

JAIC

Journal of Applied Instrumentation and Control

Avaliação de abordagens alternativas de previsão no estudo de séries de vazões

Jonatas Trabuco Belotti, Ivette Luna e Hugo Siqueira

Resumo — O presente trabalho discute a influência do uso de diferentes abordagens de previsão construídas em estudos de séries mensais de vazões fluviais. Uma das maneiras usualmente adotadas pelo Setor Elétrico Brasileiro é o uso de 12 preditores lineares mensais do tipo periódico auto-regressivo, e previsões recursivas para horizontes mais longos que um passo à frente. Uma alternativa possível é a utilização de um único modelo para toda a série e realizar de maneira direta para horizontes de mais de um passo à frente. Além disso, o uso de redes neurais artificiais tem ganhado destaque recentemente. Os resultados computacionais obtidos neste trabalho indicam que a forma frequentemente adotada pelo SEB pode não ser a mais adequada para a solução do problema. Os estudos de caso indicam também que a arquitetura de redes neurais do tipo máquina de aprendizado extremo alcançou melhor desempenho que os modelos lineares.

Palavras-chave— Abordagens de previsão, séries de vazões, modelos Box & Jenkins, redes neurais, Máquinas de Aprendizado Extremo

I. INTRODUÇÃO

A análise de séries temporais envolve diversas etapas que vão desde a modelagem de um fenômeno natural até a previsão de valores futuros, com o intuito de antecipar determinados comportamentos [1]. A principal tarefa neste processo é, sem dúvida, definir um modelo de representação adequado para desempenhar o papel de mecanismo preditor da série [2]. Entretanto, existem etapas intermediárias que podem influenciar decisivamente no desempenho de um preditor, tais como o pré-processamento de dados, a seleção das variáveis de entrada e as estratégias de determinação dos seus parâmetros livres [3].

Jonatas Trabuco Belotti é mestrando Programa de Ciências da Computação da Universidade Tecnológica Federal do Paraná (UTFPR), Campus Ponta Grossa (jonatas.T.Belotti@hotmail.com).

Ivette Luna é professora do Instituto de Economia da Universidade Estadual de Campinas (UNICAMP).

Hugo Siqueira é professor do Departamento Acadêmico de Engenharia Eletrônica da Universidade Tecnológica Federal do Paraná (UTFPR), Campus Ponta Grossa (hugosiqueira@utfpr.edu.br).

A definição da abordagem de previsão é também fundamental. Por exemplo, no caso de previsões para múltiplos passos à frente, é possível efetuar a estimativa do valor futuro da série de forma direta ou de forma recursiva; neste último caso, o preditor sempre oferece uma estimativa do próximo valor da série, e tal estimativa é realimentada até que se chegue à predição no instante futuro desejado [4]. Outra escolha importante está associada ao uso de apenas um modelo de predição para todo conjunto de dados ou de diferentes modelos especificamente projetados para tratar cada bloco da série. No caso de séries de vazões mensais com sazonalidade anual, pode ser pertinente destinar a cada mês um preditor próprio [2,3,4].

Este trabalho tem como objetivo analisar como as variadas abordagens de previsão podem afetar o desempenho de modelos preditores ajustados às séries de vazões médias mensais de usinas hidrelétricas brasileiras. Vale salientar que cerca de 77% de toda produção de energia elétrica no Brasil é de origem hidrelétrica [5]. Há, portanto, grande relevância no estudo de metodologias para promover o melhor uso da água como insumo para geração de energia [2].

A previsão de vazões afluentes é fundamental para a programação mensal do uso dos recursos hídricos e energéticos do Sistema Interligado Nacional (SIN). O Operador Nacional do Sistema Elétrico (ONS) possui, para o desenvolvimento de tais funções, uma cadeia de modelos para a otimização da operação, os quais utilizam séries de vazões médias diárias, semanais e mensais [6], sendo que o caso mensal destina-se ao planejamento de curto e médio prazos.

No Programa Mensal de Operação, coordenado pelo ONS, uma das metodologias mais utilizadas para a previsão de vazões mensais é baseada em modelos lineares de séries temporais da família Box & Jenkins [1] com destaque para os modelos periódicos auto-regressivos (PAR) [7]. O que caracteriza esta abordagem é que 12 modelos auto-regressivos (AR) distintos são ajustados de forma independente, sendo cada um otimizado para prever os dados de cada um dos 12 meses do ano [2,3,4,7,8]. Para a predição de múltiplos passos à frente, adota-

se a abordagem recursiva [9].

Este estudo irá investigar se a adoção de outras abordagens de previsão pode ser benéfica para a melhoria do desempenho dos preditores, em comparação com a proposta recursiva. Os resultados obtidos com redes neurais artificiais (RNA) da família de Máquinas de Aprendizado Extremo (ELM, do inglês *extreme learning machines*) [10,11] serão confrontados com os obtidos através de modelos lineares.

Salientamos que as RNA têm sido largamente utilizadas em problemas de previsão. Trabalhos recentes [2,3,4] mostraram que as ELM podem superar arquiteturas bastante difundidas na literatura como o tradicional Perceptron de Múltiplas Camadas (MLP) e redes recorrentes. Assim sendo, como o foco do estudo está nas abordagens de previsão, a ELM foi escolhida para representar o comportamento de uma RNA.

O presente artigo está dividido da seguinte forma: a Seção II discute as abordagens de previsão; A Seção III apresenta os modelos auto-regressivos, enquanto a Seção IV aborda sua variante mensal, o periódico auto-regressivo. A Seção V contém as Máquinas de Aprendizado Extremo e a VI os resultados computacionais e a análise destes. A conclusão está na Seção VII.

II. ABORDAGENS DE PREVISÃO

A. Previsões direta e recursiva

O planejamento energético de médio prazo, baseado nas séries de vazões médias mensais, é feito com previsões de até 12 meses à frente ($P = 12$) [12]. No entanto, à medida que o horizonte se eleva, há uma perda no poder preditivo dos modelos, sejam eles lineares ou não [3]. Segundo Andrade et al. [13], no caso específico dos modelos PAR, há uma degradação do erro quadrático médio muito evidente com o aumento de P .

Existem duas formas básicas de se fazer previsão multi-passos, a saber, os métodos direto e recursivo [4,9]:

- i) **Direto**: nesta abordagem, as entradas de um modelo preditor em determinado instante t geram diretamente a amostra x_{t+P} , sem que seja necessário prever amostras intermediárias. Por exemplo, para um modelo de 2 entradas e $P = 12$, teríamos $\hat{x}_{14} = F(x_1, x_2)$, em que \hat{x}_{14} é o dado previsto em $t = 14$, (x_1, x_2) são as entradas disponíveis em $t = 2$, e F representa a o mapeamento associado ao preditor.
- ii) **Recursivo**: neste caso, a previsão é feita de maneira que as amostras intermediárias faltantes para se obter a resposta em P são previstas e utilizadas como entradas do preditor de um passo adiante. Aproveitando-se do exemplo anterior, tem-se um conjunto de previsões expressas por (1):

$$\begin{aligned} \hat{x}_3 &= F(x_1, x_2) \\ \hat{x}_4 &= F(x_2, \hat{x}_3) \\ \hat{x}_5 &= F(\hat{x}_3, \hat{x}_4) \\ &\dots \\ \hat{x}_{14} &= F(\hat{x}_{12}, \hat{x}_{13}) \end{aligned} \quad (1)$$

Como se observa, para obter a estimativa da série em $t = 14$, serão utilizados os dados previstos para $t = 12$ e $t = 13$ como entradas do modelo.

Por não utilizar amostras intermediárias, o método direto evita a propagação de erros de predição de um instante para outro, uma vez que cada dado previsto já contém alguma medida de erro que vai sendo propagado até o instante $t + P$. Por outro lado, a correlação entre as amostras cai com o aumento do horizonte, o que, necessariamente, degrada a resposta final, justificando o uso do método recursivo. Estas potenciais vantagens ressaltam a necessidade de se comparar tais abordagens [4,9].

B. Modelos mensais e anuais

Séries com sazonalidade anual podem ser ajustadas de duas maneiras: a primeira consiste em considerar um único modelo como gerador de toda a série, de modo que apenas um ajuste é feito e, independentemente de a qual mês pertença o dado, ele será previsto por um único preditor [4,9].

Já na previsão mensal, são utilizados 12 preditores distintos, um para cada mês. De acordo com Maceira [7], séries hidrológicas com comportamento sazonal de até um ano possuem comportamento periódico em relação a propriedades estatísticas como média, variância e estrutura de correlação. Isto permite que séries de vazões apareçam como candidatas naturais a serem ajustadas por modelos mensais.

É importante mencionar que o Sistem Elétrico Brasileiro (SEB) utiliza frequentemente a previsão linear mensal e recursiva, baseada no modelo PAR [14].

III. MODELO AUTO-REGRESSIVO - AR(P)

A maneira usual de se prever os valores futuros de uma série temporal é realizar uma combinação ponderada de amostras observadas. Para isso, é necessário definir um modelo que seja suficientemente representativo dos dados conhecidos desta série e estimar seus respectivos parâmetros livres, com base em algum critério previamente estabelecido [15].

O modelo auto-regressivo de ordem p - AR(p) faz parte do conjunto de métodos descritos por Box & Jenkins para séries estacionárias[1]. A ampla utilização desse método decorre de sua eficiência e relativa facilidade no tratamento matemático [16]. A equação que define o modelo AR(p) é descrita em (2):

$$\hat{x}_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + a_t \quad (2)$$

na qual $x_{t-i}, i = 1, \dots, p$ são os valores observados, ou atrasos, \hat{x}_t é o valor previsto para o instante t , $\phi_i, i = 1, \dots, p$, são os coeficientes ajustáveis e o termo a_t é a componente aleatória ou o erro inerente ao processo de previsão.

Como pode ser percebido na Equação (1), o modelo não possui realimentação de resposta de saída. Por isso, seus coeficientes ótimos, no sentido no mínimo erro quadrático médio (MSE, do inglês *mean square error*), podem ser obtidos analiticamente através das *equações de Yule-Walker* [1,3,4], apresentadas na Expressão (3):

$$\Phi_p = P_p^{-1} \rho_p \quad (3)$$

sendo $\Phi = [\phi_1, \phi_2, \dots, \phi_p]$ o vetor dos p coeficientes que ponderam as entradas e que definem a ordem do modelo.

Os demais termos correspondem à matriz de autocorrelação e ao vetor de estimativas das funções de autocorrelação das entradas, definidos, respectivamente, como em (4):

$$\mathbf{P}_p = \begin{bmatrix} 1 & \rho_1 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \dots & \rho_{p-2} \\ \dots & \dots & \dots & \dots \\ \rho_{p-1} & \rho_{p-2} & \dots & 1 \end{bmatrix} \quad \mathbf{p}_p = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \dots \\ \rho_p \end{bmatrix} \quad (4)$$

sendo os coeficientes da autocorrelação dados por (5):

$$\rho_i = \frac{E[(x_t - \mu)(x_{t+i} - \mu)]}{\sqrt{E[(x_t - \mu)^2]E[(x_{t+i} - \mu)^2]}} \quad (5)$$

onde μ denota a média amostral e E o operador esperança matemática [4].

IV. MODELO PERIÓDICO AUTO-REGRESSIVO – PAR(p_m)

Os modelos periódicos auto-regressivos de ordem p_m - PAR(p_m) - são extensões do modelo AR, utilizados em séries temporais que apresentam variações na sua estrutura [17].

A justificativa para utilização do PAR é que algumas séries temporais, como é o caso das hidrológicas sazonais, apresentam uma estrutura de autocorrelação não apenas ligada ao atraso de tempo entre as observações, mas também ao período observado [18]. Além disso, séries hidrológicas com periodicidade de até um ano, como as vazões mensais, possuem comportamento periódico em relação a suas propriedades estatísticas como a média, a variância e a estrutura de correlação [7]. A expressão matemática do modelo PAR(p_m) é como em (6):

$$\hat{x}_t = \phi_1^m x_{t-1} + \phi_2^m x_{t-2} + \dots + \phi_{p_m}^m x_{t-p_m} + a_t \quad (6)$$

em que o índice superior m denota o mês ao qual a observação pertence.

Dessa maneira, para cada um dos 12 meses do ano será ajustado um modelo AR de forma independente. Para isso, reescrevem-se os termos das equações de Yule-Walker para o caso periódico na forma matricial [14], apresentado em (7):

$$\mathbf{P}_{p_m}^m = \begin{bmatrix} 1 & \rho_1^{m-1} & \dots & \rho_{p_m-1}^{m-1} \\ \rho_1^{m-1} & 1 & \dots & \rho_{p_m-2}^{m-2} \\ \dots & \dots & \dots & \dots \\ \rho_{p_m-1}^{m-1} & \rho_{p_m-2}^{m-2} & \dots & 1 \end{bmatrix}, \quad \Phi_{p_m}^m = \begin{bmatrix} \phi_1^m \\ \phi_2^m \\ \dots \\ \phi_{p_m}^m \end{bmatrix} \quad (7)$$

$$\mathbf{p}_{p_m}^m = \begin{bmatrix} \rho_1^m \\ \rho_2^m \\ \dots \\ \rho_{p_m}^m \end{bmatrix}$$

de modo que $m=1, 2, \dots, 12$ é índice de cada mês. A solução ótima para cálculo dos coeficientes do modelo PAR(p_m), no sentido do mínimo MSE, é dada pela Expressão (8):

$$\Phi_{p_m}^m = (\mathbf{P}_{p_m}^m)^{-1} \mathbf{p}_{p_m} \quad (8)$$

O modelo PAR pode ser diretamente utilizado para previsão e modelagem de séries de vazões mensais, caso estas sejam estacionárias [3,4].

V. MÁQUINAS DE APRENDIZADO EXTREMO

Redes neurais artificiais (RNA) são estruturas de processamento distribuído de informação, compostas por unidades de processamento simples, denominadas neurônios artificiais, e que possuem alto grau de interconexão[19]. Uma das características marcantes deste tipo de modelo é a capacidade de aprendizagem. Usualmente, este processo envolve a adaptação das eficiências das conexões entre os neurônios, representadas como pesos que ponderam os sinais transmitidos, visando aproximar uma resposta desejada na saída da rede [3,19].

A previsão de séries de vazões pode ser considerada uma tarefa de mapeamento não-linear estático. O Perceptron de Múltiplas Camadas (MLP) é uma arquitetura de RNA muito utilizada na abordagem deste problema [19]. Para isso, todos os parâmetros das camadas de neurônios de uma MLP precisam ser ajustados de maneira supervisionada, por meio de algoritmos de otimização baseados em gradiente, sendo o *backpropagation* o método mais comum de cálculo da derivada da função custo.

Em anos recentes, novas propostas de redes neurais vêm ganhando destaque [2,3,4]. Neste âmbito se inserem as Máquinas de Aprendizado Extremo (ELM), redes *feedforward*, semelhantes às tradicionais MLP e de camada intermediária única [3,10,11]. O que as diferencia é o processo de ajuste dos pesos, que, neste caso, é bastante simples. Nas ELM, a camada oculta tem pesos gerados de forma aleatória e independente, e o treinamento se limita à adaptação dos pesos da camada de saída. Além disso, os valores ótimos destes pesos são tipicamente calculados de forma analítica, já que o treinamento envolve a solução de um problema de regressão linear [11]. Desta forma, não é necessário calcular derivadas da função de erro, tampouco realizar a retropropagação do erro e aproximar a solução ótima de forma iterativa, o que traz uma significativa redução do custo computacional [3,4].

Considerando uma rede neural genérica de camada única, seja o vetor de entradas $\mathbf{u}_t = [u_1, u_2, \dots, u_{t-K+1}]^T$ que tem seus componentes passados à camada intermediária $\mathbf{W}^h \in \mathfrak{R}^{N_h \times K}$, a qual contém os pesos gerados de forma aleatória. As ativações dos neurônios da camada intermediária são obtidas de acordo com (9):

$$\mathbf{x}_t^h = \mathbf{f}^h(\mathbf{W}^h \mathbf{u}_t + \mathbf{b}) \quad (9)$$

onde $\mathbf{f}^h(\cdot)$ é a função de ativação dos neurônios, N_h é o número de neurônios, K é o número de entradas da rede e \mathbf{b} representa o vetor com as respectivas polarizações.

A saída \mathbf{y}_t da rede será composta pela combinação linear das ativações dos neurônios da camada intermediária de acordo com a expressão (10):

$$\mathbf{y}_t = \mathbf{W}^{\text{out}} \mathbf{x}_t^h \quad (10)$$

na qual $\mathbf{W}^{\text{out}} \in \mathcal{R}^{N_h \times L}$ contém os pesos da camada de saída.

O processo de treinamento envolve a minimização do erro quadrático médio entre a saída da rede e a resposta desejada \mathbf{d}_t . Esta tarefa de regressão linear admite uma solução analítica para os coeficientes do combinador linear da saída, baseada no operador de pseudo-inversão de Moore-Penrose, dada por (11):

$$\mathbf{W}^{\text{out}} = (\mathbf{X}_h^T \mathbf{X}_h)^{-1} \mathbf{X}_h^T \mathbf{d} \quad (11)$$

onde $\mathbf{X}_h \in \mathcal{R}^{T_s \times N_k}$ é a matriz de saídas da camada intermediária, T_s é o número de amostras de treinamento, $(\mathbf{X}_h^T \mathbf{X}_h)^{-1} \mathbf{X}_h^T$ é a pseudoinversa (para $N_k \leq T_s$) de \mathbf{X}_h e $\mathbf{d} \in \mathcal{R}^{T_s \times 1}$ contém as saídas desejadas. Esta solução é simples e eficiente em termos computacionais.

Trabalhos recentes têm mostrado que as ELMs podem alcançar resultados superiores aos de MLPs em diversas tarefas de previsão [2,3,4,20]. Tais trabalhos também se relacionam à previsão de vazões mensais e equalização de canais de comunicação. Por conta disso, este trabalho adotará tal rede como modelo não-linear básico para análise comparativa.

VI. ESTUDO DE CASOS E DISCUSSÃO

A. Séries de vazões médias mensais

O presente estudo considera as séries de vazões médias mensais de três importantes usinas hidrelétricas brasileiras-Furnas, Emborcação e Sobradinho. Estas possuem características distintas de média e o desvio padrão (em m³/s), como mostra a Tabela 1:

Tabela 1- Médias e Desvio Padrões Estimados

Série	Média ($\hat{\mu}$)	D. Padrão ($\hat{\sigma}$)
FURNAS	926.6177	613.1671
SOBRADINHO	2666.0229	1959.0325
EMBORCAÇÃO	486.0781	362.8067

É possível verificar que o Posto de Sobradinho possui média significativamente superior à de Furnas, e esta, por sua vez, aproximadamente o dobro do valor médio observado em Emborcação. Os dados estão disponíveis no site do Operador Nacional do Sistema Elétrico (NOS) [6]. Neste trabalho, serão consideradas as vazões entre janeiro de 1931 e dezembro de 2010, o que compreende 960 amostras mensais.

Os modelos de previsão lineares da metodologia Box & Jenkins aqui adotados pressupõem que os dados sejam estacionários. Dessa forma, antes da utilização dos modelos de previsão, faz-se necessário aplicar uma transformação

estatística aos dados conhecida por dessazonalização, com intuito de retirar o componente sazonal presente nas séries. O procedimento padrão adotado na literatura é dada pela Equação (12) [4,14]:

$$z_{i,m} = \frac{x_{i,m} - \hat{\mu}_m}{\hat{\sigma}_m} \quad (12)$$

onde $x_{i,m}$ representa a vazão observada no mês m do i -ésimo ano, $i = 1, 2, \dots, N_y$, e no mês $m = 1, 2, \dots, 12$, sendo N_y o total de anos compondo o histórico, $\hat{\mu}_m$ é a média histórica (ou de longo termo) observada para o mês m , e $\hat{\sigma}_m$ respectivo o desvio padrão.

Veja que a série original é transformada em uma nova série estacionária \mathbf{z}_t , com média zero e desvio padrão unitário [2]. Ao fim da previsão, a componente sazonal é reinserida à resposta do modelo para a análise de desempenho no domínio real da série [3], com a soma da média e a respectiva multiplicação do desvio padrão.

B. Resultados computacionais

Foram feitas diversas simulações computacionais com os modelos AR, PAR e as ELMs. Inicialmente, dividiram-se 80 anos do histórico em dois conjuntos: (1) de teste, composto por 120 meses, compreendendo os anos de 1967 a 1976; (2) de treinamento, com os demais dados disponíveis, num total de 70 anos ou 840 observações mensais.

A análise de desempenho parte da verificação da raiz do erro quadrático médio (RMSE) obtido nos conjuntos de testes, o qual é dado pela seguinte expressão (13):

$$RMSE = \sqrt{\frac{1}{N_s} \sum_{t=1}^{N_s} (d_t - \hat{x}_t)^2} \quad (13)$$

na qual d_t é a vazão observada, \hat{x}_t é a vazão prevista e N_s , o número de observações associadas ao conjunto de teste.

De acordo com [13], a forma como o modelo PAR é utilizado para este tipo de estudo considera alguns pressupostos. O primeiro é que o número máximo de entradas, ou de atrasos, aceitos é 6 [21], ou seja, a ordem do modelo PAR varia de $p_m=1$ a $p_m=6$. A seleção das variáveis de entrada é feita com base na função de autocorrelação parcial (FACP) [16], com a restrição de que estas entradas devem ser consecutivas, admitindo que apenas valores intermediários significativos [21,22]. Por fim, a previsão para horizontes mais longos que um passo à frente é feita de forma recursiva [9]. Neste estudo, adotaram-se os valores de $P = 1, 3, 6$ e 12 passos à frente.

Quanto ao modelo de predição ser mensal ou anual, foram utilizados o PAR e o AR, respectivamente, com seleção de entradas realizada pela FACP [4,22]. Em paralelo, a ELM foi aplicada segundo estes mesmos paradigmas: um modelo único para toda série (no espírito do modelo AR) e 12 diferentes redes, uma para cada mês (conforme metodologia PAR). Para as redes neurais, a seleção das variáveis de entrada foi feita por meio do *wrapper* com seleção progressiva [4,23]. A escolha do número

de neurônios nas camadas intermediárias foi realizada com base em testes preliminares. Além disso, conforme descreve a Seção 2.1, verificou-se o impacto de adotar a forma direta de previsão para $P > 1$.

Combinando as formas descritas, haverá quatro possibilidades de proceder com o processo de previsão: (i) recursiva mensal (RM) – há 12 modelos e a predição é recursiva para $P > 1$; (ii) direta mensal (DM) – também há 12 preditores, mas, para $P > 1$, a predição é direta; (iii) recursiva com série completa (RC) – um único modelo recursivo de predição é empregado para toda a série; e (iv) direta com série completa (DC) – um único preditor ajustado para estimar diretamente as amostras futuras para $P > 1$.

O teste de Friedman foi aplicado às previsões para verificação da significância dos erros [24,25]. Os resultados encontrados para o *p*-valor foram próximos de zero, o que indica que alterar o modelo e a forma de previsão implicam em resultados significativamente diferentes.

A análise de desempenho permite algumas considerações relevantes. A primeira delas é que, em 9 dos cenários analisados, a ELM teve desempenho superior ao dos modelos lineares. Isto é um indicativo de que há ganhos consistentes em se utilizar metodologias não lineares para a solução deste problema. Além disso, lembramos que o custo computacional

do treinamento destas redes é semelhante ao de um filtro linear, o que confere competitividade ao método.

Analisando a variação na forma de previsão, é conveniente agrupar os melhores resultados para cada valor de P como na Tabela 3. Nesta “Mens” indica a abordagem mensal e “SC” a série completa de preditor único.

Tabela 3 – Melhores resultados por horizonte e forma de previsão

Forma de previsão	P=1	P=3	P=6	P=12	TOTAL
Direta Mens.	2	2	0	1	5
Recursiva Mens.	0	1	1	0	2
Direta - SC	½	0	0	1	1+½
Recursiva - SC	½	0	2	1	3+½

O valor ½ faz referência ao caso em que houve empate uma vez que, para um passo à frente, o modelo AR apresenta o mesmo valor, tanto para o método recursivo como para o direto. A Figura 2 mostra os melhores resultados finais separados por horizonte e pelo número total de vezes que cada forma de prever chegou ao menor RMSE.

Tabela 2 – Valores RMSE obtidos pelos modelos AR e PAR e pelas ELM

		Modelo	P=1	P=3	P=6	P=12
Furnas	RM	PAR	268,76	326,37	353,29	367,27
		ELM-12	270,31	347,04	363,99	373,24
	DM	PAR	268,76	340,83	356,23	377,86
		ELM-12	266,86	336,31	355,64	345,94
	RC	AR	263,09	343,83	349,84	347,26
		ELM	264,16	354,78	357,12	358,85
DC	AR	263,09	357,12	363,38	354,54	
	ELM	263,91	349,32	360,62	359,95	
Emborcação	RM	PAR	174,01	227,00	232,52	229,16
		ELM-12	165,35	218,45	224,74	220,90
	DM	PAR	174,01	234,71	237,21	254,81
		ELM-12	163,97	215,48	223,59	209,99
	RC	AR	175,35	231,34	220,76	216,21
		ELM	170,90	231,02	218,06	217,05
DC	AR	175,35	243,74	235,60	223,42	
	ELM	169,03	236,90	239,39	226,86	
Sobradinho	RM	PAR	825,88	1082,1	1066,72	1070,65
		ELM-12	815,78	1090,1	997,47	998,62
	DM	PAR	825,88	1101,7	1070,56	1200,29
		ELM-12	813,31	1052,94	1021,17	986,37
	RC	AR	829,04	1211,48	1036,72	997,64
		ELM	832,66	1310,38	1048,52	981,43
DC	AR	829,04	1245,11	1082,86	1017,93	
	ELM	835,49	1222,37	1089,95	1019,21	

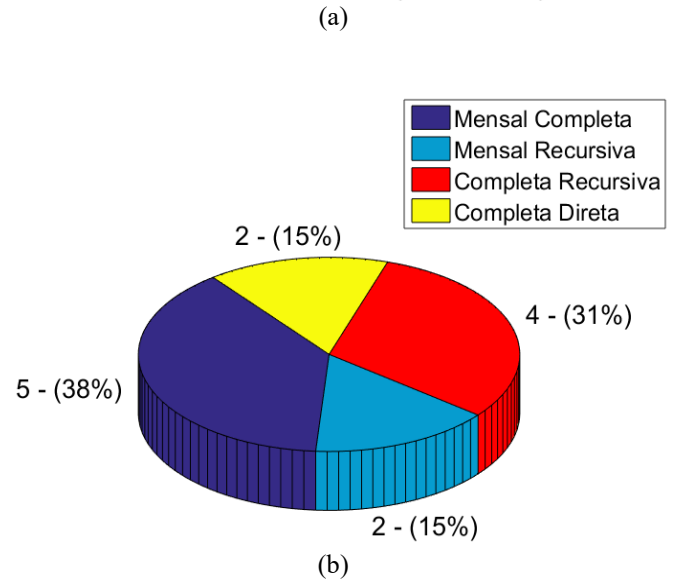
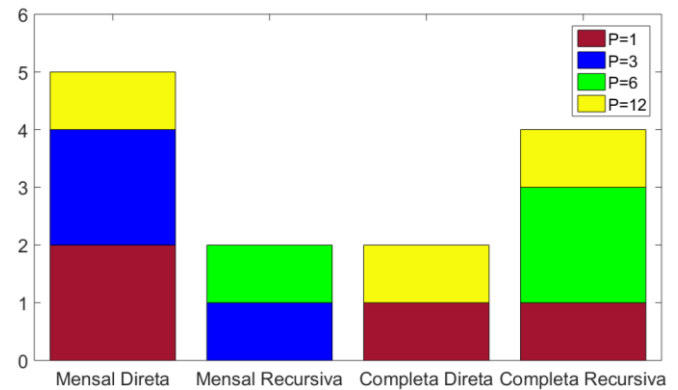


Figura 2 – Melhores resultados para as diversas abordagens de previsão

Já para o tipo de previsão para $P > 1$, o que se nota é que, dos 9 casos, 5 são favoráveis a modelos com previsão recursiva e 4 a modelos de previsão direta. Fica patente que nenhuma forma de previsão consegue ser, pelo menos uma vez, a de menor RMSE geral para todos os horizontes. Veja, na Figura 2(a), que, das 4 propostas, nenhuma barra possui as 4 cores. Em termos absolutos, o que é possível verificar é que a forma *mensal direta* conseguiu alcançar os melhores resultados em 5 casos enquanto a de série *completa recursiva* o fez em 4.

Em síntese, das abordagens de previsão analisadas, comparando-se os melhores desempenhos para modelos mensais versus de série completa, ou previsão direta versus recursiva, há quase uma equivalência considerando os resultados dos modelos preditores. Dessa forma, não é possível, com base neste conjunto de experimentos computacionais, ser categoricamente conclusivo sobre qual forma de se prever vazões é a mais adequada, levando-se em conta as abordagens estudadas. O que fica evidente é que a forma oficialmente adotada para realizar previsões - modelo linear PAR e previsão recursiva não parece ser a melhor forma de tratamento do problema, abrindo diversas perspectivas de investigação nesta área.

A Figura 3 mostra uma execução para $P = 1$ dos melhores preditores e abordagens de previsão da Tabela 2.


VII. CONCLUSÃO

Este trabalho avaliou abordagens alternativas de previsão de séries de vazões médias mensais de três usinas hidrelétricas do Sistema Interligado Nacional do Brasil – Furnas, Emborcação e Sobradinho. Entende-se por abordagens de previsão: i) para horizontes de previsão com múltiplos passos à frente, a utilização do método direto ou recursivo; ii) a adoção de um preditor único para modelagem e previsão da série temporal completa ou a aplicação de 12 diferentes modelos, sendo um ajustado para cada um dos meses.


Os preditores utilizados foram o modelo auto-regressivo – AR – (caso de modelo único) e periódico auto-regressivo – PAR – (como modelo mensal) e as redes neurais do tipo Máquinas de Aprendizado Extremo (ELM). Os resultados computacionais baseados nos erros obtidos mostraram que há praticamente uma equivalência entre modelos mensais e modelos destinados ao tratamento da série completa, bem como entre as abordagens de previsão direta e recursiva, não sendo possível afirmar qual das formas é a mais adequada ao problema. O que se observa é que na maioria dos casos, a abordagem mensal direta alcança os melhores desempenhos, seguido da de série completa recursiva.

Por outro lado, o modelo linear mensal PAR com previsão recursiva, um dos mais utilizados neste tipo de estudo, não se mostrou o mais eficiente. Na análise dos erros, dos 12 cenários abordados, os quais incluem séries e horizontes de previsão variados, este consegue chegar ao melhor desempenho em apenas dois. Isso reflete a necessidade de que novos estudos sejam feitos utilizando séries de usinas distintas e períodos de testes diferentes para uma avaliação mais apurada de qual forma de previsão é a mais adequada ao problema.


É possível ainda, destacar que modelos lineares parecem não ser a melhor escolha, já que os resultados computacionais



(a)



(b)



(c)

Figura 3 – Resultados melhores previsões $P=1$, real e dessazonalizado – (a) Furnas, (b) Emborcação, (c) Sobradinho

indicaram que a ELM conseguiu alcançar melhor desempenho geral.

Trabalhos futuros podem ser desenvolvidos utilizando outros paradigmas de modelos preditores, como as máquinas de vetores de regressão, bem como avaliar tais abordagens em séries de usinas com comportamento hidrológico diferente das abordadas.

AGRADECIMENTOS

Este trabalho contou com o suporte financeiro das agências de fomento CAPES e CNPq, processo 405580/2018-5,

REFERÊNCIAS

- [1] Box, G., Jenkins, G., and Reinsel, G. C., *Time Series Analysis, Forecasting and Control* (4^a ed.). Wiley, 2008.
- [2] Siqueira, H. V., Máquinas Desorganizadas para Previsão de Séries de Vazões. *Tese de Doutorado - FEEC/UNICAMP*, 2013.
- [3] Siqueira, H. V., Boccato, L., Luna, I., Attux, R., and Lyra, C., Performance analysis of unorganized machines in streamflow forecasting of Brazilian plants, *Applied Soft Computing*, 68, pp. 494-506, 2018.
- [4] Siqueira, H. V., Boccato, L., Attux, R., and Lyra, C., Unorganized machines for seasonal streamflow series forecasting, *International journal of neural systems*, 34 (3), pp. 1430009-1430017, 2014
- [5] EPE - Empresa de Pesquisa Energética. *Balço energético nacional 2018 (ano base 2017)*. Ministério de Minas e Energia, 2018.
- [6] ONS - Operador Nacional do Sistema Elétrico (2018) [Online] www.ons.org.br/operacao/vazoes_naturais.aspx
- [7] Maceira, M. E., Costa, F. S., Damázio, J. M., Denício, M., & Guilhon, L. G., Modelo Estocástico de Previsão de Vazões Mensais - PREVIVAZM. *Anais do XV Simpósio Brasileiro de Recursos Hídricos*. Curitiba – PR, 2003.
- [8] Maceira, M. E., Operação Ótima de Reservatórios com Previsão de Afluências. *Dissertação de Mestrado - COPPE, UFRJ*, Brasil, 1989.
- [9] Sorjamaa, A., Hao, J., Reyhani, N., Ji, Y., and Lendasse, A., Methodology for long-term prediction of time series. *Neurocomputing*, 70, pp. 2861–2869, 2007.
- [10] Huang, G.-B., Zhu, Q.-Y., and Siew, C.-K., Extreme Learning Machine: Theory and Applications. *Neurocomputing*, 70 (1-3), pp. 489-501, 2006.
- [11] Huang, G.-B., Zhou, H., Ding, X., and Zhang, R. Extreme Learning Machines for Regression and Multiclass Classification. *IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics*, 42(2), pp. 513-529, 2012
- [12] ONS - Operador Nacional do Sistema Elétrico, *Previsão de Vazões Diárias no Reservatório de Três Maras Usando Técnicas de redes Neurais*, 2001 .
- [13] Andrade, G. M., Reis, R. L., Soares, S., and Silva Filho, D., Análise do Erro de Previsão de Vazões Mensais com Diferentes Horizontes de Previsão. *Controle e Automação*, 23 (3), pp. 294-305, 2012.
- [14] Souza, R. C., Marcato, A. L., Dias, B. H., and Silva Júnior, I. C., A Pesquisa Operacional e o Planejamento de Sistemas Energéticos. *Minicurso - 42º SBPO*. Bento Gonçalves, RS, Brasil, 2010.
- [15] Souza, R. C., and Camargo, M. E., *Análise e previsão de séries temporais - os modelos ARIMA* (2^a ed.). 2004.
- [16] Morettin, P. A., and Toloi, C. M., *Análise de Séries Temporais*. São Paulo: Egard Blucher, 2006.
- [17] Vecchia, A. V., Maximum Likelihood Estimation fo Periodic Autoregressive-Moving Average Models, *Technometrics*, pp. 375-384, 1985.
- [18] McLeod, A. I., Diagnostic Checking of Periodic Autoregression Models with Applications. *Journal of Time Series Analysis*, 15(2), pp. 221-233, 1994
- [19] Haykin, S. *Neural Networks and Learning Machines* (3^a ed.). Prentice Hall, 2008.
- [20] Boccato, L. Novas Propostas e Aplicações de Redes Neurais com Estados de Eco, *Tese de Doutorado - FEEC/UNICAMP*, 2013.
- [21] Stedinger, J. R., Report on the Evaluation of CEPEL's PAR Models. *Technical Report, School of Civil and Environmental Engineering - Cornell University*. Ithaca - New York, 2001.
- [22] McLeod, A. I., Diagnostic Checking of Periodic Autoregression Models with Applications. *Journal of Time Series Analysis*, 15(2), pp. 221-233, 1994.
- [23] Kohavi, R., and John, G., Wrappers for Feature Subset Selection. *Artificial Intelligence*, 97 (1-2), pp. 273-324, 1997.
- [24] Friedman, M., The use of ranks to avoid the assumption of normality implicit in the analysis of variance. *Journal of the American Statistical Association*, 32 (200), pp. 675–701, 1937.
- [25] Luna, I., and Ballini, R., Top-Down Strategies Based on Adaptive Fuzzy Rule-Based Systems for Daily Time Series Forecasting. *Intern. Journal of Forecasting*, 27(3), pp. 708-724, 2011.

Received: Mar 31, 2017

Accepted: February 05, 2018

Published: February 25, 2018



© 2018 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC-BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Evaluation of alternative forecasting approaches in the study of flow series

Abstract — This paper discusses the influence of the use of different forecasting approaches for monthly seasonal streamflow series prediction. A procedure currently adopted by the Brazilian Electrical Sector set 12 monthly linear periodic autoregressive models and the recursive approach for horizons longer than one step ahead. However, it is possible to address a single model for the entire series as well as to perform the prediction in a direct manner to horizons longer than one step ahead. Also, the use of artificial neural networks is gained much attention in current times. The computational results obtained indicate that the procedure usually adopted may not be the most suitable for solving the problem. Furthermore, the architecture of artificial neural network known as extreme learning machine achieved a better overall performance than linear models.

Index Terms — Approach to predict, streamflow series forecasting, Box & Jenkins models, neural networks, extreme learning machines