

Comparação de diferentes modelos para previsão do percentual de energia armazenada no Sul do Brasil

Comparison of different models in forecasting the percentage of energy stored in Southern Brazil

Bruna Gregory Palm¹, Débora Missio Bayer² e Fábio Mariano Bayer^{*3}

¹Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Maria

²Departamento de Engenharia Sanitária e Ambiental e LACESM, Universidade Federal de Santa Maria

³Departamento de Estatística e LACESM, Universidade Federal de Santa Maria

Resumo

O presente trabalho visa verificar a adequação de modelos de séries temporais para modelar o percentual de energia armazenada na Região Sul do Brasil. Foram considerados o modelo autorregressivo de médias móveis (ARMA) e o modelo beta autorregressivo de médias móveis (β ARMA). O modelo ARMA é um modelo tradicional e amplamente utilizado, enquanto que o modelo β ARMA é um modelo recentemente proposto na literatura para modelar variáveis contínuas restritas ao intervalo (0,1), como o percentual de energia armazenada. Previsões acuradas para o percentual de energia asseguram o fornecimento e a distribuição de energia de forma segura, com qualidade e de maneira econômica. Os resultados evidenciam superioridade do modelo β ARMA, uma vez que apresenta valores ajustados e previstos mais próximos aos valores reais observados.

Palavras-chave: Comparação de modelos de previsão, distribuição beta, energia armazenada, modelo ARMA, modelo β ARMA.

Abstract

This paper evaluates the adequacy of time series models for stored energy percentage in Southern Brazil. The autoregressive moving average model (ARMA) and the beta autoregressive moving average (β ARMA) were considered. The ARMA model is a traditional and widely used technique, whereas the β ARMA model is a recent model proposed in the literature to fit variables restricted to the interval (0,1), as the percentage of stored energy. Accurate forecasts for the percentage of stored energy ensure economic power supply with quality. Results indicate more reliable predictions for the β ARMA model, since it predicts values closer to the real ones.

Keywords: Model comparison, beta distribution, stored energy, ARMA model, β ARMA model.

*Autor correspondente: bayer@ufsm.br

1 Introdução

Os modelos autorregressivos integrados de médias móveis (ARIMA) (Box et al., 2008; Morettin e Toloi, 2006) são tradicionalmente utilizados para modelar séries temporais e realizar previsões de variáveis ao longo do tempo. No entanto, os modelos da classe ARIMA pressupõem normalidade da variável de interesse y (Box et al., 2008; Benjamin et al., 2003), tornando-os inapropriados quando y é restrita a um intervalo limitado, uma vez que o suporte da distribuição normal é toda a reta real. Exemplos de variáveis limitadas são variáveis do tipo taxas e proporções, que estão restritas ao intervalo unitário padrão $(0,1)$, como o percentual de energia armazenada.

Uma alternativa para a modelagem adequada de variáveis limitadas seria a utilização de transformações na variável de interesse. Porém essa abordagem possui certas limitações, pois os resultados seriam interpretados em termos da média da variável transformada e não em termos da média da variável de interesse. Além do mais, variáveis como taxas e proporções costumam ser heteroscedásticas e assimétricas, levando a resultados inferenciais distorcidos em modelos que assumem erroneamente normalidade dos dados (Cribari-Neto e Zeileis, 2009; Ferrari e Pinheiro, 2011).

Como alternativa de modelagem específica para variáveis no intervalos $(0,1)$, Rocha e Cribari-Neto (2009) propuseram o modelo beta autorregressivo de médias móveis (β ARMA). Neste modelo, assim como no modelo de regressão beta (Ferrari e Cribari-Neto, 2004), assume-se que a variável de interesse segue distribuição beta, a qual possui suporte no intervalo $(0,1)$. Alguns outros exemplos de variáveis restritas à intervalos $(0,1)$ seriam: umidade relativa do ar, índice de área foliar, percentuais de mudanças de uso e de cobertura da terra, percentual de área desmatada, taxa de mortalidade, proporção de defeitos em peças, proporção de doentes, entre outros.

Uma variável restrita ao intervalo $(0,1)$ de grande importância para o setor elétrico brasileiro é a energia armazenada. A matriz hidroenergética brasileira é monitorada diariamente pelo Operador Nacional do Sistema Elétrico (ONS), através das energias naturais afluentes e das energias armazenadas. Ambas as informações são de grande relevância para a realização de previsões e para o planejamento operacional do Sistema Interligado Nacional (SIN) (ONS, 2014a). A energia natural afluente é obtida a partir das vazões naturais afluentes aos aproveitamentos hidrelétricos, enquanto a energia armazenada é a energia disponível em um sistema de reservatórios. Esta energia armazenada é expressa em termos percentuais da energia produzível a partir do volume de água armazenado em relação à capacidade máxima do sistema de reservatórios (ONS, 2014a), com seus valores possíveis pertencentes ao intervalo $(0,1)$. A fim de subsidiar o gerenciamento do sistema elétrico, estas variáveis são previstas pelo ONS no Programa Mensal de Operação, em um horizonte mensal com discretização semanal, através de informações de previsões de aflúências e de carga (ONS, 2014a). Desta maneira, encontrar ferramentas que forneçam melhores previsões da energia armazenada se faz importante para o setor energético brasileiro. Dada a importância do tema, a literatura já evidencia aplicações de modelos da classe ARIMA na área energética (Suganthi e Samuel, 2012; Abdel-Aal, 2008).

O presente trabalho visa abordar a adequação dos modelos clássicos da classe ARIMA em relação aos modelos β ARMA para modelar e prever o percentual de energia armazenada na Região Sul do Brasil. Cabe salientar que, neste trabalho, foram utilizadas séries mensais médias de armazenamento na Região Sul do Brasil. Porém, aplicações como a realizada neste estudo podem ser feitas em dados com outras escalas temporais, como diários, semanais ou anuais e, ainda, de forma isolada para cada reservatório. Para ambas as modelagens, ARIMA e β ARMA, foi utilizado a linguagem computacional R (R Development Core Team, 2012).

A organização do presente trabalho é apresentada a seguir. A Seção 2 apresenta o referencial teórico, com um breve resumo sobre os sistemas de energia elétrica no Brasil na Subseção 2.1, assim como a apresentação dos modelos de séries temporais considerados na Subseção 2.2. Uma análise descritiva dos dados é considerada na Seção 3, juntamente com os resultados das modelagens, as comparações dos modelos e a discussão dos resultados. Por fim, na Seção 4 são apresentadas as conclusões do trabalho.

considerados neste estudo, é a estacionaridade da série. Um série temporal é dita ser estacionária se ela oscila temporalmente de forma aleatória em torno de uma média constante (Morettin e Tolo, 2006).

Os modelos de séries temporais passaram por diversas mudanças nos últimos anos. Diferentes métodos de previsões foram criados, bem como o desenvolvimento de melhorias, levando assim a previsões cada vez mais confiáveis (Gooijer, 2006; Campos, 2008). Previsões em dados relacionados à energia elétrica tornaram-se um fator essencial para o fornecimento de energia de qualidade e segura com gastos reduzidos. Desta forma, predições sobre carga, demanda, consumo e armazenamento tornam-se interessantes para os setores responsáveis, pois valores previstos erroneamente geram um custo financeiro elevado, sendo por falta ou excesso de energia (Serrão, 2003).

A seguir são apresentados os modelos do tipo autorregressivo de médias móveis (ARMA) e β ARMA utilizados neste trabalho. O modelo ARMA é o caso particular do modelo ARIMA para séries temporais estacionárias, como é o caso da série de interesse neste estudo. Cabe salientar que o modelo β ARMA também pressupõe estacionaridade da série de interesse (Rocha e Cribari-Neto, 2009).

2.2.1 Modelo ARMA

Seja $y = (y_1, \dots, y_n)^\top$ um vetor aleatório, onde cada y_t , $t = 1, \dots, n$, tem distribuição condicionada a um conjunto de informações prévias de \mathcal{F}_{t-1} , seguindo distribuição normal com parâmetro de média μ_t e de variância σ^2 . A densidade condicional de y_t dado \mathcal{F}_{t-1} é dada por:

$$f(y_t | \mathcal{F}_{t-1}) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_t - \mu_t)^2}{2\sigma^2}}, \text{ com } y \in \mathfrak{R},$$

em que $\mu_t \in \mathfrak{R}$ e $\sigma^2 > 0$.

A modelagem ARMA(p, q) (Ansley e Newbold, 1980; Box et al., 2008) supõem que a média μ_t da variável de interesse y_t com n observações ordenadas no tempo, pode ser escrita pela seguinte estrutura:

$$\mu_t = \alpha + \sum_{i=1}^p \varphi_i y_{t-i} - \sum_{j=1}^q \theta_j a_{t-j},$$

em que α é uma constante, φ 's são os parâmetros autorregressivos, θ 's os parâmetros de médias móveis, a_t o erro de média móvel e p e q são as ordens do modelo.

As inferências sobre os parâmetros do modelo são baseadas em estimadores de máxima verossimilhança (EMV). A obtenção dos EMV é feita por meio da maximização do logaritmo da função de verossimilhança; para detalhes, verificar Box et al. (2008) e/ou Morettin e Tolo (2006).

2.2.2 Modelo β ARMA

Seja $y = (y_1, \dots, y_n)^\top$ um vetor com n variáveis aleatórias, em que cada y_t , $t = 1, \dots, n$ tem distribuição condicional, dada por um conjunto de informações prévias de \mathcal{F}_{t-1} , seguindo distribuição beta com parâmetro de média μ_t e de precisão ϕ . A densidade condicional de y_t dado \mathcal{F}_{t-1} é dada por:

$$f(y_t | \mathcal{F}_{t-1}) = \frac{\Gamma(\phi)}{\Gamma(\mu_t\phi)\Gamma((1-\mu_t)\phi)} y_t^{\mu_t\phi-1} (1-y_t)^{(1-\mu_t)\phi-1}, \text{ com } 0 < y < 1,$$

em que $0 < \mu_t < 1$ e $\phi > 0$. A média condicional e a variância condicional de y_t são dadas, respectivamente, por:

$$\begin{aligned} E(y_t | \mathcal{F}_{t-1}) &= \mu_t, \\ \text{var}(y_t | \mathcal{F}_{t-1}) &= V(\mu_t) / (1 + \phi), \end{aligned}$$

sendo $V(\mu_t) = \mu_t(1 - \mu_t)$ a função de variância.

O modelo β ARMA(p, q) proposto por Rocha e Cribari-Neto (2009) para modelar a esperança condicional

de y pode ser escrito da seguinte forma:

$$g(\mu_t) = \alpha + \sum_{i=1}^p \varphi_i g(y_{t-i}) + \sum_{j=1}^q \theta_j r_{t-j},$$

em que $\alpha \in \mathfrak{R}$ é uma constante, φ 's e θ 's são, respectivamente, os parâmetros autorregressivos e de médias móveis, $r_t = y_t - \mu_t$ é o termo de erro de médias móveis e $g(\cdot)$ é uma função de ligação estritamente monótona e duas vezes diferenciável $g : (0,1) \rightarrow \mathbb{R}$, assim como no modelo de regressão beta (Ferrari e Cribari-Neto, 2004). No presente artigo considerou-se função de ligação logit, ou seja, $\text{logit}(\mu) = \log\{\mu/(1 - \mu)\}$. Dado que a média μ_t está restrita ao intervalo $(0,1)$, outras funções de ligação possíveis são a probit e cloglog (Rocha e Cribari-Neto, 2009).

Assim como nos modelos da classe ARIMA, os parâmetros do modelo β ARMA também são estimados via máxima verossimilhança. Maiores detalhes sobre inferências em grandes amostras no modelo β ARMA, como função de log-verossimilhança, função escore e matriz de informação de Fisher, podem ser verificados em Rocha e Cribari-Neto (2009).

2.2.3 Medidas de qualidade de ajuste

Para efeitos de comparação da qualidade de ajuste dos modelos considerados para o percentual de energia armazenada se faz necessária a utilização de algumas medidas quantitativas. Para tanto, foram selecionadas as medidas erro quadrático médio (EQM) e erro absoluto médio percentual (MAPE). Essas medidas avaliam a diferença entre o valor real observado y e o valor predito pelo modelo $\hat{\mu}$. As medidas EQM e MAPE são definidas, respectivamente, por:

$$\text{EQM} = \frac{1}{h} \sum_{i=1}^h (y_i - \hat{\mu}_i)^2 \quad \text{e} \quad \text{MAPE} = \frac{1}{h} \sum_{i=1}^h \frac{|y_i - \hat{\mu}_i|}{|y_i|}, \quad (1)$$

em que h é o número de observações consideradas. Essas são medidas usuais na comparação de modelos, como pode ser visto em Prass et al. (2012), Kumar e Jain (2010), Suganthi e Samuel (2012) e Abdel-Aal (2008).

Para análise da qualidade de ajuste dos modelos, EQM e MAPE foram calculadas utilizando valores preditos $\hat{\mu}$ dentro e fora do intervalo de valores utilizados para ajuste do modelo. Para o cálculo das medidas com valores fora do período de observações foram reservadas as $h = 6$ últimas ocorrências dos dados originais. Tais observações foram utilizadas apenas para efeito de comparação e medição da capacidade preditiva dos modelos.

3 Resultados

Nesta seção são apresentados os resultados da modelagem do percentual médio de energia armazenada. Inicialmente foi realizada uma caracterização da série de dados por meio de uma análise descritiva. Antes da escolha dos modelos foi necessária a verificação da suposição de estacionaridade da série. Para tanto, foi realizado o teste de raiz unitária de Dickey-Fuller Aumentado (ADF) (Said e Dickey, 1984). O teste retornou $p\text{-valor} < 0,01$, rejeitando a hipótese nula de presença de raiz unitária (não estacionaridade) a níveis nominais usuais. Assumindo estacionaridade da série foram então ajustados o modelo ARMA e β ARMA, assim como realizada uma comparação de suas capacidades preditivas.

3.1 Caracterização e análise descritiva

A série de interesse é composta por resultados referentes ao percentual médio de energia armazenada na Região Sul do Brasil (ONS, 2014d). O período considerado para ajuste dos modelos foi de Janeiro de 1996 a Outubro de 2013, com observações mensais. A série temporal pode ser visualizada graficamente na Figura 2(a).

O histograma dos dados, assim como as densidades normal e beta ajustadas aos dados, são verificados na Figura 2(b)). Esta figura evidencia um comportamento assimétrico da distribuição dos dados, distanciando-se de um comportamento normal, e aproximando-se da distribuição beta. Sendo assim, a escolha de um

modelo que pressupõe normalidade dos dados não seria o mais adequado, justificando a escolha de um modelo que pressupõe distribuição beta, como o β ARMA.

Nas Figuras (2(c)) e (2(d)) observam-se, respectivamente, a função de autocorrelação (FAC) e a função autocorrelação parcial (FACP) amostrais dos dados. Esses correlogramas corroboram com o teste ADF realizado, indicando estacionaridade da série. Eles também indicam a ordem dos modelos com pelo menos um parâmetro autorregressivo e um de médias móveis, pois a FAC amostral apresenta decaimento exponencial após a defasagem 1 e a FACP amostral evidencia autocorrelações parciais não significativamente diferente de zero para defasagens maiores que 1 (Morettin e Tolo, 2006). Ainda, a fim de minimizar o critério de informação de Akaike (AIC) (Akaike, 1974) durante as modelagens, e levando em consideração o princípio da parcimônia, escolheu-se a ordem (1,1) para ambos os modelos de séries temporais estudados.

Para melhor compreensão da variável em estudo, a Tabela (1) apresenta um resumo descritivo. Pode-se verificar que o percentual de energia armazenada teve média de 0,724, com desvio padrão igual a 0,197 e coeficiente de variação de 27,21% durante todo o período analisado. O valor máximo foi 0,989 e o mínimo 0,296. Em uma série com distribuição normal espera-se que o coeficiente de assimetria se aproxime de zero e o coeficiente de curtose de 3. No entanto, para a série analisada obteve-se valores de assimetria igual a $-0,502$ e de curtose a 2,042. Logo, esta assimetria negativa indica que a amostra apresenta maior concentração de valores a direita da distribuição. Estes resultados de assimetria negativa e curtose inferior a 3 corroboram com os indícios vistos na Figura (2(b)) de não normalidade da série.

Tabela 1: Resumo descritivo da variável energia armazenada.

Medidas	Percentual de Energia
Média	0,724
Mediana	0,761
Desvio Padrão	0,197
Coeficiente de Variação (%)	27,210
Mínimo	0,296
Máximo	0,989
Assimetria	$-0,502$
Curtose	2,042

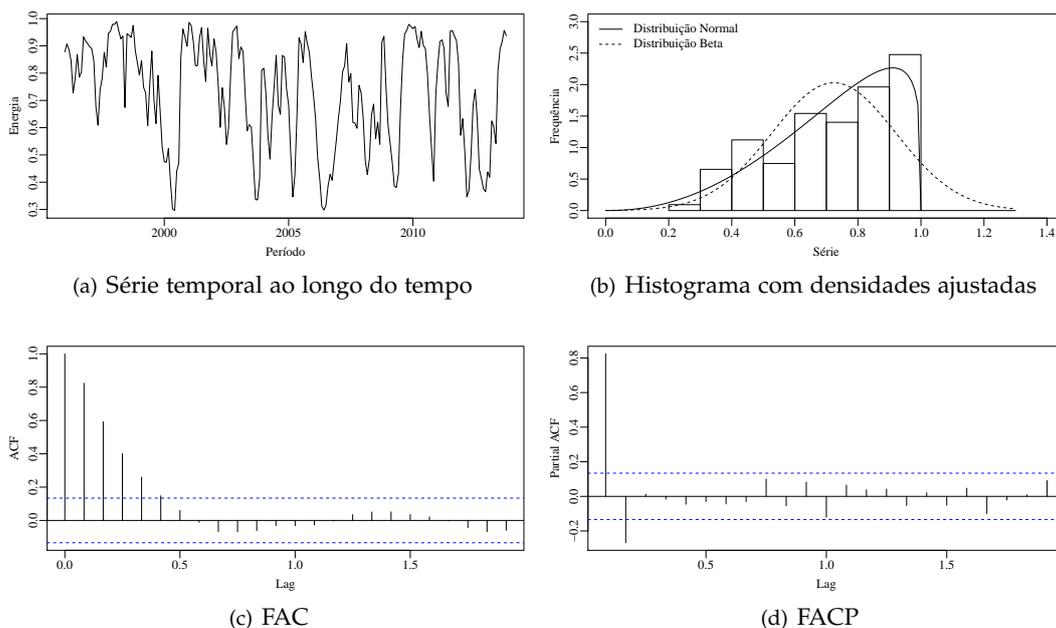


Figura 2: Análise gráfica do percentual de energia armazenada.

3.2 Ajuste do modelo ARMA

As estimativas dos parâmetros para o modelo ARMA(1,1) ajustado podem ser verificadas na Tabela (2). Nota-se que todos os parâmetros são significativos a níveis de significância usuais. Contudo, ainda se faz necessária uma análise de diagnóstico do modelo para verificar seu bom ajuste. Para essa análise serão considerados os seguintes gráficos: (i) correlogramas residuais (FAC e FACP); (ii) resíduos padronizados ao longo dos índices; (iii) Q-Q plot dos resíduos padronizados. O objetivo dessa análise de diagnóstico é a verificação de que os resíduos padronizados são ruídos branco, possuem comportamento aleatório ao redor da média zero com distribuição próxima da normal padrão.

Tabela 2: Modelo ARMA ajustado aos dados de percentual de energia armazenada.

	Estimativa	Erro-padrão	p-valor
α	0,7288	0,0360	0,0000
φ_1	0,7411	0,0527	0,0000
θ_1	0,2955	0,0715	0,0000
σ^2	0,0114		

A análise de diagnóstico do modelo ajustado, apresentada na Figura (3), mostra o bom ajuste do modelo selecionado. Isto é observado através da análise dos correlogramas residuais (Figuras (3(a)) e (3(b))), nos quais não se verifica autocorrelação significativamente diferente de zero, ou seja, todas as defasagens encontram-se dentro do intervalo de confiança. O comportamento dos resíduos padronizados pode ser visto na Figura (3(c)), no qual observa-se um comportamento aleatório em torno de zero, dentro do intervalo de -3 a 3 e com grande parte dos pontos distribuídos dentro do intervalo -2 a 2 . Por meio do Q-Q plot, Figura (3(d)), verifica-se a proximidade dos resíduos padronizados à distribuição normal. Essa análise valida o modelo ajustado tornando-o apto para traçar previsões.

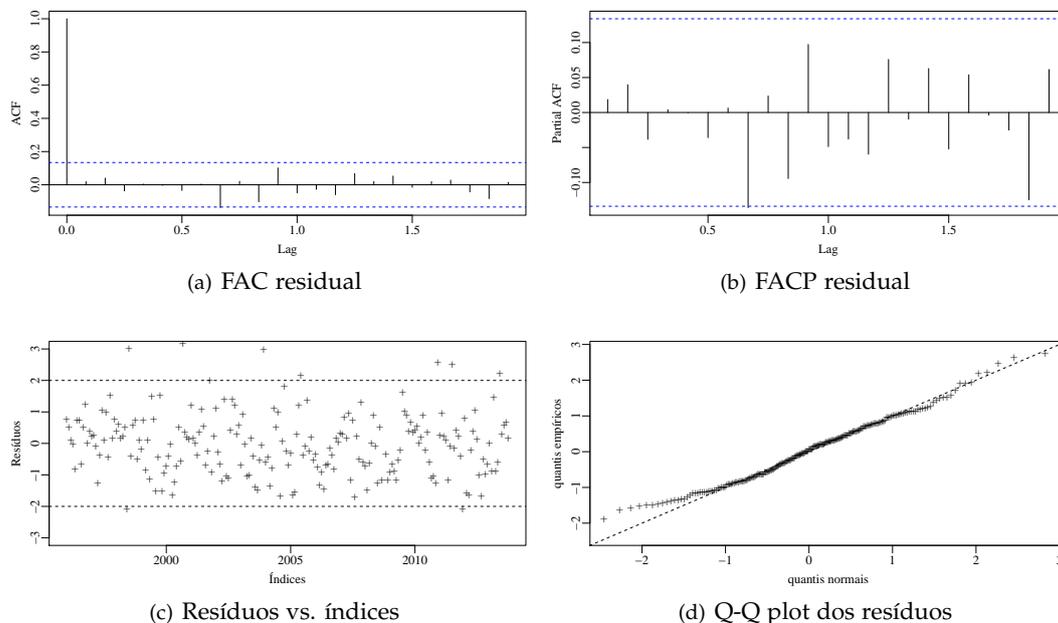


Figura 3: Gráficos dos resíduos padronizados do modelo ARMA.

A Figura (4) apresenta graficamente os valores reais observados e os valores ajustados pelo modelo. O gráfico evidencia boa relação entre valores reais e ajustados.

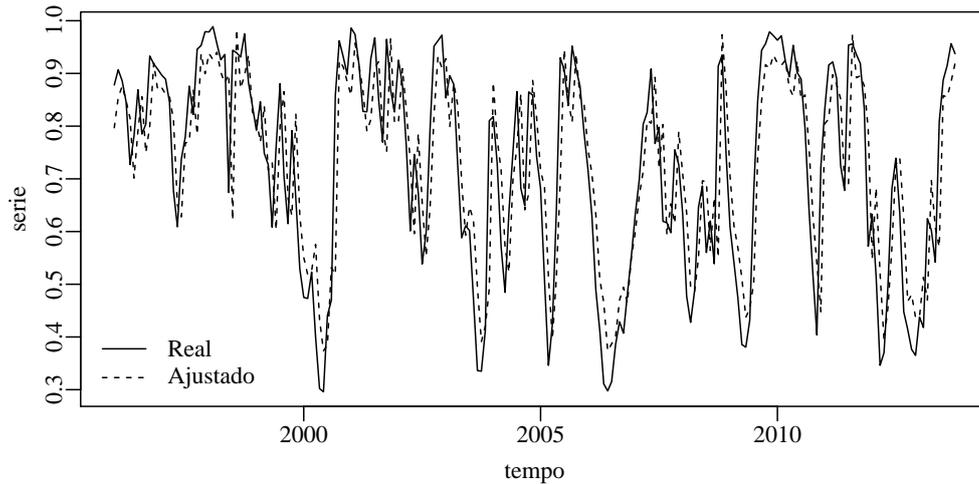


Figura 4: Valores reais e ajustados pelo modelo ARMA.

3.3 Ajuste do modelo β ARMA

Os coeficientes do modelo β ARMA(1,1) ajustado podem ser encontrados na Tabela (3). Na Figura (5) é apresentada a análise de diagnóstico do modelo. Da mesma forma que para o modelo ARMA(1,1), a análise de diagnóstico do modelo β ARMA(1,1) também evidencia que o modelo de ordens $p = 1$ e $q = 1$ é adequado. Os correlogramas residuais, conforme Figuras (5(a)) e (5(b)), não apresentam autocorrelações significativamente diferente de zero. O comportamento dos resíduos padronizados são verificados nas Figuras (5(c)) e (5(d)), onde observa-se que são distribuídos ao redor de zero de forma aleatória, dentro do intervalo de -3 a 3 , com maior concentração dos pontos no intervalo -2 e 2 , enquanto que o Q-Q plot mostra que sua distribuição é próxima da distribuição normal.

Tabela 3: Modelo β ARMA ajustado aos dados de percentual de energia armazenada.

	Estimativa	Erro-padrão	p-valor
α	0,3628	0,0539	0,0000
φ_1	0,5865	0,0265	0,0000
θ_1	1,6580	0,3299	0,0000
ϕ	13,5153		

Como forma de verificar qualitativamente o bom ajuste do modelo β ARMA considerado, a Figura (6) mostra de forma gráfica os valores reais observados e os ajustados pelo modelo. Pode-se verificar o bom ajuste do modelo.

3.4 Comparação dos modelos ajustados

A comparação dos modelos, como apresentado anteriormente, é realizada através da análise de algumas medidas de qualidade (EQM e MAPE). Além desta análise ter sido feita no período de ajuste do modelo, ela também foi realizada nas previsões passos à frente. Este horizonte de previsão foi definido como seis passos à frente (seis meses). Cabe salientar que estes seis meses não foram utilizados na fase de ajuste do modelo.

A Tabela (4) apresenta os valores reais observados juntamente com os valores previstos para os seis meses à frente por cada um dos modelos. O resultado destas previsões evidencia valores preditos pelo modelo β ARMA mais próximos aos verdadeiros valores, em comparação com o modelo ARMA. Percebe-se que houve uma diminuição dos valores reais ao longo dos seis meses e que o modelo β ARMA foi mais sensível a este decréscimo. A Figura (6) mostra graficamente tais conclusões.

A Tabela (5) apresenta os valores de EQM e MAPE para as duas modelagens. Valores menores de EQM e

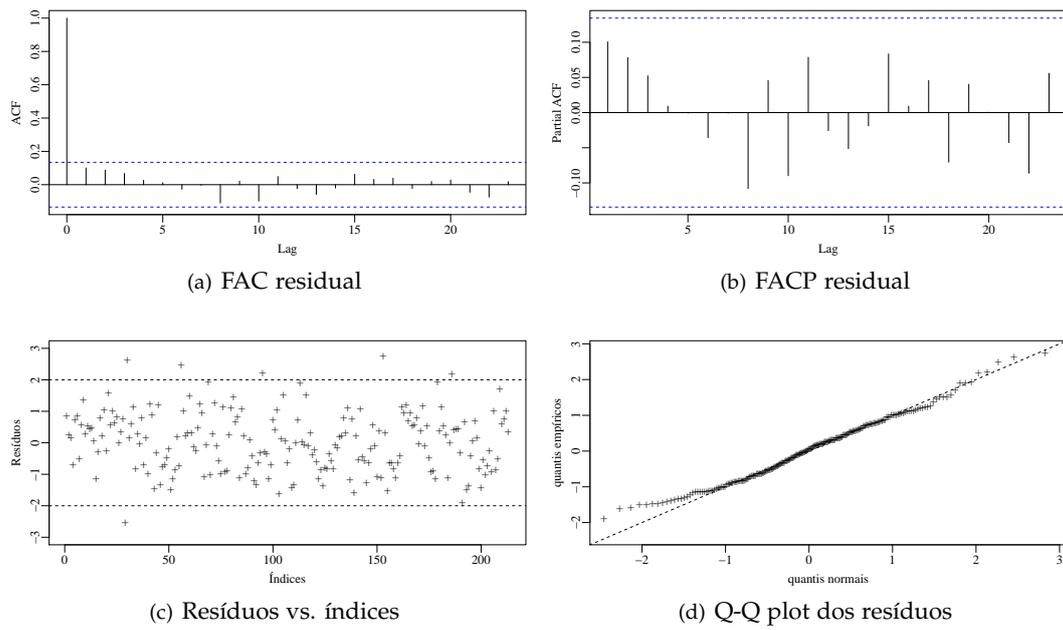


Figura 5: Gráficos dos resíduos padronizados do modelo β ARMA.

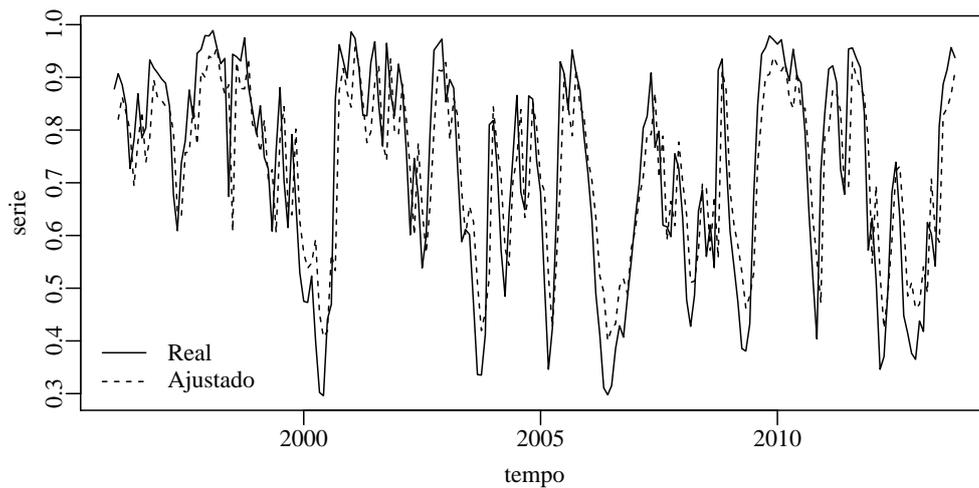


Figura 6: Valores reais e ajustados pelo modelo β ARMA.

Tabela 4: Valores reais e previstos para os diferentes modelos.

Período	Reais	ARMA	β ARMA
Novembro (2013)	0,7297	0,8890	0,8803
Dezembro (2013)	0,5774	0,8475	0,8224
Janeiro (2014)	0,5756	0,8168	0,7794
Fevereiro (2014)	0,3730	0,7940	0,7508
Março (2014)	0,4607	0,7771	0,7392
Abril (2014)	0,4390	0,7646	0,7221

MAPE significam modelos mais apropriados. O modelo β ARMA apresentou valores menores ou iguais para as medidas de qualidade em relação ao ARMA, exceto para o MAPE dentro do período de ajuste do modelo.

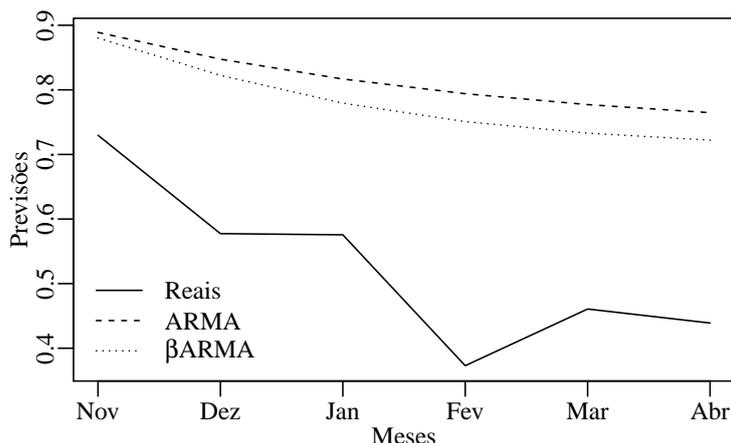


Figura 7: Gráfico comparativo entre valores reais e previstos passos à frente pelos modelos considerados.

No entanto, as previsões passos a frente se mostraram mais acuradas no modelo β ARMA, com base em ambas as medidas. Isto evidencia uma superioridade do modelo β ARMA em relação ao ARMA na obtenção de previsões. Quanto mais adequado o ajuste, decisões e conclusões mais precisas serão obtidas, ou seja, prejuízos podem ser evitados. Como no caso da variável em estudo, os valores previstos para o percentual de energia armazenada tendem a ser tão mais próximos aos valores reais quanto mais adequado for o modelo ajustado. Deste modo, pode-se verificar que o modelo β ARMA apresenta um melhor desempenho em relação ao modelo tradicional ARMA para a modelagem do percentual de energia armazenada.

Tabela 5: Valores de EQM e de MAPE dos modelos.

Modelagem	EQM	MAPE
Período de ajuste		
β ARMA	0,0002	0,1365
ARMA	0,0002	0,1303
Passos à frente		
β ARMA	0,3915	0,5390
ARMA	0,5009	0,6104

Este trabalho aborda a utilização do modelo β ARMA na variável percentual de energia armazenada. Contudo, pode-se generalizar esses resultados, afirmando que o modelo β ARMA tenderá a ter melhores resultados que os modelos da classe ARIMA para quaisquer variáveis limitadas ao intervalo $(0,1)$, pois assume uma distribuição adequada a esse tipo de variável. Um ponto muito importante, e de grande vantagem dos modelos β ARMA frente ao ARMA, é que o modelo β ARMA nunca resultará valores preditos fora do intervalo $(0,1)$, enquanto que, por assumir distribuição normal que não é restrita ao intervalo unitário padrão, um modelo ARMA eventualmente pode prever valores de energia armazenada, umidade relativa do ar ou taxa de mortalidade, por exemplo, acima de um (100%) ou abaixo de zero (0%). Este último caso é irreal e dificultará decisões e conclusões dos gestores que necessitam lançar mão dessas previsões.

4 Conclusões

Os modelos ARMA são tradicionalmente utilizados para a modelagem e previsão de variáveis ao longo do tempo. Porém, estes modelos são inapropriados quando não é razoável assumir normalidade para a variável de interesse y , como para variáveis no intervalo contínuo $(0,1)$. Para tais situações, o modelo β ARMA torna-se mais adequado, uma vez que assume distribuição beta, com suporte em $(0,1)$. Este artigo se propôs a verificar a adequação da modelagem tradicional ARMA em relação ao novo modelo β ARMA em um problema real importante do sistema elétrico brasileiro. O ajuste de ambos os modelos se mostraram

válidos, avaliados por meio das análises de diagnósticos. Contudo, o modelo β ARMA apresentou melhores resultados nas análises do que o modelo tradicional ARMA. Com isso, salienta-se a necessidade de atenção à escolha do modelo a ser utilizado, uma vez que o mesmo deve levar em consideração a natureza dos dados de interesse. Este é o caso do percentual de energia armazenada, que assume possíveis valores no intervalo $(0,1)$, no qual o modelo β ARMA mostrou-se mais adequado para a obtenção de previsões mais acuradas. Além disso, ao utilizar o modelo β ARMA evita-se a obtenção de previsões de percentuais de energia armazenada acima de 100%, valores estes possíveis de serem encontrados ao utilizar o modelo ARMA. Entende-se que o modelo β ARMA pode representar uma nova ferramenta à contribuir com o melhor gerenciamento do sistema elétrico.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio à pesquisa.

Referências

- Abdel-Aal, R. E., 2008. Univariate modeling and forecasting of monthly energy demand time series using abductive and neural networks. *Computers & Industrial Engineering* 54 (4), 903–917.
- Akaike, H., 1974. A new look at the statistical model identification. *IEEE Transactions on Automatic Control* 19 (6), 716–723.
- ANEEL, 2013. Relatório aneel 2012. Tech. rep., Agência Nacional de Energia Elétrica, Brasília - DF, 92 p.
- Ansley, C. F., Newbold, P., 1980. Finite sample properties of estimators for autorregressive moving average models. *Journal of Econometrics* 13 (2), 159–183.
- Bayer, F., Souza, A. M., 2010. Wavelets e modelos tradicionais de previsão: um estudo comparativo. *Revista Brasileira de Biometria* 28 (2), 40–61.
- Benjamin, M. A., Rigby, R. A., Stasinopoulos, D. M., 2003. Generalized autoregressive moving average models. *Journal of the American Statistical Association* 98 (461), 214–223.
- Box, G., Jenkins, G. M., Reinsel, G., June 2008. *Time series analysis: forecasting and control*, 4th Edition. Hardcover, John Wiley & Sons.
- BRASIL, 2008. Balanço energético nacional: ano base 2007. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 246 p.
- BRASIL, 2009. Balanço energético nacional: ano base 2008. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 276 p.
- BRASIL, 2010. Balanço energético nacional: ano base 2009. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 276 p.
- BRASIL, 2011. Balanço energético nacional: ano base 2010. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 267 p.
- BRASIL, 2012. Balanço energético nacional: ano base 2011. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 282 p.
- BRASIL, 2013. Balanço energético nacional: ano base 2012. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 284 p.
- BRASIL, 2014. Balanço energético nacional: relatório síntese ano base 2013. Tech. rep., Ministério de Minas e Energia (MME), Empresa de Pesquisa Energética (EPE), Brasília - DF, 284 p.

- Campos, R. J., 2008. Previsão de séries temporais com aplicações a séries de consumo de energia elétrica. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais.
- Cribari-Neto, F., Zeileis, A., 2009. Beta regression in r. Department of Statistics and Mathematics x, WU Vienna University of Economics and Business.
- Ferrari, S. L. P., Cribari-Neto, F., 2004. Beta regression for modelling rates and proportions. *Journal of Applied Statistics* 31 (7), 799–815.
- Ferrari, S. L. P., Pinheiro, E. C., 2011. Improved likelihood inference in beta regression. *Journal of Statistical Computation and Simulation* 81 (4), 431–443.
- Gooijer, J. D. and Hyndman, R. J., 2006. 25 years of time series forecasting. *International Journal of Forecasting* 22 (3), 443 – 473.
- Kumar, U., Jain, V. K., 2010. Arima forecasting of ambient air pollutants (o_3 , no , no_2 and co). *Stochastic Environmental Research and Risk Assessment* 24 (5), 751–760.
- Morettin, P. A., Toloi, C. M. C., 2006. Análise de Séries Temporais. Associação Brasileira de Estatística.
- ONS, 2014a. Acompanhamento diário da operação hidroenergética do sistema interligado nacional. Tech. rep., Operado Nacional do Sistema Elétrico, 11 p.
- ONS, 2014b. Diagrama esquemático das usinas hidroelétricas do sin. horizonte: 2014-2018. Tech. rep., Operador Nacional do Sistema Elétrico, Brasília - DF, 92 p.
- ONS, 2014c. O que é o sin - sistema interligado nacional.
URL http://www.ons.org.br/conheca_sistema/o_que_e_sin.aspx
- ONS, 2014d. Operador nacional do sistema elétrico - energia armazenada.
URL http://www.ons.org.br/historico/energia_armazenada.aspx
- Prass, T. P., Bravo, J. M., Clarke, R. T., Walter Collischonn, W. and Lopes, S. R. C., 2012. Comparison of forecasts of mean monthly water level in the paraguay river, brazil, from two fractionally differenced models. *Water Resources Research* 48 (5).
- R Development Core Team, 2012. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria, ISBN 3-900051-07-0.
- Rocha, A. V., Cribari-Neto, F., 2009. Beta autoregressive moving average models. *Test* 18 (3), 529–545.
- Said, S. E., Dickey, D. A., 1984. Testing for unit roots in autoregressive-moving average models of unknown order. *Biometrika* 71 (3), 599–607.
- Serrão, F., 2003. Modelo de previsão de carga de curto prazo utilizando redes neurais e lógica fuzzy. Dissertação de Mestrado, Programa de Pós-graduação em Engenharia Elétrica pela Pontifícia Universidade Católica, Rio de Janeiro, Brasil.
- Suganthi, L., Samuel, A. A., 2012. Energy models for demand forecasting - a review. *Renewable and Sustainable Energy Reviews* 16 (2), 1223–1240.