554} \right)$.

No passo 4, usando as variáveis exógenas $x_{i,t}$ ($i=1,2,3$), o modelo WARIMAX-GARCH foi ajustado e depois usado para gerar previsões de 48passos à frente em relação ao nível e à variância da série histórica. A função WARIMAX que melhor modelou a série é dada por:

$$\begin{aligned} \hat{y}_t = & x_{1,t-1} \times 1.38298232989 - x_{1,t-2} \times 0.383871938428 + x_{2,t-1} \times 1.22288709773 - \\ & x_{3,t-2} \times 0.488659896985 - y_{t-1} \times 0.235082399151 + y_{t-3} \times 0.235082399151 + \\ & y_{t-4} \times 0.721450081095 - y_{t-5} \times 0.23553545046 + \hat{\varepsilon}_{t-2} \times 0.0617467629966 - \\ & \hat{\varepsilon}_{t-3} \times 0.489351187041 - \hat{\varepsilon}_{t-4} \times 0.475632809678 + \hat{\varepsilon}_{t-5} \times 0.363586761893 + \\ & \hat{\sigma}_t^2 \times 2.56991622814. \end{aligned}$$

Nota-se que todas as três variáveis exógenas wavelet defasadas (por I, II e III) foram requeridas no modelo WARIMAX acima. Além disso, a previsão da variância $\hat{\sigma}_t^2$ traz um efeito não linear para a construção da previsão de \hat{y}_t na média. Além disso, o melhor modelo GARCH é o GARCH (1,1), com distribuição GED [11] para os resíduos padronizados [14] resultou no modelo abaixo:

O método da Máxima Verossimilhança tem sido usado para obter todas as melhores estimativas para os parâmetros do modelo WARIMAX-GARCH-NEURAL, e todos os valores estimados são estatisticamente significantes ao nível de 1%.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	-0.008	-0.008	0.1531		
2	-0.050	-0.050	6.3235		
3	-0.016	-0.017	6.9561		
4	-0.011	-0.014	7.2530		
5	-0.001	-0.003	7.2569		
6	0.006	0.005	7.3610		
7	0.004	0.003	7.3970		
8	-0.010	-0.010	7.6477		
9	0.001	0.001	7.6512		
10	0.022	0.022	8.9088	0.012	
11	0.007	0.007	9.0266	0.029	
12	-0.014	-0.012	9.5305	0.049	
13	-0.003	-0.002	9.5503	0.089	
14	-0.001	-0.001	9.5514	0.145	
15	-0.003	-0.003	9.5729	0.214	
16	0.017	0.016	10.304	0.244	
17	-0.002	-0.002	10.311	0.326	
18	0.034	0.036	13.227	0.211	
19	0.007	0.008	13.353	0.271	
20	0.032	0.035	15.929	0.195	
21	0.004	0.007	15.979	0.250	
22	0.005	0.010	16.036	0.311	
23	-0.004	-0.002	16.078	0.377	
24	0.003	0.004	16.097	0.446	
25	-0.002	-0.002	16.104	0.516	
26	0.028	0.028	18.115	0.448	
27	0.001	0.001	18.116	0.515	
28	0.017	0.019	18.842	0.532	
29	0.001	0.002	18.846	0.595	
30	0.046	0.049	24.202	0.337	
31	0.001	0.003	24.205	0.393	
32	0.029	0.035	26.329	0.337	
33	0.008	0.011	26.487	0.382	
34	-0.011	-0.006	26.773	0.421	
35	-0.007	-0.005	26.893	0.470	
36	-0.008	-0.011	27.042	0.516	

Figura 5 – FAC e FACP dos resíduos ordinários padronizados.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.004	0.004	0.0343	0.853	
2	0.008	0.008	0.2130	0.899	
3	-0.002	-0.002	0.2233	0.974	
4	-0.000	-0.000	0.2235	0.994	
5	-0.003	-0.003	0.2396	0.999	
6	0.001	0.001	0.2433	1.000	
7	-0.003	-0.003	0.2594	1.000	
8	-0.000	-0.000	0.2599	1.000	
9	-0.003	-0.003	0.2763	1.000	
10	0.000	0.000	0.2768	1.000	
11	-0.002	-0.002	0.2922	1.000	
12	0.001	0.001	0.2931	1.000	
13	-0.003	-0.003	0.3097	1.000	
14	0.000	0.000	0.3103	1.000	
15	-0.003	-0.002	0.3261	1.000	
16	0.001	0.001	0.3311	1.000	
17	-0.003	-0.003	0.3476	1.000	
18	-0.000	-0.000	0.3481	1.000	
19	-0.002	-0.002	0.3637	1.000	
20	0.000	0.000	0.3640	1.000	
21	-0.003	-0.003	0.3810	1.000	
22	-0.000	-0.000	0.3811	1.000	
23	-0.003	-0.003	0.3986	1.000	
24	-0.001	-0.001	0.4002	1.000	
25	-0.003	-0.003	0.4171	1.000	
26	-0.000	-0.000	0.4171	1.000	
27	-0.003	-0.003	0.4341	1.000	
28	0.000	0.000	0.4342	1.000	
29	-0.003	-0.002	0.4503	1.000	
30	0.002	0.002	0.4642	1.000	
31	-0.003	-0.003	0.4808	1.000	
32	-0.001	-0.001	0.4816	1.000	
33	-0.003	-0.003	0.4983	1.000	
34	0.001	0.001	0.4991	1.000	
35	-0.003	-0.002	0.5155	1.000	
36	0.002	0.002	0.5232	1.000	

Figura 6 – FAC e FACP dos resíduos quadráticos padronizados.

As figuras 5 e 6 mostram que a FAC e a FACP (até o lag 36) dos resíduos ordinários e dos resíduos quadráticos pa, respectivamente, para o modelo WARIMAX-GARCH-NEURAL. Note que para todos os lags até 36, a FAC e a FACP estão dentro dos intervalos de confiança de 99%, sugerindo que estes valores são todos não-significativos. A estatística de Ljung-Box (Q-Stat) sobre esses números também sugerem que não há significância (ao nível de 1%) de autodependência linear dentro da amostra para os resíduos ordinários e quadráticos para o modelo WARIMAX-GARCH-NEURAL. Também, note que o teste ARCH (Prob) na Figura 6 confirmou a variância residual constante. A estatística Durbin-Watson foi 2.026328 confirmando a ausência de autocorrelação de primeira ordem de nos resíduos.

As figuras 5 e 6 mostram que a FAC e a FACP (até o lag 36) dos resíduos ordinários e dos resíduos quadráticos pa, respectivamente, para o modelo WARIMAX-GARCH-NEURAL. Note que para todos os lags até 36, a FAC e a FACP estão dentro dos intervalos de confiança de 99%, sugerindo que estes valores são todos não-significativos. A estatística de Ljung-Box (Q-Stat) sobre esses números também sugerem que não há significância (ao nível de 1%) de autodependência linear dentro da amostra para os resíduos ordinários e quadráticos para o modelo WARIMAX-GARCH-NEURAL. Também, note que o teste ARCH (Prob) na Figura 6 confirmou a variância residual constante. A estatística Durbin-Watson foi 2.026328 confirmando a ausência de autocorrelação de primeira ordem de nos resíduos.

Dimensões	Estatística BDS	p-valores
2	-3.22E-07	0.9840
3	-9.65E-07	0.9785
4	-1.93E-06	0.9743
5	-3.22E-06	0.9707
6	-4.83E-06	0.9675

Tabela 2 – Teste BDS dentro da amostra para os resíduos ordinários padronizados.

Com base nos p-valores da Tabela 2, pode-se concluir que não há nenhuma evidência forte (a 1% de nível) de estrutura de autodependência linear ou não linear dos resíduos ordinários padronizados, dentro da amostra, para todas as dimensões. Particularmente, a autodependência linear e quadrática anteriormente presentes nos resíduos ordinários padronizados foram devidamente modelados pelo modelo WARIMAX-GARCH-NEURAL adotado anteriormente. Portanto, os resíduos padronizados em amostras normais podem ser consideradas como uma realização de um processo estocástico de ruído branco, validando o modelo WARIMAX-GARCH-NEURAL.

3.4 Comparativos de desempenhos das previsões

A Tabela 3 mostra as estatísticas MAPE e MAE para dados dentro e fora da amostra e os desempenhos de previsão do modelo ARIMA-GARCH (3, 2, 4) (2, 1) e do modelo WARIMAX-GARCH-NEURAL. Pode-se ver a partir desses resultados que o método WARIMAX-GARCH-NEURAL obteve valores menores para MAPE e MAE, e assim, melhor desempenho do que o modelo ARIMA-GARCH tanto dentro da amostra e fora da amostra. Em particular, o método WARIMAX-GARCH produziu grandes melhorias em performances de fora da amostra de previsão com 0,899% e 0,1065 MAPE MAE contra 5,324% MAPE e 0,6368 MAE para o modelo ARIMA-GARCH. Decorre-se destes resultados que a uso de componentes wavelet exógenos implica em um significativo ganho de previsão, tanto dentro da amostra e (em particular) para fora da amostra. Em outras palavras, a WARIMAX-GARCH-NEURAL melhor modelou a dinâmica da série temporal a que se refere e produziu previsões melhores do que o modelo ARIMA-GARCH convencional.

A figura 7 mostra o gráfico do erro percentual absoluto (APE) calculado para as previsões fora da amostra em cada passo à frente, para ambos os modelos. Note que o modelo WARIMAX-GARCH-NEURAL não só tinha APEs mais baixos do que o modelo ARIMA-GARCH para cada previsão 48 passo à frente, mas também produziu comparativamente melhores previsões para maiores passos em frente. De fato, enquanto os erros de previsão do modelo ARIMA-GARCH mostraram uma tendência positiva (crescimento de pouco menos de 1% a cerca de 9%) o método proposto WARIMAX-GARCH-NEURAL mostraram flutuações ao longo da linha 1%, com o aumento do horizonte de previsão.

METHODS	MAPE		MAE	
	<i>Dentro da Amostra</i>	<i>Fora da Amostra</i>	<i>Dentro da Amostra</i>	<i>Fora da Amostra</i>
ARIMA-GARCH	0.398%	5.324%	0.0448	0.6368
WARIMAX-GARCH-NEURAL	0.300%	0.899%	0.0338	0.1065

Tabela 3 - Performance de previsões para os modelos ARIMA-GARCH e WARIMAX-GARCH-NEURAL para dados dentro e for a da amostra de teste

As Figuras 8 (a) e (b) mostram os gráficos dos deslocamentos reais observados em conjunto as previsões pontuais e associados de 99% dos limites de previsão superior e inferior por (a) o modelo ARIMA-GARCH e (b) o método WARIMAX-GARCH-NEURAL. Observe que na Figura 8 (a) a previsões do modelo ARIMA-GARCH foram maiores do que os valores observados em cada tempo, porém tudo dentro dos intervalos de predição de 99%. Por outro lado, na Figura 8 (b), as previsões pelo método WARIMAX-GARCH-NEURAL rastreado a tendência em deslocamento mais estreito e também foram todos dentro dos intervalos de 99%

de previsão cujos limites eram muito menores do que as do modelo ARIMA-GARCH. Isto é, a variação da densidade preditiva de WARIMAX-GARCH-NEURAL era menor. Este gráfico também mostra a dinâmica das previsões produzidas pelo método WARIMAX-GARCH-NEURAL que tentou projetar as oscilações dos deslocamentos para o "futuro".

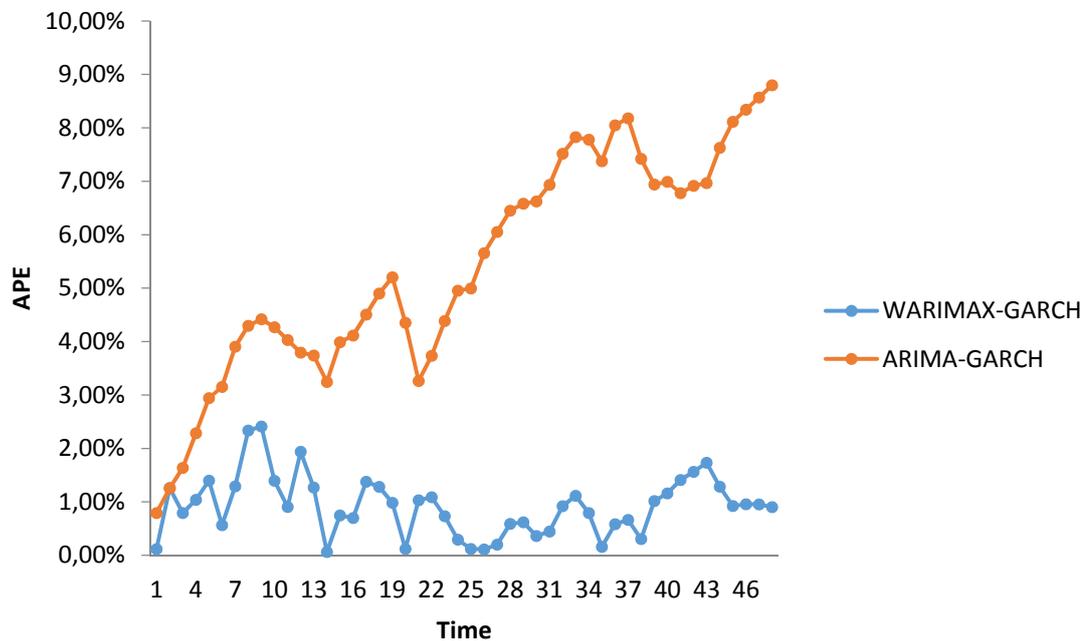
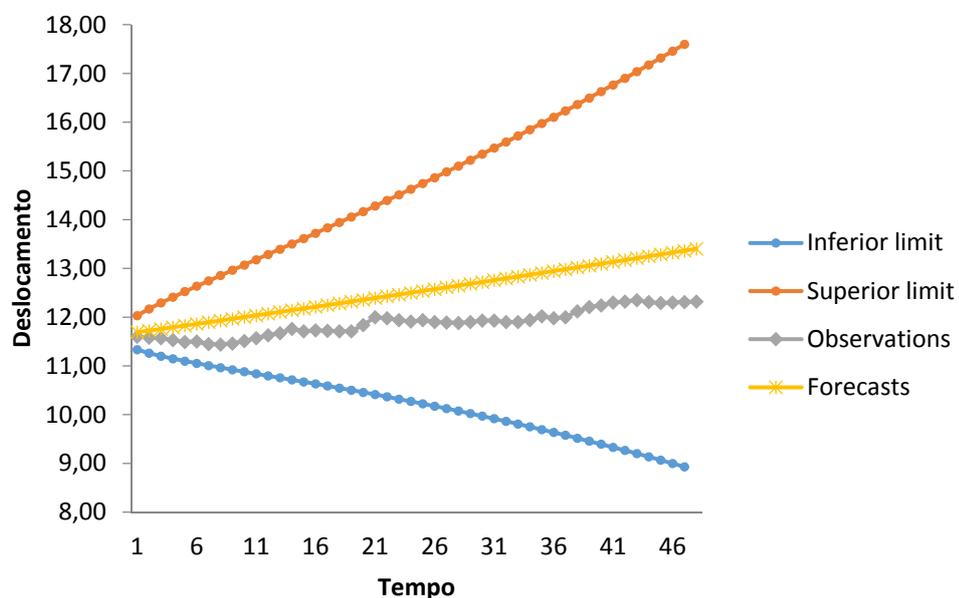


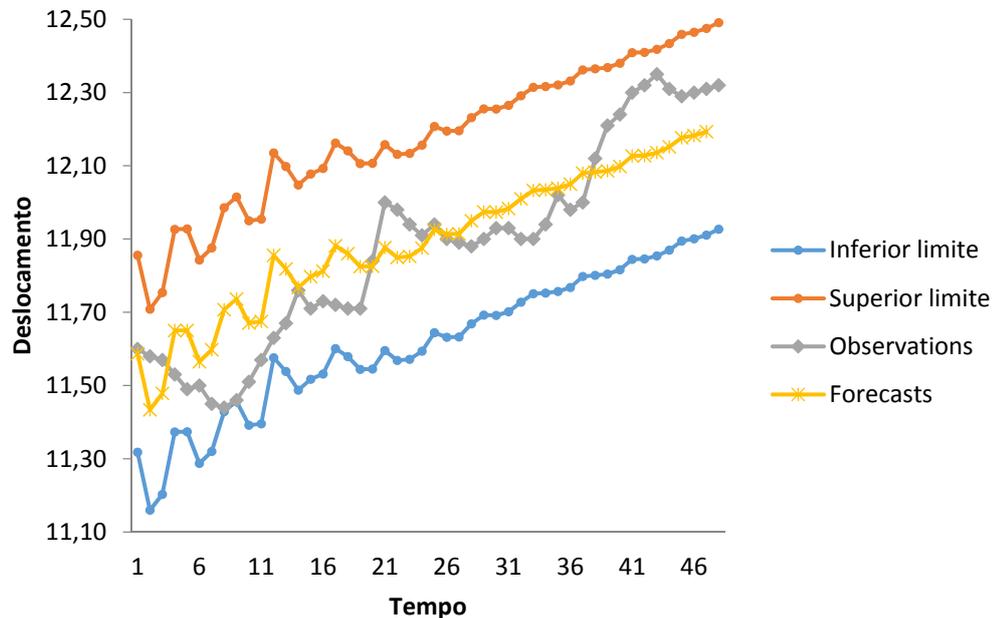
Figura 7 – Comparação da Evolução temporal do erro percentual absoluto para WARIMAX-GARCH-NEURAL e ARIMA-GARCH.



(a) Evolução do intervalo de confiança para ARIMAX-GARCH.

Em termos do coeficiente R^2 , usado para medir a quantidade de variação na série que é explicado pelo modelo, o modelo ARIMA-GARCH $R^2 = 0.361378$ e o método WARIMAX-GARCH-NEURAL tem $R^2 = 0.997249$. Estes resultados mostram que WARIMAX-GARCH-

NEURAL explicou aproximadamente 99.72% da variação na série de deslocamento do bloco da barragem da Itaipu enquanto o ARIMA-GARCH explicou apenas 36.14%.



(b) Evolução do intervalo de confiança para WARIMAX-GARCH-NEURAL.

Figura 8 - Previsões (com intervalos de previsões) e deslocamentos observados.

4. CONCLUSÕES

Neste trabalho, um novo método de previsão causal chamado de método WARIMAX-GARCH-NEURAL é proposto e incorpora variáveis wavelet (obtida a partir da decomposição wavelet da série subjacente) como variáveis exógenas implicando em melhorias substanciais em relação aos modelos de previsão ARIMA-GARCH. Os componentes incorporados wavelet têm boas propriedades estatísticas para ser utilizado como variáveis wavelet. Por exemplo, os componentes de detalhe são sempre um processo estacionário de segunda ordem (normalmente exigido de variáveis exógenas que integram um modelo de regressão estatística linear) e também sempre presente variância condicional (volatilidade) - similarmente para um número da série histórica financeira (ver, por exemplo Engle, 1982) - que permite efeitos não lineares serem contabilizados no modelo final. Além disso, a componente de aproximação wavelet sempre pode ser modelada por um ARIMA-GARCH sempre que a sua série de tempo original também for capaz. Além disso, pode-se ver facilmente que as componentes wavelet apresentam sempre uma forte correlação com a variável de resposta $y_t(t = 1, \dots, T)$, uma vez que são obtidas a partir do último.

O método proposto foi aplicado a uma série temporal diária de deslocamento de um bloco da barragem principal da Usina de Itaipu. Os resultados comparados contra o modelo ARIMA-GARCH convencional mostrou que o método WARIMAX-GARCH-NEURAL não só produziu previsões com melhores performances, de acordo com as estatísticas MAPE e MAE para dados dentro e fora da amostra apontadas na tabela 3, mas também pode ser operacionalizado de uma forma relativamente simples.

AGRADECIMENTOS

Às instituições: CEASB (Centro de Estudos Avançados em Segurança de Barragens), Itaipu Binacional, UFPR (Universidade Federal do Paraná), PPGMNE (Programa de Pós Graduação

em Métodos Numéricos em Engenharias), CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e, em especial, ao professor Luiz Albino Teixeira Junior.

REFERÊNCIAS

- [1] Itaipu, *Usina Hidrelétrica de Itaipu: Aspectos de Engenharia*. Foz do Iguaçu: TAB Marketing Editorial, 2009.
- [2] ITAIPU, “Energia hidráulica,” 2014. [Online]. Available: <https://www.itaipu.gov.br/energia/energia-hidraulica>. [Accessed: 08-May-2014].
- [3] P. A. Morettin and L. M. C. Toloí, *Análise Séries Temporais*. 2ª Ed. ABE Projeto Fisher, 2006.
- [4] N. Levan and C. S. Kubrusly, “A wavelet ‘time-shift-detail’ decomposition,” *Math. Comput. Simul.*, vol. 63, pp. 73–78, 2003.
- [5] L. A. Teixeira Júnior, “Combinação SSA-Wavelet de Métodos Preditivos com Ajuste Numérico MINIMAX , na Geração de Previsões e de Cenários,” 2013.
- [6] S. Mallat, *A Wavelet Tour of Signal Processing: The Sparse Way*, Third Edit. 2008.
- [7] I. Daubechies, “Orthonormal bases of compactly supported wavelets,” *Commun. Pure Appl. Math.*, vol. 41, no. 7, pp. 909–996, Oct. 1988.
- [8] C. S. KUBRUSLY and N. LEVAN, “Abstract Wavelets Generated by Hilbert Space Shift Operators,” *Adv. Math. Sci. Appl.*, vol. 14, pp. 643–660, 2006.
- [9] S. HAYKIN, *Redes Neurais: Princípios e Prática*. 2º ed. Porto Alegre, Bookman, 2001.
- [10] G. E. P. BOX and G. C. TIAO, “Intervention Analysis with Applications to Economic and Environmental problems,” *J. Am. Stat. Assoc.*, vol. 70, no. 349, pp. 70–79, 1975.
- [11] J. Hamilton, *Time Series Analysis*. Princeton University Press, 1994.
- [12] H. LUTKEPOHL, *New Introduction to Multiple Time Series Analysis*. Springer, 2006.
- [13] T. BOLLERSLEV, “Generalized Autoregressive Conditional Heteroscedasticity,” *J. Econom.*, vol. 31, pp. 307–327, 1990.
- [14] R. F. ENGLE, “Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation,” *Econometrica*, vol. vol. 50, no. No. 4, pp. 987–1007, 1982.
- [15] J. D. Hamilton, “Causes and Consequences of the Oil Shock of 2007-08,” May 2009.