LII Simpósio Brasileiro de Pesquisa Operacional
João Pessoa - PB, 3 a 5 de novembro de 2020

Modelagem e previsão de afluências em reservatórios equivalentes de energia no Brasil por meio de métodos híbridos

Erick Meira de Oliveira
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ - Brasil - 22451-900
erickmeira89@gmail.com

Fernando Luiz Cyrino Oliveira
Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio)
Rua Marquês de São Vicente, 225, Gávea - Rio de Janeiro, RJ - Brasil - 22451-900
cyrino@puc-rio.br

Anderson Mitterhofer Iung
Brookfield Energia Renovável
Av. Antônio Gallotti, Ed. Pacific Tower, Barra da Tijuca, Rio de Janeiro - RJ - Brasil - 22775-029
anderson.iung@brookfieldenergia.com

RESUMO

A grande disponibilidade de recursos hídricos e as adequadas condições de relevo colocam o Brasil como um dos líderes mundiais na geração de hidroeletricidade, com capacidade instalada somente menor que a da China. Neste contexto, a modelagem e previsão acurada das afluências de energia para os sistemas hidrotérmicos é essencial para se estimar, no curto prazo, a incerteza inerente à geração de energia, e para auxiliar, no longo prazo, o planejamento da operação destes sistemas. O presente trabalho propõe abordagens híbridas, que combinam métodos tradicionais de previsão de séries temporais com algoritmos de *Bagging* (*Bootstrap Aggregation*), para fornecer previsões acuradas de energia natural afluente no Brasil em até 24 meses à frente. Os ensaios são conduzidos para reservatórios equivalentes de energia em diferentes regiões brasileiras, a fim de se testar a robustez dos métodos, e a acurácia das abordagens propostas é comparada a de diferentes métodos de referência na literatura de previsão. Resultados e implicações em termos de tomada de decisão são posteriormente discutidos.

PALAVRAS CHAVE. Planejamento energético, Previsão, Energia natural afluente.

Tópicos. EN – PO na Área de Energia, Petróleo e Gás; EST – Estatística e Modelos Probabilísticos.

ABSTRACT

The great availability of hydrological resources in Brazil, along with the country's favorable topography conditions, places Brazil among the world leaders in hydroelectricity generation, ranking second in terms of hydropower installed capacity. In this context, accurate modelling and forecasting of affluent natural energy in Brazilian reservoirs is key to estimate the short run uncertainty inherent to power generation, and to aid in the strategic planning of power systems in

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

the long run. This work puts forth a hybrid approach, combining traditional time series methods with *Bagging* (*Bootstrap Aggregation*) algorithms, to improve the quality of forecasts for affluent natural energy in Brazil up to 24 months ahead. The performance of the proposed approach is compared with several forecasting benchmarks across different Brazilian reservoirs. Results and decision-making implications are further discussed.

KEYWORDS. Energy planning. Forecasting. Affluent natural energy.

Paper topics. Operational Research applied to the Energy, Oil and Gas Industry; Statistics and Probabilistic Models (EST).

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

1. Introdução

As condições naturais e climáticas do Brasil definem o país como referência mundial na geração de energia elétrica a partir de fontes renováveis, com particular destaque para fontes hídricas. A título de exemplo, essas fontes representavam, até o final de 2018, 64% da capacidade instalada disponível no Brasil (104.139 MW de 162.840 MW disponíveis) [EPE, 2019].

Diante da considerável expressividade das fontes hídricas na geração de eletricidade no Brasil, a previsão e/ou geração de cenários de hidrologia assume papel relevante e estratégico em diferentes ocasiões e horizontes temporais [De Oliveira e Cyrino Oliveira, 2017]. No curto prazo, por exemplo, os cenários simulados dão base para se determinar o Custo Marginal de Operação (CMO) e, por conseguinte, o Preço de Liquidação das Diferenças (PLD), que é utilizado para valorar os volumes de energia liquidados na Câmara de Comercialização de Energia Elétrica (CCEE). Já no longo prazo, os cenários auxiliam no dimensionamento / planejamento ótimo de sistemas de potência, corroborando a tomada de decisão estratégica dos gestores.

A modelagem, e posterior previsão ou simulação de cenários de hidrologia, pode ser feita de diferentes formas. Uma abordagem popularmente conhecida e frequentemente utilizada no Brasil é a representação adotada no modelo de planejamento da operação de sistemas hidrotérmicos interligados de longo e médio prazo (NEWAVE) do Centro de Pesquisas de Energia Elétrica (CEPEL). Segundo essa representação, o sistema hidrelétrico brasileiro é dividido em 4 subsistemas regionais, cada um contendo um ou mais Reservatórios Equivalentes de Energia (REEs). Esses reservatórios representam as vazões agregadas de usinas hidrelétricas de uma determinada área demarcada. Para esses reservatórios artificiais, as vazões hídricas, originalmente expressas em m^3/s, são transformadas em Energia Natural Afluente (ENA), geralmente expressas em MWmed, com base nos dados técnicos das usinas (potência instalada, queda, rendimento turbina-gerador etc) [CEPEL, 2018]. Também é importante observar a correlação temporal e espacial do processo hidrológico, isto é, levar em consideração que as afluências futuras de um REE dependem tanto de suas variações históricas como das variações históricas de outros REEs adjacentes.

Ao longo das últimas décadas, uma grande quantidade de abordagens foram propostas buscando-se estimar adequadamente a dinâmica das energias naturais afluentes e prever ou simular seus comportamentos futuros. A abordagem por modelos periódicos autorregressivos, proposta por Hipel e McLeod [1994], é tradicionalmente utilizada – vide, por exemplo, suas aplicações no modelo oficial de simulação do CEPEL [2018] (NEWAVE). Essa abordagem, em linhas gerais, consiste em ajustar um modelo autorregressivo de ordem p para cada um dos períodos (meses) das séries hidrológicas históricas. A estimação da ordem de cada modelo é feita tomando-se como base a estrutura de correlação das séries hidrológicas para cada mês.

Os modelos pertencentes à família (S)ARIMA (*Seasonal Autoregressive Integrated Moving Average*), inicialmente propostos por Box e Jenkins [1970], figuram como alternativa também bastante utilizada na previsão de diversas séries hidrológicas (incluindo as de ENA). Esses modelos são baseados na estrutura de autocorrelação da série e costumam ser adotados como *benchmarks*, i.e., modelos de referência, na comparação com diversas abordagens de previsão em diferentes campos de aplicação.

Outra classe de modelos / métodos que são utilizados de maneira recorrente são os métodos de amortecimento exponencial (*exponential smoothing*), propostos seminalmente por Holt [1957] e Winters [1960]. Estes, desde sua criação, vem sofrendo uma série de modificações de maneira a deixá-los cada vez mais robustos. Entre as modificações e trabalhos recentes, pode-se citar a abordagem teórica via espaço de estados, proposta por [Hyndman et al., 2002] e implementada em diferentes pacotes estatísticos. Por fim, algumas abordagens que consideram a decomposição

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

das séries estudadas em diferentes componentes, para posterior modelagem e/ou previsão, figuram como alternativas em potencial, dada a boa adequação em diferentes contextos de séries temporais – vide, por exemplo, Maçaira et al. [2015] e De Oliveira et al. [2019].

A complexidade inerente a determinados conjuntos de séries temporais, entretanto, põe em cheque a efetividade de um único método em fornecer previsões acuradas, sobretudo quando são necessários estimar o comportamento futuro muitos passos à frente De Oliveira e Cyrino Oliveira [2018]. Em muitos casos, exige-se que as técnicas propostas sejam robustas a diferentes fatos estilizados das séries envolvidas, como tendências e sazonalidades estocásticas, altas volatilidades e, em certas ocasiões, até mesmo irregularidades de dados (ausência de determinados registros históricos). Nesse contexto, as chamadas metodologias híbridas, abordagens que agregam funcionalidades de métodos estatísticos tradicionais com técnicas de aprendizado de máquina (*machine learning*), se destacam pela capacidade de agregação de funcionalidades distintas e muitas das vezes complementares.

Uma classe de métodos computacionalmente intensivos que têm demonstrado resultados bastante satisfatórios de previsão quando combinados com métodos clássicos de séries temporais são os chamados métodos de conjunto (*ensembles methods*), em particular os algoritmos de *Bagging* (*Bootstrap Aggregation*). Em linhas gerais, esses últimos consistem na reamostragem de dados com reposição (*Bootstrapping*) da série original [Efron, 1979] como meio de gerar componentes diversos, que serão tratados de forma individual – no caso em questão, previstos com o auxílio de algum método de previsão – e posteriormente agregados, seja por voto majoritário ou ponderado. Como principais argumentos à favor dessas técnicas, pode-se destacar a obtenção de maiores ganhos de acurácia por meio da fusão inteligente de classificadores bem indicados (bom desempenho individual) e a dificuldade de aplicação de outros algoritmos, como os de indução, a conjuntos de dados extremamente grandes. Já como exemplos de grande relevância em diferentes domínios / contextos de aplicação, pode-se citar as contribuições recentes de Bergmeir et al. [2016], De Oliveira e Cyrino Oliveira [2018], Dantas e Cyrino Oliveira [2018], Petropoulos et al. [2018] e [Meira et al., 2020].

Apesar dos avanços substanciais nos últimos anos, não há ainda consenso no tocante a qual combinação / estratégia híbrida possui melhor desempenho para previsão de determinado conjunto de séries temporais. Soma-se a isso o fato de que não se sabe ao certo como é o comportamento das previsões originadas por diferentes metodologias híbridas quando horizontes temporais relativamente longos (muitos passos de previsão à frente) são considerados. Neste contexto, é importante destacar que a grande maioria dos trabalhos empíricos costuma adotar um horizonte único de previsão, sem observar possíveis diferenças na performance dos modelos quando se exigem previsões múltiplos passos à frente.

À luz do acima exposto, este trabalho busca contribuir para literatura de previsão de séries temporais de três formas principais:

(i) primeiramente, ao se avaliar a acurácia de diferentes estratégias híbridas de previsão de séries temporais em um horizonte consideravelmente longo (24 passos à frente). Em particular, serão testadas combinações de *Bagging* com métodos automáticos de seleção de modelos de armortecimento exponencial e formulações ARIMA;

(ii) aplicando-se, pela primeira vez, esse conjunto de abordagens híbridas na previsão de séries de energia natural afluente em diferentes reservatórios equivalentes de energia no Brasil; e

(iii) por fim, verificando a acurácia relativa das previsões das abordagens híbridas quando comparadas a outros métodos de referência na literatura de previsão e considerando diferentes métricas de avaliação.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

O presente trabalho está estruturado em outras 4 seções, além desta introdução. A Seção 2 descreve as estapas de construção das estratégias híbridas aqui propostas. A Seção 3 traz os detalhes da base de dados utilizada e da construção dos exercícios empíricos conduzidos. Os resultados destes, por sua vez, são apresentados na Seção 4. Por fim, a Seção 5 conclui e traz direções para trabalhos futuros.

2. Métodos

As abordagens híbridas aqui propostas combinam funcionalidades de duas classes distintas de métodos: (i) técnicas de *Bootstrap Aggregation* (*Bagging*), algoritmos de aprendizagem semi-supervisionada que consistem na reamostragem de dados com reposição (*Bootstrapping*) da série original como meio de gerar componentes diversos [Efron, 1979]; e (ii) métodos univariados de previsão de séries temporais. A integração das duas classes de métodos ocorre, em linhas gerais, da seguinte forma: técnicas específicas de tratamento, decomposição e *bootstrap* são combinadas de forma a se gerar reamostragens da série original, isto é, séries que compartilham com a série original seus principais fatos estilizados, como mesmo perfil sazonal, mesma tendência, mesmas quebras estruturais, se houver, dentre outros. Após a geração de um número pré-determinado de reamostragens, um modelo estatístico único é estimado para cada uma dessas reamostragens. Em seguida, cada modelo é utilizado para se gerar previsões dessas reamostragens, no horizonte temporal (número de passos à frente) desejado. Por fim, as previsões são agregadas por meio de alguma métrica, como média ou mediana, para gerar a previsão final. Nas próximas subseções, cada um dos passos é abordado de forma detalhada.

2.1. Decomposição e reamostragem

Os primeiros passos, comuns a todas as estratégias híbridas aqui propostas, são (i) a transformação de cada série original por meio de uma uma transformação Box-Cox [Box e Cox, 1964], com o intuito de estabilizar a variância e garantindo que as componentes da série sejam aditivas (tornando a estimação de modelos mais fácil); e (ii) a separação de cada série transformada em três componentes principais – sazonalidade, tendência e *remainder*. Para esta última, utiliza-se a decomposição STL (*Seasonal and Trend decomposition using Loess*) [Cleveland et al., 1990], que propõe a estimação das componentes de tendência e sazonalidade por meio de uma série de operações de amortecimento auxiliadas por um método não paramétrico regressão local ponderada (*Loess*). A decomposição da série pode ser explicitada da seguinte forma:

$$y_t = T_t + S_t + R_t \tag{1}$$

onde y_t é a série temporal no instante t, e T_t, S_t e R_t, representam, respectivamente, as componentes resultantes de tendência, sazonalidade e *remainder*.

2.2. Reamostragem

A reamostragem é conduzida na terceira componente da decomposição supracitada: o *remainder*. Esta componente é selecionada para esta etapa em virtude da facilidade de manipulação e geração de séries equivalentes, dado que geralmente é estacionária e possui média nula.

Para se realizar a reamostragem do *remainder*, recorre-se a uma técnica de seleção e rearranjo aleatório de blocos de observações consecutivas da série, chamada de *Moving Block Bootstrap* (MBB). Trata-se, em linhas gerais, de algoritmo inicialmente desenvolvido por Künsch [1989] e recentemente modificado por Bergmeir et al. [2016] para aplicação no contexto de séries temporais, que geralmente guardam associações (correlações) entre as observações. Na formulação original do MBB, blocos de dados de igual tamanho são sorteados da série original até que uma nova série,

de tamanho similar, seja obtida. Dessa forma, para uma série com n observações e um tamanho de bloco l, n-l+1 possibilidades de blocos superpostos existem. No entanto, no contexto de séries temporais, que geralmente guardam associações entre as observações, é preciso garantir que cada valor da série original possa ser colocado em qualquer local da nova série artificial (gerada pelo MBB). Para tanto, Bergmeir et al. [2016] propuseram tomar [n/l] + 2 blocos do *remainder* e posteriormente descartar um número aleatório de valores, entre zero e l-1, do início da série artificial ("bootstrapada"). Em seguida, continua-se descartando valores (tantos quantos sejam necessários) até se obter uma série do mesmo tamanho que a original. Dessa forma, garante-se que as séries geradas não começam ou terminam necessariamente em um limite de bloco. A Figura 1 mostra um exemplo prático do processo de reamostragem por MBB: no caso, a série possui 18 observações e o tamanho de bloco selecionado é de 4 observações. Dessa forma, 15 possíveis blocos podem ser reamostrados na geração de nova série replicada (*bootstrap*). Apesar de não ser um consenso na literatura, muitos trabalhos empíricos optam por um tamanho de bloco igual ao dobro do número de observações contidas em um período sazonal (no caso de séries mensais, por exemplo, cada bloco teria 24 observações). Tal procedimento busca garantir que praticamente toda a influência sazonal seja capturada no tamanho do bloco (l), evitando grandes distorções no processo de reamostragem.

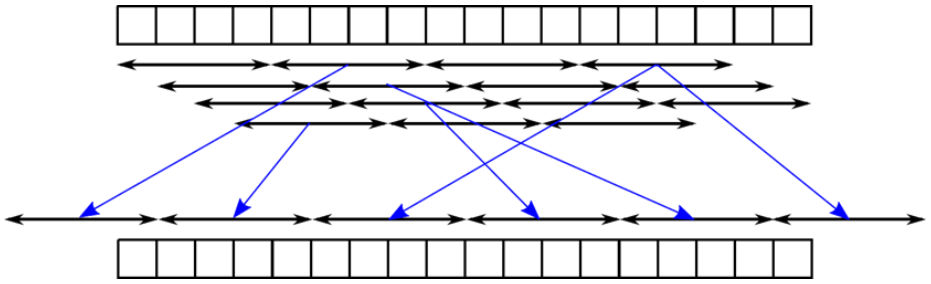


Figura 1: Exemplo prático do processo de reamostragem por MBB. Fonte: Petropoulos et al. [2018]

Após a reamostragem do *remainder*, as componentes de tendência e sazonalidade são adicionadas a cada uma das séries artificiais geradas, e a transformação Box-Cox é desfeita (reinvertida), obtendo-se o conjunto de séries reamostradas com características similares à original. Para as abordagens híbridas propostas neste trabalho, optou-se por gerar um total de 100 *bootstraps* da série original, seguindo alguns trabalhos empíricos recentes [Bergmeir et al., 2016; De Oliveira e Cyrino Oliveira, 2018; Dantas e Cyrino Oliveira, 2018].

2.3. Previsão

Após a obtenção de todas as reamostragens da série original pelos métodos supracitados, procede-se à estimação e subsequente previsão de cada uma das séries geradas por meio de diferentes modelos univariados. Neste trabalho, duas grandes classes de modelos conhecidas na literatura de previsão de séries temporais são consideradas para tal fim: os modelos de amortecimento exponencial e os modelos SARIMA (*Seasonal Autoregressive Integrated Moving Average*). As duas classes de modelos são comentadas em detalhes nas seções subsequentes.

2.3.1. Amortecimento Exponencial

Em linhas gerais, os modelos de amortecimento exponencial atribuem pesos às observações da série, que decrescem na medida que estas ficam mais "velhas", isto é, menos recentes. A

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

taxa de decréscimo é determinada por uma ou mais constantes de amortecimento. Há, na literatura, diferentes abordagens/variações desses métodos. Para uma lista extensiva dos mais usuais, sugere-se ao leitor interessado os trabalhos compilatórios de Gardner [1985, 2006].

Neste trabalho, iremos considerar na seleção do modelo de previsão para cada uma das *bootstraps* 30 possíveis formulações baseadas em espaço de estado. Essa abordagem consiste em um conjunto de diferentes modelos que podem ser obtidos ao se considerar variações de combinação nas componentes de erro, tendência e sazonalidade. De acordo com a taxonomia presente em [Gardner, 1985], as 15 possibilidades de modelos ao se variar as componentes de tendência e sazonalidade são ilustradas na Tabela 1. Além disso, a componente de erro também pode variar, sendo esta aditiva ou multiplicativa. Dessa forma, um total de 30 formulações diferentes pode ser obtida.

Componentes	Sazonalidade		
Tendência	Nenhuma (N)	Aditiva (A)	Multiplicativa (M)
Nenhuma (N)	N, N	N, A	N, M
Aditiva (A)	A, N	A, A	A, M
Aditiva Amortecida (A_d)	A_d, N	A_d, A	A_d, M
Multiplicativa (M)	M, N	M, A	M, M
Multiplicativa Amortecida (M_d)	M_d, N	M_d, A	M_d, M

Tabela 1: Possíveis variações para a tendência e a sazonalidade de formulações de amortecimento exponencial num contexto de formas de espaço de estado.

Em termos práticos, a seleção da formulação mais adequada é feita por meio da função `ets()` do pacote *forecast* para a linguagem R [Hyndman et al., 2020]. Esse mesmo pacote também é utilizado para a implementação de outros métodos de previsão que serão usados como referências de comparação (*benchmarks*) para os aqui desenvolvidos.

2.3.2. Modelos SARIMA

A classe de modelos SARIMA, inicialmente proposta por Box e Jenkins [1970], consiste em uma abordagem alternativa às formulações de amortecimento exponencial. Em linhas gerais, os modelos SARIMA são similares aos modelos de amortecimento exponencial, na medida em que são adaptativos, podem modelar tendências e padrões sazonais, e podem ser automatizados. A diferença reside no fato de que os modelos SARIMA são baseados na estrutura de autocorrelação da série em estudo, ao invés da visão estrutural das componentes de nível, tendência e sazonalidade. Em linhas gerais, os modelos SARIMA são denotados por SARIMA$(p,d,q)\times(P,D,Q)_S$ e podem ser escritos da seguinte forma:

$$\nabla_S^D \nabla^d \phi(B)\ \Phi\left(B^S\right)\ Z_t = \theta(B)\ \Theta\left(B^S\right)\ a_t \tag{2}$$

onde: S é o número de períodos sazonais; as letras minúsculas p, d, q correspondem, respectivamente, às quantidades de termos autoregressivos, integrados, e de médias móveis da parte não sazonal do modelo; as letras maiúsculas P, D, Q correspondem, respectivamente, às quantidades de termos autoregressivos, integrados, e de médias móveis da parte sazonal do modelo; a_t é o termo de erro; B é o operador de atraso (*Backward*), i.e., $By_t = y_{t-1}$; $\phi(B)$ e $\Phi\left(B^S\right)$ são aos polinômios

autoregressivos não sazonal e sazonal, respectivamente; $\theta(B)$ e $\Theta\left(B^S\right)$ são aos polinômios de médias móveis não sazonal e sazonal, respectivamente; e ∇_S^D e ∇^d são os operadores de diferenciação não sazonal e sazonal, respectivamente.

Neste trabalho, adotou-se a função `auto.arima()`, também do pacote *forecast* para a linguagem R, para a seleção do melhor modelo SARIMA (mais adequado à realidade de cada série) e posterior previsão.

2.4. Agregação

Como último passo, as previsões de cada uma das séries reamostradas são agregadas para se gerar o resultado final de cada método híbrido proposto. Neste trabalho, três formas de agregação são usadas: a média aritmética simples (ou combinação de pesos iguais para cada previsão), a média podada (aqui calibrada para se remover 10% das observações mais extremas) e a mediana. As duas últimas métricas são adotadas para se reduzir o impacto de eventuais *outliers* no conjunto de previsões a serem agregadas.

3. Seleção das séries e montagem dos experimentos

A base de dados utilizada compreende séries temporais mensais, entre Janeiro de 1931 e Dezembro de 2018, de Energia Natural Afluente (ENA) em quatro reservatórios equivalentes de energia brasileiros: Norte, Nordeste, Sul e Paraná. Estes reservatórios foram selecionados por serem os reservatórios com as maiores médias de energias naturais afluentes em cada subsistema hidrelétrico brasileiro. As usinas hidroelétricas brasileiras, segundo o modelo de planejamento NEWAVE (vide Seção 1), estão agrupadas em 4 subsistemas que, juntos, envolvem 12 reservatórios equivalentes de energia, como ilustrado na Figura 2.

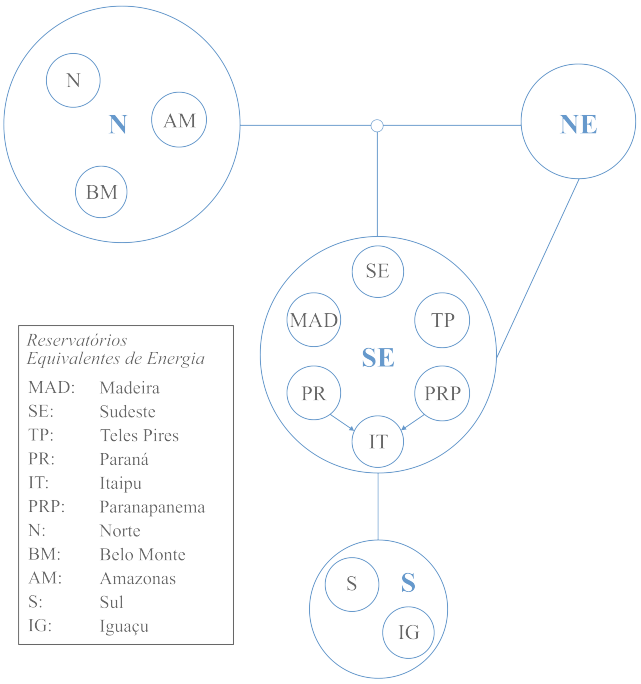


Figura 2: Representação do sistema interligado nacional de acordo com a convenção de Reservatórios Equivalentes de Energia (REEs). Fonte: [CEPEL, 2018].

Após a obtenção e arranjo dos dados, cada série selecionada foi subdividida em dois conjuntos: um primeiro, compreendendo dados entre Janeiro de 1931 e Dezembro 2016, definido como o conjunto de treinamento para estimação dos modelos (*train set*); e um segundo conjunto, de teste (*test set*), no qual os registros históricos dos meses de 2017 e 2018 foram guardados para se realizar comparações com as previsões até 24 passos à frente (*out-of-sample*) originadas por cada modelo proposto.

Para avaliação da acurácia de previsão dos métodos aqui propostos, foram utilizadas como métricas a Raiz do Erro Quadrático Médio (*Root Mean Squared Error* – RMSE), o Erro Percentual Absoluto Médio simétrico (*Symmetric Mean Absolute Percentage Error* – sMAPE) e o Erro Absoluto Médio Escalonado (*Mean Absolute Scaled Error* – MASE), calculados segundo as equações 3–5, a seguir.

$$RMSE = \sqrt{\frac{\sum_{t=1}^{h}(Y_t - \hat{Y}_t)^2}{h}} \tag{3}$$

$$sMAPE = \frac{1}{h}\sum_{t=1}^{h}\frac{2\left|Y_t - \hat{Y}_t\right|}{|Y_t| + \left|\hat{Y}_t\right|} \times 100\% \tag{4}$$

$$MASE = \frac{1}{h}\frac{\sum_{t=1}^{h}\left|Y_t - \hat{Y}_t\right|}{\frac{1}{n-m}\sum_{t=m+1}^{n}|Y_t - Y_{t-m}|} \tag{5}$$

onde: Y_t e $\hat{Y}_t$ são, respectivamente, os valores reais e previstos da série analisada; h é o horizonte de previsão (quantidade de meses à frente previstos); e m é o período sazonal. Para se ter uma ideia da acurácia das abordagens propostas, nós comparamos os resultados destas com os seguintes *benchmarks*:

- A rotina de seleção automática de formulações de amortecimento exponencial implementada no pacote *forecast* da linguagem R, por meio da função `ets()`;
- A rotina de seleção automática de modelos ARIMA, implementada também no pacote *forecast* por meio da função `auto.arima()`;
- O modelo Holt-Winters aditivo [Holt, 1957; Winters, 1960], abordagem clássica de previsão de séries temporais que possuem sazonalidade do tipo aditiva. Essa é uma das formulações de amortecimento exponencial possíveis de serem selecionadas no algoritmo da função `ets()`. Ela foi colocada aqui para dar uma noção da performance dos abordagens propostas frente a métodos bem conhecidos na literatura de previsão de séries temporais.

4. Resultados

Os resultados das previsões obtidas por meio das diferentes abordagens propostas são ilustrados na Tabela 2, que traz os valores de RMSE, sMAPE e MASE registrados para cada caso (reservatório equivalente) considerado, bem como os valores médios (ponderados entre os reservatórios). Todos os cálculos foram realizados considerando o horizonte temporal de 24 meses à frente ($h = 24$, segundo a notação das equações 3–5). Para se ter uma visualização da acurácia das previsões, a Figura 3 ilustra os valores reais (observados) das séries de cada reservatório no período de

teste (meses de Janeiro de 2017 a Dezembro de 2018) e os valores previstos com o melhor método, em termos de MASE, para cada caso.

Método de Previsão	REE Norte	REE Nordeste	REE Sul	REE Paraná	Média REEs
RMSE (MWmed)					
BaggedETS Média	3235,57	**1403,15**	3844,87	4643,51	3281,78
BaggedETS Média Podada	3260,86	1422,22	3821,65	4596,46	3275,30
BaggedETS Mediana	3265,56	1417,35	3807,24	4575,33	3266,37
BaggedARIMA Média	**2335,54**	1803,34	3629,68	3888,78	2914,33
BaggedARIMA Média Podada	2363,67	1818,32	3622,92	3834,99	**2909,98**
BaggedARIMA Mediana	2367,74	1955,35	**3619,22**	**3766,84**	2927,29
ETS	2651,97	2411,29	4084,83	5228,38	3594,12
ARIMA	2584,71	1586,33	4242,10	4344,66	3189,45
Holt-Winters aditivo	2691,30	3249,73	3688,92	5778,46	3852,10
sMAPE (%)					
BaggedETS Média	33,47	27,70	50,11	23,68	33,74
BaggedETS Média Podada	34,09	26,65	49,47	23,45	33,41
BaggedETS Mediana	34,37	**26,39**	49,17	23,16	33,27
BaggedARIMA Média	**23,93**	38,65	44,77	20,74	**32,02**
BaggedARIMA Média Podada	24,27	38,96	45,07	20,60	32,22
BaggedARIMA Mediana	24,67	41,53	44,92	**20,32**	32,86
ETS	26,72	48,73	54,81	23,40	38,42
ARIMA	30,76	32,06	48,65	23,01	33,62
Holt-Winters aditivo	108,27	120,88	**43,04**	27,48	74,92
MASE					
BaggedETS Média	0,89	0,33	0,82	0,57	0,65
BaggedETS Média Podada	0,90	0,32	0,81	0,56	0,65
BaggedETS Mediana	0,90	**0,32**	0,80	0,56	0,65
BaggedARIMA Média	**0,60**	0,46	0,70	0,47	**0,56**
BaggedARIMA Média Podada	0,61	0,46	**0,69**	**0,46**	**0,56**
BaggedARIMA Mediana	0,61	0,50	0,70	**0,46**	0,57
ETS	0,71	0,63	0,94	0,61	0,72
ARIMA	0,73	0,38	0,73	0,55	0,60
Holt-Winters aditivo	1,08	0,96	0,70	0,66	0,85

Tabela 2: Métricas de erro dos diferentes métodos de previsão, por Reservatório Equivalente de Energia (REE) considerado e ponderado entre reservatórios (mais acurado(s) em **negrito**).

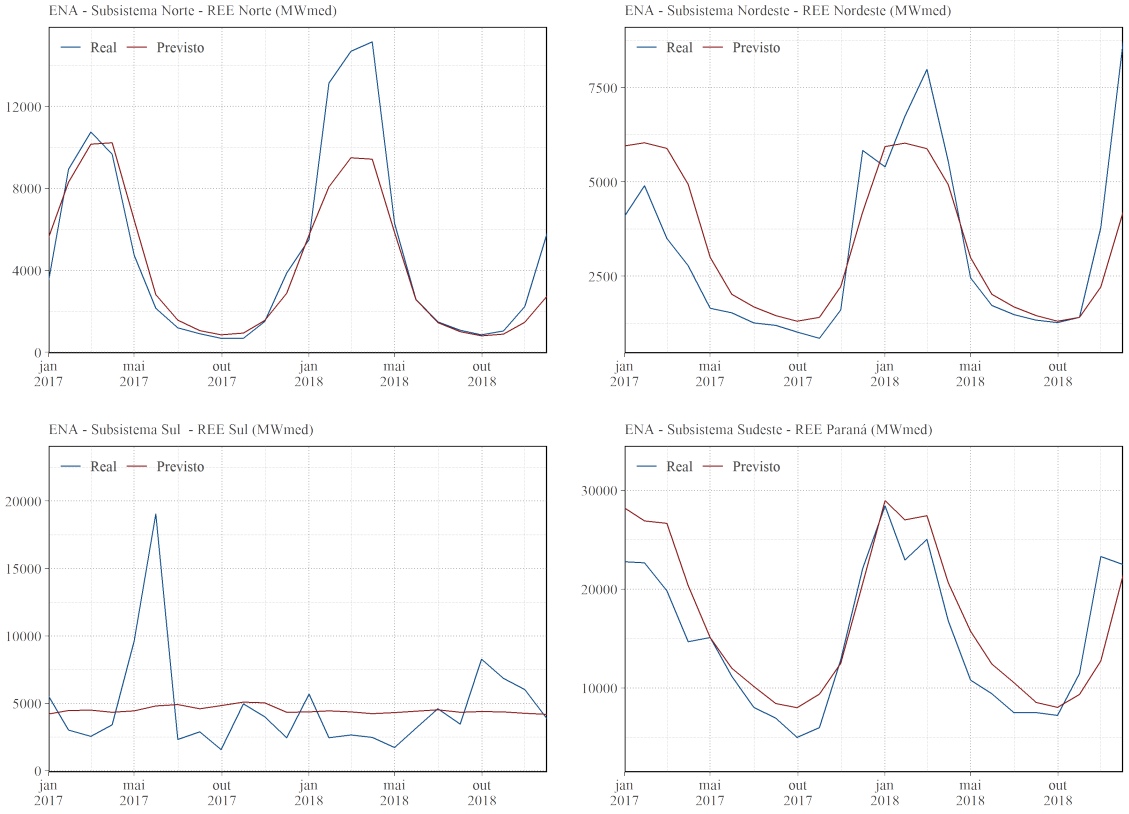


Figura 3: Energia natural afluente real (azul) e prevista pelo melhor método para cada reservatório (vermelho), nos meses entre Janeiro/2017 e Dezembro/2018. Fonte: Os autores.

Os resultados da Tabela 2 sugerem que, em média, para séries de energia natural afluente, as estratégias híbridas propostas são superiores aos *benchmarks* considerados. Por exemplo, as técnicas de BaggedETS, independente do método de agregação (seja por média, média podada ou mediana), são superiores à rotina ETS aplicada uma única vez (na série original). O mesmo vale ao se comparar as abordagens de BaggedARIMA com a rotina ARIMA automática, também aplicada uma única vez na série original. Tal constatação vai ao encontro da literatura empírica recente, apontando ganhos potenciais de acurácia ao se utilizar métodos de conjunto (*ensemble methods*) em detrimento de apenas uma única previsão da série original.

Entre as estratégias híbridas, à exceção do caso do reservatório equivalente do Nordeste, as combinações de *Bagging* com modelos ARIMA forneceram os resultados mais acurados, independente da métrica de avaliação considerada (RMSE, sMAPE ou MASE). Isso fica claro ao se observar, sobretudo, os resultados médios, ponderados entre os reservatórios. Por fim, como esperado, o método de Holt-Winters aditivo, que é uma das possíveis combinações que a rotina ETS automática de seleção de modelos considera, gerou resultados inferiores à rotina ETS (e consequentemente às estratégias híbridas) em praticamente todos os cenários considerados.

Como observado nos gráficos da Figura 3, a sazonalidade é um fato estilizado inerente às séries de energia natural afluente. À exceção do reservatório sul, em todos os demais reservatórios as séries registraram um perfil sazonal bastante pronunciado, com altas vazões observadas nos meses de dezembro a abril e vazões baixas nos meses de inverno e nos adjacentes a essa estação. A

presença de forte sazonalidade já foi sugerida como um dos fatores que explicam a boa acurácia de estratégias híbridas que combinam algoritmos de *Bagging* com determinados métodos univariados [Bergmeir et al., 2016; De Oliveira e Cyrino Oliveira, 2018]

5. Conclusões e direções para trabalhos futuros

O presente trabalho propôs estratégias híbridas de previsão de séries temporais, que combinam algoritmos de *Bagging* existentes na literatura aplicada de *machine learning* com métodos univariados, para aprimorar as previsões de energia natural afluente em diferentes reservatórios brasileiros. Os experimentos foram conduzidos em um horizonte temporal consideravelmente longo, a fim de se testar não só a robustez dos métodos, mas também sua performance relativa frente a diferentes *benchmarks* da literatura de previsão de séries temporais. Como esperado, os resultados apontam para ganhos substanciais de acurácia ao se optar pelas estratégias híbridas em detrimento de métodos "únicos" de previsão, isto é, aplicados diretamente à série original.

Outra constatação importante foi o fato de que, em média, as estratégias híbridas que realizavam a agregação de previsões geradas por meio de formulações ARIMA, foram mais acuradas que as demais estratégias híbridas. Muito embora as abordagens não apresentem grandes diferenças relativas de erros, trata-se de uma sinalização importante para a literatura empírica de previsão de séries temporais, dado que combinações de algoritmos de *Bagging* com o método ETS de previsão, têm sido consideradas como referências no aprimoramento de previsões univariadas em séries de periodicidade mensal, como mostrado ao longo do texto.

Como possíveis extensões desse trabalho, sugere-se a aplicação de outros métodos de decomposição inicial da série temporal, bem como de outras técnicas de previsão das séries artificiais ("bootstrapadas"). Sugestões possíveis para o primeiro e segundo ponto são, respectivamente, a utilização de técnicas de *Empirical Mode Decomposition* como alternativa à decomposição STL, e a combinação de algoritmos de *Bagging* com métodos de redes neurais artificiais para a etapa de previsão. Por fim, métodos alternativos de atribuição de pesos às previsões feitas sobre séries artificiais na fase de agregação também são objetos de pesquisas futuras.

Referências

Bergmeir, C., Hyndman, R. J., e Benítez, J. M. (2016). Bagging exponential smoothing methods using STL decomposition and box–cox transformation. *International Journal of Forecasting*, 32 (2):303–312.

Box, G. E. P. e Cox, D. R. (1964). An analysis of transformations. *Journal of the Royal Statistical Society. Series B (Methodological)*, 26(2):211–252.

Box, G. E. P. e Jenkins, G. M. (1970). *Time series analysis: forecasting and control*. Holden Day, San Francisco.

CEPEL (2018). Newave - modelo de planejamento da operação de sistemas hidrotérmicos interligados de longo e médio prazo. `http://www.cepel.br/`. Acessado em: 22/05/2020.

Cleveland, R. B., Cleveland, W. S., McRae, J. E., e Terpenning, I. (1990). STL: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*, 6:3–73.

Dantas, T. M. e Cyrino Oliveira, F. L. (2018). Improving time series forecasting: An approach combining bootstrap aggregation, clusters and exponential smoothing. *International Journal of Forecasting*, 34(4):748–761.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings

De Oliveira, E. M. e Cyrino Oliveira, F. L. (2017). Padrões de variabilidade em vazões afluentes a usinas hidrelétricas e associações com massas de ar. *Cadernos do IME - Série Estatística*, 43: 18–38.

De Oliveira, E. M. e Cyrino Oliveira, F. L. (2018). Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods. *Energy*, 144:776–788.

De Oliveira, E. M., Cyrino Oliveira, F. L., Klötzle, M. C., e Pinto, A. C. F. (2019). Dynamic associations between GDP and crude oil prices in brazil: Structural shifts and nonlinear causality. *Emerging Markets Finance and Trade*, p. 1–25.

Efron, B. (1979). Bootstrap methods: Another look at the jackknife. *The Annals of Statistics*, 7(1): 1–26.

EPE (2019). Relatório síntese BEN 2019 – ano base 2018. `http://www.epe.gov.br/`. Acessado em: 27/05/2020.

Gardner, E. S. (1985). Exponential smoothing: The state of the art. *Journal of Forecasting*, 4(1): 1–28.

Gardner, E. S. (2006). Exponential smoothing: The state of the art—part II. *International Journal of Forecasting*, 22(4):637–666.

Hipel, K. W. e McLeod, A. I. (1994). *Time Series Modelling of Water Resources and Environmental Systems*. Elsevier Science Pub Co.

Holt, C. C. (1957). *Forecasting seasonal and trends by exponentially weighted moving average*. O.N.R. research memorandum, no. 52. Carnegie Institute of Technology, Pittsburgh, PA.

Hyndman, R., Athanasopoulos, G., Bergmeir, C., e outros. *forecast: Forecasting functions for time series and linear models*, 2020. URL `http://pkg.robjhyndman.com/forecast`.

Hyndman, R. J., Koehler, A. B., Snyder, R. D., e Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, 18(3):439–454.

Künsch, H. R. (1989). The jackknife and the bootstrap for general stationary observations. *The Annals of Statistics*, 17(3):1217–1241.

Maçaira, P. M., Oliveria, F. L. C., e Souza, R. C. (2015). Forecasting natural inflow energy series with multi-channel singular spectrum analysis and bootstrap techniques. *International Journal of Energy and Statistics*, 03(01):1550005.

Meira, E., Oliveira, F. L. C., e Jeon, J. (2020). Treating and pruning: New approaches to forecasting model selection and combination using prediction intervals. *International Journal of Forecasting*.

Petropoulos, F., Hyndman, R. J., e Bergmeir, C. (2018). Exploring the sources of uncertainty: Why does bagging for time series forecasting work? *European Journal of Operational Research*, 268 (2):545–554.

Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3):324–342.

Galoá { Este trabalho foi publicado utilizando o **Galoá** proceedings