

DESEMPENHO DO EWMA APLICADO À PREVISÃO DE CONSUMO ENERGÉTICO DE UMA UNIVERSIDADE

Rafaela Aparecida Mendonça Marques (UNIFEI)

Aline Cristina Maciel (UNIFEI)

Antonio Fernando Branco Costa (UNIFEI)

Pedro Paulo Balestrassi (UNIFEI)



Modelos de previsão auxiliam na tomada de decisão e podem ser aplicados em diversos campos do conhecimento, inclusive na previsão de consumo energético. O monitoramento da performance do modelo é uma das etapas de previsão e ferramentas como as cartas de controle podem ser utilizadas nesse momento. Nesse sentido, o objetivo desse trabalho é avaliar a performance das cartas de controle da Média Móvel Ponderada Exponencialmente (EWMA) em identificar alterações nos erros de previsão gerados pelo modelo de Média Móvel Integrada Auto Regressiva (ARIMA). Para isso, os dados do consumo energético, pré-pandemia de COVID-19, de uma Universidade Federal brasileira foram utilizados para a criação de um modelo de previsão. Após isso, os erros de previsão foram monitorados através das cartas de controle EWMA e foi identificado o número de amostras necessário para que as cartas de controle identificassem a alteração nos erros devido à mudança no consumo energético durante a pandemia. Os resultados das cartas de controle EWMA foram comparados com o desempenho da carta de controle X de Shewhart. Baseado nos resultados dos dados de consumo energético, o gráfico X apresentou melhor desempenho que o EWMA, identificando um deslocamento nos erros de $\delta_E = -2,92$ após apenas uma amostra. Portanto, percebe-se a importância da combinação de ferramentas de previsão e de monitoramento para garantir a adequação do modelo selecionado à realidade dos dados.

Palavras-chave: ARIMA, Cartas de Controle, EWMA, Consumo Energético, COVID-19.

1. Introdução

Métodos de previsão preveem valores futuros baseados em dados de série temporal avaliando dados históricos e supondo padrões para tendências futuras (MATTA *et al.*, 2021). Nesse sentido, métodos de previsão são úteis para prever o comportamento de uma determinada variável de interesse ao longo do tempo. O método de médias móveis é um dos métodos mais simples e utilizados (MONTGOMERY; JENNINGS; KULAHCI, 2015). Porém, na literatura é possível encontrar estudos que utilizam modelos de previsão mais complexos, como de Média Móvel Integrada Auto Regressiva (ARIMA) e Redes Neurais (ANN) (ver por exemplo: (GUTERRES *et al.*, 2020; SAÚDE; GABRIEL; BALESTRASSI, 2020)).

As etapas de previsão podem ser divididas em definição do problema, coleta de dados, análise dos dados, seleção do modelo, validação do modelo, aplicação e monitoramento de performance (MONTGOMERY; JENNINGS; KULAHCI, 2015). Nesse sentido, as cartas de controle podem ser utilizadas para o monitoramento da performance do modelo de previsão. Alguns autores que já utilizaram essa ferramenta aplicada em séries temporais são Chen e Chen (2013), Hryniewicz, Kaczmarek-Majer e Opara (2019) e Harrou *et al.* (2021).

Dentre as cartas de controle, a carta da Média Móvel Ponderada Exponencialmente (EWMA) possui alta sensibilidade à pequenas mudanças no processo (MONTGOMERY, 2013; LAMPREIA *et al.*, 2018). Gráficos como o EWMA não só fornecem informações sobre o processo "sob controle", mas também sobre o desenvolvimento dinâmico do processo (KOVÁŘÍK; SARGA; KLÍMEK, 2015). Alguns autores que utilizaram a carta de controle EWMA nesse contexto foram Guterres *et al.* (2020), Fichera e Pagano (2009) e Kovářík, Sarga e Klímek (2015).

Devido à pandemia de COVID-19 muitos processos sofreram modificações e por isso, alguns modelos de previsão utilizados anteriormente já não se adequaram ao contexto pandêmico. Analisar as informações que envolvem a pandemia auxiliam a entender as mudanças que as organizações e instituições estão passando (ROBINSON *et al.*, 2021). Essas mudanças tornaram a importância do monitoramento dos modelos de previsão ainda maior, pois a identificação dessas alterações e avaliação dos modelos de previsão permite uma rápida resposta ao novo contexto, permitindo uma melhor adaptação dos processos.

Nesse sentido, o objetivo desse trabalho é avaliar o desempenho da carta de controle EWMA ao ser aplicada no monitoramento de erros de previsão obtidos através da utilização do modelo ARIMA. Para isso, dados do consumo de energia elétrica de uma universidade federal foram utilizados para construir um modelo de previsão que se adequa ao período pré-pandemia. Foi

verificado quantas amostras são necessárias para que o gráfico EWMA aponte o aumento nos erros de previsão após o início da pandemia. Este será comparado com o gráfico para observações individuais de Shewhart (X ou I).

Segundo Cihan (2022) investigações de mudanças no consumo de energia durante os bloqueios na pandemia COVID-19 tem crescido. Assim, a contribuição teórica deste trabalho foi evidenciada por meio de uma pesquisa realizada no dia 12/11/2021, utilizando a base de dados Scopus com as palavras chaves: ARIMA, Energy e EWMA, e foram obtidos apenas três artigos: Goudarzi et al. (2021), Barbeito et al. (2017) e Jurjevčič, Senegačnik e Kuštrin (2017). Porém, nenhum dos três trabalhos focou na análise do desempenho das cartas de controle.

O artigo está dividido conforme segue. Uma breve revisão sobre as cartas de controle será apresentada na sessão 2. E na sessão 3, há uma breve revisão sobre previsão. Na sessão 4 será apresentada o método utilizado nesse trabalho. Os resultados obtidos através dos dados do consumo de energia elétrica de uma Universidade Federal serão apresentados na sessão 5. E por fim, na sessão 6 serão apresentadas as considerações finais.

2. Cartas de controle

2.1. Alarmes falsos e poder do gráfico

Os desenvolvimentos matemáticos apresentados são baseados em Costa, Epprecht e Carpinetti (2004) e Montgomery (2013). Ao aplicar cartas de controle para monitoramento de processos, um teste de hipóteses, como o apresentado abaixo, é realizado.

$$H_0: O \text{ processo está em controle } (\mu = \mu_0 \text{ e/ou } \sigma = \sigma_0)$$

$$H_1: O \text{ processo fora de controle } (\mu \neq \mu_0 \text{ e/ou } \sigma \neq \sigma_0)$$

Onde μ_0 é o valor-alvo ou média em controle de uma variável aleatória X que está sendo monitorada e σ_0 é o desvio-padrão do processo quando não há causas especiais que possam alterar a variabilidade de X.

Nesse sentido, há a probabilidade de ocorrência de dois erros associados ao teste de hipóteses apresentado. O erro do tipo I diz respeito a considerar erroneamente que um processo está fora de controle, ou seja, o gráfico de controle dá um sinal (ponto fora dos limites de controle, por exemplo) sendo que o processo está em controle (H_0 é verdadeira). Nesse sentido as cartas de controle geram um alarme falso em uma determinada frequência e o número médio de amostras até um alarme falso (NMAF) é dado pela seguinte equação.

$$NMAF = \frac{1}{\alpha} \tag{1}$$

Onde α é a probabilidade de ocorrência do erro do tipo I.

Quando a média do processo é deslocada ou o desvio-padrão sofre alguma alteração devido a alguma causa especial entende-se que o processo está fora de controle. Geralmente o deslocamento da média é apresentado em unidades iguais ao desvio-padrão da variável X. Nesse sentido, o novo valor da média é dado por:

$$\mu_1 = \mu_0 + \delta\sigma_0 \quad (2)$$

Onde δ é o deslocamento em função do desvio-padrão do processo sob controle.

Sendo assim, o erro do tipo II diz respeito a considerar erroneamente que um processo está em controle. Ou seja, o gráfico de controle não dá um sinal quando o processo está fora de controle (H_1 é verdadeira). Com isso, há a probabilidade da ocorrência do erro do tipo II (β) e o poder do gráfico, que é a probabilidade da carta de controle identificar uma variação no processo, ou seja, rejeitar H_0 corretamente ($Pd = 1 - \beta$). Logo, o número médio de amostras (NMA) necessárias até que a carta de controle sinalize a presença de uma causa especial no processo, geralmente é usado para medir o desempenho de detecção de uma carta de controle (KNOTH, 2015; YANG; ARNOLD, 2016) e é dado por:

$$NMA = \frac{1}{Pd} \quad (3)$$

2.2. Carta de controle EWMA

A carta de controle de EWMA foi introduzida por Roberts (1959). Ela é uma alternativa para os gráficos de controle de Shewhart quando se deseja detectar pequenos deslocamentos na média de um determinado processo (COSTA; EPPRECHT; CARPINETTI, 2004). Isso porque a utilização de informações atuais e passadas para sua construção melhoram sua eficiência para detectar as mudanças pequenas/moderadas nos parâmetros do processo (NOOR; NOOR-UL-AMIN; ABBASI, 2021). Na literatura é possível encontrar diferentes modificações e aplicações da carta de controle de EWMA (ver por exemplo: (YANG; ARNOLD, 2016; MITRA; LEE; CHAKRABORTI, 2019; NOOR; NOOR-UL-AMIN; ABBASI, 2021)).

Os desenvolvimentos matemáticos a seguir são baseados em Roberts (1959), Costa, Epprecht e Carpinetti (2004) e Montgomery (2013).

No gráfico EWMA são plotados os valores da estatística Z_i .

$$Z_i = \lambda X_i + (1 - \lambda)Z_{i-1} \quad (4)$$

Na equação (4), $0 < \lambda \leq 1$ é uma constante e $Z_0 = \mu_0$ (média de X quando o processo está sob controle). Em alguns casos a média dos dados preliminares é utilizada como valor inicial ($Z_0 =$

\bar{X}_0). Quando $\lambda = 1$ a carta de controle de EWMA se reduz ao gráfico de Shewhart para observações individuais e portanto, os dados históricos passam a não ter influência nos cálculos. Já a variância de Z_i é obtida através da seguinte equação:

$$\sigma_{Z_i}^2 = \sigma^2 \left(\frac{\lambda}{2 - \lambda} \right) [1 - (1 - \lambda)^{2i}] \quad (5)$$

Onde σ^2 é a variância de X . Considerando σ_0 o desvio-padrão do processo sob controle, os limites de controle para k -sigma do gráfico EWMA são:

$$LSC = \mu_0 + k\sigma_0 \sqrt{\left(\frac{\lambda}{2 - \lambda} \right) [1 - (1 - \lambda)^{2i}]} \quad (6)$$

$$LM = \mu_0 \quad (7)$$

$$LIC = \mu_0 - k\sigma_0 \sqrt{\left(\frac{\lambda}{2 - \lambda} \right) [1 - (1 - \lambda)^{2i}]} \quad (8)$$

Vale salientar que à medida que i aumenta, a parte $[1 - (1 - \lambda)^{2i}]$ tende a 1. Logo, os limites de controle tendem a:

$$LSC = \mu_0 + k\sigma_0 \sqrt{\left(\frac{\lambda}{2 - \lambda} \right)} \quad (9)$$

$$LIC = \mu_0 - k\sigma_0 \sqrt{\left(\frac{\lambda}{2 - \lambda} \right)} \quad (10)$$

Porém, Montgomery (2013) recomenda a utilização dos limites de controle exatos para pequenos valores de i , pois isso aumentará o desempenho do gráfico em identificar um processo fora de controle logo após o início do monitoramento através do gráfico EWMA.

3. Previsão

3.1. ARIMA

Cihan (2022) e Montgomery, Jennings e Kulahci (2015) afirmam que o modelo ARIMA, também conhecido como modelo Box-Jenkins, é um modelo estatístico comumente utilizado para análise e previsão de séries temporais. Ao longo dos anos, eles foram aplicados com muito sucesso a muitos problemas em pesquisa e prática. No entanto, pode haver certas situações em que eles podem falhar em fornecer as respostas “certas”. Por exemplo, em modelos ARIMA, a previsão de observações futuras se baseia principalmente nos dados históricos e implicitamente assume-se que as condições em que os dados foram coletados permanecerão as mesmas no futuro. Em muitas situações, essa suposição pode não ser apropriada (MONTGOMERY;

JENNINGS; KULAHCI, 2015).

Segundo Fattah et al. (2018) o ARIMA é rotulado como um modelo (p, d, q), em que:

- p é o número de termos auto regressivos;
- d é o número de diferenças; e
- q é o número de médias móveis.

Nesse contexto, Montgomery, Jennings e Kulahci (2015) chamam de y_t um processo de Média Móvel Integrada Auto regressiva (ARIMA) de ordens p, d, e q - isto é, ARIMA (p, d, q) - se sua d-ésima diferença, denotada por $w_t = (1 - B)^d y_t$, produz um processo ARMA (p, q) estacionário. O termo integrado é usado uma vez que, para d = 1, por exemplo, pode-se escrever y_t como a soma (ou "integral") do processo w_t como:

$$\begin{aligned} y_t &= w_t + y_{t-1} \\ &= w_t + w_{t-1} + y_{t-2} \\ &= w_t + w_{t-1} + \dots + w_1 + y_0 \end{aligned} \quad (11)$$

Portanto, um ARIMA (p, d, q) pode ser escrito como:

$$\Phi(B)(1 - B)^d y_t = \delta + \Theta(B)\varepsilon_t \quad (12)$$

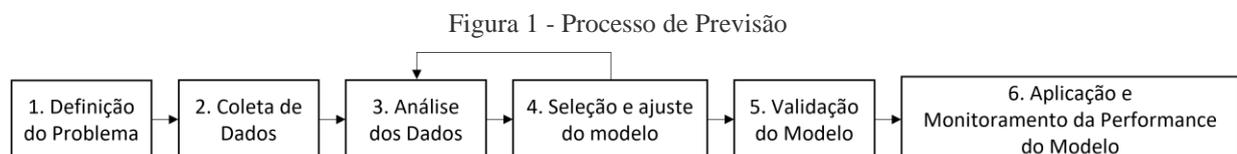
Onde ε_t é ruído branco.

Benvenuto et al. (2020) e Fattah et al. (2018) afirmam ainda, que o modelo ARIMA inclui o modelo Auto Regressivo (AR), modelo de Média Móvel (MA) e Modelo Sazonal de Média Móvel Integrada Auto Regressiva (SARIMA). Assim, Montgomery, Jennings e Kulahci (2015) afirmam que um modelo SARIMA mais geral de ordens (p, d, q) × (P, D, Q) com período s é:

$$\Phi^*(B^s)\Phi(B)(1 - B)^d(1 - B^s)^D y_t = \delta + \Theta^*(B^s)\Theta(B)\varepsilon_t \quad (13)$$

4. Método de pesquisa

Para a obtenção dos resultados presentes nesse artigo foram utilizados os passos propostos por Montgomery, Jennings e Kulahci (2015). A Figura 1 apresenta o fluxograma com o passo a passo utilizado para as previsões. Para as análises foram utilizados os softwares Microsoft Excel, Minitab, R e Fortran.

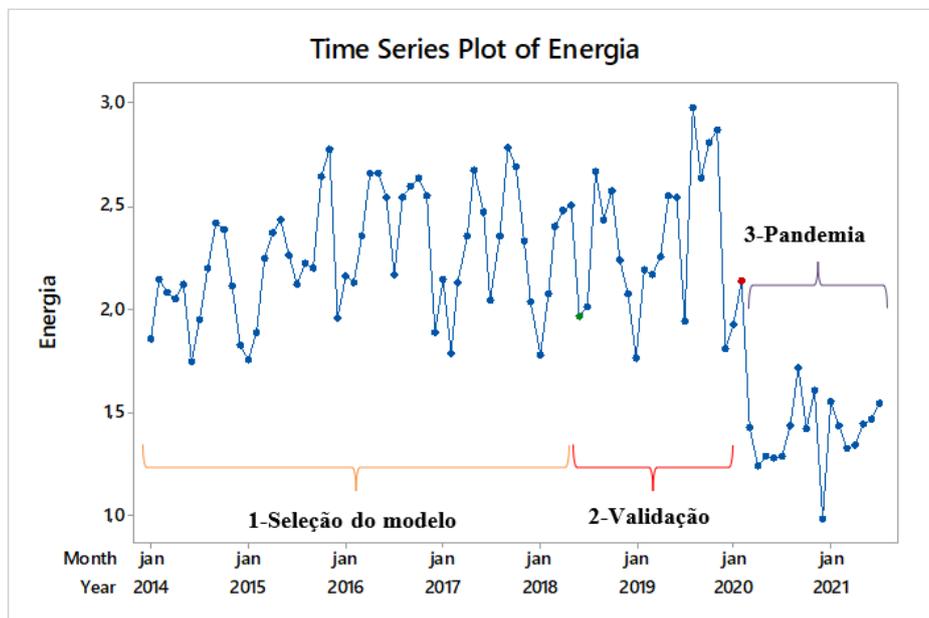


Fonte: Montgomery, Jennings e Kulahci (2015)

4.1. Coleta de dados

O consumo mensal de energia elétrica (em GW/h) de uma Universidade Federal, localizada no estado do Ceará, de janeiro de 2014 até julho de 2021 (totalizando 91 dados) foi analisado nesse estudo. Para isso, os dados foram divididos em 3 etapas. O modelo de previsão foi selecionado através dos primeiros 54 dados (janeiro 2014 a junho de 2018). Os próximos 20 dados (julho de 2018 a fevereiro de 2020) foram utilizados para a validação do modelo e obtenção dos parâmetros das cartas de controle, pois Montgomery, Jennings e Kulahci (2015) sugerem a utilização de pelo menos 20 ou 25 observações para essa etapa. Os últimos 17 dados (março de 2020 a julho de 2021), que representam o período de pandemia de COVID-19, foram utilizados para identificar o desempenho das cartas de controle em apontar mudanças que indicam que o modelo de previsão já não representa bem os dados. A Figura 2 apresenta o gráfico de séries temporais dos dados estudados e as divisões utilizadas.

Figura 2 – Série temporal dos dados analisados



Fonte: Autores

4.2. Análise dos dados

Para a análise dos dados foram utilizados os gráficos de sazonalidade com o objetivo de identificar possíveis padrões na série. Além disso, o gráfico da série temporal também foi analisado (Figura 2). O teste de Anderson-Darling foi utilizado para verificação de normalidade dos dados.

4.3. Seleção e ajuste do modelo

Para a seleção do modelo, considerando as 54 primeiras observações, foi utilizada a função

“auto.arima” presente no software R. Com o modelo obtido, os resíduos foram exportados e analisados através dos indicadores de Erro de Previsão Percentual Absoluto Médio (MAPE), Erro Quadrático Médio (MSE) e Erro médio Absoluto (MAE), através dos gráficos ACF e PACF, Teste Ljung-Box e do Teste de Normalidade de Anderson Darling.

4.4. Validação

Após a etapa de seleção e ajuste do modelo, 37 previsões foram geradas e exportadas. Para a validação, 20 dessas previsões foram comparadas com os valores reais da etapa de validação (conforme Figura 2). Os erros de previsão foram analisados através dos indicadores MAPE, MSE e MAE, dos gráficos ACF e PACF e do Teste de Normalidade de Anderson Darling. Além disso, a média e o desvio-padrão do consumo de energia e dos erros de previsão dessa etapa foram obtidos para utilização na etapa de monitoramento.

4.5. Aplicação e monitoramento da performance do modelo

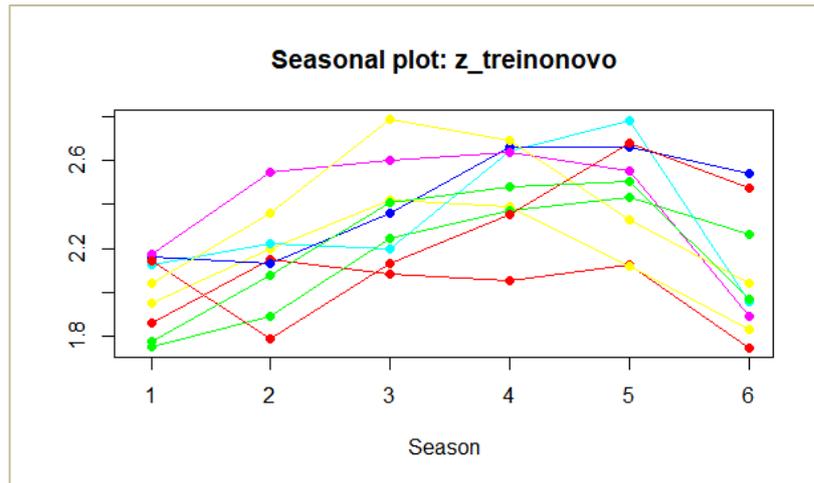
Nessa etapa os parâmetros dos erros de validação foram utilizados para a criação das cartas de controle de monitoramento dos erros. Para isso, foi verificado se os erros na etapa de validação estão sob controle estatístico. As 17 previsões restantes foram comparadas com os dados de consumo de energia no período de pandemia (ou seja, momento que causou uma variação no padrão de consumo), gerando outros erros que foram plotados nas cartas de controle. O desempenho da carta de controle de Shewhart para observações individuais (I ou X), para fator de abertura $k=3$ desvios-padrão, foi comparado com a carta de controle EWMA com $\lambda=0,1$ e $k=2,701$; $\lambda=0,2$ e $k=2,859$; e $\lambda=0,5$ e $k=2,978$. Esses parâmetros foram escolhidos baseados em um número médio de amostras até o alarme falso ($NMAF=370,4$), ou seja, quando o processo está sob controle, todas as cartas utilizadas geram, em média, um alarme falso a cada 370 amostras (COSTA; EPPRECHT; CARPINETTI, 2004).

5. Resultados

5.1. Análise dos dados

Inicialmente, a estrutura dos 54 dados selecionados para obtenção do modelo de previsão foi analisada. A Figura 3 apresenta o gráfico de sazonalidade dos dados da etapa de seleção do modelo. É possível perceber que há um padrão nos dados que se repete durante os semestres, indicando a presença de uma sazonalidade semestral.

Figura 3 – Gráfico do perfil sazonal dos dados da etapa de Seleção do Modelo



Fonte: Autores

5.2. Seleção do modelo

Através da função “auto.arima”, presente no software R, identificou-se que o modelo que mais se adequa aos dados da Etapa de seleção do modelo é o SARIMA (1,0,0) (2,1,0)₆. Portanto, esse modelo foi utilizado para essa base de dados, alcançando um MAPE = 6,57%, MSE = 0,03 e MAE = 0,15, que representam um pequeno erro para a previsão. A Tabela 1 apresenta os coeficientes dos fatores Auto Regressivo (AR ordem 1) e Auto Regressivo Sazonal (SAR ordens 1 e 2). É possível perceber que todos os fatores presentes no modelo são significativos para o modelo de previsão (p-valores < 0,05). Através do ACF e PACF percebeu-se que os resíduos não possuem autocorrelação significativa. Além disso, eles seguem a distribuição normal (Anderson-Darling com p-valor=0,923) com média igual a $\bar{X}_R = 0,024$ e desvio-padrão igual a $s_R = 0,1865$. O Teste de Ljung-Box confirmou que os resíduos não apresentam autocorrelação para um total de 11 lags (p-valor = 0,773).

Tabela 1 – Descrição dos fatores utilizados no modelo

Tipo	Coefficiente	Erro Padrão	Valor z	P-valor
AR 1	0,57994	0,13069	4,4338	<0,001*
SAR 1	-0,94230	0,15401	-6,1186	<0,001*
SAR 2	-0,38144	0,16682	-2,2865	0,022*

Nota: * P-valor < 0,05 foi considerado significativo

Fonte: Autores

5.3. Validação

Após a construção do modelo, foi previsto o consumo de energia elétrica pela universidade para

os próximos 37 meses, com o objetivo de validar o modelo e identificar a variação devido à pandemia.

Porém, para a etapa de validação, foram consideradas apenas as primeiras 20 previsões (de julho de 2018 a fevereiro de 2020), pois de acordo com Montgomery, Jennings e Kulahci (2015), uma boa regra é ter pelo menos 20 ou 25 observações para o teste de desempenho do modelo. No período de validação, a média de consumo de energia elétrica era $\bar{X}_{C_0}=2,33$ com desvio-padrão de $s_{C_0}=0,3598$. Comparando os resultados previstos com os originais, obteve-se $MAE = 0,24$, $MSE = 0,11$ e $MAPE = 9,82\%$. Os erros de previsão foram computados e avaliados. Através da análise do ACF e PACF é possível perceber que os erros não estão auto correlacionados durante o período de validação. Por fim, os erros, nesse período, seguem a distribuição normal (Anderson-Darling com p-valor=0,236), com média $\bar{X}_{E_0}=0,097$ e desvio-padrão $s_{E_0}=0,3281$.

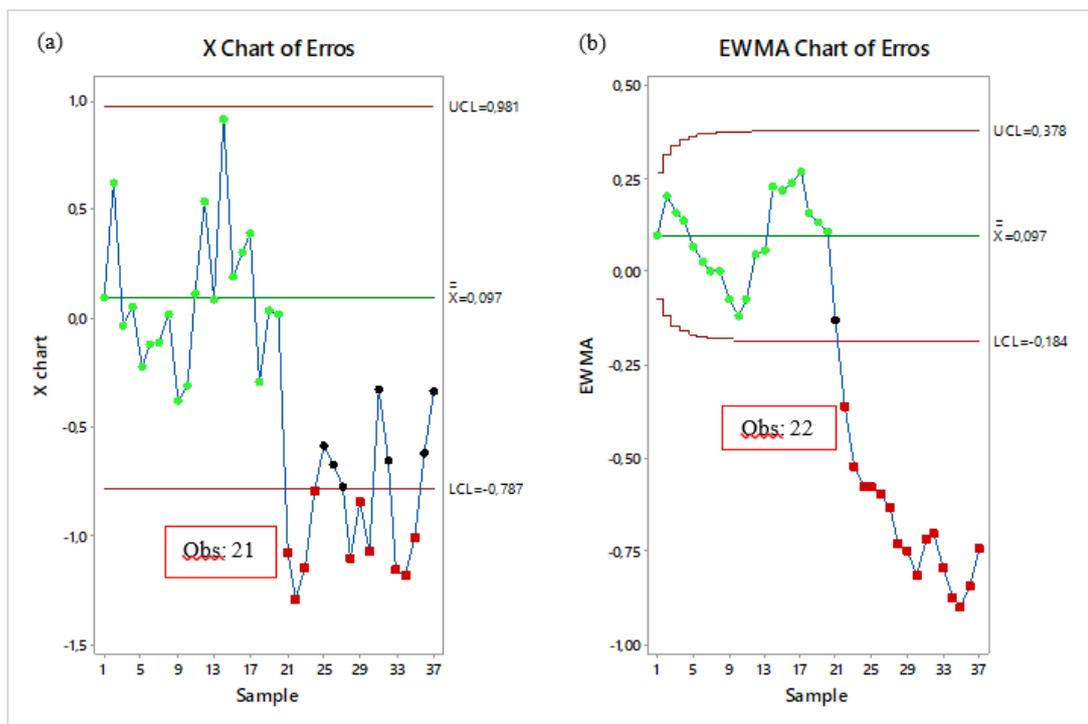
Os valores dos erros gerados na etapa de validação também foram utilizados para a determinação dos parâmetros para a construção das cartas de controle para monitoramento dos erros. Para isso, foi verificado se os erros nesse período estão sob controle. Como os dados se apresentaram sob controle (nenhum ponto fora dos limites de controle em todos os gráficos e parâmetros (λ e k) que serão comparados posteriormente), foi utilizada a média dos erros ($\bar{X}_{E_0}=0,097$) e o desvio-padrão dos erros ($s_{E_0}=0,3281$) do período de validação como parâmetros dos gráficos de controle.

5.4. Comparação dos gráficos EWMA e X no período da pandemia

Devido à pandemia por COVID-19, a média do consumo de energia elétrica na Universidade Federal analisada obteve uma queda de $\bar{X}_{C_0}=2,33$ ($s_{C_0}=0,3598$) no período de validação, para $\bar{X}_{C_1}=1,40$ no período de pandemia. Essa queda no consumo equivale a um deslocamento da média do consumo de $\delta_C=-2,58$ e gerou um deslocamento da média dos erros de $\delta_E=-2,92$. Para a avaliação do modelo de previsão durante o período de pandemia, foram comparados os valores reais nessa época (março de 2020 a julho de 2021) com os últimos 17 valores previstos pelo modelo, gerando mais 17 erros que estão sob efeito de uma causa especial. Foram comparadas as cartas de controle de Shewhart para observações individuais (I ou X) com parâmetro $k=3$ e as cartas de controle EWMA com os parâmetros $\lambda=0,1$ e $k=2,701$; $\lambda=0,2$ e $k=2,859$; e $\lambda=0,5$ e $k=2,978$. A Figura 4 apresenta um exemplo para ilustrar o uso de algumas

das cartas de controle empregadas para comparação. Os 20 primeiros pontos (em verde) representam erros no período de validação, ou seja, quando o consumo de energia elétrica e consequentemente os erros do modelo de previsão estão sob controle. A partir do 21º ponto, o consumo de energia elétrica é reduzido devido à pandemia, logo o modelo de previsão já não representa bem esse processo e espera-se que as cartas de controle identifiquem essa mudança nos erros de previsão. A Figura 4(a) apresenta o gráfico de controle para observações individuais (X ou I) para fator de abertura $k=3$ desvios-padrão e a Figura 4(b) apresenta o gráfico EWMA com os parâmetros $\lambda=0,2$ e $k=2,859$. Comparando as duas cartas de controle pode-se notar que o Gráfico X dá o sinal em 1 amostra após a mudança no padrão de consumo de energia elétrica. Já o gráfico EWMA para os parâmetros apresentados dá o sinal em 2 amostras após a mudança.

Figura 4– (a) Gráfico X para $k=3$; (b) EWMA para $\lambda=0,2$ e $k=2,859$



Fonte: Autores

A Tabela 2 apresenta o número de amostras até o sinal, comparando o desempenho dos gráficos de controle. É possível perceber que, para um deslocamento na média de consumo de $\delta_C=-2,58$ que ocasionou e um deslocamento da média dos erros de $\delta_E=-2,92$, a carta de controle de Shewhart X, no geral, apresentou melhor desempenho que o gráfico EWMA, provavelmente devido ao grande deslocamento que a média obteve durante o período de pandemia. É possível notar também, que o desempenho do EWMA melhorou com o aumento dos parâmetros λ e k .

Esses resultados estão de acordo com a literatura, pois Mitra, Lee e Chakraborti (2019) afirmam que o gráfico EWMA com um pequeno λ não detecta mudanças “grandes” tão eficientemente quanto o gráfico de Shewhart.

Tabela 2 – Comparação do número de amostras até o sinal na pandemia

	I ou X (k=3)	EWMA ($\lambda=0,5$; k=2,978)	EWMA ($\lambda=0,1$; k=2,701)	EWMA ($\lambda=0,2$; k=2,859)
Amostras até o sinal	1	1	2	2

Fonte: Autores

6. Conclusões

A aplicação de modelos de previsão na análise do consumo de energia elétrica pode auxiliar no planejamento de recursos para arcar com o futuro custo do consumo energético. Nesse sentido, este trabalho apresentou a modelagem de uma série temporal de consumo energético mensal (em GW/h) de uma Universidade Federal brasileira do período de janeiro de 2014 até julho de 2021. Através do modelo foi possível realizar a previsão de consumo no período de 37 meses, sendo 20 destes para validação. Mas dentro do período estudado, dos meses de março de 2020 a julho de 2021 tem-se a pandemia de COVID-19. Com isso o modelo de previsão, gerado pelos dados históricos anteriores ao período pandêmico, não mais atende a nova realidade de queda de consumo causada pela paralização da maioria das atividades presenciais das universidades. Desta maneira, é necessário monitorar o modelo criado para que quando este não mais sirva ao seu propósito, o usuário seja alertado para rever ou mesmo alterar completamente o modelo de previsão. E para esse monitoramento pode-se aplicar as cartas de controle, como por exemplo, de Shewhart e EWMA, bem como pode-se comparar seus desempenhos em alertar quando o modelo sai da sua função e deve ser revisado.

Inicialmente foi obtido o modelo de previsão SARIMA (1,0,0) (2,1,0)₆ e o modelo foi utilizado para essa base de dados, alcançando um MAPE = 6,57%, MSE = 0,03 e MAE = 0,15. Nota-se a componente sazonalidade de 6 meses para o modelo gerado. Também foi verificada a normalidade dos resíduos e que eles não estavam correlacionados.

Na etapa de comparação dos gráficos EWMA e X no período de pandemia pode-se notar que o Gráfico X dá o sinal em 1 amostra após a mudança no padrão de consumo de energia elétrica. Já o gráfico EWMA para os parâmetros apresentados dá o sinal em 2 amostras após a mudança, com exceção do EWMA de $\lambda=0,5$ e $k=2,978$ que apresentou sinal 1 amostra após a mudança. Esse trabalho apresenta algumas limitações. Os dados utilizados para a análise dos erros de previsão durante a pandemia correspondem ao consumo de energia de apenas uma instituição.

Nesse sentido, para trabalhos futuros, recomenda-se utilizar o banco de dados de consumo energético de outras universidades ou empresas para modelagem e previsões utilizando o ARIMA. O escopo desse trabalho focou apenas na comparação entre as cartas EWMA e X. Logo, os modelos de previsão em trabalhos futuros podem incluir as cartas de controle CUSUM, dentre outras existentes na literatura, e essas cartas podem ser comparadas quanto ao seu desempenho ao alertar a necessidade de revisão do modelo de previsão. Por fim, esse trabalho focou no modelo de previsão ARIMA. Então, futuramente outros métodos de previsão podem ser utilizados para a modelagem desses dados, como redes neurais ou métodos híbridos, e comparados os desempenhos das cartas de controle citadas para estes métodos. É possível também testar alterações nos desvios padrões dos erros e seu impacto no desempenho das cartas de controle durante o monitoramento dos modelos.

7. Agradecimentos

Agradecemos à UNIFEI, CNPq e à CAPES pelo apoio financeiro.

REFERÊNCIAS

- BARBEITO, I.; ZARAGOZA, S.; TARRÍO-SAAVEDRA, J.; NAYA, S. Assessing thermal comfort and energy efficiency in buildings by statistical quality control for autocorrelated data. **Applied Energy**, v. 190, p. 1–17, 2017. Disponível em: <https://doi.org/10.1016/j.apenergy.2016.12.100>
- BENVENUTO, D.; GIOVANETTI, M.; VASSALLO, L.; ANGELETTI, S.; CICCOCCHI, M. Application of the ARIMA model on the COVID-2019 epidemic dataset. **Data in Brief**, v. 29, p. 105340, 2020. Disponível em: <https://doi.org/10.1016/j.dib.2020.105340>
- CHEN, H.; CHEN, Y. CUSUM Residual Charts for Monitoring Enterovirus Infections. **Proceedings of the Institute of Industrial Engineers Asian Conference 2013**, p. 871–878, 2013. Disponível em: <https://doi.org/10.1007/978-981-4451-98-7>
- CIHAN, P. Impact of the COVID-19 lockdowns on electricity and natural gas consumption in the different industrial zones and forecasting consumption amounts: Turkey case study. **International Journal of Electrical Power and Energy Systems**, v. 134, n. July 2021, p. 107369, 2022. Disponível em: <https://doi.org/10.1016/j.ijepes.2021.107369>
- COSTA, A. F. B.; EPPRECHT, E. K.; CARPINETTI, L. C. R. **Controle Estatístico de Qualidade**. 1. ed., 2004.
- FATTAH, J.; EZZINE, L.; AMAN, Z.; EL MOUSSAMI, H.; LACHHAB, A. Forecasting of demand using ARIMA model. **International Journal of Engineering Business Management**, v. 10, p. 1–9, 2018. Disponível em:

em: <https://doi.org/10.1177/1847979018808673>

FICHERA, A.; PAGANO, A. Monitoring combustion unstable dynamics by means of control charts. **Applied Energy**, v. 86, n. 9, p. 1574–1581, 2009. Disponível em: <https://doi.org/10.1016/j.apenergy.2008.11.036>

GOUDARZI, S.; ANISI, M. H.; SOLEYMANI, S. A.; AYOB, M.; ZEADALLY, S. An IoT-based Prediction Technique for Efficient Energy Consumption in Buildings. **IEEE Transactions on Green Communications and Networking**, v. PP, n. c, p. 1, 2021. Disponível em: <https://doi.org/10.1109/TGCN.2021.3091388>

GUTERRES, B. D. V.; GUERREIRO, A. D. S.; NAM JUN, J.; SILVA, S. D. C. B.; SANDRINI, J. Z. Mussels as Aquatic Pollution Biosensors using Neural Networks and Control Charts*. **IEEE International Conference on Industrial Informatics (INDIN)**, v. 2020- July, p. 839–844, 2020. Disponível em: <https://doi.org/10.1109/INDIN45582.2020.9442202>

HARROU, F.; KADRI, F.; SUN, Y.; KHADRAOUI, S. Monitoring patient flow in a hospital emergency department: ARMA-based nonparametric GLRT scheme. **Health Informatics Journal**, v. 27, n. 2, 2021. Disponível em: <https://doi.org/10.1177/14604582211021649>

HRYNIEWICZ, O.; KACZMAREK-MAJER, K.; OPARA, K. R. Control charts based on fuzzy costs for monitoring short autocorrelated time series. **International Journal of Approximate Reasoning**, v. 114, p. 166–181, 2019. Disponível em: <https://doi.org/10.1016/j.ijar.2019.08.013>

JURJEVČIČ, B.; SENEGAČNIK, A.; KUŠTRIN, I. A surveillance of direct-firing system for pulverized-coal using statistically treated signals from intrusive electrostatic sensors. **Strojnikski Vestnik/Journal of Mechanical Engineering**, v. 63, n. 4, p. 265–274, 2017. Disponível em: <https://doi.org/10.5545/sv-jme.2016.4264>

KNOTH, S. Run length quantiles of EWMA control charts monitoring normal mean or/and variance. **International Journal of Production Research**, v. 53, n. 15, p. 4629–4647, 2015. Disponível em: <https://doi.org/10.1080/00207543.2015.1005253>

KOVÁŘÍK, M.; SARGA, L.; KLÍMEK, P. Usage of control charts for time series analysis in financial management. **Journal of Business Economics and Management**, v. 16, n. 1, p. 138–158, 2015. Disponível em: <https://doi.org/10.3846/16111699.2012.732106>

LAMPREIA, S. P. G. F. da S.; REQUEIJO, J. F. G.; DIAS, J. A. M.; VAIRINHOS, V.; MARTINS; BARBOSA, P. I. S. Condition monitoring based on modified CUSUM and EWMA control charts. **Journal of Quality in Maintenance Engineering**, 2018.

MATTA, C. E. da; BIANCHESI, N. M. P.; OLIVEIRA, M. S. de; BALESTRASSI, P. P.; LEAL, F. A comparative study of forecasting methods using real-life econometric series data. **Production**, v. 31, 2021.

Disponível em: <https://doi.org/10.1590/0103-6513.20210043>

MITRA, A.; LEE, K. B.; CHAKRABORTI, S. An adaptive exponentially weighted moving average-type control chart to monitor the process mean. **European Journal of Operational Research**, v. 279, n. 3, p. 902–911, 2019.

Disponível em: <https://doi.org/10.1016/j.ejor.2019.07.002>

MONTGOMERY, D. C. **Introduction to statistical quality control**. 7. ed. John Wiley & Sons, 2012.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction Time Series Analysis and Forecasting**. John Wiley & Sons, 2015.

NOOR, S.; NOOR-UL-AMIN, M.; ABBASI, S. A. Bayesian EWMA control charts based on Exponential and transformed Exponential distributions. **Quality and Reliability Engineering International**, v. 37, n. 4, p. 1678–1698, 2021. Disponível em: <https://doi.org/10.1002/qre.2820>

ROBERTS, S. W. Control Chart Tests Based on Geometric Moving Averages. **Technometrics**, v. 1, n. 3, p. 239–250, 1959. Disponível em: <https://doi.org/10.1080/00401706.1959.10489860>

ROBINSON, L.; SCHULZ, J.; RAGNEDDA, M.; PAIT, H.; KWON, K. H.; KHILNANI, A. An Unequal Pandemic: Vulnerability and COVID-19. **American Behavioral Scientist**, 2021. Disponível em: <https://doi.org/10.1177/00027642211003141>

SAÚDE, L. M. S.; GABRIEL, G. T.; BALESTRASSI, P. P. Forecasting of buffalo milk in a Brazilian diary using the arima model. **Buffalo Bulletin**, v. 39, n. 2, p. 201–213, 2020.

YANG, S. F.; ARNOLD, B. C. Monitoring Process Variance Using an ARL-unbiased EWMA-p Control Chart. **Quality and Reliability Engineering International**, v. 32, n. 3, p. 1227–1235, 2016. Disponível em: <https://doi.org/10.1002/qre.1829>