

Previsão de Deslocamentos Verticais Medido por Extensômetros de um Bloco da Barragem da Usina Hidrelétrica de Itaipu

Forecasting of the Vertical Displacements Measured by Extensometers of a Dam Block of the Itaipu Hydroelectric Power Plant

Samuel Bellido Rodrigues¹, Tásia Hickmann², Jairo Marlon Côrrea², Cleverson Gonçalves dos Santos², Edgar Manuel Carreño Franco³, Jotair Elio Kwiatkowski Junior⁴

RESUMO

Este artigo apresenta a modelagem de séries temporais provenientes dos extensômetros EM-I-7-1 e EM-I-9-1 instalados na fundação e localizados no bloco I10 da Barragem da Usina de Itaipu. Para tanto foi utilizado o método híbrido para previsões de séries temporais chamada SARIMA Support Vector Regression Wavelet de Múltiplos Núcleos (SSVRWMN) para a projeção dos deslocamentos verticais de um bloco da barragem da usina hidrelétrica de Itaipu. A projeção dos deslocamentos verticais consiste em uma das observações mais importantes na supervisão do comportamento da estrutura da barragem. Todos os resultados estatísticos alcançados por SSVRWMN são mais acurados que outras técnicas tradicionais (usadas aqui como benchmark), encorajando a sua adoção para tal finalidade.

Palavras-chave: Decomposição Wavelet. Modelos SARIMA. Support Vector Regression. Multi-Step.

ABSTRACT

This paper presents the modeling of time series from extensometers EM-I-7-1 and EM-I-9-1 installed in the foundation and located in the block I10 of the Itaipu Dam by hybrid methodology for time series forecasts called SARIMA Support Vector Regression Wavelet of Multiple Kernel (SSVRWMN) for the projection of the vertical displacements of a dam block of the Itaipu hydroelectric power plant, which consist of one of the most important observations in the supervision of the behavior of the dam structure. All the statistical results achieved by SSVRWMN are more accurate than other traditional techniques (used here as benchmark), encouraging their adoption for this purpose.

Keywords: Wavelet decomposition. SARIMA models. Support Vector Regression. Multi-Step.

¹ Doutor em Métodos Numéricos em Engenharia e Docente do Departamento de Matemática e Estatística na Universidade Tecnológica Federal do Paraná - UTFPR, Campus Medianeira.

E-mail: samuelb@utfpr.edu.br .

² Doutor es em Métodos Numéricos em Engenharia e Docentes do Departamento de Matemática e Estatística na Universidade Tecnológica Federal do Paraná - UTFPR.

³ Doutor em Engenharia Elétrica e Coordenador do Programa de Pós - Graduação em Engenharia Elétrica e Computação – PGEEC - Unioeste.

⁴ Doutorando em Métodos Numéricos em Engenharia e Docente do Departamento de Computação e Matemática na UNICENTRO.

1. INTRODUÇÃO

As barragens de concreto de usinas hidrelétricas são, em geral, monitoradas com o auxílio de instrumentos que realizam aferições de diferentes grandezas, como temperatura, subpressão, deslocamentos, tensões, deformações, entre outras. Os dados aferidos ao longo do tempo podem ser do ponto de vista estatístico interpretados como séries temporais estocásticas que exibem estruturas de autodependência (visto que o valor de leitura corrente de um instrumento é afetado pelos seus valores passados). Com efeito, tais séries obedecem a um determinado regime estocástico de comportamento, o qual pode ser mapeado de forma aproximada, por meio de um método preditivo com a finalidade de se produzir previsões.

As técnicas estatísticas em conjunto com o avanço tecnológico estão propiciando cada vez mais o uso de previsões para auxiliar os tomadores de decisão em análises e planejamento de necessidades operacionais futuras em áreas diversificadas. Pesquisadores buscam constantemente estudar e desenvolver modelos estatísticos confiáveis e que apresentem boa precisão e, neste contexto muitos métodos híbridos são apresentados, como pode ser visto em: (HICKMANN et al., 2016), (CORRÊA et al., 2016), (TEIXEIRA et al., 2015), (WALLIS, 2011), (MORETTIN; TOLOI, 2006) e (DE GOOIJER; HYNDMAN, 2006). Estes ressaltam que independentemente da metodologia utilizada na previsão o objetivo é minimizar erros provenientes dos processos utilizados na obtenção de previsões (BOX; JENKINS; REINSEL, 2008b).

No estudo de séries de tempo, três etapas são imprescindíveis: a análise, a modelagem e a previsão. Dentre as diversas técnicas usadas na análise, modelagem e previsão de séries temporais é possível citar: a teoria Wavelet, a metodologia de Box e Jenkins, o método Support Vector Regression e a combinação de previsões. Maiores detalhes sobre estas aplicações são encontrados nos seguintes trabalhos: (HAAR, 1911), (MALLAT, 2009), (BOX; JENKINS; REINSEL, 2008b), (VAPNIK, 2005), (SMOLA; SCHÖLKOPF, 1998), (BATES; GRANGER, 2001) e (TEIXEIRA JR et al., 2015).

Dentre as diversas variáveis que afetam a saúde estrutural de uma barragem de concreto estão os movimentos entre blocos, e entre estes e suas fundações, assunto de extremo interesse e relevância. Nesse trabalho são consideradas as aferições do instrumento denominado extensômetro e que medem as deformações do maciço rochoso, ou seja, medem os deslocamentos e deformações que ocorrem entre pontos no maciço da fundação. O monitoramento do comportamento do bloco I10, em termos de deslocamento

e deformações, pode ser monitorado por meio de previsões obtidas por meio do método híbrido SARIMA Support Vector Regression Wavelet de Múltiplos Núcleos (SSVRWMN) proposto em (RODRIGUES, 2015).

2. MATERIAIS E MÉTODOS

Na presente seção são apresentadas as séries temporais provenientes das aferições dos dois extensômetros selecionados e o método empregado nas previsões destas séries.

A Itaipu Binacional é uma das maiores usinas hidrelétricas do mundo e tem a sua localização no rio Paraná a 14km à montante da ponte internacional que liga a cidade de Foz do Iguaçu, no Brasil, a Ciudad del Este, no Paraguai, (ITAIPU: USINA HIDRELÉTRICA, 2009). A barragem principal de Itaipu é de concreto, do tipo gravidade aliviada, sendo composta por 20 blocos, cada um dotado de uma unidade geradora. No total são 2792 instrumentos instalados no concreto e na fundação, fornecendo dados temporais que auxiliam na análise do comportamento dos blocos e por consequência da barragem como um todo. Alguns blocos são designados blocos-chave (como é o caso do Bloco I10, objeto de nosso estudo), os quais são dotados de maior quantidade de instrumentos. Os blocos estão sujeitos, principalmente à ação do nível do lago devido à maior força que recebem da água no sentido montante-jusante, ou seja, no sentido do leito do rio. Esse volume de água também exerce, nas partes inferiores dos blocos, uma pressão (denominada de subpressão) que cria um efeito contrário ao que a sua própria massa exerce sobre a fundação, e das variações de temperatura, como no caso do verão em que ocorrem dilatações no concreto que provocam uma tendência de deformação do bloco para a direção montante, que por sua vez pode fazer com que aumentem as tensões de compressão no pé de montante dos blocos. No inverno o concreto se contrai, e provoca uma tendência de deformação do bloco à jusante. Pode-se então identificar um comportamento cíclico da estrutura, intimamente condicionado às condições ambientais da região, (OSAKO, 2002). Por esse motivo, as informações futuras, obtidas pelas previsões, se tornam valiosas no auxílio às tomadas de decisões.

Neste estudo são realizadas previsões das séries temporais provenientes do extensômetro. Os extensômetros são instrumentos instalados na fundação e são responsáveis pela aferição das deformações da fundação com relação ao ponto de ancoragem de sua haste. Este tipo de instrumento é considerado um dos mais importantes, pois é responsável pelas medições de recalques (deslocamentos verticais), que consistem em uma das observações mais importantes na supervisão do comportamento da estrutura

da barragem. Os dois extensômetros selecionados EM-I-7/1 e EM-I-9/1 estão localizados em maior profundidade na fundação: o extensômetro EM-I-7/1 se encontra a montante do bloco I10, enquanto o extensômetro EM-I-9/1 se encontra a jusante do bloco I10 que está situado no trecho I da barragem hidrelétrica de Itaipu (ver Figura 1). O instrumento extensômetro produz seus valores em milímetros. As séries provenientes das aferições dos instrumentos extensômetros EM-I-7/1 e EM-I-9/1 podem ser visualizadas na Figura 2.




Figura 1. Produções científicas distribuídas por tipos de literatura

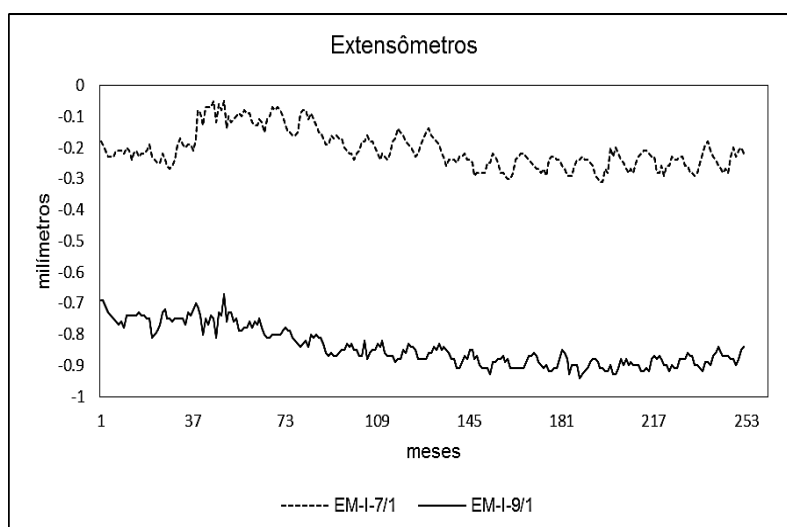


Figura 2. Séries temporal dos extensômetros EM-I-7/1 e EM-I-9/1

Inicialmente foi realizado o tratamento das informações, para serem estruturadas de acordo com a metodologia de previsão e optou-se por trabalhar com o período de 1994-2014 com valores mensais. Dos 252 valores que cada série temporal possui, os 228 primeiros dados foram utilizados no ajuste dos modelos base (SARIMA e SVR, SSVRWMN), os 12 valores seguintes foram reservados para validação e os 12 últimos valores referentes ao ano de 2014 para teste. A metodologia usada é de previsões multi step ahead, ou seja, h passos à frente, nesta aplicação $h=12$, portanto o horizonte de previsão coincide com o total de passos. Para a avaliação dos métodos, foram utilizados os erros MAPE (mean absolute percent error), MSE (mean square error) e MAE (mean absolute error), (HAMILTON, 1994) representados na Equação 1.

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y(t) - \hat{y}(t)}{y(t)} \right|, MSE = \frac{1}{T} \sum_{t=1}^T (y(t) - \hat{y}(t))^2, MAE = \frac{1}{T} \sum_{t=1}^T |y(t) - \hat{y}(t)| \quad (1)$$

O método SARIMA Support Vector Regression Wavelet de Múltiplos Núcleos considera uma série temporal que será projetada pela média das previsões obtidas por um modelo linear (SARIMA) e um não linear (Support Vector Regression Wavelet de Múltiplos Núcleos). A Figura 3 apresenta um fluxograma com as etapas do método híbrido proposto.

Na etapa 1 é realizada a modelagem via SARIMA, na série temporal original $(y(t))_{t=1}^T$, obtendo-se assim a previsão da componente linear $(L(t))_{t=1}^{T+h}$.

Na etapa 2 é realizada a decomposição ortogonal Wavelet de nível r na série temporal original, $(y(t))_{t=1}^T$, gerando $r+1$ CWs, (DAUBECHIES, 1992a) e (DONOHO; JOHNSTONE, 1994).

Na etapa 3, é realizada a modelagem das Componentes Wavelet via SVR Múltiplos Núcleos. O método denominado SVR Múltiplos Núcleos considera uma série temporal na qual são realizadas as modelagens através do SVR núcleo RBF, SVR núcleo Polynomial e SVR núcleo Sigmoidal, separadamente. As previsões obtidas através da combinação das previsões advindas das modelagens SVR núcleo RBF, SVR núcleo Polynomial e SVR núcleo Sigmoidal é que se denomina de Support Vector Regression de Múltiplos Núcleos (SVRMN). Da etapa 2, tem-se que para cada base Wavelet foram obtidos três componentes Wavelet que nesta etapa são modeladas pelo método SVRMN.

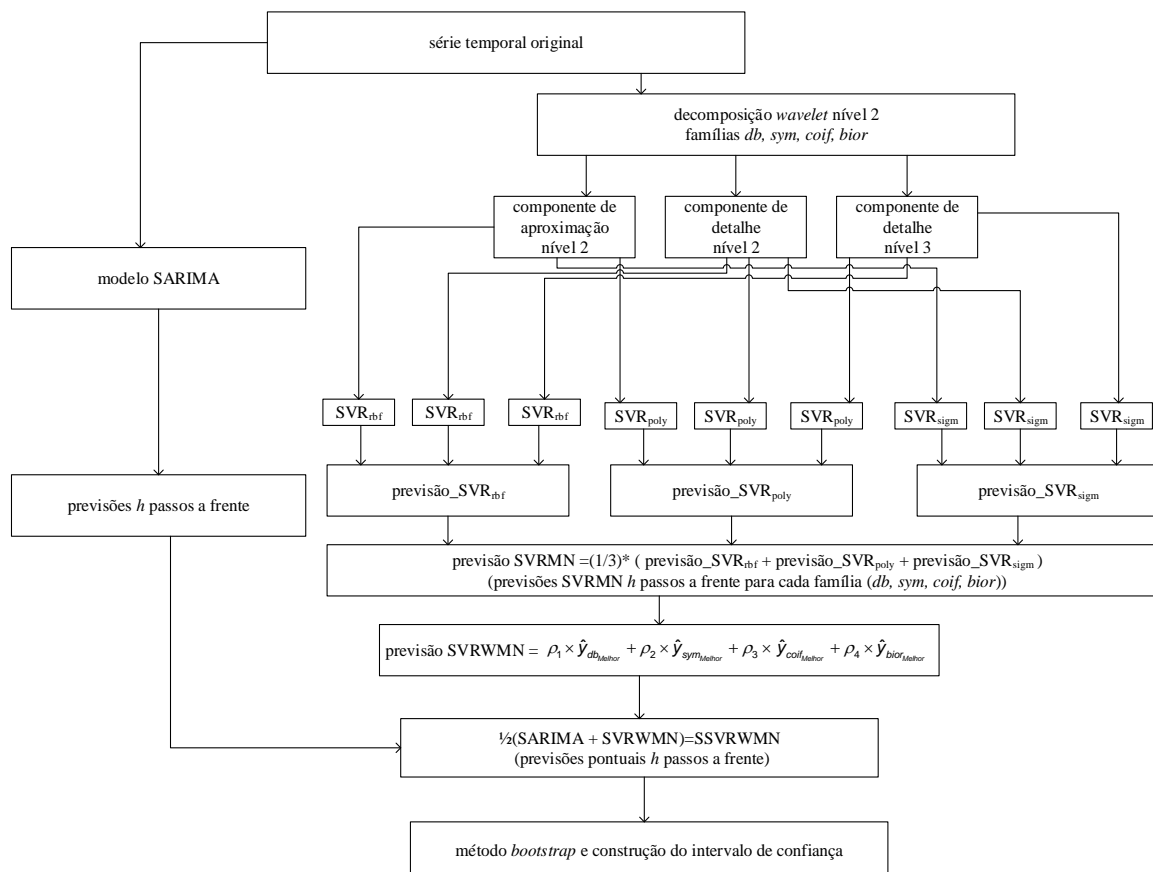


Figura 3. Fluxograma do método SSVRWMN. Fonte: (RODRIGUES, 2015)

Na etapa 4 são selecionadas as modelagens que apresentaram o menor erro quadrático médio (MSE) com base nos dados de validação, para cada família Wavelet, na etapa anterior, para em seguida ser realizada a combinação linear, obtendo-se assim a previsão da componente não linear $(N(t))_{t=1}^T$.

Na etapa 5, combinam-se as previsões obtidas na etapa 1 e obtidas na etapa 4, para a obtenção das previsões pontuais para cada instante t , gerando desta forma previsões dentro e fora da amostra (previsões multi step), que consiste nos resultados do método SARIMA Support Vector Regression Wavelet de Múltiplos Núcleos (SSVRWMN).

Na etapa 6, após obter a série dos resíduos, utilizou-se o processo Bootstrap residual, para obtenção do intervalo de confiança (IC) no nível de 95%.

Mais detalhes consultar (RODRIGUES, 2015).

3. RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados e discussões obtidas via método híbrido SSVRWMN, da modelagem das séries temporais provenientes das aferições do extensômetros EM-I-7-1 e EM-I-9-1.

Denotaremos a série temporal do extensômetro EM-I-7-1 por $(y_{em7_1}(t))_{t=1}^{252}$ e do extensômetro EM-I-9-1 por $(y_{em9_1}(t))_{t=1}^{252}$.

Na etapa 1 foi realizada para a série temporal a modelagem através de um modelo SARIMA, gerando previsões dentro da amostra de treino e previsões na amostra de teste num horizonte de 12 passos à frente, estas previsões são consideradas pelo método híbrido como as previsões da componente linear. Para modelagem SARIMA foi utilizado o *software Eviews* sendo feita a análise gráfica da série temporal e identificado o modelo apropriado. A definição das ordens dos modelos ocorreu com a análise dos gráficos das funções de autocorrelação FAC, autocorrelação parcial FACP, resíduos e testes com diversas opções de ordens p, d, q . As estatísticas encontradas da análise das séries temporais do extensômetro EM-I-7-1 e do extensômetro EM-I-9-1 estão representadas nas Tabela 1 e Tabela 2 respectivamente. A escolha da modelagem SARIMA, (BOX; JENKINS; REINSEL, 2008a) tem como objetivo capturar as estruturas de autodependência linear, considerando o efeito sazonal.

Na etapa 2 para a série temporal para cada uma das séries temporais $(y_{em7_1}(t))_{t=1}^{240}$ e $(y_{em9_1}(t))_{t=1}^{240}$ foi realizada a decomposição ortogonal *Wavelet* de nível $r = 2$, gerando uma componente de aproximação que é a representação da série original em baixa frequência, e duas componentes de detalhe que são séries de altas frequências (séries mais ruidosas) em cada decomposição realizada. O uso de *Wavelet* detecta o comportamento de uma série temporal em altas e baixas frequências (TEIXEIRA JR. *et al.* 2015), com o intuito de reduzir possíveis ruídos existentes na série original (o que significa que a componente *Wavelet* sempre apresenta padrão de comportamento mais regular para fins de modelagem). Foram consideradas as bases *daubechies* (db 1,2,...,45), *coiflets* (coif 1,2,...,5), *symlets* (sym 1,2,...,30) e *biorthogonal* (1.1, 1.3, ..., 6.8), gerando um total de 285 subséries para a série $(y_{em7_1}(t))_{t=1}^{240}$ e 285 subséries para a série $(y_{em9_1}(t))_{t=1}^{240}$. As CWs de aproximação e detalhe são obtidas a partir do aplicativo computacional *Matlab 8.0*, que oferece várias opções de bases wavelet, tais como: as famílias Daubechies (db), coiflets (coif) e symlets (sym), desenvolvidas por Ingrid Daubechies (DAUBECHIES, 1992b).

Na etapa 3 para as séries provenientes da decomposição *Wavelet* realizada na $(y_{em7_1}(t))_{t=1}^{240}$ e também na série $(y_{em9_1}(t))_{t=1}^{240}$ são obtidas as previsões via *Support Vector Regression* de Múltiplos Núcleos. No que tange à utilização do *Support Vector Regression*

(SVR), sua escolha deve-se ao fato de ser uma abordagem eficiente na modelagem de séries temporais oriundas de processos que apresentam estruturas de autodependência não lineares (CHEN *et al.* 2015). Foram considerados para compor o método os três principais núcleos, que são o RBF, o polinomial, e o *Sigmoidal* (SMOLA; SCHÖLKOPF, 2004).

Tabela 1 – Modelagem Sarima EM-I-7-1

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(1)	0.767367	0.035640	21.53120	0.0000
AR(8)	0.264256	0.039982	6.609414	0.0000
AR(18)	-0.220425	0.039471	-5.584478	0.0000
AR(24)	0.187073	0.035360	5.290584	0.0000
MA(2)	0.176284	0.070694	2.493623	0.0134
MA(4)	0.248729	0.070779	3.514168	0.0005
R-quadrado	0.911205	Média da variável dependente		-0.203009
R-quadrado ajustado	0.909091	Desvio padrão da variável dependente		0.065135
Erro padrão da regressão	0.019639	Akaike		-4.995234
Soma dos resíduos ao quadrados	0.080993	Schwarz		-4.901476
Log likelihood	545.4852	Hannan-Quinn		-4.957355
Durbin-Watson	1.988555			

Tabela 2 – Modelagem Sarima EM-I-9-1

Variável	Coefficiente	Erro padrão	Estatística-t	Probabilidade
AR(8)	-0.170767	0.065767	-2.596558	0.0101
AR(10)	0.193705	0.066151	2.928215	0.0038
SAR(12)	0.879812	0.041404	21.24940	0.0000
MA(1)	-0.637612	0.050954	-12.51347	0.0000
MA(13)	0.174263	0.050613	3.443013	0.0007
SMA(12)	-0.675231	0.074040	-9.119859	0.0000
R-quadrado	0.486061	Média da variável dependente		-0.000369
R-quadrado ajustado	0.473882	Desvio padrão da variável dependente		0.021275
Erro padrão da regressão	0.015432	Akaike		-5.477503
Soma dos resíduos ao quadrados	0.050248	Schwarz		-5.384050
Log likelihood	600.3091	Hannan-Quinn		-5.439752
Durbin-Watson	2.033248			

Na Tabela 3 são mostrados os dois melhores resultados obtidos para cada família *Wavelet* referente a estatística MSE da amostra de validação para a série $(y_{em7-1}(t))_{t=1}^{240}$ e na Tabela 4 para a série $(y_{em9-1}(t))_{t=1}^{240}$.

Da Tabela 3, observa-se que as modelagens escolhidas são aquelas que apresentaram a menor estatística MSE, para a série EM-I-7-1 são as bases db6, sym22, coif4 e bior4.4.

Tabela 3 – Dois melhores resultados para cada família *wavelet* (EM-I-7-1)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db6	0,0000522
	db40	0,0000545
<i>Symlets</i>	sym22	0,0000875
	sym26	0,0000974
<i>Coiflets</i>	coif4	0,0001904
	coif3	0,0001958
<i>Biorthogonal</i>	bior4.4	0,0000773
	bior6.8	0,0000914

Da Tabela 4, observa-se que as modelagens escolhidas são aquelas que apresentaram a menor estatística MSE, para a série EM-I-9-1 são as bases db44, sym29, coif3 e bior2.8.

Tabela 4 – Dois melhores resultados para cada família *wavelet* (EM-I-9-1)

Família	Base	Validação
		MSE
<i>Daubechies</i>	db22	0,0001080
	db44	0,0000984
<i>Symlets</i>	sym8	0,0001155
	sym29	0,0001143
<i>Coiflets</i>	coif2	0,0001180
	coif3	0,0001150
<i>Biorthogonal</i>	bior2.6	0,0001149
	bior2.8	0,0001147

Para obtenção dos parâmetros ótimos do modelo SVR, os dados da série temporal reservado para o ajuste foram subdivididos em treino e validação, sendo escolhido o modelo que apresentou um menor *MSE* no conjunto de validação, sendo a cardinalidade do conjunto de validação igual a 12. Foi utilizada uma biblioteca para SVR para *Matlab* denominada de LIBSVM, proposta por (CHANG, C. C. ; LIN, 2011), bem como outras rotinas aqui requeridas (RODRIGUES, 2015).

Na etapa 4 foram combinadas as previsões das melhores modelagens obtidas quando comparada a estatística *MSE* no conjunto de validação referente a cada família *Wavelet*.

A combinação referente à série EM-I-7-1 está representada na Equação 2 onde as constantes adaptativas assumem os seguintes valores $\rho_1 = 1,264955$, $\rho_2 = 0,419522$, $\rho_3 = -0,59129$ e $\rho_4 = -0,11061$, após a minimização do erro quadrático médio (*MSE*), e referente à série EM-I-9-1 é representada na Equação 3, onde as constantes adaptativas assumem os valores $\rho_1 = 1,889358$, $\rho_2 = 0,000162$, $\rho_3 = -0,54076$ e $\rho_4 = -0,34884$, após a minimização do erro quadrático médio (*MSE*).

$$\left(\hat{y}_{em7-1}(t)\right)_{t=12}^{240} = \left[\begin{array}{l} \rho_1 \times \left(\hat{y}_{db6-em7-1}(t)\right) + \rho_2 \times \left(\hat{y}_{sym22-em7-1}(t)\right) + \\ \rho_3 \times \left(\hat{y}_{coif4-em7-1}(t)\right) + \rho_4 \times \left(\hat{y}_{bior4.4-em7-1}(t)\right) \end{array} \right]_{t=12}^{240} \quad (2)$$

$$\left(\hat{y}_{em9-1}(t)\right)_{t=12}^{240} = \left[\begin{array}{l} \rho_1 \times \left(\hat{y}_{db44-em9-1}(t)\right) + \rho_2 \times \left(\hat{y}_{sym29-em9-1}(t)\right) + \\ \rho_3 \times \left(\hat{y}_{coif3-em9-1}(t)\right) + \rho_4 \times \left(\hat{y}_{bior2.8-em9-1}(t)\right) \end{array} \right]_{t=12}^{240} \quad (3)$$

Nesta etapa, foram obtidas as previsões do modelo SVR *Wavelet* Múltiplos Núcleos para a série EM-I-7-1 $\left(\hat{N}_{em7-1}(t)\right)_{t=12}^{240}$ e também para a série EM-I-9-1 $\left(\hat{N}_{em9-1}(t)\right)_{t=12}^{240}$ que são as componentes não lineares do modelo híbrido proposto.

Na etapa 5 tomam-se as previsões obtidas pelo modelo linear (SARIMA) e pelo modelo não linear (SVRWMN) e calcula-se a média, para a obtenção das previsões pontuais para cada *t*, para cada uma das séries temporais modeladas.

O método híbrido SSVRWMN apresenta em sua estrutura de autodependência informações lineares e não lineares e é considerada como uma versão filtrada da série temporal $y(t)$, tanto por um filtro linear (etapa 1) quanto por um filtro não linear (etapas 3 e 4). Logo a lista de previsões para série temporal do extensômetro EM-I-7-1 é

$(\hat{y}_{em7_1}(t))_{t=12}^{240+12} = \frac{1}{2}(\hat{L}_{em7_1}(t) + \hat{N}_{em7_1}(t))_{t=12}^{240+12}$ e para a série temporal do extensômetro EM-I-9-1 é $(\hat{y}_{em9_1}(t))_{t=12}^{240+12} = \frac{1}{2}(\hat{L}_{em9_1}(t) + \hat{N}_{em9_1}(t))_{t=12}^{240+12}$. Nesta etapa, é possível fazer a comparação das previsões do método proposto com as previsões obtidas pelo método SARIMA, SVR e combinação SARIMA-SVR. As estatísticas de aderência comparadas são: MSE, MAPE e MAE, que são apresentadas na Tabela 5 para a série $y_{em7_1}(t)$ e na Tabela 6 para a série $y_{em9_1}(t)$.

Tabela 5 - Comparativo MSE, MAPE e Mae para A série EM-I-7-1 *multi step* $h= 12$

Método	MSE	MAPE	MAE
SARIMA	0,000243	5,638%	0,0129
SVR	0,000594	8,398%	0,0209
SARIMA-SVR	0,000286	5,682%	0,0135
SSVRWMN	0,000226	5,546%	0,0119

Da Tabela 5, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento EM-I-7-1 uma redução nas três estatísticas MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SARIMA), a redução relativa foi de, aproximadamente, 7% na medida MSE.

Tabela 6 - Comparativo MSE, MAPE e Mae para a série EM-I-9-1 *multi step* $h= 12$

Método	MSE	MAPE	MAE
SARIMA	0,000722	2,9392%	0,02546
SVR	0,000876	3,1855%	0,02751
SARIMA-SVR	0,000751	2,8291%	0,02454
SSVRWMN	0,000522	2,4418%	0,02107

Da Tabela 6, verifica-se que o método proposto SSVRWMN obteve nas previsões da série temporal do instrumento EM-I-9-1 uma redução nas três estatísticas MSE, MAPE e MAE, em relação a todos os demais métodos preditivos listados. Comparando-o ao segundo melhor resultado (a saber, o método SARIMA), a redução relativa foi de, aproximadamente, 28% na medida MSE. Tais resultados demonstram a eficiência preditiva

do método proposto diante de abordagens consagradas na literatura de séries temporais, como: SARIMA, SVR e o híbrido SARIMA-SVR.

Na etapa 6, após obter a série dos resíduos, utilizou-se o processo *Bootstrap* residual, para obtenção do intervalo de confiança (IC) no nível de 95%, que pode ser visto na Figura 4 para a série EM-I-7-1 e EM-I-9-1.

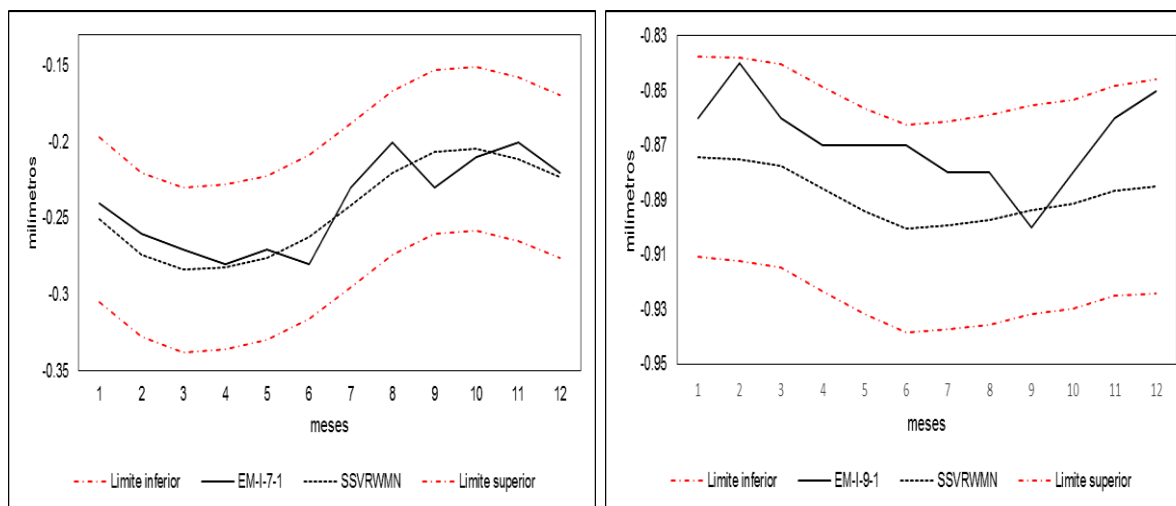


Figura 4. IC e previsões pelo método SSVRWMN das séries EM-I-7-1 e EM-I-9-1

5. CONSIDERAÇÕES FINAIS

O presente artigo apresentou a modelagem de séries temporais provenientes dos extensômetros EM-I-7-1 e EM-I-9-1 instalados na fundação e localizados no bloco I10 da Barragem da Usina de Itaipu através do método SSVRWMN. Os extensômetros são responsáveis pela aferição das deformações da fundação com relação ao ponto de ancoragem de sua haste. Este tipo de instrumento é considerado um dos mais importantes, pois é responsável pelas medições de recalques (deslocamentos verticais), que consistem em uma das observações mais importantes na supervisão do comportamento da estrutura da barragem.

Em síntese, no processo de geração de previsões, o método SSVRWMN gerou previsões substancialmente melhores que os obtidos pelos métodos preditivos SARIMA e SVR individualmente, e o composto SARIMA-SVR, em todas as estatísticas de aderência consideradas. Portanto, as previsões provenientes do método SSVRWMN veem agregar informações, contribuindo desta forma com a tomada de decisão, no que se refere ao problema estudado.

O método SSVRWMN se mostrou uma alternativa factível e eficiente à modelagem de séries temporais (advindas de acontecimentos reais), dadas a sua abrangência e a sua eficiência mostrada nas pesquisas.

Tais resultados são motivadores da aplicação do método para séries temporais de outras áreas, mesmo que a base teórica do método híbrido proposto é matematicamente complexo, o uso dos softwares e rotinas computacionais referenciados no texto permite a sua utilização.

AGRADECIMENTOS

Os autores externam seus agradecimentos às instituições UTFPR - Medianeira, ao programa de pós-graduação em engenharia elétrica e computação - UNIOESTE - Foz do Iguaçu, a UFPR, ao CEASB e a equipe de superintendência de engenharia da Itaipu Binacional pelo apoio e contribuição das discussões.

REFERÊNCIAS

- BATES, J. M.; GRANGER, C. W. J. The combination of forecasts. p. 391–410, 1 jan. 2001.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis : forecasting and control**. [s.l.] J. Wiley & Sons, 2008a.
- BOX, G.; JENKINS, G.; REINSEL, G. **Time Series Analysis: Forecasting and Control**. [s.l.: s.n.].
- CHANG, C. C.; LIN, C. J. {LIBSVM}: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, n. 3, p. 27:1--27:27, 2011.
- CHEN, R. et al. Forecasting holiday daily tourist flow based on seasonal support vector regression with adaptive genetic algorithm. **Applied Soft Computing**, v. 26, p. 435–443, jan. 2015.
- CORRÊA, J. M. et al. Time series forecasting with the WARIMAX-GARCH method. **Neurocomputing**, 2016.
- DAUBECHIES, I. **Ten lectures on wavelets**. 1. ed. [s.l.] Society for Industrial and Applied Mathematics, 1992a.
- DAUBECHIES, I. **Ten Lectures on Wavelets**. [s.l.: s.n.].
- DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International Journal of Forecasting**, v. 22, n. 3, p. 443–473, jan. 2006.
- DONOHU, D. L.; JOHNSTONE, J. M. Ideal spatial adaptation by wavelet shrinkage. **Biometrika**, v. 81, n. 3, p. 425–455, 1994.

HAAR, A. Zur Theorie der orthogonalen Funktionensysteme. **Mathematische Annalen**, v. 71, n. 1, p. 38–53, 1911.

HAMILTON, J. D. **Time Series Analysis**. [s.l.] Princeton University Press, 1994. v. 39

HICKMANN, T. et al. Wavelet – SVR hybrid methodology for the projection of relative displacements in block I11 of the Itaipu hydroelectric plant dam. **Revista Gestão da Produção Operações e Sistemas**, v. 11, n. 2, p. 103–120, jun. 2016.

MALLAT, S. G. **A Wavelet Tour of Signal Processing**. [s.l.] Elsevier, 2009.

MORETTIN, P. A.; TOLOI, C. M. DE C. **Análise de séries temporais**. [s.l.] Edgard Blucher, 2006.

OSAKO, C. I. **A manutenção dos drenos nas Fundações de Barragens o caso da Usina Hidrelétrica de Itaipu**. [s.l.] Dissertação Curso de Pós-Graduação em Construção Civil, Universidade Federal do Paraná, 2002.

RODRIGUES, S. B. **Método híbrido iterativo sarima support vector regression wavelet de múltiplos núcleos na previsão de séries temporais de instrumentos de barragens**. [s.l.] Tese de Doutorado - Univerisdade Federal do Paraná, 2015.

SMOLA, A. J.; SCHÖLKOPF, B. **A tutorial on support vector regression** *Statistics and Computing*, 1998.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, p. 199–222, 2004.

TEIXEIRA JR, L. A. et al. Artificial Neural Network and Wavelet decomposition in the Forecast of Global Horizontal Solar Radiation. **Sobrapo**, v. 35, n. 1, p. 1–16, 2015.

TEIXEIRA, L. L. et al. Forecasts for the Canadian Lynx time series using method that combine neural networks, wavelet shrinkage and decomposition. **Revista Gestão da Produção Operações e Sistemas**, v. 10, n. 4, p. 159–172, 3 dez. 2015.

VAPNIK, V. Universal learning technology: Support vector machines. **Nec Journal Of Advanced Technology**, v. 2, n. 2, p. 137–144, 2005.

WALLIS, K. F. Combining forecasts : forty years later. **Applied Financial Economics**, p. 33–41, 2011.