

A short-term electricity demand forecasting in the Southern Region of Brazil using the ARIMA Model and the Holt Exponential Smoothing Model (SEH)

Mariane C. Amaral¹, Anderson G. Silveira¹, Viviane L.D. Mattos², Eduardo N. Borges³

¹Programa de Pós-graduação em Modelagem Computacional
Universidade Federal do Rio Grande (FURG) Cep 96202-900 – Rio Grande – RS – Brazil

²Instituto de Matemática Estatística e Física (IMEF)
Universidade Federal do Rio Grande (FURG) –Rio Grande, RS – Brazil.

³Centro de Ciências Computacionais (C3)
Universidade Federal do Rio Grande (FURG) – Rio Grande, RS – Brazil

{marianecamaral, a.garcia.ee, vivianeldm.furg}@gmail.com, eduardoborges@furg.br

Abstract. *Predicting the demand for electricity is an essential task for the nation's economic strategy, and an adequate balance between generation of distribution is extremely necessary. In this context, this work performed the forecast of electricity demand in the Southern Region of Brazil using time series modeling of residential consumption data. The Holt Exponential Smoothing Model and the ARIMA Model were used. The results achieved showed that the models were able to adequately fit the data in short-term, presenting a low validation error, which can be explained by the 2008 global economic crisis.*

Resumo. *Prever a demanda por energia elétrica é tarefa essencial para estratégia econômica da nação, sendo de extrema necessidade ocorrer um balanceamento adequado entre geração de distribuição. Neste contexto, este trabalho realizou a previsão da demanda de energia elétrica na Região Sul do Brasil utilizando modelagem da série temporal de dados de consumo residencial. Foram utilizados o Modelo de Suavização Exponencial de Holt e o Modelo ARIMA. Os resultados alcançados mostraram que os modelos foram capazes de se ajustar adequadamente aos dados em curto prazo, apresentando baixo erro de validação que pode ser explicado pela crise econômica global de 2008.*

1. Introdução

A economia mundial pode ser fortemente influenciada pela geração e distribuição de energia. Assim, deve ocorrer um balanço energético adequado e, segundo [dos Santos 2015], há um grande desafio para previsão da demanda de energia elétrica, considerando a investigação, ainda dos fatores e variáveis que influenciam a demanda como, por exemplo, crises econômicas.

Conforme explicado por [Silveira et al. 2019], conhecer previamente o comportamento do consumo de energia pode servir de base para o planejamento da infraestrutura do país. Dessa maneira, a previsão de demanda, segundo [Gaither and Frazier 2001], pode ser definida como uma estimativa futura que contribui para um equilíbrio econômico das nações.

De acordo com o Balanço Energético Nacional do ano de 2020, a oferta interna de energia teve um acréscimo de 1,4% em relação ao ano de 2019 [EPE 2020]. Esses e outros dados são expostos geralmente por observações feitas ao longo do tempo, denominadas séries temporais. Se tratando de análises quantitativas, pode-se dizer que a previsão de demanda pode ser baseada em cálculos estatísticos, citando-se como exemplo os Modelos de Suavização Exponencial e os Modelos Autorregressivos Integrados de Médias Móveis (ARIMA), abordados em [Hyndman and Athanasopoulos 2018].

Neste contexto, o trabalho apresentado neste artigo propõe realizar a previsão de demanda de energia elétrica na Região Sul do Brasil a curto prazo através da comparação da modelagem exponencial de Holt e da modelagem ARIMA.

Os resultados encontrados mostram que ao tentar-se prever a demanda de energia elétrica, uma série de dados pode não ser suficiente para descrever a real situação do consumo. Mesmo assim, estes primeiros testes com os referidos modelos se mostram satisfatórios, ao analisarmos as porcentagens de erro encontradas. O restante do texto está organizado da seguinte forma. A Seção 2 apresenta o embasamento teórico acerca de séries temporais, modelo ARIMA e o modelos de suavização exponencial com tendência. Na Seção 3 é definida a metodologia adotada. Os resultados encontrados são detalhados na Seção 4. Por fim, a Seção 5 sintetiza as conclusões e apresenta possíveis direções de trabalhos futuros.

2. Trabalhos relacionados

O tema de previsão de eletricidade, com auxílio da modelagem ARIMA e Holt, vem sendo abordado em diversos trabalhos ao longo dos anos. Em [de Menezes et al. 2014] são utilizados os modelos Box e Jenkins e Holt-Winters associados a abordagem Singular Spectrum Analysis para a modelagem de uma série temporal de consumo residencial mensal de energia elétrica de uma concessionária do Rio de Janeiro.

Em [Junior et al. 2018] foi realizada a previsão do consumo de eletricidade para o nordeste brasileiro através de um modelo ARIMA sazonal, encontrando um modelo $SARIMA(1, 1, 0)(0, 0, 1)_{12}$ com melhor resultado para a realização de previsões. O trabalho de [Amaro et al. 2017], por sua vez, compara o desempenho preditivo de modelos ARIMA para a série de demanda de energia elétrica de médio prazo do Brasil, e como resultado tem-se que as evidências empíricas encontradas consideram o modelo ARIMA(2,1,1) como o melhor processo para as previsões.

Em [Jiang et al. 2020] são utilizados modelos de Holt-Winters para prever o consumo por eletricidade em uma cidade da China, os autores apresentam uma metodologia para selecionar os melhores parâmetros na aplicação do método, chegando a um resultado preciso, mesmo para amostras pequenas.

Já o trabalho de [Miswan et al. 2016] intencionou avaliar o desempenho do modelo ARIMA combinado com um modelo de regressão linear na previsão de energia elétrica, sendo este trabalho aplicado na cidade de Johor Bahru, na Malásia. O estudo de [Hussain et al. 2016] aplica os modelos Holt-Winter e ARIMA para prever o consumo de eletricidade no Paquistão, concluindo que para os dados estudados, o método de Holt-Winter apresentou melhor resultado.

3. Embasamento teórico

Este trabalho é embasado, principalmente, em critérios e conceitos de séries temporais e testes de hipóteses a estas aplicados. Também são abordados alguns métodos de modelagem envolvendo séries de dados para ser possível a realização de previsões.

3.1. Séries Temporais

Para [Gaither and Fraizer 2001], uma série temporal é nada mais do que uma sequência de dados observados ao longo do tempo, podendo ser estacionária ou não estacionária. Ser estacionária está relacionado com o fato de os dados oscilarem em torno de uma média constante. Também pode-se analisar se uma série temporal possui ou não uma tendência. Se possuir, já se sabe que essa série é não estacionária, pois não estaria mais oscilando em torno de uma média constante.

Alguns testes podem ser aplicados às séries temporais para facilitar suas análises. Os testes de raiz unitária, também conhecidos como testes de estacionariedade, são baseados em testes de hipóteses, principalmente. Assim, considera-se a hipótese nula, também conhecida como H_0 , e a hipótese alternativa, a H_1 . Esses testes são utilizados para determinar quantas vezes as séries precisam ser derivadas para que se tornem estacionárias, sendo de fundamental importância já que a presença raiz unitária em séries temporais, faz com que as previsões se tornem mais imprecisas, conforme explica [Silveira et al. 2017]. Assim, esses testes serão utilizadas para a descoberta de parâmetros da modelagem ARIMA deste trabalho.

O teste de Dickey-Fuller aumentado (ADF), proposto por [Dickey and Fuller 1981], tem como sua hipótese nula a não estacionariedade, assim como o teste de Phillips-Perron (PP), abordado por [Phillips and Perron 1988]. Já o teste KPSS, proposto por [Kwiatkowski et al. 1992], tem sua hipótese nula na estacionariedade. Os três testes podem ser baseados no parâmetro de rejeição ou não *dop-valor*, sendo considerado neste trabalho como 0,05.

Para a normalidade, a ser testada nos resíduos, dois testes muito utilizados são os de Jarque-Bera e Shapiro-Wilk, explicados em [Jarque and Bera 1980] e [Shapiro and Wilk 1965], respectivamente. Ambos têm como hipótese nula a normalidade e, dessa maneira, se o *p-valor* se apresentar menor do que 0,05, deve-se rejeitar a normalidade. Já se o *p-valor* for maior do que 0,05, não são encontradas evidências de não normalidade.

Para testar se existe autocorrelação entre os resíduos, pode ser considerado o teste de Ljung-Box, proposto por [Ljung and Box 1978]. Assim, para a proposição de modelos que utilizam séries temporais, tais como o Modelo de Médias Móveis Integradas Autorregressivas, é necessário realizar este teste para confirmar e se certificar que os resíduos sejam independentes. O teste de [McLeod and Li 1983] tem como hipótese nula a homocedasticidade dos resíduos.

3.2. Modelagem ARIMA

O Modelo de Médias Móveis Integradas Autorregressivas (ARIMA), utiliza correlações entre os dados da série e é baseado principalmente em três parâmetros, conforme Equação 1, onde p e q correspondem, respectivamente, às ordens das par-

tes regressiva e de médias móveis, e d indica o grau de diferenciação, segundo [Hyndman and Athanasopoulos 2018].

$$ARIMA = (p, d, q) \quad (1)$$

Para representação de uma série temporal por um modelo ARIMA é necessário que a série seja estacionária, não dependendo do tempo. Nesse processo, os testes de ADF, PP e KPSS auxiliam informando, de acordo com suas hipóteses próprias, se a série é estacionária ou não. Dessa maneira, para escolha do parâmetro d na modelagem ARIMA, deve-se analisar quantas vezes será necessário diferenciar a série para que esta seja estacionária.

3.3. Modelos de Suavização Exponencial com tendência

Os modelos de suavização exponencial são modelos que utilizam todos dados das séries temporais em questão, amortizando os efeitos dos valores do passado e dando a eles diferentes valores. Dessa maneira, um dado mais antigo terá o seu peso menor do que um dado mais recente. Conforme explica [Samohyl et al. 2008], as observações mais recentes são mais valorizadas na previsão.

O modelo de [Holt 1957] é um tipo de método de suavização exponencial que é utilizado quando a série de dados possui uma tendência linear, diferentemente do método de suavização simples, que é utilizado quando a série se mantém oscilando em torno de um valor médio. Segundo [Hyndman and Athanasopoulos 2018], o método de tendência linear de Holt é descrito através de uma equação de previsão, Equação 2, e duas equações de suavização, sendo uma para o nível e outra para a tendência, Equação 3 e Equação 4.

$$\hat{y}_{t+h|t} = l_t + hb_t \quad (2)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (4)$$

Das Equações 2, 3, e 4, nota-se que l_t corresponde ao nível estimado, tendo seu parâmetro α de suavização e b_t , por sua vez, corresponde à tendência estimada em um certo tempo t com padrão de suavização β . Os valores de α e β variam de 0 a 1. Ainda, pode-se dizer que l_t é uma média ponderada de y_t , enquanto b_t é uma média ponderada da tendência. Os modelos de tendência amortecida, por sua vez, possuem um parâmetro que, segundo [Hyndman et al. 2002], têm a função de atenuar a tendência aditiva, se mostrando mais efetivos ainda. As equações do modelo de tendência amortecida são dadas por:

$$\hat{y}_{t+h|t} = l_t + (\phi + \phi^2 + \dots + \phi^h)b_t \quad (5)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1}) \quad (6)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)\phi b_{t-1} \quad (7)$$

As variáveis das Equações 5, 6 e 7 são análogas às variáveis das Equações 2, 3, e 4. Ainda, tem-se o fator ϕ que amortece a tendência.

4. Metodologia

Como conjunto de dados analisado, foi utilizada a série anual da demanda de energia elétrica residencial na região sul do Brasil em Gigawatt-hora (GWh). A série original tem seu início no ano de 1979, com observação até o ano de 2017 e foi recuperada da página online do Instituto de Pesquisa Econômica Aplicada (Ipea¹), com uma observação anual.

Para a aplicação da modelagem ARIMA, parte-se da análise gráfica através da construção dos gráficos da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP). Também são utilizados os testes apresentados na Seção 2: ADF, PP e KPSS, a fim de determinar a ordem de integração do modelo candidato. Os modelos candidatos são comparados entre si a fim de escolher o modelo que minimiza os critérios de informação considerados: Critério de Informação de Akaike (AIC), Critério de Informação de Akaike Corrigido (AICc) e Critério Bayesano de Informação de Schwarz (BIC). Em seguida, são realizados os testes de homocedasticidade, normalidade e o teste de autocorrelação dos resíduos, uma vez que são pressupostos para aplicação da modelagem ARIMA.

A modelagem Holt com amortecimento parte da seleção do valor da variável ϕ gerando os modelos que também serão comparados através dos critérios de informação AIC, AICc e BIC. De posse do modelo selecionado, são realizados os testes de homocedasticidade, normalidade e o teste de autocorrelação dos resíduos, sendo a independência uma característica indispensável na aplicação do modelo. Os modelos de suavização exponencial de Holt e o ARIMA permitiram a análise da demanda a curto prazo. Para implementar os testes e modelagens realizados neste artigo, foi utilizado o *software* R².

5. Resultados

A série de dados escolhida não contava com os valores anuais, portanto foram somados os consumos mensais de cada ano e carregados no R. O gráfico anual da série é mostrado logo abaixo, na Figura 1, elaborada com dados do Ipea.

Nota-se uma tendência linear de aumento do consumo de energia elétrica em GWh com o passar dos anos. Foi escolhido que a série seria janelada do ano de 1979 até o ano de 2010, garantindo que aproximadamente 80% da série fosse utilizada para construção do modelo e 20% utilizado para validação. Os valores de 2011 até 2017 serão posteriormente utilizados para que seja feita a comparação dos valores preditos via cada modelo com os valores observados.

A não estacionariedade ou estacionariedade da série pode ser verificada pelo teste de Dickey-Fuller aumentado (ADF), pelo teste de Phillips-Perron (PP) e pelo teste KPSS. O Dickey-Fuller aumentado parte da hipótese nula de que a série é não estacionária. O teste ADF retornou os valores conforme mostrados na Tabela 1.

¹Instituto de Pesquisa Econômica Aplicada - <http://ipeadata.gov.br>

²The R Project for Statistical Computing - <http://r-project.org>

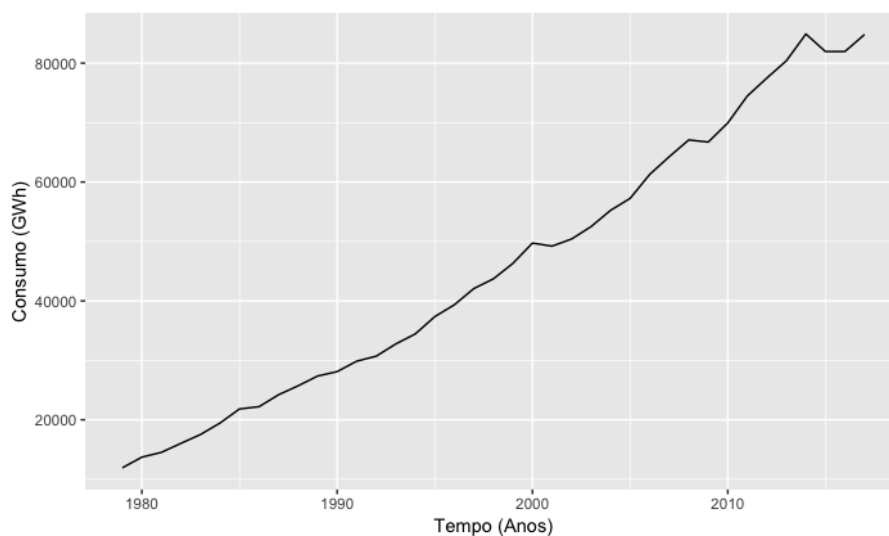


Figura 1. Consumo de energia elétrica na região Sul do Brasil entre 1979 e 2017

Tabela 1. Resultados do Teste ADF

Tipo	<i>p</i>-valor em nível	<i>p</i>-valor - primeira diferença
Sem constante e sem tendência	0,99	0,06
Com constante e sem tendência	0,99	0,01
Com constante e com tendência	0,75	0,01

Observa-se que em todos os casos, o *p* – *valor* não é menor que 0,05 e não se rejeita a hipótese nula, ou seja, não se rejeita a hipótese da série ser não estacionária (rejeitamos que a série é estacionária). Seria necessário, teoricamente, diferenciar a série. Após diferenciar a série, nota-se que o valor com constante e com tendência, bem como o valor com constante e sem tendência, são menores do que 0,05. O teste Phillips-Perron parte da hipótese nula de que a série é não estacionária, assim como o teste ADF, e tem seus resultados mostrados na Tabela 2. Analogamente ao ADF, os resultados deste teste são igualmente interpretados.

Tabela 2. Resultados do Teste PP

Tipo	<i>p</i>-valor em nível	<i>p</i>-valor - primeira diferença
Sem constante e sem tendência	0,94	0,18
Com constante e sem tendência	0,97	0,01
Com constante e com tendência	0,85	0,01

Já o teste de raiz unitária KPSS parte da hipótese nula da série sendo estacionária, ao contrário dos dois testes realizados acima. Os valores obtidos através do KPSS podem ser visualizados na Tabela 3.

Nota-se que o *p*-*valor* não é menor do que 0,05 em todos os casos. Isso significa que não se pode rejeitar a hipótese nula, que neste caso é a estacionariedade. Assim, rejeita-se a não estacionariedade neste teste.

Tabela 3. Resultados do Teste KPSS

Tipo	<i>p</i>-valor em nível	<i>p</i>-valor - primeira diferença
Sem constante e sem tendência	0,07	0,10
Com constante e sem tendência	0,07	0,10
Com constante e com tendência	0,10	0,10

Diante dos três testes, será considerada, em primeira diferença, a estacionariedade na série, confirmada pelos testes de ADF e PP. Para a sugestão do valor do valor de d do modelo ARIMA, temos o valor é 1, pois a série foi diferenciada uma vez para se tornar estacionária. A partir disso, passa-se a investigar os possíveis valores de p e q , visto que podem ser determinados pelo gráfico da função de autocorrelação, mostrado na Figura 2.




Figura 2. Gráfico de autocorrelação ACF e PACF

Examinando os picos de cada defasagem (lag), pode-se identificar que no gráfico da função de autocorrelação e da autocorrelação parcial que o modelo ARIMA mais adequado aponta ser ARIMA(1,1,0). Entretanto, deve-se analisar os valores dos testes de normalidade, bem como o gráfico de histograma dos resíduos para realmente propor o modelo. Ao serem analisados, esses testes demonstraram resultados insatisfatórios e, portanto, foi preciso encontrar outro modelo ARIMA através de tentativas próximas.

Os critérios de informação AICc e BIC podem ser utilizados para a proposição da ordem do modelo ARIMA. Na Tabela 4 são mostrados os valores de critérios de informação conforme a modelagem ARIMA simulada.

O modelo ARIMA que atendeu aos testes é caracterizado como ARIMA(0,1,0), tendo seus valores de critério de informação os menores possíveis. A normalidade foi testada nos resíduos e os resultados obtidos no teste de Jarque-Bera e Shapiro-Wilk são mostrados na Tabela 5.

Em ambos os casos o p -valor se apresenta maior que 0,05, não rejeitando a hipótese de não normalidade no teste de Jarque-Bera e no teste de Shapiro-Wilk. O histo-

Tabela 4. Valores dos critérios de informação para diferentes modelos ARIMA

ARIMA (p,d,q)	AIC	AICc	BIC
0,1,0	521,09	521,52	523,96
1,1,0	522,89	523,78	527,20
0,1,1	522,92	523,81	527,23
1,1,1	523,79	525,33	529,52
2,1,0	524,59	526,13	530,33
2,1,1	525,48	527,88	532,65
0,1,2	524,72	526,26	530,45
1,1,2	525,36	527,76	532,53

Tabela 5. Testes de normalidade - Modelo ARIMA

Teste	p -valor
Jarque-Bera	0,662
Shapiro-Wilk	0,607

grama dos resíduos é mostrado na Figura 3, concordando com os resultados dos testes. Já o teste de McLeod Li apresentou o p -valor 0,502, não sendo possível rejeitar a hipótese de homocedasticidade nos resíduos, já que seu valor é maior do que 0,05.

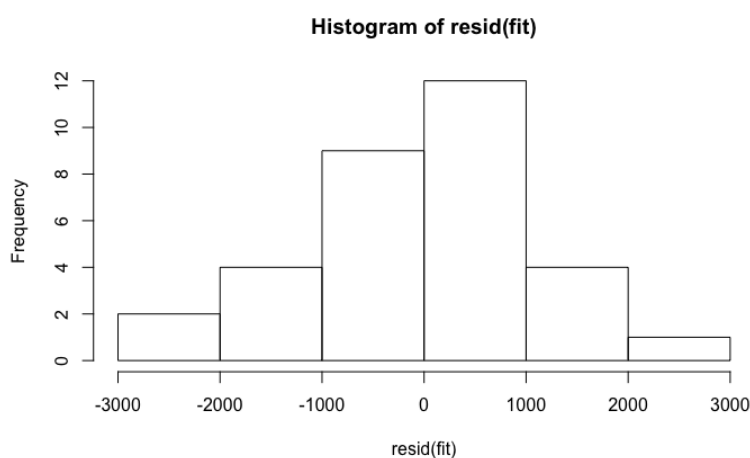


Figura 3. Gráfico de normalidade entre os resíduos

Para testar a autocorrelação entre os resíduos, usa-se o teste de Ljung-Box. O p -valor neste caso é 0,64, assegurando a independência dos resíduos. Ao analisarmos a acurácia do modelo ARIMA, temos os valores abaixo relacionados, na Tabela 6.

Agora, para a modelagem Holt com amortecimento, inicialmente o valor de ϕ pode ser alterado, iniciando-se em 0,8 e até 0,98 a fim de encontrar-se critérios de informação minimizados. Diante dos valores, esta modelagem será realizada considerando o valor $\phi = 0,98$. Esses resultados são mostrados na Tabela 7.

Ainda, foi realizado o teste de Ljung-Box para o Modelo Holt amortecido, obtendo-se o p -valor de 0,7337. Os resultados dos testes de normalidade dos resíduos

Tabela 6. Erros encontrados para a modelagem ARIMA(0,1,0)

Erro	Valor
MAE	747,92
RMSE	997,65
MAPE	2,00
MASE	0,38

Tabela 7. Critérios de informação de acordo com ϕ

ϕ	AIC	AICc	BIC
0,80	575,10	577,41	582,43
0,85	573,39	575,70	580,72
0,90	572,07	574,38	579,40
0,98	566,63	568,94	573,96

são mostrados na Tabela 8. Em ambos os testes, obteve-se um resultado maior que o nível de significância considerado. Já os valores de erros encontramos neste caso estão demonstrados na Tabela 9. O teste de McLeod Li apresentou o *p-valor* 0,510, não sendo possível rejeitar a hipótese de homocedasticidade nos resíduos, já que seu valor é maior do que 0,05.

Tabela 8. Testes de normalidade - Modelo Holt Amortecido

Teste	<i>p-valor</i>
Jarque-Bera	0,544
Shapiro-Wilk	0,562

Tabela 9. Erros encontrados para a modelagem Holt amortecida

Erro	Valor
MAE	815,91
RMSE	1058,45
MAPE	2,11
MASE	0,42

Considerando os dois modelos testados, tem-se o gráfico ilustrando os valores da série temporal original (na cor preta) com os valores estimados na Figura 4. Dessa maneira, com auxílio da função *forecast*, é possível realizar a previsão que, neste caso, é até 2020. O gráfico resultante é mostrado na Figura 5. A Tabela 10 mostra os valores reais, fornecidos pela série original de 2011 até 2017, sendo comparados com o Modelo de Holt amortecido (denominado HA) e com o modelo ARIMA. São mostrados também os erros, em porcentagem, de cada um dos modelos.

Analisando-se a Tabela 10, é possível perceber que em nenhum dos casos o erro foi maior de 8,90%. Ainda, é perceptível que os maiores erros estão associados à faixa mais íngreme do gráfico, onde o consumo de energia da região Sul aumentou mais do que o esperado. Salienta-se também que a modelagem ARIMA em questão teve o menor

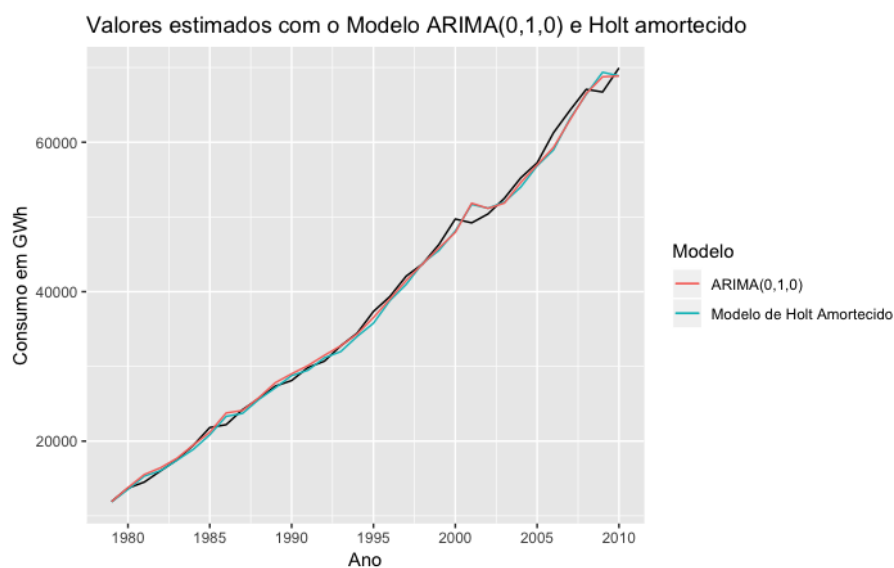


Figura 4. Valores estimados pelos modelos de Holt amortecido e ARIMA




Figura 5. Previsão até 2020 com os modelos de Holt amortecido e ARIMA

Tabela 10. Valores reais e previstos para modelagem Holt amortecida e ARIMA

Ano	Valor Real	HA	% erro HA	ARIMA	% erro ARIMA
2011	74470	71757	3,64	71805	3,57
2012	77490	73650	4,95	73667	4,93
2013	80393	75487	6,10	75548	6,02
2014	84900	77269	8,90	77420	8,81
2015	81949	78997	3,60	79291	3,24
2016	81957	80674	1,56	81163	0,96
2017	84813	82300	2,96	83034	2,09

erro percentual em todos os anos, de 2011 a 2017. Pode-se notar que os modelos não se adequaram bem ao vale de 2008. Neste ano aconteceu a crise econômica mundial, colapsando as bolsas de valores de todo o mundo.

6. Conclusões

Este estudo desejou realizar uma previsão do consumo de energia elétrica na região sul do Brasil em curto prazo através da utilização de conceitos de análise de séries temporais e modelos de previsão. Foram utilizados duas modelagens: a modelagem ARIMA e a modelagem de Holt amortecida. Os dois modelos testados atenderam aos testes de independência e normalidade entre os resíduos, sempre indicando valores maiores que o nível de significância estipulado (0,05).

Nota-se que em ambos os casos, do ano de 2011 até o ano de 2017, os valores de previsão estão levemente subestimados. Isso se deve ao fato de a série apresentar um crescimento mais íngreme a partir de 2010. Esse crescimento concorda com o Balanço Energético Nacional citado neste estudo, onde é relatado que a capacidade de geração instalada no Sul do Brasil teve um crescimento nos últimos anos de maneira acentuada, gerando um maior consumo de energia.

Após a crise do ano de 2008, seria natural que a inclinação da curva aumentasse para recuperar a tendência, mas os modelos não foram capazes de prever esse comportamento anômalo em relação ao consumo de energia a curto prazo. Dessa maneira, podem ser estudados modelos que relacionem a demanda por energia elétrica com variáveis econômicas nos próximos trabalhos. Assim, é prudente dizer que a previsão de energia elétrica residencial a partir da série de dados apenas do consumo pode não fornecer uma análise completa da situação. Mesmo assim, estes primeiros testes com os referidos modelos se mostram satisfatórios, ao analisarmos as porcentagens de erro quando validamos o modelo pois, em nenhum caso, a discrepância foi maior do que 8,9% entre os valores reais e previstos.

Referências

- Amaro, R. S., Ceretta, P. S., Coronel, D. A., Bender Filho, R., and de Oliveira, M. G. (2017). Comparação da capacidade preditiva de modelos arima para o consumo de energia elétrica no brasil. *Revista UNEMAT de Contabilidade*, 6(11).
- de Menezes, M. L., Cassiano, K. M., de Souza, R. M., Souza, R. C., and Júnior, L. A. T. (2014). Singular spectrum analysis associada à modelagem arima e holt-winters na previsão de consumo de energia. *Simpósio de Pesquisa Operacional e Logística da Marinha-Publicação Online*, 1(1):213–224.
- Dickey, D. A. and Fuller, W. A. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica: journal of the Econometric Society*, pages 1057–1072.
- dos Santos, B. F. C. (2015). Caracterização de diagramas de consumo doméstico de eletricidade na perspectiva da comercialização. Master's thesis, Faculdade de Engenharia da Universidade do Porto, Portugal.
- EPE, E. D. P. E. (2020). Balanço energético nacional: Relatório síntese, ano base 2019. *Rio de Janeiro: Ministério de Minas e Energia*. Disponível em <http://www.epe.gov.br/>; acesso em agosto-2020.

- Gaither, N. and Fraizer, G. (2001). Administração da produção e operações, 8^a. *Pioneira, São Paulo, 598p.*
- Holt, C. C. (1957). Forecasting trends and seasonal by exponentially weighted moving averages. *ONR Memorandum, 52.*
- Hussain, A., Rahman, M., and Memon, J. A. (2016). Forecasting electricity consumption in pakistan: The way forward. *Energy Policy, 90:73–80.*
- Hyndman, R. J. and Athanasopoulos, G. (2018). *Forecasting: principles and practice.* OTexts.
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., and Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of forecasting, 18(3):439–454.*
- Jarque, C. M. and Bera, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics letters, 6(3):255–259.*
- Jiang, W., Wu, X., Gong, Y., Yu, W., and Zhong, X. (2020). Holt–winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption. *Energy, 193:116779.*
- Junior, L. M. C., Melquíades, T. F., da Costa Martins, K. d. L., Júnior, E. P. S., and de Freitas, G. P. (2018). Previsão do consumo de eletricidade no nordeste brasileiro. *Engevista, 20(3):408–423.*
- Kwiatkowski, D., Phillips, P. C., Schmidt, P., Shin, Y., et al. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root. *Journal of econometrics, 54(1-3):159–178.*
- Ljung, G. M. and Box, G. E. (1978). On a measure of lack of fit in time series models. *Biometrika, 65(2):297–303.*
- McLeod, A. I. and Li, W. K. (1983). Diagnostic checking arma time series models using squared-residual autocorrelations. *Journal of time series analysis, 4(4):269–273.*
- Miswan, N. H., Said, R. M., and Anuar, S. H. H. (2016). Arima with regression model in modelling electricity load demand. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC), 8(12):113–116.*
- Phillips, P. C. and Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika, 75(2):335–346.*
- Samohyl, R. W., Souza, G. P., and de Miranda, R. G. (2008). *Métodos simplificados de previsão empresarial.* Ciência Moderna.
- Shapiro, S. S. and Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika, 52(3/4):591–611.*
- Silveira, A. G., Amaral, M. C., and de Mattos, V. L. D. (2019). Relação de longo prazo entre a renda média domiciliar da população e a demanda residencial por energia elétrica. *Revista Mundi Engenharia, Tecnologia e Gestão (ISSN: 2525-4782), 4(2).*
- Silveira, A. G., de Mattos, V. L. D., and Konrath, A. C. (2017). Avaliação da estacionariedade e teste de cointegração em séries temporais o caso da demanda de energia elétrica residencial no brasil. *RETEC-Revista de Tecnologias, 9(3).*