

Modelos BATS, Regressão Dinâmica, Harmônica e TBATS na modelagem da demanda de energia elétrica no Sudeste do Brasil (2018 – 2019)

Tiago C. E. Franque^{1†}, Dúlcida C. G. Ernesto², Eduardo Y. Nakano³, José A. Fiorucci⁴

¹Aluno do Programa de Pós-graduação de Estatística na Universidade de Brasília-UnB.

²Aluno do Programa de Pós-graduação de Estatística Aplicada na Universidade Federal de Lavras-UFLA.

³Professor no Departamento de Estatística na Universidade de Brasília-UnB.

⁴Professor no Departamento de Estatística na Universidade de Brasília-UnB.

Resumo: A crescente demanda por energia elétrica vem estimulando estudos e ações não somente para o aumento da capacidade de geração de usinas, mas também o uso racional desse importante recurso energético. Com isso, o aumento de número de publicações relacionadas a demanda de energia elétrica, gerando assim um número bem maior de trabalhos científicos e assim como pesquisas qualitativas e/ou quantitativas, o que torna a filtragem e análise bem trabalhoso. Neste sentido, a análise e modelação da demanda de energia elétrica com base no banco de dados dos anos passados é uma ação fundamental neste momento para prever o futuro de consumo deste importante recurso. Diante do exposto, o presente artigo tem como objetivo realizar uma previsão da demanda de energia elétrica nos próximos anos a partir de banco de dados publicado pelo Operador Nacional do Sistema elétrico do Brasil, os dados que foram usados para este estudo, são referentes a demanda de energia elétrica em Megawatts (MW) desde 2018 a 2019 nos estados do Sudeste/Centro – Oeste do Brasil.

Palavras-chave: Série; Sazonalidade; Previsão, Análise.

BATS, Dynamic Regression, Harmonic and TBATS models in modeling electricity demand in Southeast Brazil (2018 – 2019)

Abstract: The growing demand for electricity has stimulated studies and actions not only to increase the generation capacity of power plants, but also the rational use of this important energy resource. This has led to an increase in the number of publications related to electricity demand, generating a much larger number of scientific papers and qualitative and/or quantitative research, which makes filtering and analysis very laborious. In this sense, the analysis and modeling of electricity demand based on the database of past years is a fundamental action at this time to predict the future consumption of this important resource. In view of the above, the aim of this article is to forecast electricity demand in the coming years based on a database published by the National Electricity System Operator of Brazil. The data used for this study refers to energy consumption in Megawatts (MW) from 2018 to 2019 in the Southeast/Central-West states of Brazil.

Keywords: Series; Seasonality; Forecasting; Analysis.

Introdução

Na situação atual energético mundial, o consumo de energia é um importante indicador de desenvolvimento para os países. Em geral, países do primeiro mundo e/ou desenvolvidos incrementam sua demanda energético à medida que sua economia se desenvolve como afirma (SOUSA et al., 2019).

Segundo IEA (2019), a revista International Energy Agency, só no ano de 2018 a demanda mundial por eletricidade apresentou um incremento de 4,1% em relação ao ano de 2017. O Brasil, sendo um país em desenvolvimento, segue a mesma tendência dos países já desenvolvidos, na qual espera-se que haja um crescimento no consumo de eletricidade proporcional ao desenvolvimento da sua economia e surgimento de novas tecnologias, Oliveira (2017) citado por Juliana et al. (2021), num dos seus artigos.

[†]Autor correspondente: tiagochandionaernestofranque@gmail.com.

Segundo a Empresa de Pesquisa Energética (EPE, 2020), no ano de 2019, o Brasil apresentou uma progressão de 1,3% na demanda final por energia elétrica, sendo os setores que mais colaboraram para essa progressão, em termos de valores absolutos: o comercial (+4,5), o residencial (+3,5%), o energético (+4,1) e o público (+2,1). Desse modo, se mostra necessário a implementação de medidas que possibilitem não só o aumento da oferta de energia por meio de fontes renováveis, mas também o seu uso de maneira racional e eficiente (LEITE et al., 2019).

A eficiência energética pode ser definida como a obtenção de um mesmo serviço energético, utilizando menos energia durante o processo. Nesse contexto, é possível proporcionar o uso racional e eficiente da energia em todas as etapas do processo, desde sua obtenção em forma primária até o consumo final. A eficiência energética se mostra como uma ferramenta de relevante impacto e baixo custo para redução dos gastos com energia, podendo alcançar aproximadamente 20% de economia quando comparada à aquisição de novas fontes de geração (SOUZA et al., 2019).

Sendo assim, um sistema de gestão energética implementa, constantemente, métodos técnicos e organizacionais que visam buscar oportunidades de conservação, manutenção dos equipamentos da produção e utilização eficiente da energia nas instalações, tendo como objetivo a redução dos custos que cada cidadão sente no fim do dia após o consumo do mesmo recurso.

Neste contexto, pretende-se fazer uma breve abordagem neste artigo para prever a demanda de energia elétrica no caso particular dos estados da região Sudeste/Centro-Oeste do Brasil, de forma a verificar se a demanda de energia, tenderá a aumentar, diminuir ou permanecerá nos próximos anos. Os Modelos de Previsão de alisamento convencionais não permitem fazer uma boa previsão para este estudo, enfatizar-se-á os modelos BATS, Regressão Dinâmica Harmônica (RDH) e TBATS neste trabalho (mais detalhes sobre estes modelos, vide na seção 2).

O trabalho está dividido em 4 seções: Na primeira seção apresenta uma descrição sucinta em forma de uma introdução, descrevendo com clareza o propósito do trabalho. Na segunda seção começa com a descrição de forma resumida da situação atual da demanda da energia elétrica no Brasil e o tipo de energia consumida no sudeste - Oeste do Brasil. Também nesta seção aborda-se sobre alguns conceitos básicos sobre modelos BATS, Regressão Dinâmica Harmônica (RDH) e TBATS de uma forma bem resumida, na terceira Seção faz-se um estudo da previsão da demanda da energia elétrica no Sudeste/Centro - Oeste do Brasil com base nos dados extraídos na ONS - Brasil dos anos 2018 e 2019, nesta seção foram implementados os modelos BATS, RDH e TBATS para fazer a previsão da demanda de energia elétrica. Já na quarta Seção Apresenta as conclusões da pesquisa e as referências bibliográficas exploradas na realização deste trabalho.

Conceitos Básicos

Situação Atual de Demanda de Energia Elétrica no Sudeste, Centro-Oeste do Brasil

Até a última atualização foi feita no dia 13 de Fevereiro de 2023, as 00h:43 minutos, na página oficial da ONS (Balanço de Energia (ons.org.br)). A população dos estados da região Sudeste/Centro-Oeste do Brasil consome quatro tipos de energia a saber: Hidráulica, Eólica, Térmica e Solar sendo a Eólica a mais consumida entre elas. O consumo total de todos os tipos de energia na região é um pouco mais de 17400 MW. Para melhor compreender sobre a demanda da energia na região Sudeste/Centro - Oeste do Brasil observa a tabela que se segue.

Como pode-se ver na tabela anterior, nenhuma família consome a energia elétrica solar.

Modelos de Previsão Avançados

Esta seção apresenta os modelos de previsão avançados, isto é, os modelos que tratam os dados com múltiplos ciclos sazonais em Análise de Séries Temporais.

Tabela 1: A demanda e tipo de energia elétrica no Brasil.

Tipo de Energia Consumida ou Gerada	Demanda (MW)
Hidráulica	5926,4
Eólica	10847,5
Térmica	650,4
Solar	0
Total	17423,5

Fonte: Banco de dados ONS, Brasil.

Modelo BATS, RDH e TBATS

Segundo Fiorucci (2020), algumas séries possuem múltiplos ciclos sazonais que não são captados por modelos de alisamento exponencial ou ARIMA convencionais, em especial, dados de frequência maior que mensal (também chamada de alta frequência):

- (a) Séries semanais usualmente apresentam ciclos sazonais mensal e anual;
- (b) Séries diárias podem apresentar ciclos sazonais semanal, mensal e anual;
- (c) Séries horárias podem apresentar ciclos sazonais diário, semanal, mensal e anual.

Estas também podem conter ciclos não inteiros (complexos) como por exemplo: Séries semanais possuem ciclo anual de $365.25/7 = 52.17857$.

- **Decomposição STL com Múltipla Sazonalidade (MSTL)**

Cleveland et al. (1990) defendem que a decomposição MSTL tem as seguintes vantagens em relação ao método clássico:

- (a) Tendência via Loess (Regressão Dinâmica);
- (b) Sazonalidade Dinâmica;
- (c) Usualmente fornece melhores resultados que a decomposição clássica.
- (d) Faz múltiplas aplicações da decomposição STL

- **Modelo BATS**

A sigla BATS tem o seguinte significado em Análise de Séries Temporais:

B: transformação de Box-cox para heterogeneidade

A: modelo ARMA para erros

T: Tendência via alisamento exponencial

S: Sazonalidade múltipla via alisamento exponencial

Supõe-se que tem uma série y_t , e seja ω parâmetro de transformação de Box-Cox, $\gamma_1, \gamma_2, \dots, \gamma_M$ os parâmetros de alisamento sazonal e m_1, m_2, \dots, m_M os tamanhos dos respectivos M ciclos sazonais. O modelo BATS é descrito pelo seguinte conjunto de equações dinâmicas:

$$y_t^{(\omega)} = \begin{cases} \frac{y_t^\omega}{\omega}, & \text{se } \omega \neq 0 \\ \log(y_t), & \text{se } \omega = 0 \end{cases} \quad (1)$$

E por outro lado tem se a série

$$y_t^{(\omega)} = l_{t-1} + \phi \times b_{t-1} + \sum_{i=1}^M S_{t-m_i}^{(i)} + e_t \quad (2)$$

$$l_t = l_{t-1} + \phi \times b_{t-1} + \alpha \cdot e_t \tag{3}$$

$$b_t = \phi \times b_{t-1} + \beta \cdot e_t \tag{4}$$

$$S_t^{(i)} = S_{t-m_i}^{(i)} + \gamma_i \cdot e_t \tag{5}$$

$$y_t^{(\omega)} = l_{t-1} + \phi \times b_{t-1} + \sum_{i=1}^M S_{t-m_i}^{(i)} + e_t \tag{6}$$

$$e_t = \sum_{i=1}^p \phi_i e_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \tag{7}$$

As equações (1), (2) e (7) representam séries de transformação de Box-Cox, HW + Damped e ARMA respectivamente. A ordem do modelo BATS é identificado por: $BATS(\omega, p, q, \phi, m_1, \dots, m_M)$.

- (a) Assim como os modelos ETS, o modelo BATS também pode ser escrito como um modelo de espaço de estado não linear;
- (b) Assumindo normalidade, então a verossimilhança é conhecida;
- (c) Previsão pontual e intervalar podem ser feitos via bootstrap;
- (d) Ainda que o modelo BATS permita múltiplas sazonalidades, os ciclos sazonais não inteiros precisam ser arredondados;
- (e) O modelo BATS pode ser utilizado em situações em que os resíduos do modelo ETS não atendem a suposição de independência.

O modelo BATS está implementado no R na biblioteca forecast na seguinte função:

```
bats(y, # objeto ts ou msts devidamente especificado
use.box.cox=NULL, # Se NULL testa com e sem Box-Cox;
use.trend=NULL, # Se NULL testa crescimentos A e N do ETS;
use.damped.trend=NULL, #Se NULL testa crescimentos A e Ad do ETS;
seasonal.periods=NULL, #Vetor de ciclos sazonais (se y numeric);
use.arma.errors=TRUE, # Se TRUE usa ARMA(p,q) nos erros;
use.parallel=length(y)>1000, # Rodar em multicore?;
um.cores = 2, # Numero de cores do processador;
... # argumentos adicionais da auto.arima()
# recomendo stepwise=FALSE)
```

Essa função faz a seleção e o ajuste do modelo.

• **Modelo de Regressão Dinâmica Harmônica (RDH)**

Sabe-se que as equações da Regressão Dinâmica Dinâmica são dadas por:

$$y_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_k X_{k,t} + \eta_t \tag{8}$$

$$\eta_t = \phi_1 \eta_{t-1} + \dots + \phi_p \eta_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \tag{9}$$

A Regressão Dinâmica Harmônica:

- (a) Utiliza Séries Harmônicas (de Fourier) para modelar a sazonalidade;
- (b) Permite modelar múltiplos ciclos sazonais;
- (c) São necessários poucos parâmetros mesmo para ciclos sazonais grandes;
- (d) As Séries Harmônicas entram na Regressão Dinâmica como variáveis regressoras.

O modelo RDH está implementado no R no pacote Forecast na seguinte função:

```
fourier(x,      #serie temporal
        K,      #vetor com o numero maximo de termos de fourier
              #por ciclo sazonal
        h = NULL #horizonte de previsao requerido,
              #deve ser utilizado apenas para previsao)
```

• **Modelo TBATS**

A sigla TBATS significa:

- T: termos Trigonométricos para sazonalidade
- B: transformação de Box-Cox para heterogeneidade
- A: modelo ARMA para erros
- T: Tendência via alisamento exponencial (ETS)
- S: Sazonalidade múltipla ou para períodos não inteiro

Oliveira et al. (2011) afirmam que uma série original no tempo t y_t deduz-se para modelo TBATS se forem feitas as seguintes transformações dinâmicas:

$$y_t^{(\omega)} = \begin{cases} \frac{y_t^\omega}{\omega}, & \text{se } \omega \neq 0 \\ \log(y_t), & \text{se } \omega = 0 \end{cases} \quad (10)$$

$$y_t^{(\omega)} = l_{t-1} + \phi \times b_{t-1} + \sum_{i=1}^M S_{t-m_i}^{(i)} + e_t \quad (11)$$

$$l_t = l_{t-1} + \phi \times b_{t-1} + \alpha \cdot e_t \quad (12)$$

$$b_t = \phi \times b_{t-1} + \beta \cdot e_t \quad (13)$$

$$S_t^{(i)} = \sum_{j=1}^{k_i} S_{j,t}^{(i)} \quad (14)$$

$$S_{j,t}^{(i)} = S_{j,t-1}^{(i)} \cos \lambda_j^{(i)} + S_{j,t-1}^{(i)} \text{sen} \lambda_j^{*(i)} + \gamma_1^{(i)} e_t \quad (15)$$

$$S_{j,t}^{*(i)} = -S_{j,t-1}^{(i)} \text{sen} \lambda_j^{(i)} + S_{j,t-1}^{(i)} \cos \lambda_j^{*(i)} + \gamma_2^{(i)} e_t \quad (16)$$

$$e_t = \sum_{i=1}^p \phi_i e_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (17)$$

As equações (10), (11), (14) e (18) representam séries de transformação de Box - Cox, HW+Damped, Fourier e ARMA respectivamente. Portanto, a ordem do modelo BATS é identificado por: $TBATS(\omega, p, q, \phi, \{ \langle m_1, k_1 \rangle, \langle m_2, k_2 \rangle, \dots, \langle m_M, \dots, k_M \rangle \})$.

- (a) O modelo TBATS também é um modelo de espaço de estado não linear;
- (b) A verossimilhança é conhecida;
- (c) Previsão pontual e intervalar podem ser feitos via bootstrap;

O modelo está implementado no R na biblioteca forecast na seguinte função:

```
tbats(y, #objeto ts ou msts devidamente especificado
      use.box.cox=NULL, #Se NULL testa com e sem Box-Cox;
      use.trend != NULL, #Se NULL testa crescimentos A e N do ETS;
      use.damped.trend=NULL, #Se NULL testa crescimentos A e Ad do ETS;
      seasonal.periods=NULL, #Vetor com ciclos sazonais;
      use.arma.errors=TRUE, #Se TRUE usa ARMA(p,q) nos erros;
      use.parallel=length(y)>1000, #Rodar em multicore?;
      num.cores = 2, #Numero de cores do processador;
      ... #argumentos adicionais da auto.arima()
      #recomendo stepwise!=FALSE)
```

Essa função faz a seleção e o ajuste do modelo TBATS.

Metodologias

Uma vez os dados em estudos (medição da demanda de energia elétrica em MW) foram observadas hora em hora, isto é, variam em função do tempo (em horas), portanto gera-se uma série com múltiplas sazonalidades. As Séries horárias podem apresentar ciclos sazonais diário, semanal, mensal e anual, estes também podem conter ciclos não inteiros (complexos), nestes casos os ciclos sazonais que neles existem não são captados por modelos de alisamento exponencial ou ARIMA convencionais. Para fazer a previsão de demanda de energia nos estados do Sudeste/Centro-Oeste do Brasil dos anos 2018 a 2019, aplicou-se os modelos BATS, RDH e TBATS abordados na segunda seção deste trabalho.

A série originada por este conjunto de dados em estudo da quí em diante chamar-se-á de "Série da medição de energia elétrica hora em hora nos estados Sudeste/Centro-Oeste do Brasil entre 2015 a 2019. Nesta pesquisa foram colhidas 17520 observações feitas horas em horas. Deste universo 8761 observações que serão analisadas neste trabalho (para reduzir o custo computacional).

A série original y_t foi reduzida para as formas padrões dos modelos BATS, RDH e TBATS através de software R na biblioteca Forecast nas funções `BATS(...)`, `Fourier(...)` e `TBATS(...)` respectivamente, em seguida fez-se a previsão pontual e intervalar do consumo de energia com base dos gráficos dos seus resíduos.

Previsão de demanda de energia elétrica

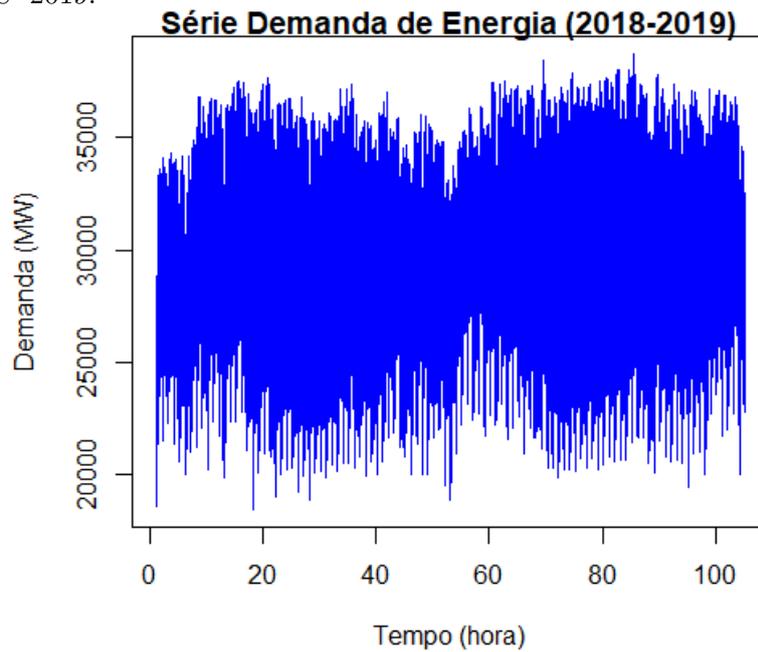
Representação e decomposição da série: demanda de energia no Sudeste/Centro-Oeste do Brasil entre 2018 a 2019

No total serão analisados 8761 observações que compreende entre dia 01 de Janeiro de 2018 a 01 de Janeiro de 2019, a contagem foi feita hora em hora.

Representação Gráfica da Série Original, y_t (o conjunto de todos dados)

A seguir está apresentada o gráfico da série original y_t medição da demanda de energia elétrica dos observados de hora em hora de 01 de Janeiro de 2018 até o primeiro dia de Janeiro 2019 no Sudeste/Centro-Oeste) do Brasil.

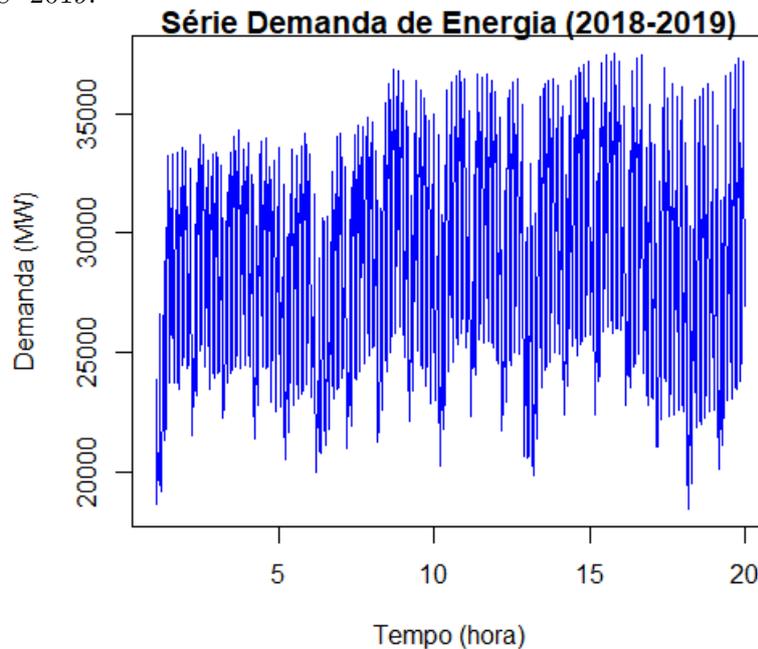
Figura 1: Representação gráfica da série medição da demanda de energia elétrica hora em hora no Brasil de 2018 -2019.



Fonte: Elaborado pelos autores, com base de Banco de dados de ONS – Brasil, 02/2023.

Também podemos fazer a representação do gráfico da série cortando algumas janelas, conforme a Figura 2.

Figura 2: Representação gráfica da série Medição hora em hora de demanda de energia elétrica no Brasil de 2018 -2019.

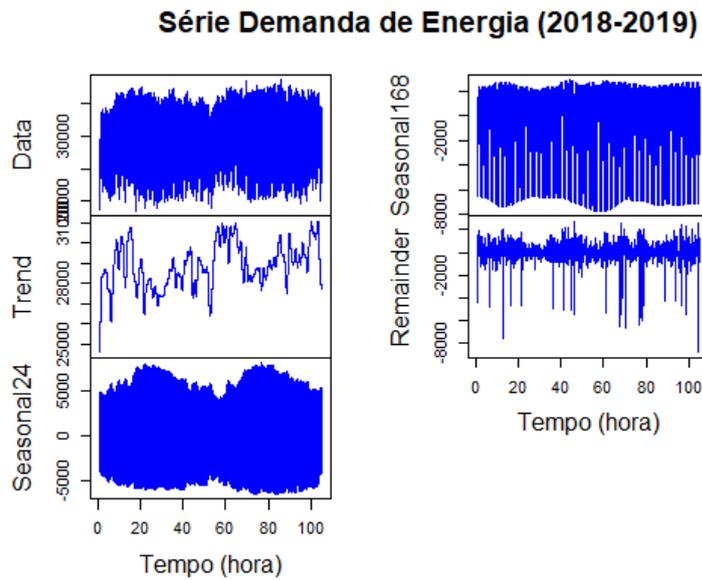


Fonte: Elaborado pelos autores, com base de Banco de dados de ONS – Brasil, 02/2023.

Decomposição da Série Via MSTL (Múltipla Sazonalidade, tendência e Level)

Depois de representar o gráfico da série original, fez-se a decomposição da mesma série via MSTL, como mostra a Figura 3.

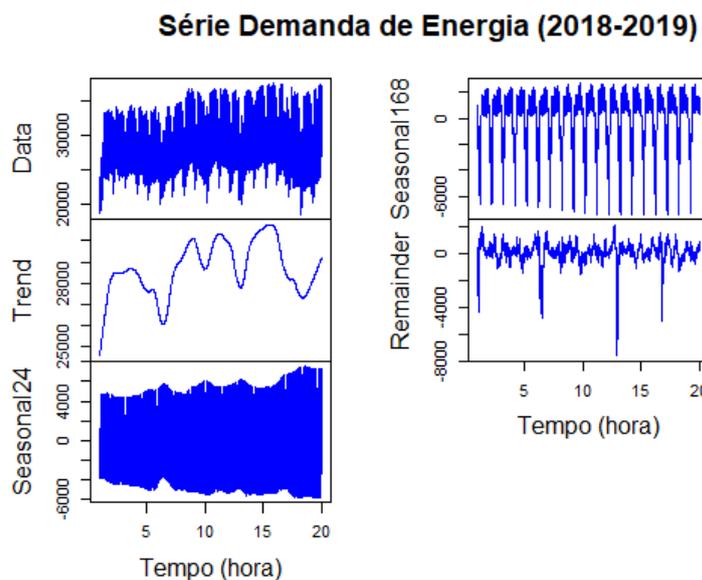
Figura 3: Decomposição da série energia via MSTL.



Fonte: Elaborado pelos autores com base de dados da ONS – Brasil, 2018 – 2019.

A Figura 4 ilustra a série demanda de energia com a decomposição MSTL. Os dados estão distribuídas em torno de um valor fixo, a tendência é crescente, ela apresenta 2 ciclos de sazonalidade com frequência igual a 24 e 168. finalmente o ruído branco apresenta amplitude constante com alguns picos. Os ciclos sazonais são diárias e semanal.

Figura 4: Decomposição da Série Energia Via MSTL.



Fonte: Elaborado pelos autores com base de dados da ONS – Brasil, 2018 – 2019.

Seleção de Modelos e Previsão de Consumo de Energia Elétrica

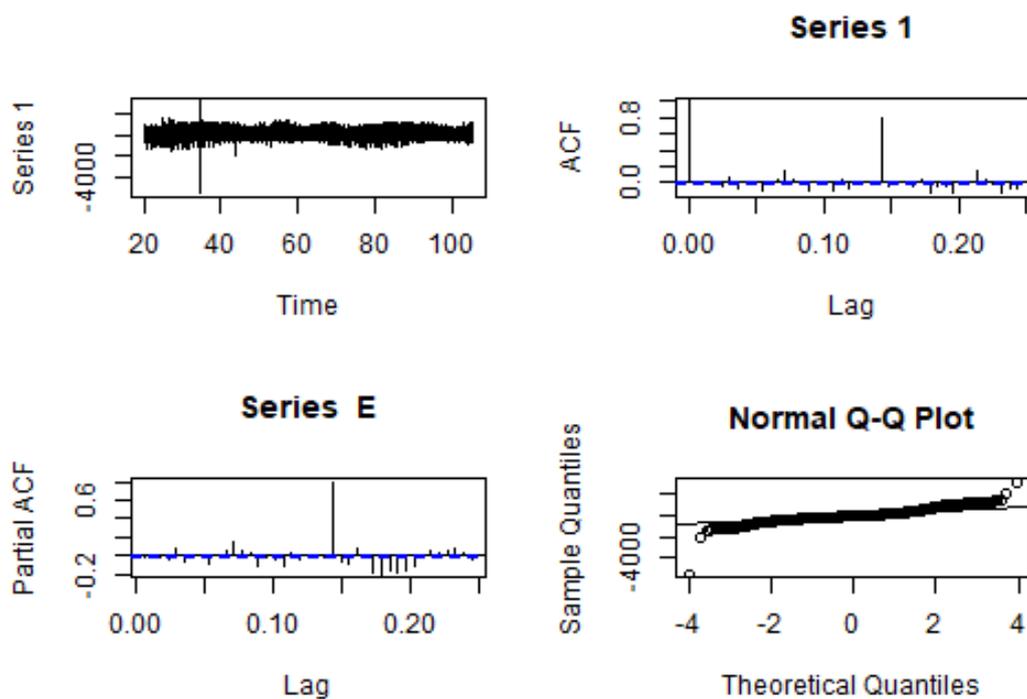
• Previsão Via Modelo BATS

Nesta subseção do trabalho, faz-se a previsão da demanda de energia aplicando o modelo BATS - fazendo análise gráfica do seu resíduo ajustados, previsão da demanda via gráfica a partir do ano 2020 em diante.

Recorrendo a biblioteca Forecast da Software R fez a seleção e ajuste do modelo BATS da seguinte ordem: BATS(0.7744, (2, 1,1), 2, 24, 168), $\sigma = 34.47$ e AIC = 376276,7.

(i) Análise gráfica dos resíduos do modelo BATS ajustado

Figura 5: Análise gráfica dos resíduos do modelo BATS ajustado.



Fonte: Elaborado pelos autores com base de dados da ONS – Brasil, 2018– 2019.

Com base no Figura 5 pode-se concluir que a série de demanda de energia é estacionária e as suposições de independência e normalidade verificam-se. Os testes Kpss, Box-Ljung foram aplicados para verificar a estacionaridade e a independência.

A seguir apresenta-se a previsão da demanda de energia elétrica via análise visual.

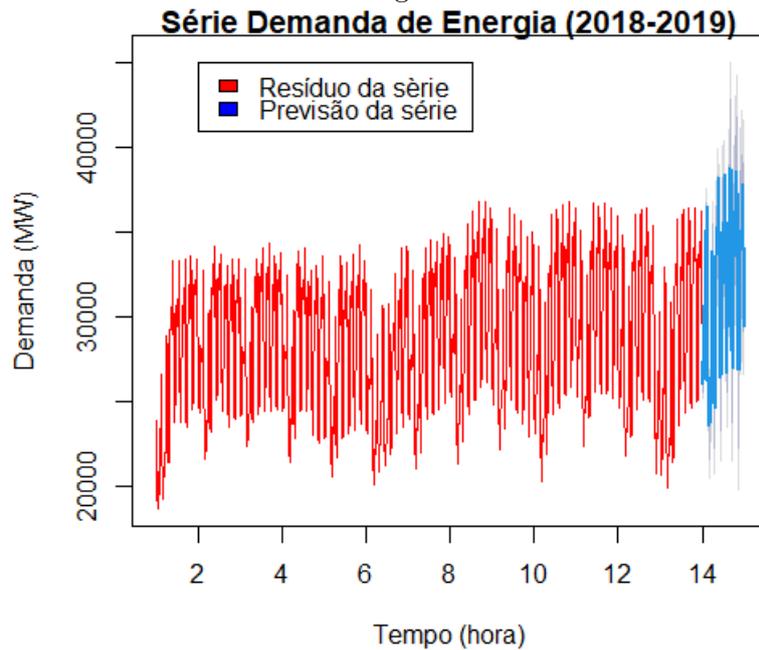
(ii) Gráfico da previsão da demanda da energia elétrica via modelo BATS

Antes de fazer a previsão via modelo BATS, primeiramente fez-se a previsão via STL + Modelo (ARIMA ou ETS) como ilustram os seguintes gráficos:

Os gráficos das duas figuras acima, mostram a previsão da demanda de energia elétrica via modelo STL + ARIMA e ets respectivamente, mostra cum ligeiro aumento da demanda de energia elétrica como mostra os gráficos 6 e 7.

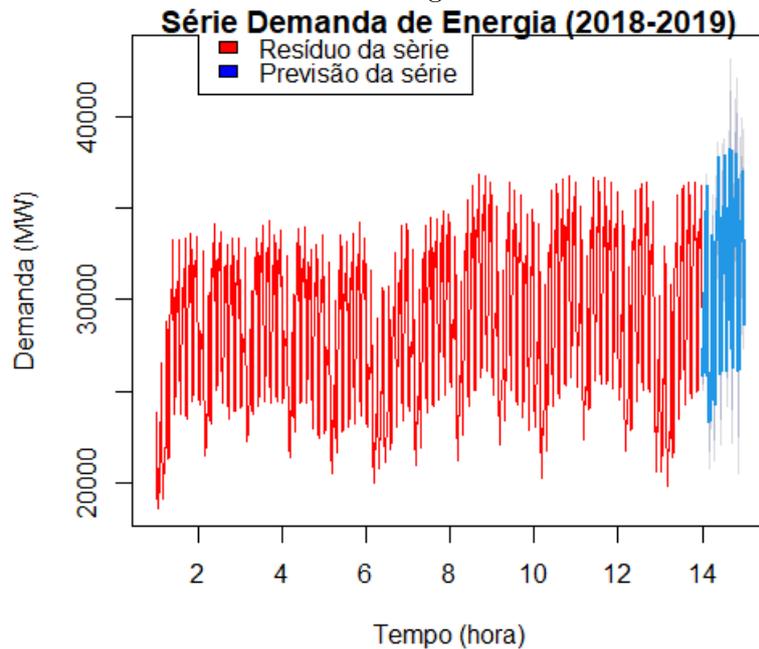
A seguir apresenta-se a previsão da demanda via modelo BATS de uma forma visual.

Figura 6: Previsão da demanda da energia elétrica via STL + Modelo ARIMA.



Fonte: Autores.

Figura 7: Previsão da demanda da energia elétrica via STL + Modelo ets.



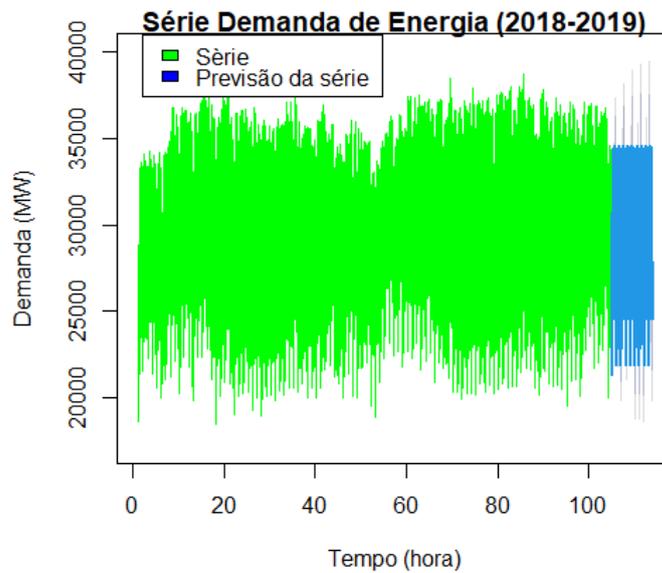
Fonte: Autores.

Previsão Via Modelo Regressão Dinâmica Harmônica

Como viu-se numa das seções anterior deste trabalho, a Regressão Dinâmica Harmônica utiliza as séries Harmônicas (de Fourier) para modelar múltiplos ciclos de sazonalidades, as Séries Harmônicas ou de Fourier entram na Regressão Dinâmica como variáveis regressoras.

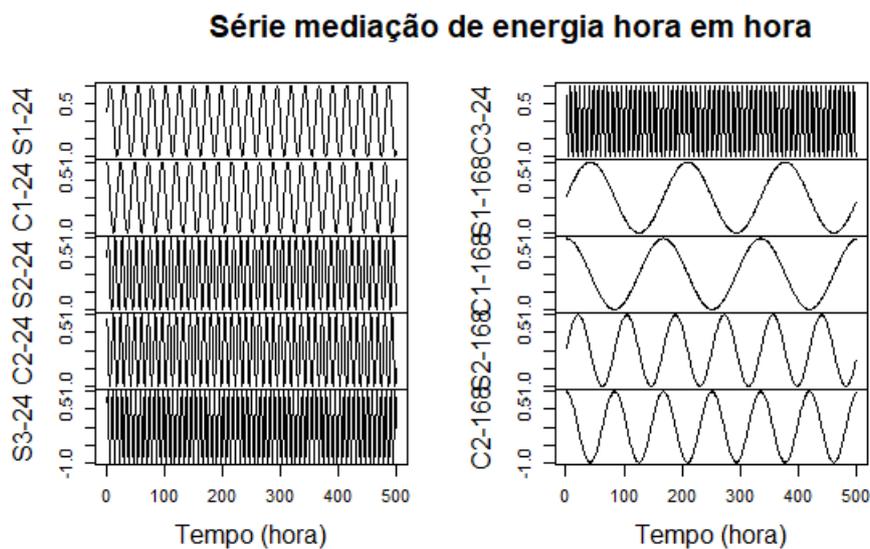
Com base dos dados observados, foram construídas as primeiras 10 séries de Fourier, veja a figura que se segue:

Figura 8: Previsão da demanda de energia elétrica.



Fonte: Autores.

Figura 9: Representação gráfica das 10 primeiras séries de FOURIER.



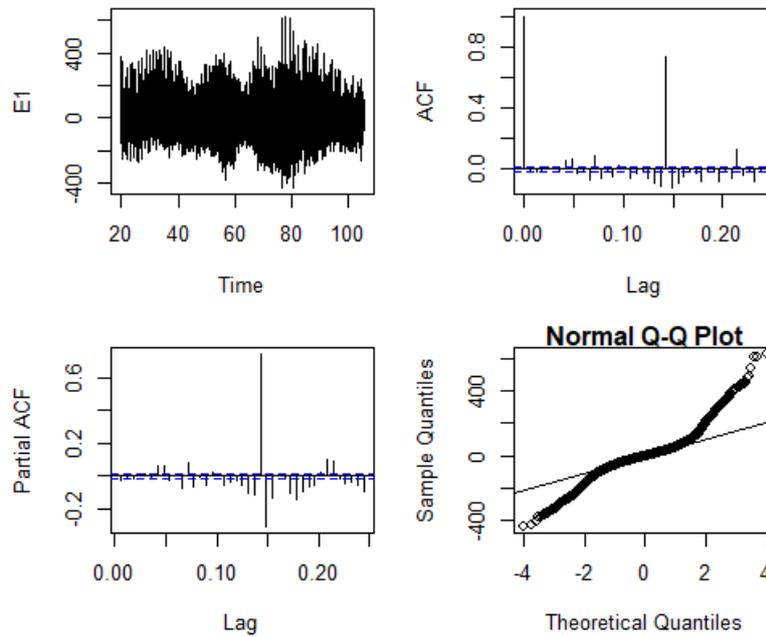
Fonte: Autores.

Sabe-se que as séries harmônicas são de amplitudes constantes, como observa-se na Figura 9, essas séries entram na modelagem como termos regressoras.

O modelo da Regressão Harmônica selecionado e ajustado é Regressão Dinâmica com erros do modelo ARIMA: (2, 1, 1). Os termos regressoras tem amplitude constante.

A seguir apresenta-se a análise dos resíduos do modelo para verificar as suposições de estacionariedade, independência e normalidade, recorrendo os seus gráficos.

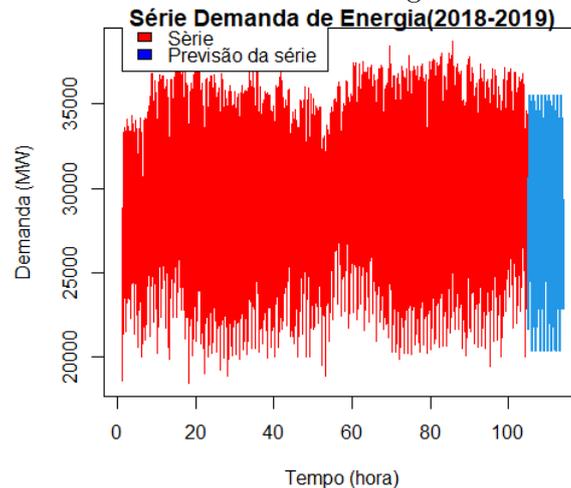
Figura 10: Análise residual do modelo RDH.



Fonte: Autores.

Graficamente, pode-se dizer que o modelo não atende as suposições de estacionariedade, independência e normalidade. A seguir vamos apresentar a previsão por meio deste modelo.

Figura 11: Previsão utilizando a Regressão Harmônica.



Fonte: Autores.

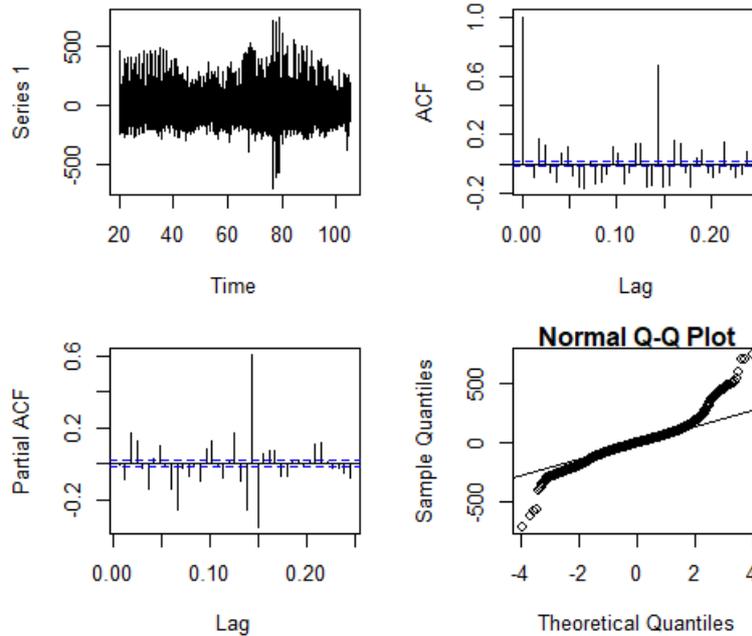
Como pode-se observar na Figura 11, o modelo Regressão Dinâmica Harmônica aponta que a demanda de energia não terá nenhuma variação, mas este não é um modelo candidato adequado para modelar estes tipos de dados, por outro lado ele não atendeu as suposições necessárias para adequação.

Previsão Via Modelo TBATS

O modelo TBATS selecionado e ajustado para a série medição de demanda de energia elétrica em estudo tem seguintes características:

Ordem do modelo: TBATS(0.916, 0,5,2, i24,5i, i24*7,6i). A seguir apresenta-se os gráfico dos seus resíduos para verificar a estacionaridade, independência e normalidade.

Figura 12: Análise residual do modelo TBATS.

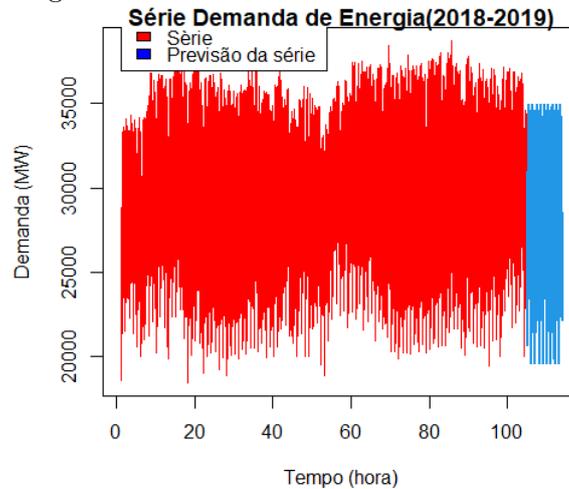


Fonte: Autores.

Observando a Figura 12, as suposições para adequação do modelo não foram atendidas, de facto este não é modelo candidato para fazer uma boa previsão dos dados em estudo.

A seguir apresenta-se o gráfico da previsão para analisar o seu comportamento, assim,

Figura 13: Previsão via do modelo TBATS.



Fonte: Autores.

De acordo com o gráfico da Figura 13, indica que a demanda da energia elétrica permanecerá a mesma, no entanto sem nenhuma variação.

Conclusão

Verificou-se que os modelos sem a transformação de Box-Cox não iriam fazer estimativas de previsões pontuais consistentes com o comportamento da série; este fato pode-se justificar por presença de duas sazonalidade, portanto Nesses modelos (sem Box-Cox) a projeção das sazonalidades acabariam ficar no meio termo entre a amplitude mais alta do final da série com a amplitude mais baixa do início da série. Por outro lado, os modelos que utilizam a transformação de

Box-Cox (BATS, RDH e TBATS) são capazes de superar este problema como foi abordado nas referências teóricas deste artigo, podendo ser uma alternativa para séries como este de um número elevado de observações, com mais de uma sazonalidade com altas frequências e com ciclos não inteiros. Os três modelos quanto ao suposições de adequação (estacionaridade, independência e normalidade) o modelo BATS mostrou se mais robusto em relação aos RDH e TBATS, sendo assim, aconselharia aplicar o modelo BATS para modelar estes tipos de dados nas condições dadas. Quanto à previsão, o modelo BATS fez boas previsões da demanda de energia elétrica em relação aos outros dois modelos.

Referências

CLEVELAND et al; Terpenning, I. MSTL: A seasonal-trend decomposition; *Journal of official statistics*, 6 (1), 3–73; 1990.

OLIVEIRA et al. Forecasting time series with complex seasonal patterns using exponential smoothing. *Journal of the American statistical association*, v.106, n.496, p.1513-1527, Taylor & Francis, 2011.

OLIVEIRA et al. *Forecasting time series with complex seasonal patterns using exponential smoothing*. Jaboticabal: Taylor & Francis, v.106, n.496, p.e26210414085-e26210414085, 2021.

JULIANA et al. Eficiência energética aplicada ao consumo de eletricidade: Um estudo de revisão bibliográfica. *Research, Society and Development*, v.10, n.4, p.-42, 1955.

IEA (Proost, Joris). State-of-the art CAPEX data for water electrolyzers, and their impact on renewable hydrogen price settings; *International Journal of Hydrogen Energy*, Elsevier, v.44, n.9, p.4406-4413, 2019.

LEITE et al. *XXV SNPTEE Seminário Nacional De Produção E Transmissão De Energia Elétrica*, 10 a 13 de novembro de 2019, Belo Horizonte-MG, 2009.

SOUSA et al. Análise do potencial de aproveitamento energético de biogás de aterro e simulação de emissões de gases do efeito estufa em diferentes cenários de gestão de resíduos sólidos urbanos em Varginha (MG). *Engenharia Sanitaria e Ambiental, SciELO Brasil*, v.24, p.887-896, 2019.