

APRIMORANDO PREVISÕES DE ABASTECIMENTO DE ENERGIA COM ALGORITMOS DE BAGGING E MÉTODOS DE AMORTECIMENTO EXPONENCIAL

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

Fotios Petropoulos

University of Bath
School of Management, University of Bath, Bath, BA2 7AY, UK
f.petropoulos@bath.ac.uk

Jooyoung Jeon

University of Bath
School of Management, University of Bath, Bath, BA2 7AY, UK
j.jeon@bath.ac.uk

RESUMO

Os algoritmos de *Bagging* (*Bootstrap Aggregation*), métodos de aprendizagem semi-supervisionada que constroem um conjunto de classificadores por *Bootstrap* e posteriormente classificam novos pontos de dados combinando previsões por meio de algum voto ponderado, têm recebido particular atenção no contexto de séries temporais. Suas aplicações para séries de energia, contudo, ainda são relativamente escassas e não há consenso sobre qual algoritmo oferece maiores ganhos de acurácia quando combinados a diferentes métodos de previsão. Utilizando-se três diferentes variações de *Bagging* e suas combinações com até 30 métodos distintos de amortecimento exponencial, o presente trabalho busca aprimorar as previsões pontuais de abastecimento total de energia elétrica em 30 diferentes países da OCDE. Os ensaios são conduzidos em diferentes horizontes temporais (curto, médio e longo prazo), a fim de se testar a robustez dos métodos e sua performance frente a diferentes *benchmarks*. Resultados e implicações em termos de tomada de decisão são posteriormente discutidos.

PALAVRAS CHAVE. Bagging, Previsão, Aprovisionamento energético.

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

ABSTRACT

Bagging (Bootstrap Aggregation) algorithms have received particular attention in time series forecasting tasks in recent years. Nevertheless, studies involving applications to the energy industry are relatively scarce. In addition, there is no common ground as to which *Bagging* algorithm performs better/leads to more accuracy gains when combined with different forecasting methods. This work offers some answers to such questions by testing the overall forecasting performance of three different *Bagging* variants when combined with (up to) 30 distinct exponential smoothing methods. An empirical evaluation is conducted using monthly energy supply time series from 30 different OCDE countries. The performance of the proposed combinations is assessed under different forecasting horizons and compared with several forecasting benchmarks. Results and decision-making implications are further discussed.

KEYWORDS. *Bagging*. Forecasting. Energy supply.

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

1. Introdução

A disponibilidade de informações consistentes sobre comportamentos atuais e futuros de diferentes eventos estratégicos contribui decisivamente para a tomada de decisões nas organizações, impactando positivamente suas chances de sucesso por meio da redução de incertezas e priorização inteligente de atividades, além do eventual aproveitamento de oportunidades vindouras [Makridakis, 1996].

Muitos dos fatores e/ou variáveis que influenciam as atividades das organizações podem ser mensurados ou parcialmente estimados por meio de dados disponibilizados em forma de séries temporais. Nesse contexto, objetivando antecipar o comportamento futuro de diferentes fenômenos estratégicos, diversos métodos quantitativos de previsão têm sido propostos na literatura. Os modelos pertencentes à família ARIMA, inicialmente propostos por [Box e Jenkins, 1970], certamente figuram entre os mais utilizados e ainda hoje são tidos como modelos de referência na comparação com abordagens alternativas.

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, podem ser citados a abordagem teórica via espaço de estados, proposta por [Hyndman et al., 2002], além da modificação que permite a incorporação de mais de um período sazonal, proposta por [Taylor, 2010].

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, alta volatilidade e, em certas ocasiões, até mesmo irregularidade de dados (ausência de determinados registros históricos). Soma-se a isso o fato de que o comportamento de alguns setores, como os de energia e transportes, costumam sofrer forte influência de fatores externos (exógenos), como o impacto de variáveis macroeconômicas ou decisões estratégicas de governo, que podem trazer quebras estruturais consideráveis no comportamento usual das séries. 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 (eg. ARIMA, Amortecimento Exponencial, dentre outros) – 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 [Tsoumakas et al., 2005]. Para o estudo específico de previsão em séries temporais, nas quais os dados geralmente possuem dependência entre defasagens, citam-se como contribuições relevantes a variante do método de *Moving Blocks Bootstrap* (originalmente proposto por [Künsch, 1989] e modificado

por [Bergmeir et al., 2016]), o *Circular Blocks Bootstrap* [Politis e Romano, 1991], o *Sieve Bootstrap* [Bühlmann, 1998], o *Tapered Block Bootstrap* [Paparoditis e Politis, 2001] e o *Linear Process Bootstrap* [McMurry e Politis, 2010]. Tais técnicas, sobretudo o *Moving Blocks Bootstrap* vem sendo combinadas com métodos estatísticos clássicos de previsão de séries temporais, resultando em previsões bastante acuradas em diversos setores de interesse. Como exemplos recentes de grande relevância, pode-se citar as contribuições de [Bergmeir et al., 2016], [Dantas et al., 2017], [De Oliveira e Cyrino Oliveira, 2018], [Dantas e Cyrino Oliveira, 2018] e [Petrooulos et al., 2018].

Apesar dos avanços substanciais nos últimos anos, não há ainda um consenso no tocante a qual método de reamostragem possui melhor desempenho para previsão de determinado conjunto de séries temporais. Em particular, nota-se que trabalhos mais recentes têm dado preferência à variante do algoritmo de *Moving Block Bootstrap* [Künsch, 1989] recém proposta por [Bergmeir et al., 2016]. Isso se deve, em grande parte, pelo boa acurácia do algoritmo quando combinado com métodos de amortecimento exponencial na previsão de séries da M3 Competition – a 3ª edição da série M-Competitions (Makridakis-3), uma competição global de previsão de séries temporais disputada por pesquisadores e representantes do mercado do mundo todo [Makridakis et al., 2018]. Outro ponto digno de nota é que ainda não se sabe ao certo como é o comportamento das previsões originadas por *Bagging* em diferentes horizontes temporais: a grande maioria dos trabalhos costuma adotar um horizonte único de previsão, sem observar possíveis diferenças de performance quando outros intervalos temporais são levados em conta (ex. curto, médio e longo prazo).

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 combinações de algoritmos de *Bagging* com métodos estatísticos de previsão. Em particular, serão testadas três diferentes variantes de processos de reamostragem – os métodos de *Moving Block Bootstrap* [Künsch, 1989; Bergmeir et al., 2016], *Circular Blocks Bootstrap* [Politis e Romano, 1991], e *Linear Process Bootstrap* [McMurry e Politis, 2010] – e suas interações com 30 modelos possíveis de amortecimento exponencial;
- (ii) aplicando-se, pela primeira vez, esse conjunto de técnicas híbridas em séries de provisionamento mensal de energia elétrica (*Energy Supplied*) em 30 diferentes países; e
- (iii) por fim, verificando o comportamento das previsões em diferentes horizontes temporais: curto prazo (meses 1 a 6), médio prazo (meses 7 a 12) e longo prazo (meses 13 a 18).

O presente trabalho está estruturado em outras 4 seções, além desta introdução. Na Seção 2, uma breve reflexão sobre a importância da adequada estimação do abastecimento futuro de energia elétrica é apresentada, motivando-se a busca por modelos cada vez mais acurados de previsão. A Seção 3, por sua vez, explica as metodologias empregadas na construção das previsões pontuais. A Seção 4 traz os resultados, bem como suas discussões. Por fim, a Seção 5 conclui e traz direções para trabalhos futuros.

2. Do adequado abastecimento de energia elétrica

Garantir o adequado fornecimento de energia elétrica é uma questão fundamental em praticamente qualquer nação do globo. Do ponto de vista econômico, o abastecimento deve atender à demanda a qualquer instante de tempo. Nesse contexto, um item fundamental para a tomada racional de decisões no setor elétrico é a previsão acurada de valores futuros do consumo de eletricidade, já que as consequências da sobre ou subestimação podem ser bastante custosas [De Oliveira

e Cyrino Oliveira, 2018]. Por exemplo, quando a carga despachada é superior à demanda atual, o fornecedor não apenas desperdiça recursos mas também incorre no risco de arcar com elevados custos devido à forte regulação dos mercados *spot* de energia em determinados países. Por outro lado, a subestimação naturalmente resulta em apagões e racionamento, o que se traduz em uma perda de produtividade e novamente sujeita o fornecedor a sanções e penalidades legais.

Ao longo das últimas décadas, uma grande quantidade de abordagens tem sido propostas buscando-se estimar adequadamente a dinâmica do fornecimento de energia e prever seu comportamento futuro. A grosso modo, as abordagens podem ser divididas em duas grandes categorias, a depender do horizonte de previsão selecionado: curto e médio/longo prazo. Enquanto a atenção do primeiro está voltada para frequências temporais horárias, sub-horárias ou até de minutos, o segundo busca estimar o comportamento do abastecimento de energia em horizontes de meses, trimestres, ou até em uma quantidade considerável de anos à frente. Para este último, a previsão do abastecimento é geralmente vista como uma tarefa bastante complexa, devido à natureza não linear e multidimensional desta variável. Além disso, muitos elementos imprevisíveis entram em jogo em longos horizontes de previsão, como quebras estruturais e efeitos transitórios oriundos de variáveis externas. Entretanto, a previsão no médio/longo prazo de abastecimento de energia assume um papel fundamental no planejamento energético, dado que sinaliza a necessidade de expansão da capacidade de geração/transmissão do sistema. [Kaboli et al., 2017] argumenta ainda que a estimação do comportamento futuro do abastecimento neste horizonte temporal é de grande interesse para companhias que operam em um ambiente desregulado, já que proporciona informações preciosas acerca da necessidade de energia do mercado, do calendário de manutenção de usinas de geração, do estoque de combustíveis fósseis (para atender um eventual excesso de demanda no sistema) e de necessidades ocasionais de energia elétrica para exportação. O presente trabalho busca contribuir para a literatura nesse sentido, ao propor modelos que forneçam previsões suficientemente acuradas para a tomada de decisão de médio prazo (até 18 meses à frente) no setor elétrico.

3. Dados e metodologia

3.1. Seleção das Séries

A base de dados utilizada compreende séries temporais mensais, entre Janeiro de 2000 e Dezembro de 2018, de Energia Elétrica Fornecida (*Energy Supplied*) em 30 países da Organização para a Cooperação e Desenvolvimento Econômico (OCDE), a saber: Alemanha (DE), Austrália (AU), Áustria (AT), Bélgica (BE), Canadá (CA), Coreia do Sul (KR), Dinamarca (DK), Espanha (ES), Eslováquia (SK), Estados Unidos (US), Finlândia (FI), França (FR), Grécia (GR), Holanda (NL), Hungria (HU), Irlanda (IE), Islândia (IS), Itália (IT), Japão (JP), Luxemburgo (LU), México (MX), Noruega (NO), Nova Zelândia (NZ), Polônia (PL), Portugal (PT), Reino Unido (UK), República Tcheca (CZ), Suécia (SE), Suíça (CH) e Turquia (TR). Todos os dados foram compilados dos relatórios mensais de energia da Agência Internacional de Energia (*International Energy Agency*) [IEA, 2019]. A seleção também buscou envolver, sempre que possível, séries com diferentes fatos estilizados, a fim de se testar a robustez dos métodos aqui propostos. A título de exemplo, a Figura 1 traz o comportamento do abastecimento de energia elétrica em oito diferentes países do conjunto analisado. Como se pode notar, este varia bastante entre os países selecionados: algumas séries apresentam tendências (subida ou descida) bem definidas ao longo dos anos (praticamente determinísticas), enquanto outras registraram, ao longo dos anos, praticamente o mesmo padrão de consumo. Além disso, alguns países apresentam, em certos momentos, quebras estruturais bastante notáveis em seus níveis de abastecimento.




Figura 1: Fornecimento mensal de energia elétrica em oito diferentes países (GWh). Fonte: [IEA, 2019]

Após a obtenção e arranjo dos dados, cada série selecionada foi subdividida em dois conjuntos: um primeiro, compreendendo dados entre Janeiro de 2000 e Junho de 2017, 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 restantes de 2017 e do ano inteiro de 2018 foram guardados para se realizar comparações com as previsões até 18 passos à frente (*out-of-sample*) originadas por cada modelo proposto.

3.2. Métodos

3.2.1. Decomposição e reamostragem

Os primeiros passos, comum a todas as variantes de *Bagging* aqui propostas, são (i) a transformação de cada série original por meio de 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*” –, por meio de uma decomposição STL (*Seasonal and Trend decomposition using Loess*) [Cleveland et al., 1990], basicamente uma série de seis operações de amortecimento/suavização auxiliadas por um método não paramétrico de regressão local ponderada (*Loess*).

Os métodos de reamostragem e agregação (*Bootstrap Aggregation - Bagging*) aqui propostos focam na terceira componente da decomposição STL: o *Remainder*. Como comentado anteriormente, três diferentes variantes são propostas nesta etapa:

- Na primeira abordagem (*Moving Block Bootstrap - MBB*), recorre-se a uma reamostragem direta da componente residual da decomposição (*Remainder*) por meio de uma seleção e rearranjo aleatório de blocos de observações consecutivas da série. Este algoritmo foi 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. Mais especificamente, em sua formulação original, 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 2 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, 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;
- Como primeira alternativa ao MBB, propõe-se também a aplicação do algoritmo *Circular Blocks Bootstrap* (CBB), desenvolvido por [Politis e Romano, 1991]. Em linhas gerais, este propõe que a série a ser reamostrada seja “envolvida” em um círculo antes que a reamostragem ocorra. Ou seja, o início da “construção” dos blocos pode ocorrer em qualquer instância da série, já que ela está “envelopada”. Este procedimento visa garantir que as primeiras e as últimas $l-1$ observações não sejam subamostradas, o que teoricamente faz com que o CBB seja superior ao MBB. Mais uma vez, a escolha do tamanho de bloco (l) para o CBB segue

as mesmas orientações empíricas do MBB para o caso de séries temporais (dois períodos sazonais completos);

- Por fim, recorre-se a uma reamostragem do *Remainder* por meio do *Linear Process Bootstrap* [McMurry e Politis, 2010], um algoritmo de cinco passos básicos que permite a reamostragem de séries com estrutura de covariâncias com quedas abruptas – típicas de processos de média móvel (*Moving Average* - MA) – sem a necessidade de estimar os coeficientes de forma explícita (o que, no caso de processos MA, requer o uso de métodos numéricos de otimização ou de um algoritmo de inovação).




Figura 2: Exemplo prático do processo de reamostragem por MBB. Fonte: [Petrooulos et al., 2018]

Independentemente do algoritmo escolhido, 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 cada um dos três métodos acima expostos, 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].

3.2.2. Previsão

Após a obtenção de todas as séries artificiais pelos métodos supracitados, procede-se à estimação e subsequente previsão de cada uma das séries geradas por meio de diferentes modelos de amortecimento exponencial – métodos que atribuem pesos às observações da série e que decrescem na medida que estas ficam mais “velhas”, isto é, menos recentes. 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.

Em termos práticos, a seleção da formulação mais adequada é feita por meio da função `ets()` com parâmetros de seleção automática do pacote *forecast* para a linguagem R [Hyndman et al.,

Componentes	Sazonal		
	Nenhuma (N)	Aditiva (A)	Multiplicativa (M)
Tendência			
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 combinações para as componentes sazonal e de tendência no contexto de formas de espaço de estado. Obs: o subscrito “ d ” significa *damped* (amortecido).

2019]. 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.

4. Resultados e Discussões

Os resultados das previsões obtidas por meio das diferentes abordagens propostas, para todo o horizonte temporal (18 meses à frente), são ilustrados na Tabela 2, a seguir. Eles são apresentados como valores médios (ponderados entre as 30 séries envolvidas) das métricas de Erro Percentual Absoluto Médio simétrico (*Symmetric Mean Absolute Percentage Error* – sMAPE), Erro Absoluto Médio Escalonado (*Mean Absolute Scaled Error* – MASE) e Média Geral Ponderada (*Overall Weighted Average* - OWA), calculadas segundo as equações 1–3, a seguir.

$$sMAPE = \frac{1}{h} \sum_{t=1}^h \frac{2 |Y_t - \hat{Y}_t|}{|Y_t| + |\hat{Y}_t|} \quad (1)$$

$$MASE = \frac{1}{h} \frac{\sum_{t=1}^h |Y_t - \hat{Y}_t|}{\frac{1}{n-m} \sum_{t=m+1}^n |Y_t - Y_{t-m}|} \quad (2)$$

$$OWA = \frac{sMAPE_{rel} + MASE_{rel}}{2} \quad (3)$$

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); m é o período sazonal; e $sMAPE_{rel}$ e $MASE_{rel}$ são os valores médios de sMAPE e MASE de cada método analisado respectivamente divididos pelos valores médios de sMAPE e MASE do método Naïve 2 – um método de previsão usado como referência que basicamente envolve repetir, na previsão h passos à frente de uma série, suas últimas h observações.

Para cada algoritmo de *bootstrap*, duas estratégias de previsão foram utilizadas:

- baggedETS: consiste na aplicação da função `ets()` do pacote *forecast* em cada uma das 100 séries “bootstrapadas” (replicadas segundo o algoritmo selecionado). A função escolhe, dentro da gama dos 30 modelos de amortecimento exponencial na forma de espaço de estado possíveis, qual o mais adequado para cada *bootstrap*. Em seguida, por meio da função `forecast()` do mesmo pacote, obtém-se a previsão ETS h passos à frente de cada uma das *bootstraps*. Por fim, as previsões são agregadas em um resultado final (*final output*) de acordo com a mediana.

Algoritmo de <i>Bootstrap</i>	Método de Previsão	sMAPE	MASE	OWA
MBB	baggedETS	2,5842	0,7414	0,7855
MBB	BMC	2,5859	0,7311	0,7802
CBB	baggedETS	2,5668	0,7347	0,7793
CBB	BMC	2,5731	0,7280	0,7767
LPB	baggedETS	2,6079	0,7443	0,7906
LPB	BMC	2,5858	0,7308	0,7800
Nenhum	Naïve 2	3,3711	0,9215	1,0000
Nenhum	ETS	2,6940	0,7557	0,8096
Nenhum	(S)ARIMA	2,7827	0,7929	0,8429

Tabela 2: Avaliação das previsões pontuais para todo o horizonte de previsão (18 passos à frente). Valores ponderados entre todas as 30 séries envolvidas (mais acurados em **negrito**).

- BMC: abreviação de *Bootstrap Model Combination*, uma estratégia desenvolvida por [Petropoulos et al., 2018]. Ela consiste primeiramente em realizar a seleção (estimação) do modelo mais adequado a cada *bootstrap* (assim como na baggedETS) mas, ao invés de subsequentemente prever cada uma das *bootstraps* com o modelo ETS escolhido, o BMC computa quais foram as combinações de erro, tendência e sazonalidade selecionadas (e a quantidade de vezes que foram) pela função `ets()` nas 100 séries “bootstrapadas”. Em seguida, as n combinações selecionadas são usadas para se estimar e posteriormente prever a série original e a ponderação das n previsões é feita segundo a quantidade de vezes que o modelo que a originou foi selecionado na primeira etapa. Essa estratégia obteve grande êxito na previsão de séries mensais, trimestrais e anuais da M1 e M3 *Competitions* [Makridakis et al., 2018].

Os resultados da Tabela 2 sugerem que, para séries de abastecimento mensal de energia, em média, as combinações CBB + baggedETS e CBB + BMC oferecem os resultados mais acurados quando se deseja obter previsões para um horizonte de até 18 passos à frente. Além disso, à exceção da combinação LPB + BMC, todos os métodos de conjunto obtiveram resultados melhores (mais acurados) que os *benchmarks*, aqui representados pelos métodos: Naïve 2, ETS – que consiste na aplicação da função `ets()` na série original (seleção da melhor, entre 30 formas de espaço de estado, combinação de erro, tendência e sazonalidade) e posterior previsão – e (S)ARIMA – uma classe de modelos inicialmente proposta por [Box e Jenkins, 1970] como alternativas às formulações de amortecimento exponencial, diferenciando-se destas últimas por serem baseados na estrutura de autocorrelação da série em estudo, ao invés da visão estrutural das componentes de nível, tendência e sazonalidade. 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.

Outro pronto digno de nota é o fato de que, em média, as previsões agregadas (*bagged*) que empregaram como método de reamostragem o *Circular Blocks Bootstrap* (CBB) foram mais acuradas que aquelas originadas pela aplicação dos métodos ETS nas replicações do *Moving Blocks Bootstrap* (MBB), muito embora as abordagens não apresentem grandes diferenças relativas de erros. De qualquer forma, isso pode ser visto como uma contribuição relevante para a literatura empírica de previsão de séries temporais, dado que o MBB tem sido considerado como uma referência no aprimoramento de previsões univariadas em séries de periodicidade mensal [Bergmeir

et al., 2016; Dantas et al., 2017].

Para se verificar o comportamento das previsões em outros horizontes temporais (e ao mesmo tempo se testar a robustez dos métodos de conjunto), a Tabela 3 traz a avaliação das previsões obtidas por cada um dos métodos propostos no curto (até 6 meses à frente), médio (meses 7 a 12) e longo prazo (meses 13 a 18). Tal divisão tem como base a classificação sugerida para séries mensais em [Klein, 1991]. Para se conservar espaço, foram mostrados apenas os valores da métrica de Média Geral Ponderada (OWA).

Algoritmo de <i>Bootstrap</i>	Método de Previsão	OWA (curto prazo)	OWA (médio prazo)	OWA (longo prazo)
MBB	baggedETS	0,7057	0,8356	0,8033
MBB	BMC	0,7495	0,8298	0,7540
CBB	baggedETS	0,7021	0,8290	0,7952
CBB	BMC	0,7455	0,8291	0,7478
LPB	baggedETS	0,7179	0,8360	0,8071
LPB	BMC	0,7462	0,8335	0,7525
Nenhum	Naïve 2	1,0000	1,0000	1,0000
Nenhum	ETS	0,7544	0,8674	0,7967
Nenhum	(S)ARIMA	0,8268	0,9032	0,7961

Tabela 3: Avaliação das previsões pontuais no curto, médio e longo prazo (envolve o horizonte temporal de previsão dos 6 primeiros meses à frente, dos meses 7 a 12 e dos meses 13 a 18, respectivamente). Valores ponderados de OWA entre todas as 30 séries envolvidas (mais acurados em **negrito**).

Como pode ser observado, assim como no horizonte inteiro (todos os 18 meses à frente) a combinação CBB + BMC oferece as previsões mais acuradas dentre todas as combinações no longo prazo. No curto e médio prazo, porém, o método de agregação por baggedETS passa a oferecer melhores resultados, ainda que por uma diferença pequena para a combinação CBB + BMC. Um ponto digno de nota é que, no longo prazo, alguns métodos “únicos” de previsão (sem envolver *bootstraps*) se tornam atrativos, performando melhor que algumas combinações nesse horizonte. Contudo, no geral, pode-se dizer os métodos de conjunto seguem oferecendo resultados mais acurados.

5. Conclusões e direções para trabalhos futuros

O presente trabalho propôs novas combinações de algoritmos de *Bagging* existentes na literatura aplicada de *machine learning* com métodos de amortecimento exponencial, buscando-se aprimorar as previsões de abastecimento mensal de energia elétrica em 30 diferentes países da OCDE. Os experimentos foram conduzidos em diferentes horizontes temporais, 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 por tais combinações 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 previsões agregadas que empregaram como método de reamostragem o *Circular Blocks Bootstrap* (CBB) foram mais acuradas que as que tiveram como meio de replicação o algoritmo de *Moving Blocks Bootstrap* (MBB). 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 o MBB

tem sido considerado como uma referência 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”). Além disso, 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.
- Bühlmann, P. (1998). Sieve bootstrap for smoothing in nonstationary time series. *The Annals of Statistics*, 26(1):48–83.
- 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.
- Dantas, T. M., Oliveira, F. L. C., e Repolho, H. M. V. (2017). Air transportation demand forecast through bagging holt winters methods. *Journal of Air Transport Management*, 59:116–123.
- 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.
- Efron, B. (1979). Bootstrap methods: Another look at the jackknife. *The Annals of Statistics*, 7(1): 1–26.
- 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.
- 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., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., e Yasmeen, F. *forecast: Forecasting functions for time series and linear models*, 2019. URL <http://pkg.robjhyndman.com/forecast>. R package version 8.5.
- 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.
- IEA (2019). International energy agency monthly statistics - the latest oil, gas, electricity and prices data from oecd countries. <https://www.iea.org/statistics/monthly/>. Acessado: 2019-04-04.
- Kaboli, S. H. A., Fallahpour, A., Selvaraj, J., e Rahim, N. (2017). Long-term electrical energy consumption formulating and forecasting via optimized gene expression programming. *Energy*, 126:144–164.
- Klein, L. R., editor (1991). *Comparative Performance of U.S. Econometric Models*. Oxford University Press. URL <https://doi.org/10.1093/acprof:oso/9780195057720.001.0001>.
- Künsch, H. R. (1989). The jackknife and the bootstrap for general stationary observations. *The Annals of Statistics*, 17(3):1217–1241.
- Makridakis, S. (1996). Forecasting: its role and value for planning and strategy. *International Journal of Forecasting*, 12(4):513–537.
- Makridakis, S., Spiliotis, E., e Assimakopoulos, V. (2018). The m4 competition: Results, findings, conclusion and way forward. *International Journal of Forecasting*, 34(4):802–808.
- McMurry, T. L. e Politis, D. N. (2010). Banded and tapered estimates for autocovariance matrices and the linear process bootstrap. *Journal of Time Series Analysis*, 31(6):471–482.
- Paparoditis, E. e Politis, D. N. (2001). Tapered block bootstrap. *Biometrika*, 88(4):1105–1119.
- 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.
- Politis, D. N. e Romano, J. P. (1991). A circular block-resampling procedure for stationary data. Technical Report EFS NSF 370, Department of Statistics, Stanford University, Stanford, CA, USA.
- Taylor, J. W. (2010). Triple seasonal methods for short-term electricity demand forecasting. *European Journal of Operational Research*, 204(1):139–152.
- Tsoumakas, G., Angelis, L., e Vlahavas, I. (2005). Selective fusion of heterogeneous classifiers. *Intelligent Data Analysis*, 9(6):511–525.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3):324–342.