



PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA RESIDENCIAL NO ABASTECIMENTO DE VEÍCULOS ELÉTRICOS: UMA MODELAGEM ECONOMETRICA

PREDICTION OF RESIDENTIAL ELECTRICITY CONSUMPTION IN THE SUPPLY OF ELECTRIC VEHICLES: AN ECONOMETRIC MODELING

ÁREA TEMÁTICA: ADMINISTRAÇÃO DA INFORMAÇÃO

Émerson Felipe Neves dos Santos, Universidade Federal de Santa Catarina, Brasil,
emersonfelipe1717@gmail.com

Mauricio Uriona Maldonado, Universidade Federal de Santa Catarina, Brasil, mauricio.uriona@gmail.com

Caroline Rodrigues Vaz, Universidade Federal de Santa Catarina, Brasil, caroline.vaz@ufsc.br

Resumo

No Brasil, o setor elétrico está inserido em projetos de infraestrutura e no desenvolvimento global. Nesse sentido, é importante haver uma elaboração de um planejamento satisfatório para expansão da capacidade de produção e de estrutura para geração, transmissão e distribuição de energia. Portanto, o presente artigo tem o objetivo de o objetivo principal é a construção de um modelo econométrico para previsão do consumo de energia elétrica residencial no Brasil com a inserção da frota de veículos elétricos na rede, a partir de variáveis explicativas econômicas empregando a regressão linear múltipla com método. Os resultados mostraram que o modelo desenvolvido, através de algumas variáveis preditoras, como consumo de energia elétrica na rede, frota de veículos elétrico, população total do Brasil e PIB per capita, pode colaborar para construção de modelos mais robustos para a previsão de demanda de energia elétrica no setor residencial a partir da inserção dos veículos elétricos.

Palavras-chave: Energia Elétrica; Veículos Elétricos; Setor Residencial; Regressão Linear Múltipla.

Abstract

In Brazil, the electricity sector is inserted in infrastructure projects and in global development. In this sense, it is important to develop a satisfactory plan for expanding production capacity and the structure for generation, transmission and distribution of energy. Therefore, the present article has the objective of building an econometric model for forecasting the consumption of residential electricity in Brazil with the inclusion of the fleet of electric vehicles in the network, based on economic explanatory variables using linear regression multiple with method. The results showed that the model developed, through some predictive variables, such as consumption of electricity in the network, fleet of electric vehicles, total population of Brazil and GDP per capita, can contribute to the construction of more robust models for forecasting demand for electricity. electricity in the residential sector from the insertion of electric vehicles.

Keywords: *Electricity; Electric Vehicles; Residential Sector; Multiple Linear Regression.*

1. INTRODUÇÃO

Considerada como o maior problema ambiental que o planeta enfrenta, a mudança climática muito é afetada pelo setor elétrico, em que, 40% da energia primária consumida e 42% do dióxido de carbono gerado no setor de energia em países da OCDE são provenientes do setor elétrico (Ćorović et al., 2022). Por isso que incentivar o desenvolvimento de produção e consumo de energia aumenta a segurança energética e todos os países devem participar ativamente da cooperação internacional no setor de energético para garantir essa segurança em todos os países do mundo, em que os mercados de energia elétrica, geralmente regulados sofreram mudanças significativas devido aos incentivos ambientais e econômicos, portanto, a construção de uma estrutura de mercado facilita modelos mais competitivos e menos regulados e tem sido uma tendência mundial para esse setor. (Klopčič et al., 2022). Tendo em vista o impacto potencial que a energia elétrica tem na desigualdade, no desenvolvimento humano e na qualidade de vida e que tem causado vários estudos empíricos, e principalmente que o consumo de eletricidade se correlaciona positivamente com o índice de desenvolvimento humano e o PIB para 120 países (Sarkodie & Adams, 2020).

E, nos últimos anos, preocupações com o meio ambiente, aumento da inserção de veículos elétricos, altas taxas de demandas de carga, medição inteligente e necessidades de armazenamento de energia, além de uma rede elétrica mais eficiente e confiável, exigiram uma rede elétrica mais complexa e inteligente dentro do mercado de eletricidade (Azad & Ghotbi, 2017). No Brasil, o setor elétrico está inserido em projetos de infraestrutura e no desenvolvimento global, e como forma de acompanhar essa dinâmica é visualizar tanto a demanda por energia no país quanto o PIB (Maestri & Andrade, 2022). O seu fornecimento interno de energia elétrica no Brasil teve uma crescente de 170,36% do ano de 2002 (382,29 TWh) para o ano de 2019 (651,28 TWh) e 168,95% para o ano de 2020 (645,91 TWh) (Velasquez et al., 2022).

Por isso, é importante haver uma elaboração de um planejamento satisfatório para expansão da capacidade de produção e de estrutura para geração, transmissão e distribuição de energia (Caldas & Santos, 2012). Sendo essa uma abordagem salutar para a elaboração deste estudo, o objetivo principal é a construção de um modelo econométrico para previsão do consumo de energia elétrica residencial com a inserção da frota de veículos elétricos na rede, a partir de variáveis explicativas econômicas, tendo em vista que a política energética brasileira prevê um crescimento das fontes de energia na oferta de energia doméstica, na qual, a participação já ultrapassa 40% e suas projeções indicam que a participação chegará a quase 50% até 2030 (Lassio et al., 2021). E, tendo em vista o aumento na adoção de veículos elétricos no mundo, a adoção de carregamento doméstico trás potenciais benefícios (redução na emissão de gás carbônico, e benefícios para auxiliar nas operações da rede elétrica) e garantem subsídios para os veículos elétricos e seus carregadores domésticos, mas também avaliar os impactos dos veículos elétricos na rede elétrica é fundamental para o planejamento de capacidade e gerenciamento da rede (Qiu et al., 2022).

O artigo é dividido em seis seções. A primeira, Introdução, na qual foi abordado o contexto que o estudo está embasado e suas justificativas e objetivos da pesquisa. Na segunda seção, mostra os fatos detalhadamente sobre o consumo de energia elétrica brasileira no setor residencial e sobre o carregamento doméstico de veículos elétricos, bem como a metodologia de regressão linear múltipla utilizada, a partir da revisão de autores da temática. Na terceira seção, o estudo aborda sobre a metodologia aplicada para realização da análise proposta. Na análise dos resultados obtidos está na quarta seção. Em seguida, na quinta posição, são apresentadas as

principais conclusões do trabalho. E por fim, na última seção está o referencial bibliográfico utilizado na pesquisa.

2. REFERENCIAL TEÓRICO

2.1 CONSUMO DE ENERGIA ELÉTRICA NO SETOR RESIDENCIAL NO BRASIL

O setor elétrico brasileiro passou por várias e significativas mudanças nas últimas décadas e o consumo de energia, entre 2009 e 2018, passou de 384.306 Gwh para 474.820 Gwh em uma taxa de crescimento de 23,6% e o setor residencial, que teve aproximadamente, uma contribuição de 25,4% no consumo total de energia elétrica do país apresentou também um crescimento ainda maior no período, de 36,%, crescendo em média 3,8% (Martins et al., 2021).

E, o serviço público de transmissão de energia elétrica do sistema Interligado Nacional (SIN) compreende uma das mais complexas e mais externas redes elétricas do mundo, com aproximadamente 140 mil quilômetros de extensão (EPE, 2019). No Brasil, o mercado de energia elétrica foi desenhado considerando o enorme sistema integrado de energia que é responsável por entregar mais de 99% do consumo de energia elétrica do país; a oferta hídrica, que fornece cerca de 70% do consumo de eletricidade dependendo das condições hidrológicas do ano; e a demanda de eletricidade que aumenta cerca de 3% ao ano (Munhoz, 2021). No que diz respeito a energia elétrica no setor residencial, em 1990 o consumo era de 48.666 Giga x Watts x hora (GWh), e em 2012 a quantidade consumida já era de 117.646 GWh, representando uma variação relativa de 142%, um aumento consideravelmente superior ao crescimento populacional de 34% nesse mesmo período (Oliveira & Rebelatto, 2015).

No entanto, a pandemia alterou ainda mais estas tendências, diminuindo o consumo na indústria, transportes e edifícios, com todas as medidas de contingência de restrição de mobilidade e convívios, conseqüentemente, as atividades se transportaram para as residências, alterando os padrões de consumo doméstico e que, provavelmente, continuarão integrados nesses novos estilos de vida, como o teletrabalho, estudos online, entre outros (González-Torres et al., 2022).

Com isso, o setor residencial durante o século atual ganhou ainda mais importância e precisa de mais análises específicas de sua influência no setor energético. Pois, projeta-se um crescimento considerável ao longo dos próximos anos em todos os setores, principalmente no residencial, e que, em 2018 a população do Brasil atingiu o nível de 208,4 milhões de pessoas e o número estimado de domicílios deverá aumentar em cerca de 40 milhões em 2050 em relação a 2012 (Dranka & Ferreira, 2020).

2.2 CARREGAMENTO DOMÉSTICO DE VEÍCULOS ELÉTRICOS

Os veículos elétricos à bateria possibilitam potenciais de reduzir as importações de petróleo e as emissões de gases de efeito estufa, porém, têm um alcance com um certo limite e precisam de um grande tempo de recarga para reabastecimento, se comparar com o veículo convencional (Neubauer & Wood, 2014). E, observar as variações nas quantidades de veículos elétricos no uso da eletricidade nas residências é interessante. Pois o impacto na rede a partir da inserção de veículos elétricos pode haver variabilidade do uso de eletricidade para as residências, com variações sazonais no uso de eletrodomésticos, iluminação, aquecimento, entre outros (Munkhammar et al., 2015).

A adoção de veículos elétricos em todo o mundo aumentou consideravelmente nos últimos anos, nos Estados Unidos, o número projetado de veículos elétricos nas estradas chegará a 18,7 milhões, compartilhando em torno de 7% de todos os carros, caminhões leves em 2030 e sua ampla adoção pode ter impacto significativo na rede elétrica e criará pressão na infraestrutura

da rede elétrica e influenciará na expansão da rede e conseqüentemente, um aumento na poluição ambiental. (Qiu et al., 2022). Esses impactos podem ser vistos durante a transmissão, distribuição e geração de energia elétrica, caso ocorra onde já existe um déficit de capacidade de rede, uma difusão em larga escala pode ocasionar em sérios problemas de rede, principalmente se coincidir com a alta demanda de eletricidade de outras cargas domésticas (Hartvigsson et al., 2022).

Então, o papel dos veículos elétricos será crucial para os sistemas de energia residencial para os próximos anos, muito por sua capacidade ecológica e de mitigar o excesso de energia das fontes, pois suas estratégias e tecnologias eficazes são necessárias para enfrentar os desafios que cada vez mais crescem (Sadeghian et al., 2022).

2.3 REGRESSÃO LINEAR MÚLTIPLA

A regressão linear múltipla é uma abordagem mais generalizada que o modelo de regressão linear simples, que fornece possibilidades para entender os efeitos mútuos da variável dependente em relação as variáveis independentes, ela é muito aplicada para situações ocasionadas por pesquisadores em várias áreas como, economia, finanças, ciências comportamentais, administração de empresas, entre outras (Flores-Sosa et al., 2022). Os modelos de regressão são empíricos ou funções de aproximação que se envolvem em situações ocasionadas por diversas variáveis independentes e quando o vínculo funcional real entre as variáveis dependentes e independentes é desconhecido, constroem uma relação entre elas, através de formas complexas das variáveis independentes para representar, de forma satisfatória e correta, as funções desconhecidas (Ajona et al., 2022).

A regressão linear múltipla pode ser vista como uma extensão da regressão linear simples para situações em que existem vários previsores, porém a equação deverá mostrar um intercepto (constante b_0), um coeficiente de regressão para cada variável previsora (b_1, b_2, \dots) e diferença entre o modelo e os valores reais (e_i) (Chagas, 2017).

$$Y = b_0 + (b_1 * x_1) + (b_2 * x_2) + \dots + (b_n * x_n) + e_i$$

Onde:

Y : variável dependente

b_0 : intercepto

b_1, \dots, b_n : coeficiente de regressão

X_1, \dots, X_n : variáveis explicativas

e_i : diferença entre modelo e os valores reais

Também, a regressão linear múltipla pode conseguir fornecer previsões instantâneas da variável dependente, organizando uma linha de um ajuste melhor aos dados para a observação, reduzindo a necessidade de análises repetidas (Kong et al., 2019).

E, como forma de garantia da aderência do modelo de regressão é preciso assegurar que todas as suposições a seguir sejam atendidas a partir da realização de testes estatísticos nos dados: linearidade dos parâmetros, covariância nula entre os resíduos e suas variáveis, valor médio do resíduo igual a zero, homoscedasticidade, erros independentes, número de observações maior que o número estimado, variância não-nula das variáveis independentes, erros geralmente distribuídos, ausência de viés de especificação (Chagas, 2017).

3. METODOLOGIA

A metodologia do estudo tem como objetivo apresentar como foi feita a seleção de dados, como foi construída as tabelas de resultados e quais critérios foram adotados para alcançar o objetivo geral do trabalho. O estudo consiste na aplicação do modelo de regressão linear múltipla, com

o consumo de energia elétrica na rede como variável dependente, e sendo explicada por uma série de variáveis econômicas e sociais.

Primeiro, foi definido o período dos dados a serem estudados, que foram de 2012 a 2021, resultando 10 observações anuais, em condições das restrições de disponibilidade e frequência das medições nas bases de dados disponíveis. Então, a coleta de dados de consumo de energia elétrica na rede em MWh foi encontrada através da Câmara de Comercialização de Energia Elétrica (CCEE, 2022)..Além disso, foi coletada a frota de veículos elétricos do País através dos dados da Associação Brasileira do Veículo Elétrico (ABVE, 2022). Também foram consideradas as séries histórias de população total através dos dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2022). E PIB per capita a partir dos dados da *The World Bank* (The world bank, 2022). A tabela 1 mostra os dados coletados na pesquisa.

ANO	CONSUMO DE ENERGIA ELÉTRICA NA REDE (MWH)	FROTA DE VEÍCULOS ELÉTRICOS	POPULAÇÃO TOTAL BRASILEIRA	PIB PER CAPITA (US\$)
2012	448.126.391	117	198.314.934	9056,6
2013	463.142.494	491	200.004.188	9247,6
2014	474.823.454	855	2017.175.41	9215
2015	465.987.156	846	203.475.683	8814
2016	462.068.775	1091	205.156.587	8455,3
2017	467.474.733	3296	206.804.741	8498,3
2018	475.764.500	3970	208.494.900	8582,3
2019	482.515.814	11858	210.147.125	8622,1
2020	476.568.909	19745	211.755.692	8228,8
2021	502.165.240	34990	213.317.639	8551,2

Tabela 1 – Série história das variáveis consumo de energia elétrica, frota de veículos elétricos, população total brasileira e PIB per capita

Para os procedimentos econométricos da regressão linear múltipla utilizou-se o *Software IBM SPSS Statistic*, que é o líder no mercado para estudos desse tipo. Essa ferramenta possibilita uma quantidade ampla de relatórios, análises e gráficos, como teste de hipóteses (IBM, 2022). E, para análise do modelo, foi empregado o método *Stepwise*, para a seleção correta das variáveis que demonstram como o modelo funciona e que, as variáveis que se determinarem com pouca influência à variável dependente, são excluídas da solução final (Ferreira, 2013). Com isso, a partir dos outputs do software, foram feitos vários testes estatísticos para verificação do modelo, como suas estatísticas descritivas, suas correlações, normalidade, multicolinearidade e autocorrelação dos resíduos.

4. RESULTADOS E DISCUSSÕES

Foram A partir da inserção dos dados de frota de veículos elétricos, população total e PIB per capita no software, pôde-se observar, de início, as estatísticas descritivas das variáveis, como, média, desvio padrão e Número.

	Média	Desvio padrão	N
CONSUMOENERGIA	471863746,6	14403019,99	10
FrotaVeículosElétrico	7725,9000	11486,21536	10
PopulaçãoTotal	205918903,0	5067476,047	10
PIB	8727,1200	343,60005	10

Figura 1 – Estatísticas descritivas

Em seguida, a tabela de correlações foi obtida através do teste Correlação de Pearson, já que os dados do consumo de energia e da frota de veículos elétricos são considerados paramétricos. Nesse teste, foi possível entender se as variáveis analisadas possuem correlação significativa e a força dessa correlação, conforme mostrado na figura 2.

	CONSUMOENERGIA	FrotaVeículos Elétrico	PopulaçãoTotal	PIB
Correlação de Pearson				
CONSUMOENERGIA	1,000	,846	,829	-,384
FrotaVeículosElétrico	,846	1,000	,815	-,509
PopulaçãoTotal	,829	,815	1,000	-,821
PIB	-,384	-,509	-,821	1,000
Sig. (1 extremidade)				
CONSUMOENERGIA	.	,001	,002	,136
FrotaVeículosElétrico	,001	.	,002	,066
PopulaçãoTotal	,002	,002	.	,002
PIB	,136	,066	,002	.
N				
CONSUMOENERGIA	10	10	10	10
FrotaVeículosElétrico	10	10	10	10
PopulaçãoTotal	10	10	10	10
PIB	10	10	10	10

Figura 2 – Correlações

De início, através do método *Stepwise* selecionado no SPSS, foram encontradas as variáveis frota de veículos elétricos, população total do país e PIB per capita, como os melhores fatores para explicar o consumo de energia elétrica a partir da frota de veículos elétricos. Os parâmetros de cada uma destas variáveis são encontrados na ferramenta, permitindo uma definição da equação do modelo, como a seguinte:

$$Y = -697101640,421 + 121,544FVE + 4,142PT + 36116,424PIB$$

Onde:

FVE: Frota de Veículos Elétricos;

PT: População Total

PIB: PIB per capita;

Com isso, o *software* fornece as abordagens de cada uma das variáveis e permite a análise da qualidade do modelo a partir do valor do R² ajustado, sendo esse resultado com uma aproximação com os dados reais equivalente em 93,8%, esse valor indica o quanto o modelo consegue explicar os valores observados, como mostra a figura a seguir:

Modelo	R	R quadrado	R quadrado ajustado	Erro padrão da estimativa	Alteração de R quadrado
					,958
1	,979 ^a	,958	,938	3599300,634	,958

Figura 3 – R² ajustado

Na tabela ANOVA são analisados alguns resultados que mostram que não há interferências significativas no estudo, em que, todos os pressupostos abordados antes da regressão em que houve dúvidas foram, agora, confirmados. A figura 4 a seguir apresentam os resultados.

ANOVA^a

Modelo		Soma dos Quadrados	df	Quadrado Médio	F	Sig.
1	Regressão	1,789E+15	3	5,964E+14	46,039	,000 ^b
	Resíduos	7,773E+13	6	1,295E+13		
	Total	1,867E+15	9			

a. Variável dependente: CONSUMOENERGIA

b. Preditores: (Constante), PIB, FrotaVeículosElétrico, PopulaçãoTotal

Figura 4 – Resultado do valor *F* do modelo

O valor “Sig” é menor que 0,05 o que indica que o pressuposto de tem um ajuste que é diferente do ajuste do modelo sem nenhum previsor, ou seja, incluir esses previsores melhorou a qualidade desse modelo. Portanto, a linearidade das variáveis não foi ferido e pode ser dado continuidade na regressão linear.

A figura 5, mostrada pela regressão linear, apresenta o valor da constante e dos coeficientes angulares de cada variável independente.

Coefficientes^a

Modelo		Coeficientes não padronizados		Coeficientes padronizados	t	Sig.
		B	Modelo padrão	Beta		
1	(Constante)	-697101640,4	197125395,8		-3,536	,012
	FrotaVeículosElétrico	121,544	206,419	,097	,589	,577
	PopulaçãoTotal	4,142	,706	1,457	5,869	,001
	PIB	36116,424	7000,835	,862	5,159	,002

a. Variável dependente: CONSUMOENERGIA

Figura 5 – Coeficiente e o teste *t*

Com os valores apresentados na coluna Beta, nota-se que a variável Frota de Veículos Elétrico explica 9,7%, a variável População Total explica 145,7% e o PIB explica 86,2% da variável dependente em análise. E o teste *t*, tem o objetivo de analisar a linearidade dos parâmetros e relevância de cada variável para o modelo, a partir do seu coeficiente beta calculado. Para isso, a hipótese é considerada nula de que esses coeficientes, das variáveis, são iguais a zero. Porém para o teste *t*, é necessário que os valores do “Sig” sejam menores que 0,05 e, na figura 3, os valores da População total e do PIB são menores que 0,05 mostrando relevância para o modelo proposto.

A seguir, o histograma é importante para verificar se o modelo atende ao pré-requisito da normalidade, e foi utilizado o teste de *Kolmogorov-Smirnov* que analisa a maior diferença absoluta entre a função de distribuição acumulada assumida para os dados, no caso a normal, e a função de distribuição empírica dos dados na distribuição dos dados a partir dos dois gráficos

abaixo (Ferreira, 2013). Ambos comparam as informações do modelo com a distribuição normal de probabilidade, sendo observadas maiores variações em alguns pontos do histograma.

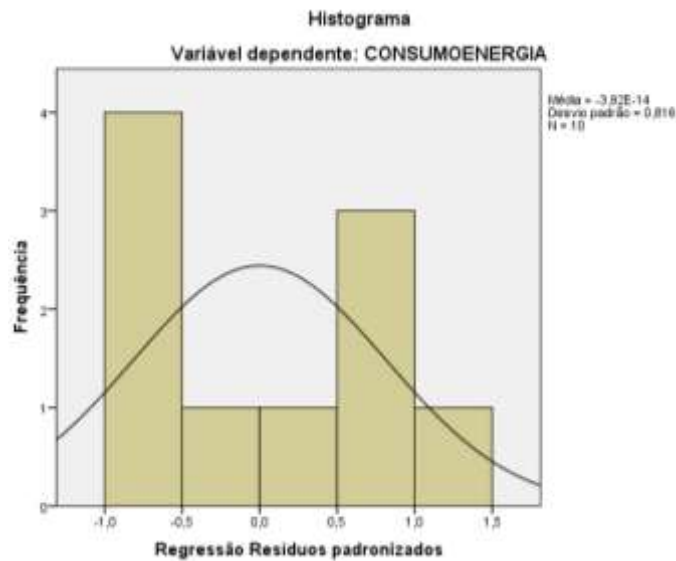


Figura 6 – Histograma do modelo

Gráfico P-P normal de regressão Resíduos padronizados

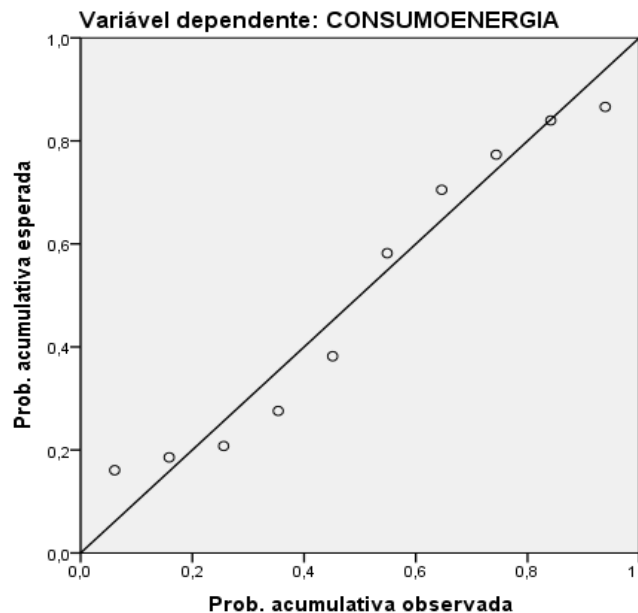


Figura 7 – Gráfico de distribuição normal

Para que haja uma verificação da multicolinearidade é feito um teste VIF (*Variance Inflation Factor*), a literatura mostra que o VIF é um indicativo de problema se for maior que 10. Por isso, como o VIF é uma saída direto do SPSS, é importante analisar se cada variável é menor que 10 para assim conseguir ser verificada na multicolinearidade. No início, esse termo significava a existência de uma interação linear completa ou exata entre todas, ou quase todas, variáveis explanatórias do modelo de regressão (Gujarati, 2011). A figura 6 a seguir mostra as saídas VIF do SPSS.

MODELO		VIF
1	(Constante)	
	FrotaVeículosElétrico	3,905
	PopulaçãoTotal	8,885
	PIB	4,020

Tabela 2 – Valores de VIF de cada variável

Portanto, conforme a tabela 1, os valores de VIF de todas as variáveis estão menores que 10, o modelo passa no teste de multicolinearidade.

Na figura 8, que mostra as estatísticas de mudança, o *Durbin Watson* é o pré-requisito que verifica se os resíduos (diferença entre valor previsto e valor observado) são independentes e que para estarem nos valores aceitáveis tem que ser entre 1,5 e 2,5.

Estatísticas de mudança					Durbin-Watson
Alteração de R quadrado	Alteração F	df1	df2	Sig. Alteração F	
,958	46,039	3	6	,000	1,194

Figura 8 – Estatísticas de mudança

Portanto, o modelo não passa no teste de verificação de ausência de autocorrelação. E, segundo Gujarati e Porter (2011), não é um resultado surpreendente, pois em grande parte das regressões em séries temporais, como é o caso analisado nesta pesquisa, apresentam autocorrelação.

5. CONSIDERAÇÕES FINAIS

Com os resultados previamente discutidos é possível concluir que o modelo de regressão linear múltipla para a previsão do consumo de energia elétrica residencial com a inserção da frota de veículos elétricos na rede, a partir de variáveis “consumo de energia elétrica na rede, frota de veículos elétrico, população total do Brasil até o ano 2021, PIB per capita”, pode colaborar à prospecção do consumo de energia elétrica no setor residencial no Brasil.

Outro fator de relevância que garante os efeitos positivos deste estudo, é que o modelo encontrado foi aprovado em 5 dos 6 testes estatísticos pelos quais foi submetido. Porém, o resultado do teste de autocorrelação do *Durbin Watson*, (e_i =diferença entre modelo e os valores reais) já era esperado, uma vez que a base dos dados utilizada é constituída por séries temporais, em que apresentam problemas de inércia, falta de variáveis e alterações relevantes quando utilizadas na realização da regressão.

Portanto, o estudo possibilita uma ferramenta com condições de analisar projeções futuras sem grandes disposições para análise, dado os alguns pontos para melhorias identificados. Algumas é necessários alguns olhares para variáveis que podem impactar no consumo energético com a inserção da frota elétrica na rede doméstica e, conseqüentemente, na demanda, na distribuição e na transmissão de energia elétrica em residências. Então, fatores a serem considerados nas tomadas de decisões em relação à capacidade do Brasil na evolução do setor de energia e que possa atender as necessidades que as residências precisam.

REFERÊNCIAS

- ABVE. (2022). *Eletrificados batem todas as previsões em 2021*. <https://www.abve.org.br/eletrificados-batem-todas-as-previsoes-em-2021/>
- Ajona, M., Vasanthi, P., & Vijayan, D. S. (2022). Application of multiple linear and polynomial regression in the sustainable biodegradation process of crude oil. *Sustainable Energy Technologies and Assessments*, *54*, 102797. <https://doi.org/10.1016/J.SETA.2022.102797>
- Azad, S., & Ghotbi, E. (2017). A game equilibrium model of a retail electricity market with high penetration of small and mid-size renewable suppliers. *The Electricity Journal*, *30*(5), 22–29. <https://doi.org/10.1016/J.TEJ.2017.04.017>
- Caldas, A. A. S. e, & Santos, E. F. N. (2012). Previsão de consumo de energia elétrica em petrolina - pe. *Revista Brasileira de Energia*, *18*, 129–141.
- CCEE. (2022). *Consumo de energia elétrica cresce 4,1% em 2021*. 19-01-2022. <https://www.ccee.org.br/pt/web/guest/-/consumo-de-energia-eletrica-cresce-4-1-em-2021-aponta-ccee>
- Chagas, E. F. B. (2017). Módulo 4 -CURSO DE ESTATÍSTICA APLICADA PARA INICIANTES. *Fundepe, Marília, September 2016*. <https://doi.org/10.13140/RG.2.2.21763.09765>
- Ćorović, N., Urošević, B. G., & Katić, N. (2022). Decarbonization: Challenges for the electricity market development — Serbian market case. *Energy Reports*, *8*, 2200–2209. <https://doi.org/10.1016/J.EGYR.2022.01.054>
- Dranka, G. G., & Ferreira, P. (2020). Load flexibility potential across residential, commercial and industrial sectors in Brazil. *Energy*, *201*, 117483. <https://doi.org/10.1016/J.ENERGY.2020.117483>
- EPE. (2019). *Balanco Energético Nacional 2019*. <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2019>
- Ferreira, M. C. C. dos S. (2013). *Modelos de regressão: uma aplicação em medicina dentária*. 143.
- Flores-Sosa, M., Avilés-Ochoa, E., Merigó, J. M., & Kacprzyk, J. (2022). The OWA operator in multiple linear regression. *Applied Soft Computing*, *124*, 108985. <https://doi.org/10.1016/J.ASOC.2022.108985>
- González-Torres, M., Pérez-Lombard, L., Coronel, J. F., Maestre, I. R., & Paolo, B. (2022). Activity and efficiency trends for the residential sector across countries. *Energy and Buildings*, *273*, 112428. <https://doi.org/10.1016/J.ENBUILD.2022.112428>
- Gujarati, D. N. . D. C. P. (2011). *Econometria Básica - 5 ed* (AMGH (ed.); 5th ed.).
- Hartvigsson, E., Taljegard, M., Odenberger, M., & Chen, P. (2022). A large-scale high-resolution geographic analysis of impacts of electric vehicle charging on low-voltage grids. *Energy*, *261*, 125180. <https://doi.org/10.1016/J.ENERGY.2022.125180>
- IBGE. (2022). *Instituto Brasileiro de Geografia e Estatística*. <https://www.ibge.gov.br/>
- Klopčič, A. L., Hojnik, J., & Bojnec, Š. (2022). What is the state of development of retail electricity markets in the EU? *The Electricity Journal*, *35*(3), 107092. <https://doi.org/10.1016/J.TEJ.2022.107092>
- Kong, Y. S., Abdullah, S., Schramm, D., Omar, M. Z., & Haris, S. M. (2019). Development of multiple linear regression-based models for fatigue life evaluation of automotive coil springs. *Mechanical Systems and Signal Processing*, *118*, 675–695. <https://doi.org/10.1016/J.YMSSP.2018.09.007>
- Lassio, J. G., Magrini, A., & Castelo Branco, D. (2021). Life cycle-based sustainability indicators for electricity generation: A systematic review and a proposal for assessments in Brazil. *Journal of Cleaner Production*, *311*, 127568. <https://doi.org/10.1016/J.JCLEPRO.2021.127568>

- Maestri, C. O. N. M., & Andrade, M. E. M. C. (2022). Priorities for tariff compensation of distributed electricity generation in Brazil. *Utilities Policy*, *76*, 101374. <https://doi.org/10.1016/J.JUP.2022.101374>
- Martins, L. O. S., Amorim, I. R., Mendes, V. de A., Silva, M. S., Freires, F. G. M., Teles, E. O., & Torres, E. A. (2021). Price and income elasticities of residential electricity demand in Brazil and policy implications. *Utilities Policy*, *71*, 101250. <https://doi.org/10.1016/J.JUP.2021.101250>
- Munhoz, F. C. (2021). Two-settlement system for the Brazilian electricity market. *Energy Policy*, *152*, 112234. <https://doi.org/10.1016/J.ENPOL.2021.112234>
- Munkhammar, J., Widén, J., & Rydén, J. (2015). On a probability distribution model combining household power consumption, electric vehicle home-charging and photovoltaic power production. *Applied Energy*, *142*, 135–143. <https://doi.org/10.1016/J.APENERGY.2014.12.031>
- Neubauer, J., & Wood, E. (2014). The impact of range anxiety and home, workplace, and public charging infrastructure on simulated battery electric vehicle lifetime utility. *Journal of Power Sources*, *257*, 12–20. <https://doi.org/10.1016/J.JPOWSOUR.2014.01.075>
- Oliveira, M. H. D. F., & Rebelatto, D. A. D. N. (2015). The evaluation of electric energy consumption in the Brazilian residential sector: A technological improvement proposal in order to increase its efficiency. *Renewable and Sustainable Energy Reviews*, *49*, 836–844. <https://doi.org/10.1016/J.RSER.2015.04.069>
- Qiu, Y. L., Wang, Y. D., Iseki, H., Shen, X., Xing, B., & Zhang, H. (2022). Empirical grid impact of in-home electric vehicle charging differs from predictions. *Resource and Energy Economics*, *67*, 101275. <https://doi.org/10.1016/J.RESENEECO.2021.101275>
- Sadeghian, O., Oshnoei, A., Mohammadi-ivatloo, B., Vahidinasab, V., & Anvari-Moghaddam, A. (2022). A comprehensive review on electric vehicles smart charging: Solutions, strategies, technologies, and challenges. *Journal of Energy Storage*, *54*, 105241. <https://doi.org/10.1016/J.EST.2022.105241>
- Sarkodie, S. A., & Adams, S. (2020). Electricity access, human development index, governance and income inequality in Sub-Saharan Africa. *Energy Reports*, *6*, 455–466. <https://doi.org/10.1016/J.EGYR.2020.02.009>
- The world bank. (2022). *GDP per capita (constant 2015 US\$) - Brazil*. https://data.worldbank.org/indicator/NY.GDP.PCAP.KD?end=2021&locations=BR&name_desc=false&start=1996
- Velasquez, C. E., Zocatelli, M., Estanislau, F. B. G. L., & Castro, V. F. (2022). Analysis of time series models for Brazilian electricity demand forecasting. *Energy*, *247*, 123483. <https://doi.org/10.1016/J.ENERGY.2022.123483>