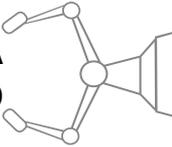


ANÁLISE DO CONSUMO MENSAL DE ENERGIA ELÉTRICA NO ESTADO DE SÃO PAULO



Cleber Bisognin

cleber.bisognin@ufsm.br; Universidade Federal de Santa Maria

Liane Werner

werner.liane@gmail.br; Universidade Federal do Rio Grande do Sul

Resumo: A energia elétrica contribui com o desenvolvimento. A energia elétrica é uma necessidade básica da população, deixando a margem da inclusão social quem ainda não possui. Neste setor, a tomada de decisão e os desdobramentos para o desenvolvimento da infraestrutura de uma região dependem fundamentalmente de previsões acuradas da demanda. Para tanto, este trabalho visa para prever os futuros valores da série temporal do Consumo Mensal de Energia Elétrica no Estado de São Paulo como base em modelos de séries temporais e combinações de previsões. No estudo foram utilizadas 183 observações mensais disponíveis, de janeiro de 2004 a março de 2019 visando obter as previsões para o período de janeiro a dezembro de 2019. Foram utilizados 4 modelos individuais: SARIMA, com tendência estocástica e determinística, Holt-Winters com efeitos sazonais aditivos e multiplicativos e após realizou-se todas as combinações de dois, três e os quatro modelos, para os métodos de combinação de previsões: média, mediana, regressão MQO, regressão robusta MM e variância mínima. As melhores medidas de acurácia foram encontradas para a combinação via regressão MQO com base nos quatro modelos, sendo esta então usada para obter as previsões do ano de 2019.

Palavras-chave: energia elétrica; previsão; combinação de previsões.

Abstract: *Electricity contributes to development. Electric energy is a basic need of the population, leaving the margin of social inclusion to those who do not have it. In this sector, decision-making and developments for a region's infrastructure development depend fundamentally on accurate demand forecasts. To this end, this work aims to predict the future values of the Monthly Electricity Consumption time series in the State of São Paulo based on time series models and forecast combinations. The study used 183 available monthly observations from January 2004 to March 2019 to obtain forecasts for the period January to December 2019. Four individual models were used: SARIMA, with stochastic and deterministic tendency, Holt-Winters with additive and multiplicative seasonal variables and then all two, three and four model combinations were performed for the forecast combination methods: mean, median, OLS regression, robust MM regression and minimum variance. The best accuracy measures were found for the combination via OLS regression based on the four models, which was then used to obtain 2019 forecasts.*

Keywords: *electric energy, forecasting, combining forecast.*

Resumen: *La energía eléctrica contribuye al desarrollo. La electricidad es una necesidad básica de la población, dejando el margen de inclusión social a quienes aún no la tienen. En este sector, la toma de decisiones y los desarrollos para el desarrollo de infraestructura en una región dependen fundamentalmente de pronósticos precisos de la demanda. Por lo tanto, este trabajo tiene como objetivo predecir los valores futuros de las series de*

tiempo de Consumo Mensual de Electricidad en el Estado de São Paulo como base para modelos de series de tiempo y combinaciones de pronósticos. En el estudio se utilizaron 183 observaciones mensuales disponibles, de enero de 2004 a marzo de 2019 para obtener los pronósticos para el período de enero a diciembre de 2019. Se utilizaron cuatro modelos individuales: SARIMA, con tendencia estocástica y determinista, Holt-Winters con efectos aditivos estacionales y multiplicativos y después de que se realizaron todas las combinaciones de dos, tres y cuatro modelos, para los métodos de combinación de pronóstico: media, mediana, regresión OLS, regresión MM robusta y varianza mínima. Las mejores medidas de precisión se encontraron para la combinación a través de la regresión OLS basada en los cuatro modelos, que luego se utilizó para obtener pronósticos para el año 2019.

Palabras clave: *energía eléctrica; pronóstico; combinación de pronósticos.*

1. INTRODUÇÃO

Para Tidre *et al.* (2013) a energia elétrica visa contribuir com o desenvolvimento da população humana, bem como proporcionar uma comodidade nas várias atividades. Na realidade a energia elétrica é uma necessidade básica, deixando a margem da inclusão social quem ainda não a possui. Conforme Reis; Cunha (2014) ainda em pleno século XXI cerca de dois bilhões de pessoas não tem acesso a ela. Já no Brasil de acordo com o Ministério de Minas e Energia (MME), serão beneficiados pelo programa Luz para todos, em 2019, 380 mil moradores que vivem sem acesso à rede elétrica no meio rural (NASCIMENTO, 2018). Contudo pelo fato de haver uma perda na capacidade de financiamento para investimentos estatais, e pelo fraco desempenho econômico do País, no período de 1980 a 2000, o setor foi afetado por uma crise que abalou sua expansão (IRFFI *et al.*, 2009).

Com a privatização da infraestrutura iniciada na década de 90, o setor de energia elétrica, que apresenta características de monopólio natural em alguns dos seus segmentos (transmissão e distribuição), a preocupação em expandir e modernizar todos os segmentos contribuiu para estimular os investimentos no setor e possibilitar as projeções de crescimento do país (SCHMIDT; LIMA 2004; SIQUEIRA *et al.*, 2006).

A partir deste novo marco institucional, o planejamento da expansão do sistema, realizado pelo MME, deixou de ser indicativo para determinativo. Visto que a energia elétrica é um bem não-estocável, esse planejamento deve ser feito com antecedência. Sendo assim, previsões da demanda serão subsídio ao planejamento estratégico necessário para captar o comportamento do sistema e avaliar a sistemática de contratação de energia elétrica junto às transmissoras, imposta às distribuidoras (SIQUEIRA *et al.*, 2006; FOGLIATTO *et al.*, 2005).

No setor de energia, incluindo o de energia elétrica, a tomada de decisão e os desdobramentos para o desenvolvimento da infraestrutura do País dependem fundamentalmente de previsões acuradas da demanda. Uma previsão de qualidade para a demanda futura de energia elétrica, além de ser um insumo indispensável ao desenvolvimento

econômico das sociedades atuais, é também fundamental para aprimorar a gestão do sistema energético e seus processos operacionais. (CASTRO; MONTINI, 2010; MOREIRA *et al.*, 2011)

Para Moreira *et al.* (2011) realizar a previsão da curva de demanda de carga de um determinado dia, o processo baseia-se nas curvas de consumo de dias já conhecidos. Os autores usaram um modelo que demonstrou uma boa capacidade de extração de características das componentes envolvidas na combinação, verificando que os resultados obtidos na maior parte das vezes, superava numericamente ou muito se aproximava do resultado da melhor componente individual.

Para tanto, este trabalho visa prever os futuros valores da série temporal do Consumo Mensal de Energia Elétrica no Estado de São Paulo como base em modelos de séries temporais e combinações de previsões.

2. TÉCNICAS DE PREVISÃO

Nesta seção são apresentados os modelos utilizados para atingir o objetivo deste estudo, a saber, os modelos SARIMA(p,d,q) \times (P,D,Q) $_s$ e Suavização Exponencial, além dos métodos para realizar combinações de previsões: média, mediana, regressão via mínimos quadrados ordinários, regressão via MM e variância mínima. A seguir são definidos os processos SARIMA(p,d,q) \times (P,D,Q) $_s$ proposto por Box; Jenkins (1976).

Definição 1: Seja $\{X_t\}_{t \in \mathbb{Z}}$ um processo estocástico satisfazendo a equação (1)

$$\Phi(B^s)\phi(B)(1-B^s)^D(1-B)^d(X_t - \mu) = \theta(B)\Theta(B^s)\varepsilon_t, \quad (1)$$

onde: μ é a média do processo, $\{\varepsilon_t\}_{t \in \mathbb{Z}}$ é o processo ruído branco, $s \in N$ é a sazonalidade, B é o operador defasagem ou de retardo, isto é, $B^j(X_t) = X_{t-j}$ e $B^{sj}(X_t) = X_{t-sj}$, para $j \in N$, $\phi(\cdot)$, $\theta(\cdot)$, $\Phi(\cdot)$ e $\Theta(\cdot)$ são os polinômios de ordem p , q , P e Q , respectivamente, definidos pelas equações (2) e (3).

$$\phi(z) = \sum_{l=1}^p (-\phi_l)z^l, \quad \theta(z) = \sum_{m=1}^q (-\theta_m)z^m, \quad (2)$$

$$\Phi(z) = \sum_{r=1}^P (-\Phi_r)z^r, \quad \Theta(z) = \sum_{l=1}^Q (-\Theta_l)z^l, \quad (3)$$

com ϕ_l , $1 \leq l \leq p$, θ_m , $1 \leq m \leq q$, Φ_r , $1 \leq r \leq P$ e Θ_l , $1 \leq l \leq Q$, constantes reais e $\phi_0 = \Phi_0 = -1 = \Theta_0 = \theta_0$. Então $\{X_t\}_{t \in \mathbb{Z}}$ é um processo sazonal autorregressivo integrado de média móvel de ordem (p,d,q) \times (P,D,Q) $_s$ com sazonalidade s , denotado por SARIMA(p,d,q) \times (P,D,Q) $_s$, onde e e s são, respectivamente, o grau de diferenciação e o grau de diferenciação sazonal.

Também serão utilizados os modelos de suavização exponencial devido a sua simplicidade e facilidade de ajustes além da boa acurácia (PELEGRINI; FOGLIATTO, 2000). A seguir são definidos os modelos de Holt-Winters para efeitos sazonais aditivos e multiplicativos. Maiores detalhes podem ser encontrados em Morettin; Tolo (2006).

Considere uma série temporal $\{X_t\}_{t=1}^n$ com período s .

Definição 2: Os Modelos de Holt-Winters para efeitos sazonais aditivos, consideram que tal série é formada pela soma do nível, tendência e um fator sazonal, como apresentado pela equação (4).

$$X_t = L_t + T_t + S_t + \varepsilon_t, \text{ para } t = s + 1, \dots, n. \quad (4)$$

As estimativas do nível da série no tempo t , denotado por L_t , da tendência, denotada por T_t e do fator sazonal, denotado por S_t , cada um destes componentes é dado por uma equação que tem, respectivamente, como parâmetro α é o coeficiente de ponderação exponencial do nível ($0 \leq \alpha \leq 1$), β é o coeficiente de ponderação exponencial da tendência ($0 \leq \beta \leq 1$) e γ é o coeficiente de ponderação exponencial do fator sazonal ($0 \leq \gamma \leq 1$).

Definição 3: Os Modelos de Holt-Winters para efeitos sazonais multiplicativos, considera-se que tal série é formada por uma tendência aditiva, por um fator sazonal multiplicativo, como apresentado pela equação (5).

$$X_t = L_t \times T_t + S_t + \varepsilon_t, \text{ para } t = s + 1, \dots, n. \quad (5)$$

As estimativas do nível da série no tempo t , denotado por L_t , da tendência, denotada por T_t e do fator sazonal, denotado por S_t , cada um destes componentes é dado por uma equação que tem, respectivamente, como parâmetro α é o coeficiente de ponderação exponencial do nível ($0 \leq \alpha \leq 1$), β é o coeficiente de ponderação exponencial da tendência ($0 \leq \beta \leq 1$) e γ é o coeficiente de ponderação exponencial do fator sazonal ($0 \leq \gamma \leq 1$).

Existem métodos utilizados para melhorar a acurácia das previsões, tais métodos são chamados de combinação de previsões. Estes métodos consistem em utilizar mecanismo para captar os diversos fatores que afetam cada técnica de previsão individual usada como base de obtenção da previsão combinada. Os precursores dos métodos de combinação de previsões foram Bates; Granger (1969), combinando duas previsões. Newbold; Granger (1974) estenderam os métodos dos precursores para k previsões.

Neste trabalho, além das combinações de previsão por média aritmética e mediana, também será utilizada a combinação por variância mínima, conforme estabelecido por Newbold; Granger (1974), a qual satisfaz a equação (6), sujeita a condição $\sum_{j=1}^k w_j = 1$, onde $w_j \geq 0$ é o peso da previsão F_j , para $j = 1, \dots, k$.

$$F_{ct} = w_1 F_{1t} + \dots + w_k F_{kt}, \text{ para } k \geq 2 \text{ e } t = 1, \dots, n. \quad (6)$$

Segundo Granger; Ramanathan (1984), alguns métodos de combinação de previsões podem também ser interpretados como um modelo de regressão linear, onde a previsão combinada é a variável resposta e as previsões dos modelos como variáveis explicativas. Tal modelo satisfaz a equação (7), sujeita as condições onde $\beta_0 \neq 0$ e $\beta_j \geq 0$ é o peso da previsão F_j , para $j=1, \dots, k$.

$$F_{ct} = \beta_0 + \beta_1 F_{1t} + \dots + \beta_k F_{kt} + \varepsilon_t, \text{ } k \geq 2 \text{ e } t = 1, \dots, n. \quad (7)$$

As estimativas dos pesos $\beta = (\beta_0, \beta_1, \dots, \beta_k)$, para $k \geq 2$, podem ser encontradas pelo método dos mínimos quadrados ordinários, além de inúmeros métodos de regressão robusta, tal como o método MM, proposto por Yohai (1987). Os estimadores baseados neste último método são altamente eficientes quando os erros possuem distribuição normal e são qualitativamente robustos.

Porém para encontrarmos qual técnica de previsão - individual ou combinação - é a melhor, faz-se necessário obter medidas de acurácia. Dentre as existentes, as mais utilizadas são: o RMSE (a raiz quadrada do erro quadrático médio) e a MAPE (erro percentual absoluto médio) (MAKRIDAKIS *et al.*, 1998). Também será utilizado, para análise o coeficiente U de Theil que analisa a qualidade das previsões. Segundo Blemiel (1973), quanto mais próximo for esta medida de zero, significa que o erro de previsão gerado por determinado modelo ou combinação é menor que da previsão ingênua.

3. PROCEDIMENTOS METODOLÓGICOS

A etapa da obtenção de dados consistiu em resgatar dados históricos do site da EPE - Empresa de Pesquisa Energética (<http://www.epe.gov.br>). Serão utilizadas as 183 observações mensais disponíveis, de janeiro de 2004 a março de 2019, ou seja, $n=183$. O uso deste período deve-se ao fato de ser o período mais completo disponíveis na internet e encontrado pelos autores. Inicialmente utilizaremos o período de janeiro de 2004 a dezembro de 2018 para ajuste dos modelos e obteremos as predições (dentro da amostra) a um passo. Após serão calculadas as previsões para o período de janeiro a dezembro de 2019 (previsão fora da amostra com base em dezembro de 2018) e as medidas de acurácia para o período de janeiro a março de 2019.

A análise da série temporal foi realizada usando as rotinas dos pacotes *forecast*, *lmtest*, *randtests*, *tseries*, *fpp*, *ggplot2*, *ForecastCombinations*, *GeomComb* e *stat* do software R Core Team (2018), para ajustar os seguintes modelos: SARIMA(p,d,q) \times (P,D,Q) $_s$ consideran-

do tendência estocástica; SARIMA(p,d,q) \times (P,D,Q) $_s$ considerando tendência determinística; Holt-Winters para efeitos sazonais aditivos e Holt-Winters para efeitos sazonais multiplicativos.

Definidos os modelos, estimados os seus parâmetros e feita a análise de resíduos, serão aplicadas as técnicas de combinação de previsão: média, mediana, regressão via mínimos quadrados ordinários, regressão via MM e variância mínima. A verificação da acurácia da técnica ou modelo a ser escolhido para realizar as previsões para o período de janeiro a dezembro de 2019, se dará por meio das medidas RMSE, MAPE e U de Theil. Tais medidas foram calculadas utilizando-se a rotina *accuracy* do pacote *forecast* do R Core Team (2018).

4. RESULTADOS E DISCUSSÕES

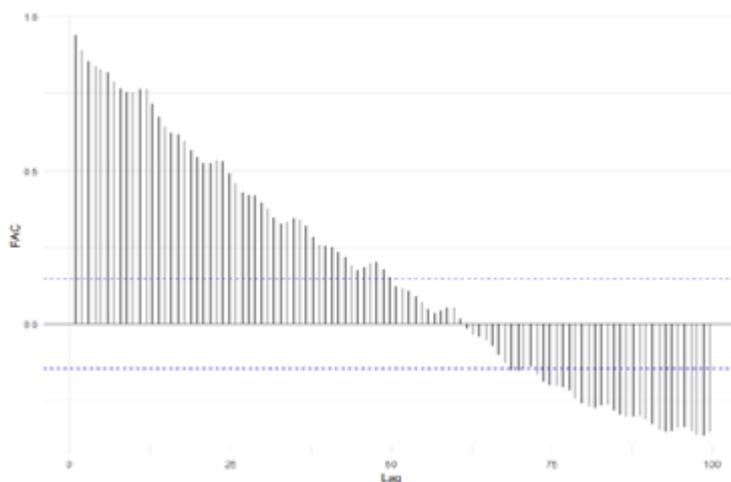
Estamos interessados em encontrar um modelo ou uma técnica adequada para a série temporal Consumo Mensal de Energia Elétrica do Estado de São Paulo, de janeiro de 2004 a março de 2019, visando prever tal consumo para os meses de abril a dezembro de 2019. As Figura 1a e 1b apresenta o gráfico e a função de autocorrelação amostral da série temporal que será alvo de estudo neste trabalho.

Figura 1a: Gráfico da Série Temporal - Consumo Mensal de Energia Elétrica no Estado de SP, no período de janeiro de 2004 a março de 2019



Fonte: Autores

Figura 1b: Função de Autocorrelação Amostral - Consumo Mensal de Energia Elétrica no Estado de SP, no período de janeiro de 2004 a março de 2019



Fonte: Autores.

Uma vez que utilizaremos o período de janeiro de 2004 a dezembro de 2018 para ajuste dos modelos e calcular as combinações e obter as medidas de acurácia. Podemos perceber, pelo gráfico da série temporal (Figura 1(a)) que se trata de uma série não estacionária. Foram aplicados os testes de raiz unitária de Dickey-Fuller [p-valor=0,6409] e de Phillips-Perron [p-valor=0,0971]. Os testes foram realizados utilizando, respectivamente, as rotinas *adf.test* e *pp.test*, do pacote *tseries* do software R Core Team (2018). Os resultados dos testes de raiz unitária comprovam a não estacionariedade da série temporal. Em ambos os testes a hipótese nula (H_0) significa que a série temporal apresenta raiz unitária. Analisando a função de autocorrelação amostral (ver Figura 1(b)) também nos leva a concluir que a série temporal é não estacionária. Analisando a Função de Autocorrelação da série temporal (Figura 1(b)) podemos perceber que a mesma apresenta sazonalidade.

Por tratar-se de uma série temporal não estacionária e com sazonalidade e, como o objetivo deste trabalho é prever, iremos tratar a tendência desta série temporal como estocástica, utilizando os modelos $SARIMA(p,d,q) \times (P,D,Q)_s$, e como determinística, ou seja, a tendência é tratada através de um modelo linear e após é ajustado um modelo $SARIMA(p,d,q) \times (P,D,Q)_s$, com $d=0=D$.

Serão ajustados ainda os modelos Holt-Winters onde a componente sazonal será tratada com aditiva e multiplicativa. Ambas as sazonalidades foram calculadas utilizando a rotina *decompose*, do R Core Team (2018). Analisando os resíduos de ambas as decomposições, obtemos que a soma dos quadrados das autocorrelações amostrais, para 100 lags, é

3,0989, para efeitos sazonais aditivos, e 3,0174, para efeitos sazonais multiplicativos. Desta forma percebemos uma pequena vantagem em usarmos o modelo multiplicativo. Mesmo assim, neste trabalho, optamos em analisar a predição utilizando os dois modelos de Holt-Winters. A seguir são apresentados os quatro modelos que foram ajustadas à Série Temporal do Consumo Mensal de Energia Elétrica no Estado de São Paulo.

Modelo 1 - Modelo SARIMA $(p,d,q)(P,D,Q)_s$. Considerando tendência estocástica, foi ajustado o modelo SARIMA $(2,1,2) \times (1,0,1)_{12}$. Sendo que as estimativas dos 6 parâmetros, foram todas significativas [p-valor<0,0001]. Para este modelo, obtivemos a log-verossimilhança: -2490,63 e Critério de Informação de Akaike (AIC) igual a 4995,26. Para a análise de resíduos utilizamos o teste de Box-Pierce com $df = 15$, cujo p-valor encontrado foi de 0,2626. Assim, ambos indicam que os resíduos do modelo são não correlacionados.

Modelo 2 - Considerando tendência determinística, foi ajustado o modelo linear $X_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 t^3 + \beta_4 t^4 + \beta_5 t^5 + Y_t$, onde $t=1, \dots, n$, que obteve um $R^2 = 0,9091$.

As Figuras 2a e 2b apresentam a série temporal sem tendência e sua respectiva função de autocorrelação amostral. Foram aplicados os testes de raiz unitária de Dickey-Fuller [p-valor<0,01] e de Phillips-Perron [p-valor<0,01], indicando que a série temporal ficou estacionária, após retirada a tendência determinística.

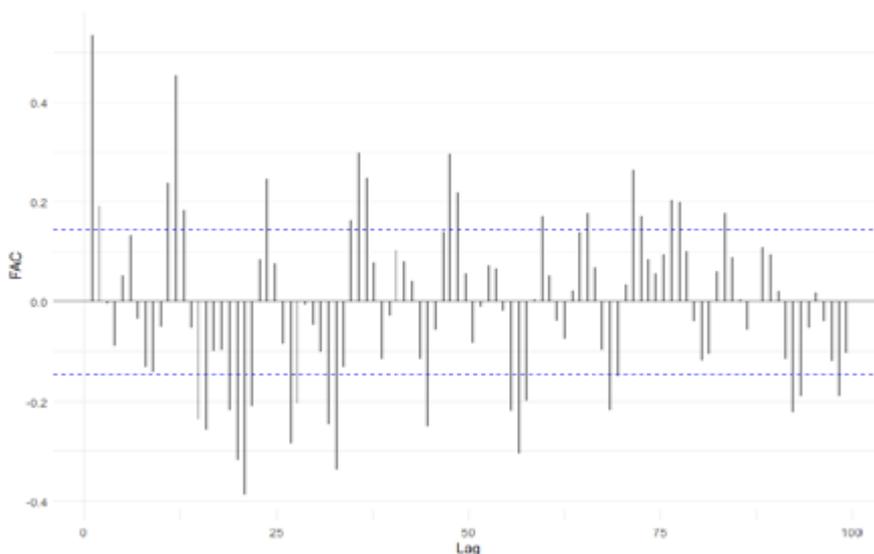
A seguir, foi ajustado um modelo SARIMA $(3,0,2) \times (1,0,1)_{12}$. As estimativas dos coeficientes foram todas significativas [p-valor<0,001] e pelo Teste de Ljung-Box [p-valor=0,7272], os resíduos do modelo são não correlacionados, indicando que o modelo é adequado aos dados.

Figura 2a: Gráfico da Série Temporal sem Tendência - Consumo Mensal de Energia Elétrica no Estado de São Paulo entre de jan/2004 e dez/2018, depois de retirada da tendência determinística.



Fonte: Autores.

Figura 2b: Função de Autocorrelação Amostral sem Tendência - Consumo Mensal de Energia Elétrica no Estado de São Paulo entre de jan/2004 e dez/2018, depois de retirada da tendência determinística.



Fonte: Autores.

Modelo 3 - Modelo de Suavização Exponencial Holt-Winters (Aditivo): as estimativas para os parâmetros do modelo foram: do coeficiente de ponderação exponencial do nível α igual a 0,5027; do coeficiente de ponderação exponencial da tendência β igual a 0,0051 e do coeficiente de ponderação exponencial do fator sazonal γ é igual a 0,5476.

Modelo 4 - Modelo de Suavização Exponencial Holt-Winters (Multiplicativo): as estimativas para os parâmetros do modelo foram: do coeficiente de ponderação exponencial do nível α igual a 0,4667; do coeficiente de ponderação exponencial da tendência β igual a 0,0069 e do coeficiente de ponderação exponencial do fator sazonal γ é igual a 0,5753.

Estabelecidos os modelos, estimado os seus parâmetros, foram calculadas as previsões - estimativa da série temporal um passo à frente, para o período observado - e previsões necessárias. Feito este passo, passamos ao cálculo dos métodos de combinações de previsão. No caso do método da variância mínima foram obtidas as estimativas dos pesos w_1, \dots, w_k , para $k = 2, 3$ e 4 obtendo todas as combinações possíveis com os modelos estimados e pelos métodos de regressão (MQO e MM) as estimativas dos coeficientes $\beta = (\beta_0, \beta_1, \dots, \beta_k)$ para $k = 2, 3$ e 4 obtendo todas as combinações possíveis com os modelos estimados. Da mesma forma, obtivemos as respectivas previsões das combinações média e mediana.

Por fim, foram calculadas as médias de acurácia RMSE, MAPE e U de Theil. Na tabela 1 são apresentadas estas medidas para os modelos individuais. Na Tabela 2 são apresentadas estas medidas para as combinações com as melhores medidas, porém cabe destacar que apresentamos as duas melhores combinações: de dois modelos, de 3 modelos e para a combinação dos 4 modelos, para cada método de combinação do estudo.

Tabela 1: Medidas de acurácia dos Modelos 1 a 4.

Modelo	RMSE	MAPE	U de Theil
1	202789.7640	1.5224	0.00971
2	190035.3295	1.4004	0.00910
3	231917.8800	1.7766	0.01110
4	231956.9162	1.7816	0.01110

Fonte: Autores

Legenda: RMSE e U de Theil são medidas adimensionais e MAPE, em kWh.

Na Tabela 2 estão realçadas as melhores medidas de acurácia para cada método de combinação. Percebemos analisando tal tabela que o menor RMSE e menor U de Theil foram obtidos ao combinar todos os quatro modelos usando o método de Regressão via MQO, já o menor MAPE foi obtido usando os quatro modelos utilizando o método de Regressão Robusta MM. Estes resultados corroboram os achados de Makridakis & Winkler (1983), em seu estudo os autores verificaram que a acurácia aumenta de acordo com o número de técnicas combinadas, embora o grau de saturação tenha sido com o emprego de quatro ou cinco. Desta forma é esperado que combinar todos os modelos fornecesse melhores medidas.

Ainda com base na Tabela 2, podemos observar que os métodos de combinação pela média e mediana, técnicas mais simples e que levam em conta apenas os modelos 1 e 2, apresentam um desempenho inferior de 2,03%, 3,42% e 2,07%, respectivamente sobre as melhores medidas de acurácia das combinações consideradas mais acuradas (que combinam os quatro modelos). Tal fato, pode levar o previsor a escolher técnicas mais simples, assumindo um erro maior.

Tabela 2: Medidas de acurácia para as Combinações de Previsão.

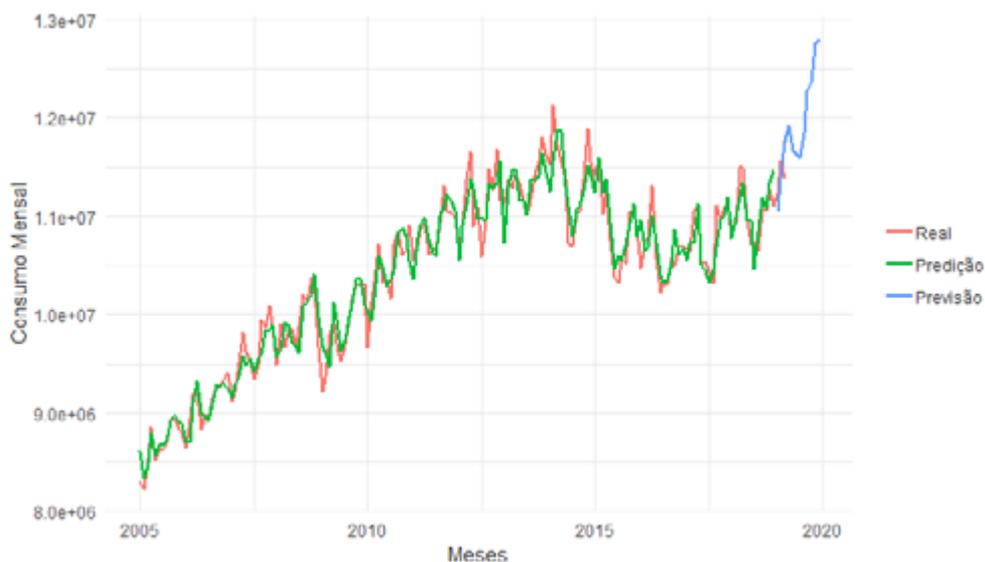
Combinação	Modelos	RMSE	MAPE	U de Theil
Média Aritmética	1 e 2	191642,64	1,4269	0,00918
	2 e 3	201339,87	1,5074	0,00964
	1, 2 e 4	196684,82	1,4770	0,00941
	2, 3 e 4	209252,31	1,5862	0,01001
	Todos	202966,60	1,5330	0,00971
Mediana	1 e 2	191642,64	1,4269	0,00918
	1, 2 e 4	196660,54	1,4569	0,00942
	1, 2 e 3	197606,16	1,4708	0,00946
	2 e 3	201339,87	1,5074	0,00964
	Todos	207110,59	1,5632	0,00991
Regressão - MQO	Todos	187752,10	1,3802	0,00899
	2, 3 e 4	188726,30	1,3827	0,00904
	2 e 4	189832,80	1,3939	0,00909
	1 e 2	189377,00	1,3955	0,00907
	1, 3 e 4	197755,90	1,5018	0,00947
Regressão Robusta - MM	Todos	188072,91	1,3781	0,00901
	2, 3 e 4	189029,23	1,3830	0,00905
	2 e 3	190046,33	1,3910	0,00910
	1 e 2	189451,26	1,3941	0,00907
	1, 3 e 4	197827,68	1,4998	0,00948
Variância Mínima	1 e 2	191239,01	1,4222	0,00916
	1, 2 e 4	194544,63	1,4558	0,00931
	Todos	199511,60	1,4995	0,00955
	1, 3 e 4	210883,43	1,6041	0,01009
	3 e 4	231587,78	1,7767	0,01108

Legenda: RMSE e U de Theil são medidas adimensionais e MAPE, medido em kWh.

Fonte: Autores.

Contudo como o previsor sempre busca o menor erro possível, realizamos as previsões utilizando o método de Regressão via MQO dos quatro modelos, visto que apresentou duas das melhores medidas de acurácia e o segundo melhor MAPE (Tabela 2). Na Figura 3 são apresentadas a série do Consumo Mensal de Energia Elétrica no Estado de São Paulo e as previsões para o período de janeiro a dezembro de 2019, com base em dezembro de 2018.

Figura 3: Consumo Mensal de Energia Elétrica no Estado de São Paulo, no período de janeiro de 2004 a março de 2019 e as previsões para ano 2019.



Fonte: Autores.

Tabela 3: Previsões para o período de janeiro a dezembro de 2019.

Período	Jan	Fev	Mar	Abr	Mai	Jun
Previsão	11045192	11388709	11768740	11913750	11666150	11642684
Período	Jul	Ago	Set	Out	Nov	Dez
Previsão	11595579	11849601	12281587	12358904	12751567	12800499

5. CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo usar técnicas de previsões para averiguar qual a mais adequada para prever do Consumo Mensal de Energia Elétrica no Estado de São Paulo. Para isto, foi utilizado a série temporal de janeiro de 2004 a março de 2019.

Inicialmente foi realizada uma análise preliminar da série temporal visando avaliar a estacionariedade da série. Após, foram ajustados quatro modelos aos dados do consumo de energia. O primeiro que foi ajustado, considerando tendência estocástica, foi o SARIMA $(2,1,2) \times (1,0,1)_{12}$. O segundo modelo ajustado foi SARIMA $(3,0,2) \times (1,0,1)_{12}$, com tendência determinística. Os outros dois modelos ajustados foram Holt-Winters com sazonalidade aditiva e multiplicativa. De posse dos quatro modelos individuais foram obtidas as previsões que deram suporte ao cálculo, dos coeficientes e pesos das com-

combinações por regressão (MQO e robusta MM) e variância mínima, e após foram obtidas todas as combinações de previsões para estes métodos, além dos métodos de combinação da média e da mediana. Realizaram-se as combinações levantando em conta todos os resultados possíveis de combinação de dois modelos, de três modelos e para os quatro modelos, para todas as cinco técnicas de combinação de previsões.

Para avaliar qual a técnica mais acurada entre as combinações e os modelos individuais foram obtidas três medidas de acurácia, a saber: RMSE; MAPE e U de Theil. Dentre as medidas de acurácia dos modelos ajustados e todas as combinações, o menor RMSE e menor U de Theil foram obtidos ao combinar todos os quatro modelos usando Regressão via MQO, já o menor MAPE foi obtido usando os quatro modelos utilizando Regressão Robusta MM. Diante disto e, lembrando que o previsor sempre deseja sempre o menor erro possível, as previsões foram realizadas com o método de Regressão via MQO dos quatro modelos.

Referências

- BATES, J. M.; GRANGER, C. W. J. The Combining of Forecasts. **Operational Research Quarterly**, v. 20, n. 4, p. 451-468, 1969.
- CASTRO, J. B.; MONTINI, A. A. Previsão do consumo residencial de energia elétrica no Brasil: aplicação do modelo ARX. **Future Studies Research Journal**, v.2, n.2, p. 3-16, 2010.
- FOGLIATTO, F. S.; RIBEIRO, J. L. D.; WERNER, L.; LEMOS, F. O.; BRUM, M. P. Previsão de demanda de energia elétrica – método e aplicação. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 25., 2005, Porto Alegre. **Anais** [...]. Porto Alegre, 2005. p. 3100-3107.
- IRFFI, G.; CASTELAR, I.; SIQUEIRA, M. L.; LINHARES, F. C. Previsão de demanda por energia elétrica para classes de consumo na região nordeste, usando OLS dinâmico e mudança de regime. **Economia Aplicada**, v. 13, n.1 p. 69-98, jan/mar 2009.
- GRANGER, C. W. J.; RAMANATHAN, R. Improved Methods of Forecasting. **Journal of Forecasting**, v. 3, n. 2, p.197-204, 1984.
- MAKRIDAKIS, S.; WINKLER, R. L. Averages of Forecasts: Some Empirical Results. **Management Science**, v. 29, n. 9, p. 987-996, 1983.
- MOREIRA, M. O.; SALGADO, R. M.; OHISHI, T.; FERREIRA, E. B. Modelo baseado em combinação de previsores para previsão de séries temporais de carga elétrica. **Revista GEINTEC**, v. 1, n. 2, p. 20-31, 2011.
- MORRETIN, P. A.; TOLOI, C. M. de C. **Previsão de Séries Temporais**. 2. ed. São Paulo: Editora Edgard Blucher, 2006.

NASCIMENTO, L. **Orçamento do Luz para Todos em 2019 será de R\$ 1,07 bilhão**. Agência Brasil de Brasília. Publicado em 14 set. 2018. Disponível em: <http://agenciabrasil.ebc.com.br/economia/noticia/2018-09/orcamento-do-luz-para-todos-em-2019-sera-de-r-107-bilhao> Acesso em: 12 ago. 2019.

NEWBOLD, P.; GRANGER, C. W. J. Experience with Forecasting Univariate Time Series and Combination of Forecasts. **Journal Royal Statistical Society**, series A, v. 137, n. 2, p. 131-165, 1974.

PELLEGRINI, F.; FOGLIATTO, F. Estudo Comparativo entre os Modelos de Winters e de Box-Jenkins para Previsão de Demanda Sazonal. **Produto & Produção**. v. 4, n. especial, p. 72-85, abril 2000.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. R. Foundation for Statistical Computing, Vienna. 2018. Disponível em: <https://www.R-project.org>

REIS, L. B. ; CUNHA, E.C.N. **Energia elétrica e sustentabilidade**: Aspectos tecnológicos, socioambientais e legais. 2. ed. Ed. Manole, 2014.

SCHMIDT, C. A. J.; LIMA, M. A. M. A demanda por energia elétrica no Brasil. **Revista Brasileira de Economia**, v. 58, n. 1, p. 67-98, jan/mar 2004.

SIQUEIRA, M. L.; CORDEIRO Jr., H. H.; CASTELAR, I. A demanda por energia elétrica no nordeste brasileiro após o racionamento de 2001-2002: previsões de longo prazo. **Pesquisa e Planejamento Econômico**, v. 36, n. 1, p. 137-178, abril 2006.

TIDRE, P. V.; BIASE, N. G.; SILVA, M. I. S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. **Revista Eletrônica de Matemáticas e Estatística em Foco**, v. 1, n. 1, p. 57 - 66, jun. 2013.

YOHAI, V. J. High breakdown point and high efficiency robust estimates for regression. **Annals of Statistics**, v. 15, p. 642-656, 1987.