

MODELO PREVISOR PARA SÉRIES DE TEMPO BASEADO EM REDES NEURAS ARTIFICIAIS E DECOMPOSIÇÃO DE MODO EMPÍRICO

Levi Lopes Teixeira (UTFPR) E-mail: prof.levilopes@gmail.com

Resumo: Neste artigo, fez-se um comparativo dos resultados das previsões multipassos à frente (estratégia recursiva) de vazões mensais coletadas no posto 266-Itaipu. Comparou-se as previsões oriundas de três métodos: ARIMA, Redes Neurais Artificiais (RNA) *Feedforward* e um método híbrido formado por Decomposição de Modo Empírico (EMD), RNA *Feedforward* e Regressão Linear Múltipla (RLM). O método híbrido, denominado EMD-RNA-RLM, apresentou erros de previsão menores aos individuais ARIMA e RNA. Os Erros Médios Percentuais Absolutos (MAPE) obtidos para uma previsão doze passos à frente por meio dos métodos ARIMA, RNA e EMD-RNA-RLM, foram 7,5%, 14,8% e 20,6%, respectivamente.

Palavras-chave: Decomposição de Modo Empírico, Previsão de Séries Temporais de Vazões, Redes Neurais Artificiais.

FORECASTING MODEL FOR TIME SERIES BASED ON ARTIFICIAL NEURAL NETWORKS AND EMPIRICAL MODE DECOMPOSITION

Abstract: In this article, a comparative was made from results of the multi-step forecasts ahead (recursive strategy) of monthly flows collected at post 266-Itaipu. Forecasts from three methods were compared: ARIMA, Artificial Neural Networks (ANN) *Feedforward* and a hybrid method formed by Empirical Mode Decomposition (EMD), ANN *Feedforward* and Multiple Linear Regression (MLR). The hybrid method, called EMD-ANN-MLR, presented minor forecasting errors to the individual ARIMA and ANN. The Mean Absolute Percentage Error (MAPE) obtained for a forecast twelve steps ahead using the ARIMA, ANN and EMD-ANN-MLR methods were 7.5%, 14.8% and 20.6%, respectively.

Keywords: Empirical Mode Decomposition, Flow Time Forecasting, Artificial Neural Networks.

1. Introdução

A matriz elétrica brasileira é constituída em sua maioria por energia gerada a partir de usinas hidrelétricas. A Empresa de Pesquisa Energética publicou em 2018 o Plano Decenal de Expansão de Energia (EPE, 2018), o documento informa que 60% da capacidade instalada no Sistema Interligado Nacional (SIN) no final de maio de 2018 é proveniente das usinas hidrelétricas. Um dos pontos de grande relevância no gerenciamento desse sistema de geração de energia elétrica é a previsão de vazões afluentes diárias, semanais e mensais.

Um dos modelos para previsão de vazões no âmbito do SIN é o SMAP/ONS, esse modelo tem como base o modelo SMAP que é determinístico e de simulação hidrológica do tipo transformação chuva-vazão (LOPES; BRAGA; CONEJO, 1982). O Centro de Pesquisas de Energia Elétrica (CEPEL) desenvolveu os modelos PREVIVAZ, PREVIVAZH e PREVIVAZM para previsões de vazões semanais, diárias e mensais. A família PREVIVAZ é formada por modelos propostos por Box e Jenkins (BOX; JENKINS, 1970). Além desses modelos, o Operador Nacional do Sistema (ONS) aplica outros sistemas de previsão, inclusive aqueles que envolvem os vários tipos de Redes Neurais Artificiais (RNA).

Redes Neurais Artificiais são sistemas formados basicamente por neurônios artificiais distribuídos em camadas, utilizando simultaneamente unidades do sistema na manipulação das informações, armazenando-as e disponibilizando-as para o futuro (HAYKIN, 2001). São diversos os tipos de redes neurais: *Perceptron*, *Adaline*, *mult-Layered Perceptron*, *Recorrentes*, entre os quais, os modelos mais atuais de *Deep Neural Network*. Revisando a literatura especializada encontram-se numerosos estudos que atestam o sucesso das RNA na previsão de séries temporais (GOOIJER; HYNDMAN, 2006). Camelo et al. (2017) fizeram previsão da velocidade do vento para regiões do nordeste brasileiro a partir dos modelos ARIMA, HOLT-WINTERS e RNA, concluíram que modelos híbridos RNA-HOLT foram os mais eficientes entre os modelos testados. Humphrey et al. (2016) aplicaram um híbrido envolvendo RNA e modelo chuva-vazão GR4J na previsão de vazão no sudeste australiano. Os autores afirmam que o modelo híbrido foi 8 vezes mais preciso que os modelos RNA e GR4J quando aplicados separadamente.

Nos processos de geração de vazões, os mecanismos não lineares são mais fortes em escalas menores de tempo, sendo as vazões mensais não lineares e sazonais (WANG et al., 2006). Zang e Qi (2005) concluíram para as redes *feedforward*, que estas terão dificuldades na modelagem de séries temporais sazonais, sendo de grande importância a associação deste tipo de rede neural com algum método de pré-processamento dos dados. Basta (2018) fez previsões de séries econômicas usando *wavelet* na extração dos ruídos das séries ante que estas fossem submetida ao método predictor. Wang et al. (2017) propõem um método híbrido para previsão de séries temporais não lineares e não estacionárias. Para tanto, fizeram uma associação do método Decomposição de Modo Empírico (EMD) e regressão por RNA *Feedforward*.

O método EMD foi introduzido por Huang et al. (1998) e caracteriza-se pela decomposição do sinal em funções de modo intrínseco (IMF), podendo ser aplicado em processos não lineares e não estacionários. He et al., (2016) aplicaram o modelo Média Móvel Ponderada Exponencial (MMPE) associado ao EMD na previsão dos preços da energia elétrica no mercado australiano, concluíram que o modelo EMD-MMPE foi mais eficiente que o MMPE. Niu; Liang; Hong, (2017) fizeram previsões do vento na província de Gansu na China. Utilizaram EMD e Rede Neural de Regressão Geral (RNRG) otimizada pelo algoritmo da mosca da fruta (FOA – sigla em inglês). Os autores compararam os resultados obtidos por meio do EMD-RNRG-FOA com outros sete métodos individuais e híbridos, constataram a eficiência daquele em relação a esses. KIM et al., (2018); Wang et al., (2020); Rezaie-Balf et al., (2019), entre outros, lançaram mão do EMD, como parte de seus métodos, na previsão de séries temporais.

Neste trabalho aplicou-se o método EMD associado à RNA para a previsão de uma série temporal de vazões mensais. A série foi decomposta por meio do EMD, resultando da decomposição as componentes IMF e resíduo. Estas foram submetidas à RNA *Multilayer Feedforward*, obtendo-se as previsões das IMF e resíduos. A fim de se determinar previsões doze passos à frente pela estratégia recursiva, aplicou-se Regressão Linear Múltipla (RLM) envolvendo as previsões das IMF e resíduo (variáveis independentes) e vazão observada (variável dependente). Os resultados obtidos foram comparados às modelagens executadas a partir dos métodos individuais ARIMA e RNA *Multilayer Feedforward*. Verificando-se, para a série em estudo, vantagem preditiva do método composto em relação aos individuais.

2. Série temporal

Neste trabalho, foi utilizada uma série temporal de vazão afluente mensal média da usina de Itaipu com 492 observações. Os dados foram obtidos no *site* do ONS e são resultados de medições no posto 266, localizado na Usina Hidrelétrica de Itaipu. A série temporal citada está representada no gráfico da Figura 1.




Figura 1 – Série de vazões mensais obtidas no posto 266 no período de 1970- 2010. Fonte: autor.

A análise do correlograma (Figura 2) da série temporal de vazões mensais observada mostra a existência de componente de sazonalidade com período igual a doze, confirmada pelo teste QS para o nível de significância de 5% (p-valor = 0,0). Embora as autocorrelações sejam não decrescentes nos atrasos múltiplos de doze, indicando não estacionariedade, o teste KPSS não confirma tal conclusão para o nível de 5% (p-valor = 0,1), neste teste a hipótese nula indica que a série é estacionária.




Figura 2 – Correlograma da série de vazões mensais. Fonte: autor.

3. Decomposição de modo empírico

O método EMD decompõe uma série temporal em um número finito de Funções de Modo Intrínseco (IMF), que devem satisfazer duas condições: (1) em todo o conjunto de dados, o número total de extremos (máximos e mínimos) é igual ao número de zeros atravessados ou diferir no máximo em um; (2) a média entre as envoltórias superior (formada pelos pontos de máximo) e inferior (formada a partir dos mínimos) é zero em qualquer ponto. Para se obter uma IMF, Huang et al. (1998) sugerem o processo denominado *sifting*. O procedimento inicializa-se com a determinação de uma envoltória ao sinal original, obtida a partir de interpolação *spline* cúbica envolvendo os pontos de máximo e mínimo. Na sequência, calcula-se a média (m) entre as envoltórias superior e inferior do sinal $y(t)$. A Figura 3, traz uma ilustração de sinal original $y(t)$, envolvido pelas envoltórias superior e inferior e a média (m) entre essas envoltórias.

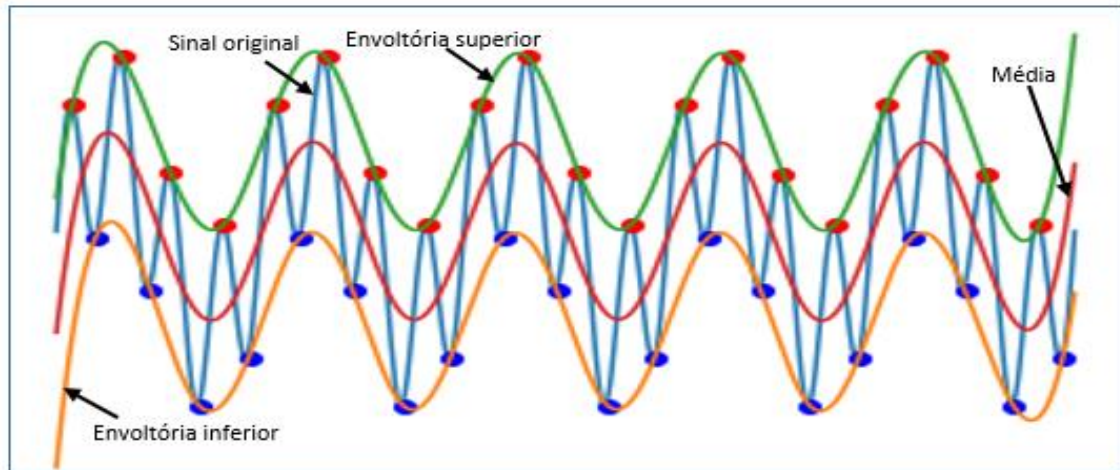


Figura 3 - Representação de sinal original, envoltórias e média em um processo EMD. Fonte: Ryan, 2019.

A fim de se obter a IMF, faz-se a diferença entre $y(t)$ e m , conforme a Equação 1.

$$IMF = y(t) - m \tag{1}$$

A Figura 4 mostra um pseudocódigo resumido para o processo de *sifting*. Para maiores detalhes sobre o algoritmo, inclusive critérios de parada, veja Huang et al. (1998).

```

Fazer  $r_0 = y(t)$  (série temporal original);  $j=0$ ;  $C=0$ 
Enquanto  $C == 0$ , faça:  $j=j+1$ 
    Determinar as envoltórias superior  $r_{j-1}^s$  e inferior  $r_{j-1}^i$ 
     $m_{j,0} = \frac{r_{j-1}^s + r_{j-1}^i}{2}$ 
     $h_{j,0} = r_{j-1} - m_{j,0}$ 
    Se  $h_{j,0}$  satisfaz as condições de uma IMF, então:
         $IMF_j = h_{j,0}$ 
    Caso contrário
         $SD=1$ ;  $k=0$ 
        Enquanto  $SD < 0,2$  ou  $SD > 0,3$ , faça:  $k=k+1$ 
            Determinar as envoltórias  $h_{j,k-1}^s$  e  $h_{j,k-1}^i$ 
             $m_{j,k} = \frac{h_{j,k-1}^s + h_{j,k-1}^i}{2}$ 
             $h_{j,k} = h_{j,k-1} - m_{j,k}$ 
             $SD = \sum_{t=1}^T [|h_{j,k-1}(t) - h_{j,k}(t)|^2 / h_{j,k-1}^2(t)]$ 
        Fim Enquanto  $SD$ 
         $IMF_j = h_{j,k}$ 
    Fim Se
     $r_j = r_{j-1} - IMF_j$ 
    Se, de  $r_j$ , não for possível extrair IMF ou  $r_j$  é monotônica, então
         $C=1$ ;  $r_n = r_j$ .
    Fim Se  $r_j$ 
Fim Enquanto  $C$ 
    
```

Figura 4 – Pseudocódigo do processo de decomposição EMD. Fonte: autor

A reconstituição do sinal original é obtida por meio da Equação 2, considerando que foram determinadas n IMF e o resíduo final é r_n .

$$y(t) = \sum_{i=1}^n (IMF_i) + r_n \quad (2)$$

4. Redes neurais *multilayer perceptron feedforward*

Seja uma RNA *feed-forward* com uma camada escondida, onde f_h e f_s denotam funções de ativação concernentes às junções aditivas oriundas da camada intermediária e da última camada, respectivamente. O sinal de entrada (padrão k) está definido pelo vetor de sinais $(x_1^k, x_2^k, \dots, x_n^k)$. Os pesos sinápticos das duas camadas foram denotados, respectivamente, por w_{ij}^k e w_j^k com $i = 1, \dots, n$ e $j = 1, \dots, h$, sendo h o número de neurônios da camada oculta. As simbologias x_{0j}^k e b_s^k representam os bias, que podem aumentar ou diminuir a entrada líquida da função de ativação.

Matematicamente, a saída y_k da rede descrita no parágrafo anterior pode ser calculada por meio da Equação 3.

$$y_k = f_s \left[\sum_{j=1}^h w_j^k f_h \left(\sum_{i=1}^n w_{ij}^k x_i^k + x_{0j}^k \right) + b_s^k \right] \quad (3)$$

Para o treinamento da RNA, pode-se utilizar o algoritmo o *backpropagation*, ele é largamente utilizado e faz o ajuste dos pesos sinápticos por meio de um processo de otimização realizado em duas fases: *forward* e *backward*. 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.

O problema de previsão de séries temporais $y(t)$ por meio de RNA, consiste na utilização de dados observados para se prever $y(t + H)$, onde H é o passo de tempo de previsão para o futuro. Uma vez definido o tamanho da janela (d) de entrada de dados e H , constrói-se a sequência $(y(t), y(t - 1), \dots, y(t - d + 1), y(t + 1), \dots, y(t + H))$ de dados, que forma um conjunto de padrões de treinamento, onde: $(y(t), y(t - 1), \dots, y(t - d + 1))$ e $(y(t + 1), \dots, y(t + H))$ representam as entradas e saídas desejadas, respectivamente.

5. Método EMD-RNA-RLM

A seguir são descritas com mais detalhes as etapas do método EMD-RNA-RLM aplicado na previsão da série temporal de vazões mensais, considerando que H é o tamanho da amostra de teste.

Etapa 1: separação da série temporal original $(y_t)_{t=1}^N$ nas séries de treinamento $(y_{treino,t})_{t=1}^{N-H}$ e teste $(y_{teste,t})_{t=N-H+1}^N$. A série $y_{treino,t}$, por sua vez, é dividida em duas novas séries, $(y_{train,t})_{t=1}^{N-3H}$ para treinamento e $(y_{valid,t})_{t=N-3H+1}^{N-H}$ para validação.

Etapa 2: decomposição por EMD da série $y_{train,t}$. Da decomposição resultam n IMF $(I_{T1,t}, I_{T2,t}, \dots, I_{Tn,t})$ e o resíduo $r_{T,t}$, com $t = 1, 2, \dots, N - 3H$.

Etapa 3: modelagem por RNA *Feedforward* do resíduo e IMF obtidas na Etapa 2. Determinando-se as previsões: $\hat{I}_{T1,t}, \hat{I}_{T2,t}, \dots, \hat{I}_{Tn,t}$ e $\hat{r}_{T,t}$, com $t = d, \dots, N - 3H$ e d o

tamanho dos padrões de entrada da rede. Na sequência, faz-se as previsões (Estratégia Recursiva) $2H$ passos à frente para cada uma das n IMF e resíduo, sendo denotadas por $:\hat{I}_{V1,t}, \hat{I}_{V2,t}, \dots, \hat{I}_{Vn,t}$ e $\hat{r}_{V,t}$, $t = N - 3H + 1, \dots, N - H$.

Na Estratégia Recursiva, a previsão H passos à frente para uma série temporal y com N observações para treinamento e janela d é realizada na forma descrita na Equação 4, sendo \hat{f} é o modelo treinado na estratégia um passo à frente e $h = 1, 2, \dots, H$.

$$\hat{y}_{N+h} = \begin{cases} \hat{f}(y_N, y_{N-1}, \dots, y_{N-d+1}), se(h = 1) \\ \hat{f}(\hat{y}_{N+h-1}, \dots, \hat{y}_{N+1}, y_N, \dots, y_{N-d+1}) se(h \in \{2, \dots, d\}) \\ \hat{f}(\hat{y}_{N+h-1}, \hat{y}_{N+h-2}, \dots, \hat{y}_{N+h-d}) se(h \in \{d + 1, \dots, H\}) \end{cases} \quad (4)$$

Etapa 4: tendo as previsões: $(\hat{I}_{T1,t}, \hat{I}_{T2,t}, \dots, \hat{I}_{Tn,t}$ e \hat{r}_T) e $(\hat{I}_{V1,t}, \hat{I}_{V2,t}, \dots, \hat{I}_{Vn,t}$ e $\hat{r}_{V,t}$), obtém-se as previsões da amostra de validação $y_{valid,t}$ a partir da Regressão Linear Múltipla (RLM), conforme as Equações 5 e 6, onde $m = N - 3H$.

$$\hat{\beta} = (X^T \cdot X)^{-1} \cdot X^T \cdot y_{train} \quad (5)$$

$$\begin{bmatrix} \hat{y}_{valid,m+1} \\ \hat{y}_{valid,m+2} \\ \vdots \\ \hat{y}_{valid,N-H} \end{bmatrix} = [\beta_0 \quad \beta_1 \quad \dots \quad \beta_{n+1}] \cdot \begin{bmatrix} 1 & 1 & \dots & 1 \\ \hat{I}_{V1,m+1} & \hat{I}_{V1,m+2} & \dots & \hat{I}_{V1,N-H} \\ \hat{I}_{V2,m+1} & \hat{I}_{V2,m+2} & \dots & \hat{I}_{V2,N-H} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{I}_{Vn,m+1} & \hat{I}_{Vn,m+2} & \dots & \hat{I}_{Vn,N-H} \\ \hat{r}_{V,m+1} & \hat{r}_{V,m+2} & \dots & \hat{r}_{V,N-H} \end{bmatrix} \quad (6)$$

$$X = \begin{bmatrix} 1 & \hat{I}_{T1,d} & \hat{I}_{T2,d} & \dots & \hat{I}_{Tn,d} & \hat{r}_{T,d} \\ 1 & \hat{I}_{T1,d+1} & \hat{I}_{T2,d+1} & \dots & \hat{I}_{Tn,d+1} & \hat{r}_{T,d+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 1 & \hat{I}_{T1,m} & \hat{I}_{T2,m} & \dots & \hat{I}_{Tn,m} & \hat{r}_{T,m} \end{bmatrix}, \hat{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_{n+1} \end{bmatrix}, y_{train} = \begin{bmatrix} y_{train,d} \\ y_{train,d+1} \\ \vdots \\ y_{train,m} \end{bmatrix}$$

Etapa 5: faz-se a decomposição EMD da série temporal $y_{treino,t}$, obtendo-se as IMF $(I_{treino_1,t}, I_{treino_2,t}, \dots, I_{treino_n,t})$ e o resíduo $r_{treino,t}$, com $t = 1, \dots, N - H$.

Etapa 6: utilizando-se os hiperparâmetros das redes obtidas na Etapa 3, ajustam-se as IMF e resíduo provenientes da Etapa 4 por meio de RNA *feedforward*. Em seguida faz-se as previsões das IMF e resíduo H passos à frente, conforme descrito na Etapa 3.

Etapa 7: tendo as previsões:

$(\hat{I}_{treino_1,t}, \hat{I}_{treino_2,t}, \dots, \hat{I}_{treino_n,t}$ e $\hat{r}_{treino,t}$, sendo $t = d, \dots, N - H$) e $(\hat{I}_{teste_1,t}, \hat{I}_{teste_2,t}, \dots, \hat{I}_{teste_n,t}$ e $\hat{r}_{teste,t}$, com $t = N - H + 1, \dots, N$ obtém-se as previsões da amostra de teste a partir da Regressão Linear Múltipla (RLM), conforme descrito na Etapa 4.

6. Resultados obtidos

A fim de se averiguar a capacidade preditiva do método EMD-RNA-RLM, fez-se um comparativo dos resultados obtidos por esse método e os tradicionais e eficientes ARIMA e RNA *feedforward*. As análises, decomposições e ajustes das séries temporais foram executadas no programa R V. 3.6.3 (R CORE TEAM, 2020).

6.1 Métodos ARIMA e RNA *multilayer feedforward*

A série de vazões em estudo possui componente sazonal (seção 2), então o modelo ARIMA sugerido é o multiplicativo, representado por $ARIMA(p,d,q) \times (P,D,Q)_S$. Sendo S o período sazonal, D a ordem do operador diferença sazonal, Q a ordem do modelo médias móveis sazonal e P a ordem do modelo autorregressivo sazonal (SOUZA; CAMARGO, 2004). Com o intuito de se obter o modelo ARIMA mais apropriado para a previsão da série temporal de vazões mensais, aplicou-se uma diferenciação de ordem $D=12$ (por conta da sazonalidade de período 12). Com a série diferenciada, fez-se a análise dos gráficos das funções de autocorrelações (FAC) e autocorrelações parciais (FACP), podendo assim definir possíveis modelos para o ajuste dos dados. As análises das FAC e FACP dos resíduos oriundos das previsões dos modelos candidatos e o teste de Box-Pierce, indicaram que entre os modelos candidatos o $ARIMA(1,0,2) \times (0,1,2)_{12}$ é o que melhor se ajusta aos dados da série de vazões analisada neste trabalho.

Para a modelagem da série de vazões por RNA, utilizou-se o tipo *feedforward multilayer perceptron* com tamanho da janela de entrada igual a trinta e seis, duas camadas escondidas composta por 60 e 30 neurônios artificiais. Nas camadas escondidas foi utilizada a função de ativação logística e linear na camada de saída, sendo o algoritmo de aprendizado o *Backpropagation*.

O erro na amostra de teste foi calculado a partir de duas abordagens: o Erro Médio Percentual Absoluto (MAPE) e Raiz do Erro Quadrático Médio (RMSE), representados por $MAPE = (1/T) \sum_{t=1}^T |(y_t - \hat{y}_t)/y_t|$ e $RMSE = ((1/T) \sum_{t=1}^T (y_t - \hat{y}_t)^2)^{1/2}$, respectivamente.

A amostra de teste, formada pelas últimas 12 observações, apresentou MAPE igual a 20,6% com o modelo ARIMA e 14,7% com a modelagem por RNA. Na Figura 5 estão representados os gráficos da amostra de teste e as previsões realizadas por ARIMA e RNA, nessa figura, pode-se observar que os valores previstos por meio da RNA estão mais próximos dos valores observados, exceto nos meses de fevereiro (2) e abril (4) onde ocorreu uma fraca superioridade preditiva do ARIMA em relação à RNA. Os gráficos em questão são um indicativo que o modelo neural é, neste caso, mais generalista que o modelo ARIMA.

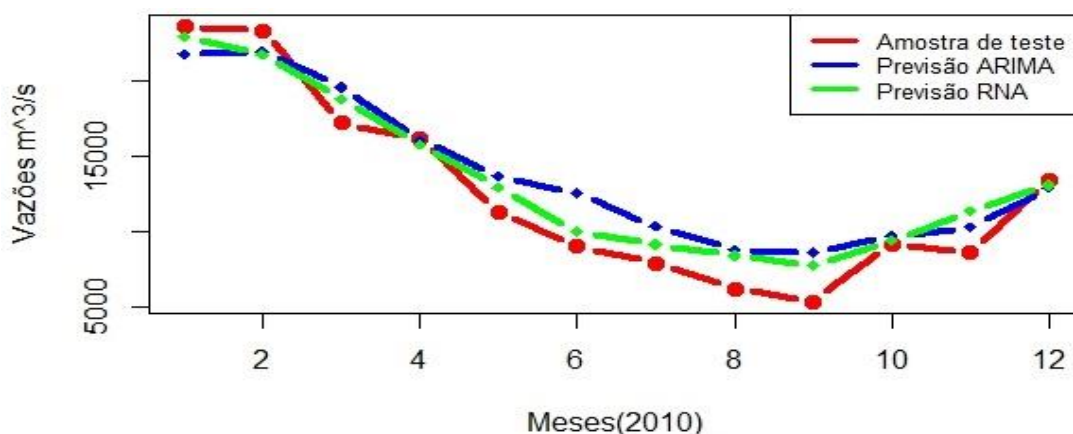


Figura 5 – Gráficos da amostra de teste e previsões por ARIMA e RNA. Fonte: autor.

6.2 Previsões: método EMD-RNA-RLM

Foram submetidas à modelagem por RNA as componentes resultantes de quatro decomposições por EMD, com cinco, seis, sete e oito componentes. A decomposição

que resultou oito componentes, teve uma delas classificada como resíduo, de acordo com as características sugeridas por Huang et al. (1998). Mas, para efeitos de previsão, a decomposição com seis componentes possibilitou os melhores ajustes, oferecendo vantagem preditiva em relação às outras três. Então, optou-se por esta última, ficando cinco IMF e outra denominada por resíduo, embora não tivesse as características de um resíduo resultante da decomposição EMD. Na Figura 6 podem ser observadas as seis componentes oriundas da decomposição EMD da série temporal de vazões $(y_t)_{t=1}^{t=480}$ utilizadas no processo de previsão.




Figura 6 – Decomposição EMD: IMF. Fonte: autor.

Na modelagem, por RNA, das seis componentes oriundas da decomposição por EMD da série de vazões, os tamanhos das janelas de entrada de dados utilizados foram: 15, 36, 24, 2, 2 e 9 para as IMF1, IMF2, IMF3, IMF4, IMF5 e resíduo, respectivamente. As redes eram constituídas por duas camadas escondidas com 50 neurônios artificiais na primeira e 30 na segunda, sendo a função de ativação a logística e o algoritmo de aprendizado o *backpropagation*. Estando as redes treinadas, fez-se a previsão doze passos à frente (estratégia recursiva) das IMF ($\hat{I}_{teste_j,t}, j = 1, 2, \dots, 5$), resíduo ($\hat{r}_{teste,t}$) e vazão ($\hat{y}_t)_{t=481}^{t=492}$) (amostra de teste). Esta última foi obtida a partir da Equação 7, sendo os coeficientes dessa equação provenientes da Regressão Linear Múltipla envolvendo as previsões das IMF e resíduo ($\hat{I}_{treino_1,t}, \hat{I}_{treino_2,t}, \dots, \hat{I}_{treino_n,t}$ e \hat{r}_{treino} : variáveis

independentes) e observações das vazões ($(y_t)_{t=1}^{t=480}$: variável dependente). Segundo o coeficiente de determinação R^2 , o modelo linear explica, a partir das variáveis independentes, 96% da variabilidade da variável dependente. O teste ANOVA, por sua vez, acusou valor-p nulo, indicando que há evidências de relação linear entre as variáveis independentes e dependente. Na Equação 7, os valores dos coeficientes são: $\beta = (0,975245; 0,99518; 0,858391; 0,91418; 1,054361; 1,004586)$.

$$\hat{y}_{teste,t} = \sum_{j=1}^5 (\beta_j \hat{I}_{teste_j,t}) + \beta_6 \hat{r}_t \tag{7}$$

Na Tabela 1 pode-se observar os valores da amostra de teste e as previsões doze passos à frente das séries: IMF, resíduo e amostra de teste.

Tabela 1 – Amostra de teste e previsões: IMF, resíduo e vazão.

2010	y_{teste}	\hat{I}_{teste_1}	\hat{I}_{teste_2}	\hat{I}_{teste_3}	\hat{I}_{teste_4}	\hat{I}_{teste_5}	\hat{r}_{teste}	\hat{y}_{teste}
Jan	23603,9	119,9	7940,2	642,8	818,8	967,9	12701	23098,9
Fev	23343,1	-476,5	10014,8	561,4	817,9	928,3	12695,0	24463,5
Mar	17203,5	-486,6	4972,5	384,3	709,2	787,3	12639,4	18979,6
Abr	16189,6	-475,9	2112,7	267,5	763,0	845,1	12684,3	16199,1
Mai	11319,6	104,0	-2682,5	78,5	710,3	802,1	12679,8	11732,1
Jun	9057,66	-86,6	-5576,8	-111,9	642,1	758,4	12675,6	8389,9
Jul	7941,79	-276,8	-7087,3	-283,4	560,2	714,2	12672,4	6429,3
Ago	6268,67	84,6	-7678,4	-418,2	466,4	669,8	12670,2	5942,9
Set	5398,60	-255,7	-7495,7	-507,7	362,9	625,2	12667,7	5571,9
Out	9239,92	-72,1	-6264,6	-546,7	251,9	580,7	12663,9	6790,8
Nov	8675,76	-63,5	-3659,4	-540,3	136,3	536,5	12662,0	9242,9
Dez	13419,8	-202,6	597,5	-494,8	18,6	492,6	12660,4	13227,1

Fonte: autor.

A Figura 7 ilustra a proximidade das previsões pontuais aos valores observados, tendo um distanciamento maior apenas no mês dez por conta de componente aleatória inerente aos dados observados. O erro MAPE das previsões na amostra de teste foi de 7,5%

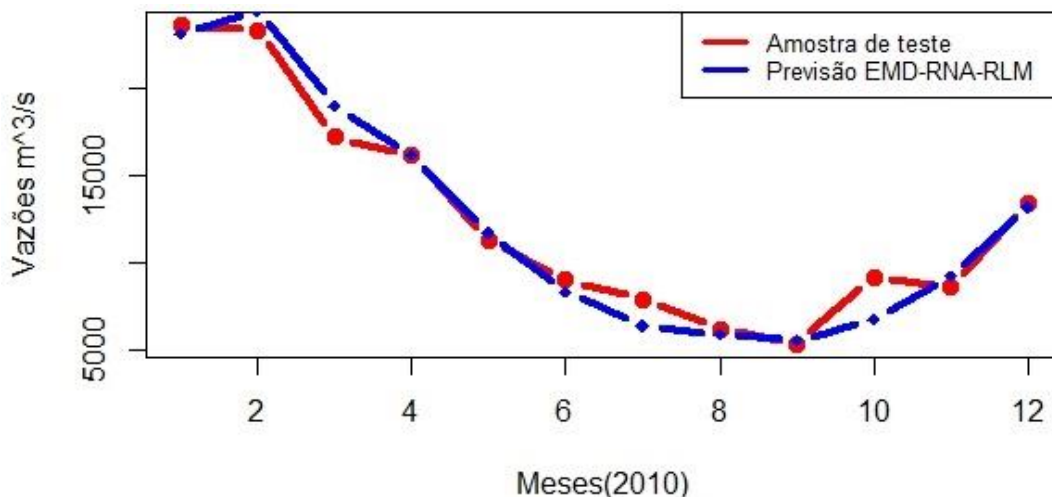


Figura 7 – Gráfico da amostra de teste e previsão pelo EMD-RNA- RL. Fonte: autor.

6.3 Comparativo entre os métodos

A Tabela 2 informa o MAPE e o RMSE correspondentes às previsões feitas doze passos à frente da amostra de teste retirada da série de vazões, onde se pode observar uma

superioridade do método proposto em relação aos outros métodos aplicados neste trabalho.

Tabela 2 – MAPE e RMSE amostra de teste

Métodos	Medidas de acurácia	
	MAPE em %	RMSE em m^3/s
EMD-RNA-RLM	7,5	1082,5
RNA	14,8	1554,8
ARIMA	20,6	2148,5

Fonte: autoria própria.

A aplicação do método EMD-RNA-RLM na previsão da série temporal de vazões mensais possibilitou uma redução do erro MAPE na ordem de 49% em relação ao método RNA individual e 63% quando comparado com o método ARIMA. Esta superioridade preditiva do método EMD-RNA-RLM em relação aos outros métodos testados, pode ser reforçada observando-se o comportamento dos valores dos Erros Percentuais Absolutos (APE). A Figura 8 mostra que os APE relativos ao EMD-RNA-RLM são mais estáveis em relação aos métodos ARIMA e RNA. Nesses métodos, os valores do APE violaram em vários instantes a faixa dos 20%, enquanto que em apenas um instante isso ocorre no método proposto. Além disso, na maioria dos instantes, o método proposto apresenta valores de APE inferiores aos outros dois.

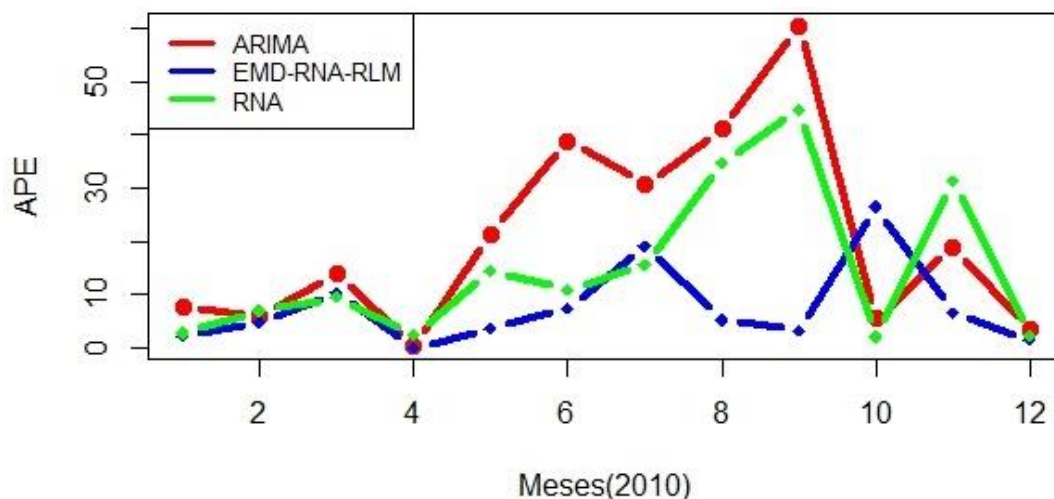


Figura 8 – Erro APE na amostra de teste para os métodos RNA, ARIMA e EMD-RNA-RLM. Fonte: autor.

7. Considerações finais

Neste artigo foram utilizados três métodos para a previsão de uma série temporal de vazões mensais coletadas no posto 266-Itaipu. Um deles faz a associação da decomposição da série temporal pelo método EMD, sendo as componentes desta decomposição modeladas via RNA *feedforward* e as previsões obtidas são submetidas a uma regressão linear múltipla a fim de se obter as previsões doze passos à frente, de forma recursiva, da série de vazões. Os outros dois métodos utilizados foram os individuais ARIMA e RNA *feedforward*.

A combinação do EMD com a RNA apresentou resultados significativos, haja vista que a redução do erro MAPE em relação ao segundo melhor método (RNA individual) foi de 49%. Por outro lado, o uso da RLM propiciou uma redução de apenas 3% em relação a opção de obtenção das previsões da série de vazões através da soma das previsões das componentes EMD, ou seja: fazer os coeficientes $\beta_j = 1, j=1, \dots, 6$, na Equação 7.

Os resultados obtidos neste trabalho e em outros encontrados na literatura apontam para uma maior eficiência preditiva do método em que se incorpora ao modelador neural a decomposição EMD. Além disso, o método poderá ser aperfeiçoado com a aplicação de outro tipo de estratégia de previsão multipassos à frente, é consenso na literatura especializada que a estratégia recursiva está entre aquelas que apresentam os maiores erros de previsão.

Referências

- BASTA, M.** Time Series Forecasting With a Prior Wavelet-Based Denoising Step. *Acta Oeconomica Pragensia*, v. 26(1), p. 5–24, 2018.
- BOX, G.; JENKINS, G.** *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day, 1970.
- CAMARGO, H. N. et al.** Métodos de Previsão de Séries Temporais e Modelagem Híbrida ambos Aplicados em Médias Mensais de Velocidade do Vento para Regiões do Nordeste do Brasil. *Revista Brasileira de Meteorologia*, v. 32, n. 4, 2017.
- EMPRESA DE PESQUISA ENERGÉTICA – EPE.** Plano Decenal de Expansão de Energia 2027. Brasília: MME/EPE, 2018.
- GOOLJER, J. G.; HYNDMAN, R. J.** 25 years of time series forecasting. *International Journal of Forecasting*, p.443– 473, 2006.
- HAYKIN, S.**, *Redes Neurais Princípios e Aplicações*, 2. Ed. Porto Alegre: Bookman, 2001.
- HE, K. et al.** Forecasting Electricity Market Risk Using Empirical Mode Decomposition (EMD)—Based Multiscale Methodology. *Energies*, v.9, 2016,
- HUANG, N. E. et al.** The Empirical Mode Decomposition and the Hilbert Spectrum For Nonlinear and Non-Stationary Time Series Analysis. *Proc. R. Soc. Lond.*, v. 454, p. 903-995, 1998
- HUMPHREY, G. B. et al.** A hybrid approach to monthly streamflow forecasting: integrating hydrological model outputs into a Bayesian artificial neural network. *Journal of Hydrology*, v.540, p.623-640, (2016)
- KIM, T. et al.** Identification of relationships between climate indices and long-term precipitation in South Korea using ensemble empirical mode Decomposition. *Journal of Hydrology*, v.557, p. 726-739, 2018
- LOPES, J.E.G., BRAGA B.P.G., CONEJO J.G.L.** SMAP – A Simplified Hydrological Model. In: SINGH, V.P. *Applied Modelling in Catchment Hydrology*. Colorado: Water Resources Publications, 1982, p.167-176.
- NIU, D.; LING, Y.; HONG, W.C.** Wind Speed Forecasting Based on EMD and GRNN Optimized by FOA. *Energies*, v.10, 2017.
- R CORE TEAM.** R: A language and environment for statistical computing. R Foundation for Statistical Computing, 2020. Vienna, Austria. Disponível em: <https://www.R-project.org/>. Acesso em: 20/04/2020.
- REZAIIE-BALF, M., et al.** Daily river flow forecasting using ensemble empirical mode decomposition based heuristic regression models: Application on the perennial rivers in Iran and South Korea. *Journal of Hydrology*, v.572, p. 470-485, 2020.
- RYAN, M.** Decomposing Signal Using Empirical Mode Decomposition — Algorithm Explanation for Dummy. *Towards Data Science*, 2019. Disponível em: <https://towardsdatascience.com/decomposing-signal-using-empirical-mode-decomposition-algorithm-explanation-for-dummy-93a93304c541>. Acesso em: 12/05/2020
- SOUZA, R. C.; CAMARGO, M.E.** *Análise e Previsão de Séries Temporais: os modelos ARIMA*. Ijuí: SEDIGRAF, 2004.
- WANG, A.B.W.; VAN GELDER,P.H.A.J.M.;URIJLING,J.K.; MA, J.** Testing for nonlinearity of streamflow processes at different time scales. Amsterdam: *Journal of Hydrology*, v. 322, p. 247-268, 2006
- WANG, J. et al.** Teleconnection analysis of monthly streamflow using ensemble empirical mode decomposition. *Journal of Hydrology*, v.582, 2020.

WANG, J. et al. A A Weighted EMD-Based Prediction Model Based on TOPSIS and Feed Forward Neural Network For Noised Time Series. *Knowledge-Based Systems*, v. 132, p. 167-178, 2017

ZHANG, G. P.; QI, M. Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, v. 160, p. 501–514, 2005.