

IMPACTO DA VOLATILIDADE NO PREÇO DO CIMENTO PORTLAND

Volatility impact in Portland cement price

 Bianca Reichert¹

 Adriano Mendonça Souza²

Resumo: O objetivo deste artigo é identificar qual é o melhor modelo de séries temporais que represente o comportamento autorregressivo e oscilatório do preço do cimento Portland 32, modelo ARIMA ou ARCH. A análise teve como base o preço médio nacional e o preço médio praticado na região Sul do país. Os dados foram coletados por meio da Câmara Brasileira da Indústria da Construção, de junho de 1994 a janeiro de 2018. O melhor modelo ajustado para as duas séries foi o modelo de volatilidade ARCH (1,0). Conclui-se que, quando houver algum choque na produção ou na venda de cimento, o preço nacional terá um impacto maior enquanto que os preços da região Sul irão variar em menor escala e por um período mais longo. Essa pesquisa fornece informação para tomada de decisão no controle de compras e estoque de cimento em lojas do setor e em construtoras.

Palavras-chave: Modelos ARIMA. Modelos ARCH. Preço do cimento.

Abstract: This paper aims to identify the best time series model to represent the autoregressive and oscillatory behavior of Portland 32 cement, ARIMA or ARCH model. The analysis was based on the national price and the southern region price. Data were collected in the Brazilian Chamber of Construction Industry from June 1994 to January 2018. The best model for the both series was ARCH (1,0). We concluded that when there is a shock in production or sale of national price cement will have a greater impact, while South region prices will vary in a smaller scale and for a longer period. This study provides information for decision making in cement stock and purchase control in sector stores as well as in construction companies.

Keywords: ARIMA models. ARCH models. Cement price.

¹Universidade Federal de Santa Maria
Mestre em Engenharia de Produção
Doutoranda do Programa de Pós-Graduação em
Engenharia de Produção
Universidade Federal de Santa Maria, Santa Maria
– RS, Av. Roraima, nº 1000, prédio 7.
bianca.reichert@hotmail.com

²Doutor em Engenharia de Produção
Professor Titular do Departamento de Estatística
da Universidade Federal de Santa Maria
Santa Maria – RS, Av. Roraima, nº 1000, prédio 13.
amsouza.sm@gmail.com

1 Introdução

O cimento Portland é um dos principais produtos utilizados na construção civil, pois sua propriedade fundamental é a resistência à ação da água. Devido a essa característica, além da construção de casas, prédios e pavimentações, o cimento Portland também é utilizado na fabricação de pré-moldados (F. M. Souza, Almeida, Guarnieri, A. M. Souza & Lopes, 2010).

Ao analisar o setor da construção civil, percebe-se que o cimento e a sua comercialização são potencializadores da economia brasileira. Isso pode ser evidenciado em estudos realizados por Capozza, Hendershott, Mack e Mayer (2002) e por P. V. S. de Souza, Costa e Silva (2017), os quais revelaram que indicadores econômico-financeiro de empresas de materiais de construção impactam os valores do mercado imobiliário brasileiro. Observa-se que a produção do cimento Portland é relevante para o desenvolvimento do país.

O preço do cimento também possui relação com o desenvolvimento econômica do país, dado que no segundo semestre do ano a movimentação do setor da construção civil é maior, assim como o preço do cimento (Departamento de Pesquisas e Estudos Econômicos, 2017). Ademais, as oscilações do preço ao longo do ano são influenciados pelo nível da atividade econômica e pelo preço da energia, cujos valores são significativos na composição dos custos base da produção do cimento (Departamento de Pesquisas e Estudos Econômicos, 2017).

Ao analisar as variações no preço do cimento, percebe-se que compreender o comportamento dessa variável ao longo do tempo é uma tarefa complexa, o que pode dificultar o gerenciamento de estoques e o planejamento de compras principalmente em lojas de materiais de construção e construtoras (Reichert & Souza, 2016). Diante disso, a dificuldade em manter os níveis de estoque do cimento Portland é real devido a sua alta demanda e à variabilidade do seu preço. Essa variabilidade acaba influenciando diretamente o desempenho econômico das lojas de materiais construção, pois a margem de contribuição deixada pelo produto é mínima (Schneider, 2018).

Estudos realizados com o intuito de prever o preço de materiais da construção civil utilizam, em sua grande maioria, modelos autorregressivos devido a característica de autocorrelação presente nos preços desses produtos (Hwang, Park, Lee & Kim, 2012; Moura, 2017).

O objetivo desta pesquisa é identificar qual é o melhor modelo autorregressivo, modelos ARIMA ou ARCH, capaz de realizar previsões do preço do cimento Portland 32, com base no preço médio nacional e no preço médio praticado na região Sul do país.

2 Referencial teórico

Para compreender a base teórica da pesquisa, esse capítulo dedica-se a explicar os modelos de previsão utilizados para análise do preço do cimento, sendo esses os modelos da classe geral ARIMA e os modelos não lineares ARCH.

Os modelos ARIMA são modelos lineares aplicados às observações autocorrelacionadas (Box & Jenkins, 1970), enquanto que o modelo ARCH tem por objetivo estimar a volatilidade dos dados (A. M. Souza, F. M. Souza, Zanini & Menezes, 2012; Coelho, Rezende, Sáfyadi & Calegário, 2009; Engel, 1982). Nos tópicos a seguir, os modelos lineares e não lineares serão explorados, bem como os seus procedimentos técnicos.

2.1 Modelagem linear

O modelo autorregressivo integrado de médias móveis (ARIMA) é um modelo econométrico utilizado na análise de dados autocorrelacionadas. Esta metodologia, desenvolvida por Box e Jenkins (1970), baseia-se na ideia de que observações passadas influenciam o comportamento de observações futuras, permitindo a predição de valores (Box & Jenkins, 1970).

A classe geral ARIMA possui variações representadas pelos seguintes filtros: autorregressivo (AR), modelo de médias móveis (MA), modelo autorregressivo e de médias móveis (ARMA), e modelo autorregressivo integrado e de médias móveis (ARIMA) (Box, Jenkins & Reinsel, 1994). O modelo ARIMA (p, d, q) é representado pela Equação 1.

$$\phi(B)\Delta^d X_t = \theta(B)a_t \quad (1)$$

Onde: B é o operador de retardo, d a ordem de integração, ϕ o parâmetro da parte autorregressiva representado no modelo pela letra p , θ o parâmetro de médias móveis representado pela letra q e a_t o resíduo do modelo conhecido como Ruído Branco $a_t \approx N(0, \sigma^2)$, pois apresenta média zero, variância constante e valores não autocorrelacionados (Box & Jenkins, 1970).

Para aplicar a modelagem ARIMA, os dados necessitam ser estacionários e autocorrelacionados. A estacionariedade de uma série temporal é representada pela flutuação dos seus valores em torno de uma média fixa, apresentando variância constante. A autocorrelação consiste na influência de observações passadas sobre os valores de observações futuras (Bueno, 2008). Os pressupostos de estacionariedade e autocorrelação podem ser verificados por meio dos gráficos da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP). Essas funções também auxiliam na identificação do filtro (AR, MA, ARMA ou ARIMA) e da ordem do modelo a ser estimado (Box, Jenkins & Reinsel, 1994).

Os testes de raízes unitárias também podem ser utilizados para confirmar a estacionariedade da série ou verificar qual deve ser a ordem de integração, $d = 0, 1$ ou 2 . O teste de raiz unitária de Dickey-Fuller Aumentado (ADF) assume como hipótese nula que a série possui uma raiz dentro do círculo unitário, ou seja, que a série não é estacionária (Chain, Costa, Sant'Ana & Benedicto, 2015; F. M. Souza, 2016). Conhecer a ordem de integração d é fundamental para realizar o ajuste do modelo ARIMA.

Após o ajuste dos modelos, o melhor modelo será selecionado com base nos pressupostos de parcimônia e de resíduos do tipo Ruído Branco. A parcimônia relaciona-se com o número de parâmetros no modelo, assim, quanto menor o número de parâmetros ajustados para representar o comportamento da série original mais parcimonioso será o modelo (Bueno, 2008). Para verificar a parcimônia do modelo ajustado, utilizam-se estatísticas de ajuste, como os critérios de informação Akaike (AIC) e Bayesiano (BIC) (Brunham & Anderson, 2004; Vrieze, 2012; Aho, Derryberry & Peterson, 2014).

O melhor modelo ajustado será aquele que apresentar os valores mínimos para essas estatísticas, conforme as Equações 2 e 3 (Akaike, 1974; Schwarz, 1978). Estes critérios são denominados penalizadores, pois consideram o número de parâmetros estimados (Bozdogan, 1987).

$$AIC = T \ln(SQR) + 2n \quad (2)$$

$$BIC = T \ln(SQR) + n \ln(T) \quad (3)$$

Onde: T representa o número de observações, SQR a soma dos quadrados dos resíduos e n o número de parâmetros que foram estimados no modelo.

O modelo mais parcimonioso também deverá atender ao pressuposto de resíduos com características de Ruído Branco $a_t \approx N(0, \sigma^2)$: média igual a zero, variância constante e valores não autocorrelacionados (Morettin & Toloj, 2004).

2.2 Modelagem não-linear

O modelo ARCH (p) é um modelo autorregressivo com heterocedasticidade condicional, que tem por objetivo modelar a variância dos resíduos oriundos de um modelo previamente ajustado (Engel, 1982; Morettin & Toloj, 2004). O modelo geral é representado pelas Equações 4 e 5.

$$X_t = \sqrt{h_t} a_t \quad (4)$$

$$h_t = \alpha_0 + \alpha_1 X_{t-1}^2 + \dots + \alpha_i X_{t-i}^2 \quad (5)$$

Onde, X_t é uma série de retornos, a_t o Ruído Branco com distribuição $a_t \approx N(0, \sigma^2)$ e h_t a volatilidade da série.

Após estimados diversos modelos da classe ARCH, o melhor modelo deve ser escolhido com base nos mesmos critérios utilizados na modelagem linear: parcimônia e resíduos do tipo Ruído Branco. Assim, devem-se analisar os valores dos critérios de informação AIC e BIC e realizar a análise dos resíduos, com atenção à sua média, à variância e à independência dos seus valores (Bueno, 2008; Morettin & Toloj, 2004).

3 Metodologia

Para o desenvolvimento desta pesquisa, foi utilizada a variável preço do saco de cimento Portland 32 (50kg), obtida a partir dos dados da Câmara Brasileira da Indústria da Construção (2018). A variável foi analisada por duas perspectivas, pelo preço médio nacional e pelo preço médio da região Sul do país. As duas séries temporais compreendem 284 observações, coletadas no período de junho de 1994 a janeiro de 2018.

A primeira etapa realizada foi a análise gráfica do comportamento das séries originais, a fim de identificar comportamentos não estacionários e verificar a presença de tendência e/ou sazonalidade. Os primeiros pressupostos verificados foram a estacionariedade e a autocorrelação, as quais foram analisadas por meio da FAC e FACP. Também foi utilizado o teste de raiz unitária ADF para confirmar a estacionariedade das séries e indicar a ordem de integração d . Com o auxílio da FAC e FACP, também foi possível determinar o tipo de filtro (AR, MA, ARMA, ARIMA) e a ordem do modelo que seria utilizado para representarem os movimentos de cada série.

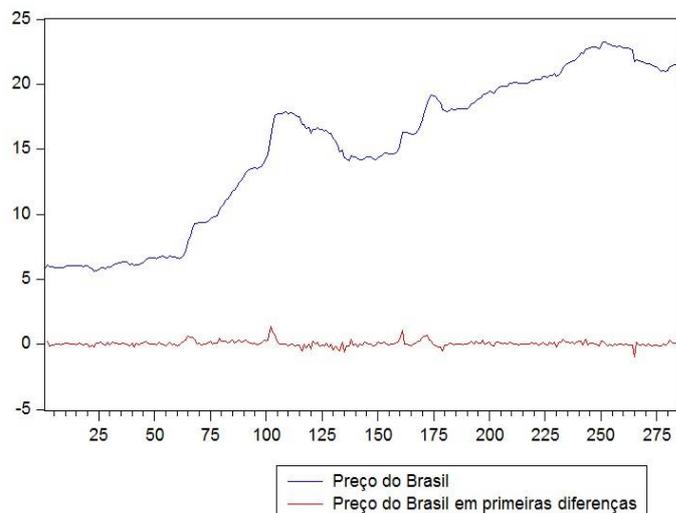
Tendo o conhecimento da ordem de integração, da dependência entre as observações e do tipo de filtro do modelo a ser utilizado, foram estimados modelos da classe geral ARIMA e modelos não-lineares ARCH. Todas as análises gráficas, cálculo de estatísticas e ajustes dos modelos foram realizados com o auxílio do *software EvIEWS 10 SV*.

Após o ajuste dos modelos concorrentes, analisaram-se resíduos, os quais necessitam apresentar característica de Ruído Branco: média zero, variância constante e valores não autocorrelacionados. Essas características foram verificadas por meio dos gráficos da FAC e FACP elaborados a partir dos valores dos resíduos dos modelos estimados. Dentre os modelos que apresentaram resíduos do tipo Ruído Branco, os melhores modelos foram selecionados por meio dos valores mínimos dos critérios de informação AIC e BIC.

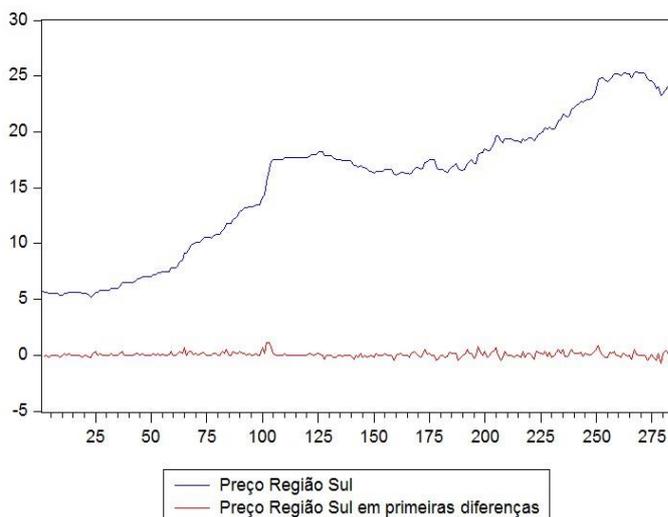
Selecionados os melhores modelos com base nas estatísticas de ajuste, elaboraram-se gráficos dos valores ajustados e dos resíduos da modelagem. Com a análise desses gráficos, pode-se identificar se o modelo ajustado é adequado ou não para representar os movimentos e oscilações das séries originais. Por fim, verificou-se a variância condicional de cada modelo ARCH estimado, por meio do gráfico da volatilidade (σ_{t-1}^2), com o objetivo de identificar qual série do preço do cimento possui maior variabilidade.

3.1 Resultados

Ao analisar o preço do cimento Portland 32, para a média nacional e para a média na região Sul, observa-se nas Figuras 1 e 2 o comportamento das séries em nível e em primeiras diferenças, onde o eixo X representa o número de observações e o eixo Y indica a amplitude dos dados.

Figura 1 - Gráfico da série do preço do cimento no Brasil em nível e em primeiras diferenças

Fonte: Autores.

Figura 2 - Gráfico da série do preço do cimento na região Sul em nível e em primeiras diferenças

Fonte: Autores.

Nota-se que as séries são não estacionárias, devido ao comportamento variável e crescente ao longo do tempo e, ao aplicar as primeiras diferenças, observa-se que ambas as séries se tornam estacionárias. Verificar a estacionariedade da série é o pressuposto básico para a aplicação da modelagem ARIMA.

Com o objetivo de confirmar a não estacionariedade dos dados, realizou-se o teste de raiz unitária ADF, no qual a hipótese nula afirma a existência de raiz unitária. Os resultados do teste são apresentados na Tabela 1.

Tabela 1 – Teste de raiz unitária para o preço do cimento no Brasil e na região Sul

Valor Crítico	Preço do cimento no Brasil		Preço do cimento na região Sul	
	Série em nível	Série em primeiras diferenças	Série em nível	Série em primeiras diferenças
1%	-3,4535	-3,4535	-3,4534	-3,4534
5%	-2,8716	-2,8716	-2,8716	-2,8716
10%	-2,5722	-2,5722	-2,5722	-2,5722
Estatística-t	-1,1704	-6,4332	-1,1395	-11,7893
p-valor	0,6878	< 0,01	0,7007	< 0,01

Fonte: Autores.

Observa-se que as duas séries possuem raiz unitária em nível e se tornam estacionárias em primeiras diferenças, confirmando a conclusão da análise gráfica. Assim, a ordem de integração das séries será $d = 1$.

Antes do ajuste dos modelos, analisaram-se os gráficos da FAC e FACP em primeiras diferenças para as séries do preço no Brasil e na região Sul, com o objetivo de identificar quais os filtros e ordem do modelo que podem melhor representar o comportamento de cada série. Os gráficos podem ser observados nas Figuras 3 e 4.

Figura 3 – Gráficos da FAC e FACP do preço do cimento no Brasil em primeiras diferenças

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	0.462	0.462	61.112	0.000	
2	0.439	0.286	116.33	0.000	
3	0.207	-0.097	128.65	0.000	
4	0.140	-0.041	134.28	0.000	
5	0.048	-0.020	134.97	0.000	
6	0.020	-0.004	135.09	0.000	
7	-0.006	-0.003	135.10	0.000	
8	0.039	0.069	135.55	0.000	
9	0.063	0.058	136.71	0.000	
10	0.123	0.076	141.21	0.000	
11	0.140	0.046	147.01	0.000	
12	0.132	-0.005	152.16	0.000	
13	0.071	-0.061	153.67	0.000	
14	0.024	-0.046	153.84	0.000	
15	0.068	0.107	155.24	0.000	
16	0.007	-0.024	155.25	0.000	
17	0.077	0.069	157.06	0.000	
18	-0.011	-0.069	157.09	0.000	
19	0.092	0.083	159.65	0.000	
20	0.055	0.010	160.58	0.000	
21	0.085	-0.010	162.82	0.000	
22	0.047	-0.019	163.51	0.000	
23	0.121	0.107	168.02	0.000	
24	0.000	-0.098	168.02	0.000	

Fonte: Autores.

Figura 4 – Gráficos da FAC e FACP do preço do cimento na região Sul em primeiras diferenças

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.296	0.296	24.999	0.000
		2	0.126	0.042	29.538	0.000
		3	0.027	-0.023	29.751	0.000
		4	0.013	0.007	29.804	0.000
		5	0.121	0.128	34.028	0.000
		6	0.145	0.086	40.166	0.000
		7	0.120	0.042	44.382	0.000
		8	0.097	0.041	47.125	0.000
		9	-0.019	-0.070	47.233	0.000
		10	0.025	0.036	47.423	0.000
		11	0.096	0.080	50.150	0.000
		12	0.141	0.077	56.040	0.000
		13	0.076	-0.027	57.754	0.000
		14	0.011	-0.029	57.791	0.000
		15	-0.018	-0.014	57.885	0.000
		16	0.038	0.047	58.325	0.000
		17	0.025	-0.022	58.516	0.000
		18	0.151	0.119	65.430	0.000
		19	0.140	0.056	71.397	0.000
		20	0.058	-0.014	72.445	0.000
		21	-0.056	-0.087	73.408	0.000
		22	-0.002	0.040	73.410	0.000
		23	0.027	0.001	73.643	0.000
		24	0.090	0.030	76.151	0.000

Fonte: Autores.

O comportamento dos gráficos da FAC e FACP sugere a aplicação da modelagem ARIMA, com os filtros AR e MA para as duas séries analisadas, com ordem 1 ou 2.

Para realizar a modelagem das séries, foram utilizados os modelos da classe geral ARIMA e os modelos ARCH. Os modelos concorrentes, que apresentaram os melhores resultados para os critérios de AIC e BIC e resíduos com característica de Ruído Branco, são descritos nas Tabelas 2 e 3.

Tabela 2 - Modelos concorrentes ARIMA-ARCH para o preço do cimento no Brasil

Modelo 1	ARIMA (1,1,1)	Coeficientes	Erro-padrão	Estatística-t	p-valor	AIC	BIC		
		$\phi_2 = 0,4513$	0,0532	8,4821	< 0,05	-0,5039	-0,4653		
		$\vartheta_1 = 0,3675$	0,0355	10,3529	< 0,05				
Modelo 2	ARIMA (1,1,1) – ARCH (1,0)	Coeficientes	Erro-padrão	Estatística-z	p-valor	AIC	BIC		
		$\phi_2 = 0,4426$	0,0616	7,1853	< 0,05	-0,5818	-0,5304		
		$\vartheta_1 = 0,3954$	0,0762	5,1928	< 0,05				
		Equação de Variância							
		C = 0,0268	0,0011	23,7992	< 0,05				
$a_{t-1}^2 = 0,1649$	0,0506	3,258	< 0,05						

Fonte: Autores.

Tabela 3 - Modelos concorrentes ARIMA-ARCH para o preço do cimento na região Sul

Modelo 1	ARIMA (2,1,1)	Coeficientes	Erro-padrão	Estatística-t	p-valor	AIC	BIC
		$\phi_1 = 0,3185$	0,0424	7,5106	< 0,05	-0,1731	-0,1216
$\phi_5 = 0,4952$	0,1176	4,2121	< 0,05				
$\vartheta_5 = -0,4154$	0,1329	-3,1269	< 0,05				
Modelo 2	ARIMA (2,1,1) – ARCH (1,0)	Coeficientes	Erro-padrão	Estatística-z	p-valor	AIC	BIC
		$\phi_1 = 0,3502$	0,0691	5,0674	< 0,05	-0,1834	-0,1182
		$\phi_5 = 0,4549$	0,1149	3,9563	< 0,05		
		$\vartheta_5 = -0,3611$	0,1249	-2,8895	< 0,05		
		Equação de Variância					
C = 0,0409	0,0029	14,0501	< 0,05				
$\alpha_{t-1}^2 = 0,1739$	0,0863	2,0156	< 0,05				

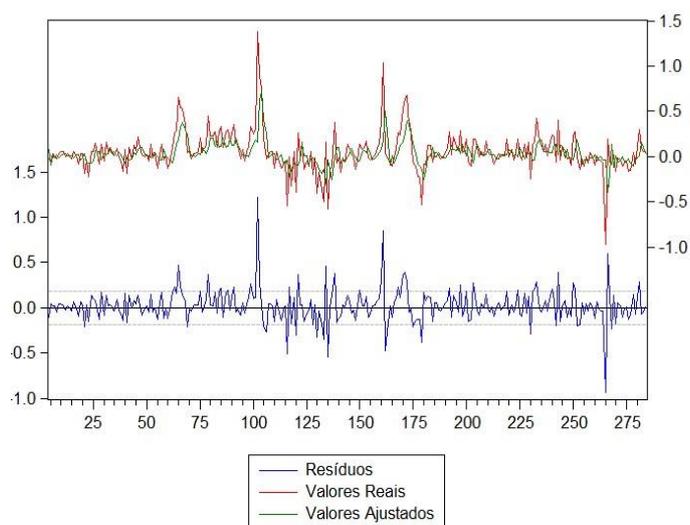
Fonte: Autores.

Dentre todos os modelos ajustados, nas Tabelas 2 e 3 estão descritos apenas os melhores modelos encontrados para a classe ARIMA e ARCH em ambas as séries. Observa-se que todos os parâmetros são significativos com p-valor inferior a 5%. Os modelos que captam o efeito da volatilidade nas séries demonstraram os melhores resultados, tanto para o preço médio do cimento no Brasil quanto para o preço na região Sul.

O melhor modelo para a série do preço do cimento no Brasil é um ARCH, com 1 parâmetro autorregressivo no *lag* 2, ordem de integração igual a 1, e 1 parâmetro de médias móveis no *lag* 1. Para a série do preço do cimento na região Sul, o melhor modelo também é um ARCH, com 2 parâmetros autorregressivos, um no *lag* 1 e outro no *lag* 5, ordem de integração igual a 1, e 1 parâmetro de médias móveis no *lag* 5.

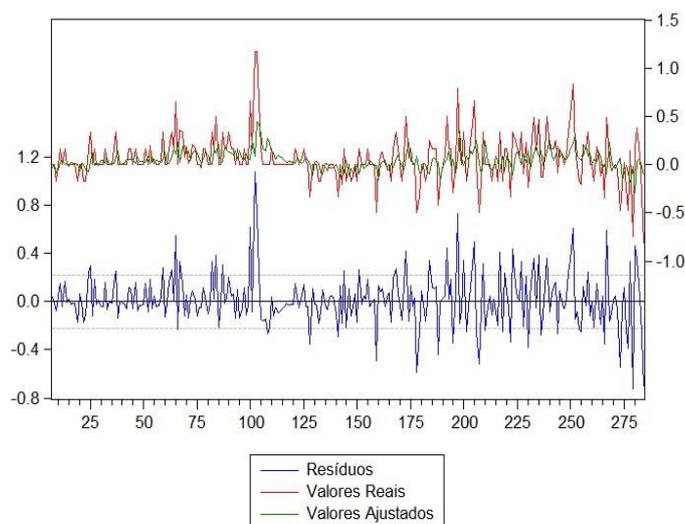
Para analisar se os modelos ajustados conseguem captar os movimentos da série original, elaboraram-se os gráficos que representam os valores ajustados e os resíduos da modelagem. O desempenho dos modelos pode ser verificado nas Figuras 5 e 6.

Figura 5 – Gráfico dos valores reais, ajustados e resíduos do modelo ARIMA - ARCH do preço do cimento no Brasil



Fonte: Autores.

Figura 6 – Gráfico dos valores reais, ajustados e resíduos do modelo ARIMA - ARCH do preço do cimento na região Sul



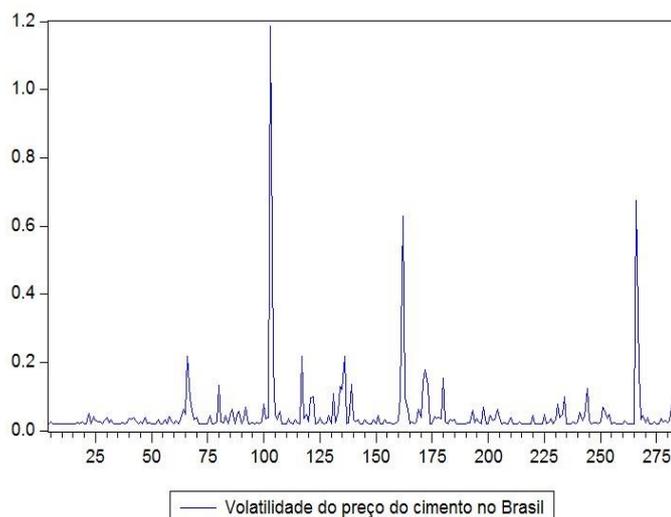
Fonte: Autores.

Observa-se que as séries estimadas convergem para a séries originais, mostrando que os modelos ajustados conseguem captar os movimentos oscilatórios das séries. Contudo, ao analisar os valores ajustados para o preço na região Sul, percebe-se que o modelo estimado não é capaz de identificar totalmente a variabilidade da série real.

Ademais, os resíduos oriundos da modelagem representam de forma consistente a volatilidade dos dados, o que indica que seria mais assertivo utilizar os resíduos para realizar uma análise mais aprofundada, como a elaboração de gráficos de controle (Montgomery, 1997).

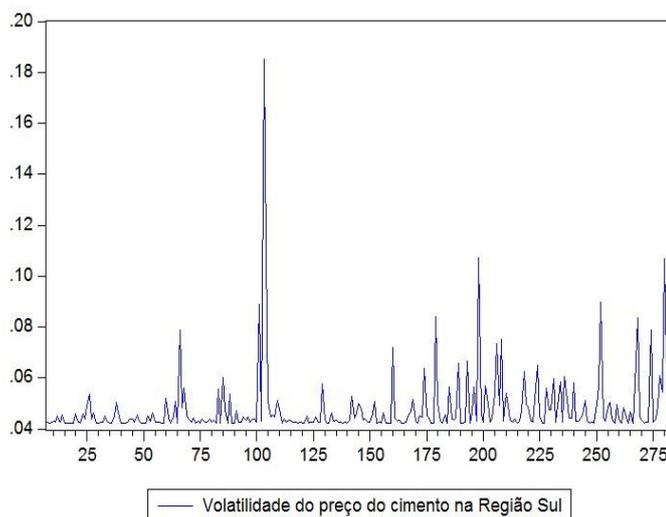
Ao analisar os resultados da etapa de ajuste e o comportamento das séries nos gráficos em nível e da FAC e FACP, pode-se afirmar que as séries possuem volatilidade. No caso do preço do cimento no Brasil, a volatilidade é igual a $\alpha_{t-1}^2 = 0,1649$, e para o preço na região Sul, $\alpha_{t-1}^2 = 0,1739$. Nas Figuras 7 e 8, observa-se a variância condicional presente em cada uma das séries.

Figura 7 – Gráfico da volatilidade do preço do cimento no Brasil



Fonte: Autores.

Figura 8 – Gráfico da volatilidade do preço do cimento na região Sul



Fonte: Autores.

Com a análise dos gráficos, verifica-se que o maior pico de volatilidade ocorre de forma simultânea na 104ª observação, a qual corresponde ao período de janeiro de 2003. Nesse período, a variação percentual do preço do cimento foi de 4,27% no Brasil e 2,94% na região Sul. Além disso, também se observa que a persistência da volatilidade do preço do cimento é maior para a região Sul

do país, porém a amplitude de variação é maior para o preço médio nacional.

4 Conclusão

Dentro da análise de séries temporais, o uso da modelagem ARCH é pertinente quando as observações apresentam volatilidade. Nesta pesquisa, o objeto de estudo foi o preço do cimento Portland 32 praticado na região Sul do país e a média do preço nacional, com dados coletados entre junho de 1994 a janeiro de 2018.

Como os preços apresentaram valores autocorrelacionados e volatilidade, a etapa de ajuste teve como base a modelagem ARIMA, responsável por tratar a autocorrelação, e a modelagem ARCH, que tratou a variância condicional dos dados. O ajuste do modelo de volatilidade possibilitou captar os movimentos oscilatórios do preço do cimento e proporcionou uma previsão mais assertiva.

Dado que o preço do cimento é influenciado por diversas variáveis, verifica-se que quando houver algum choque na produção ou na venda de cimento, o preço nacional terá um impacto grande e momentâneo, enquanto que os preços da região Sul irão variar em menor escala e por um período mais longo. Portanto, conhecer a volatilidade do preço do cimento de maneira nacional e regional auxilia os gestores de empresas do ramo da construção civil a gerenciarem seus estoques e programarem as compras desse produto de uma forma mais eficaz e lucrativa.

Sugere-se para pesquisas futuras a análise das demais variáveis que impactam na volatilidade do preço do cimento, como a cotação do dólar e o PIB brasileiro, bem como o ajuste de modelos econométricos e elaboração de gráficos de controle a partir dos resíduos da modelagem ARCH.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) e do Laboratório de Análise e Modelagem Estatística (LAME) da Universidade Federal de Santa Maria – UFSM.

Referências

- Aho, K., Derryberry, D. W. & Peterson, T. (2014). Model selection for ecologists: the worldviews of AIC and BIC. *Ecology*, 95(3), 631-636.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723.
- Box, G. E. P. & Jenkins, G. M. (1970). *Time series analysis, forecasting and control*. San Francisco: Holden-Day.

- Box, G. E., Jenkins, G. M. & Reinsel, G.C. (1994). *Time series analysis: Forecasting and control* (3a ed.). New Jersey: Printice Hall.
- Bozdogan, H. (1987). Model selection and Akaike's information criterion (AIC): The general theory and its analytical extensions. *Psychometrika*, 52(3), 345-370.
- Bueno, R. de L. da S. (2008). *Econometria de séries temporais*. São Paulo: Cengage Learning.
- Burnham, K. P. & Anderson, D. R. (2004). Multimodel Inference: Understanding AIC and BIC in Model Selection. *Sociological Methods & Research*, 33(2), 261-304.
- Câmara Brasileira da Indústria da Construção. (2018). *Banco de Dados: consumo, produção e valores de materiais de construção*. Recuperado em 26 março, 2018, de <http://www.cbicdados.com.br/menu/materiais-de-construcao/cimento>
- Capozza, D. R., Hendershott, P. H., Mack, C. & Mayer, C. J. Determinants of real house price dynamics. *National Bureau of Economic Research*, 2002.
- Chain, C. P., Costa, D. F., Sant'Ana, N. L. dos S. & Benedicto, G. C. de (2015). Contribuição da modelagem de valores atípicos na previsão da arrecadação do ICMS do Estado de Minas Gerais. *Exacta*, 13(2), 239-249.
- Coelho, L. M., Jr., Rezende, J. L. P. de, Sáfyadi, T. & Calegário, N. (2009). Análise do comportamento temporal dos preços da borracha natural no mercado internacional. *Ciência Florestal*, 19(3), 293-303.
- Departamento de Pesquisas e Estudos Econômicos. (2017, junho). *Cimento*. Recuperado em e maio, 2018, de https://www.economiaemdia.com.br/EconomiaEmDia/pdf/infset_cimento.pdf
- Engle, R. F. (1982). Autoregressive Conditional Heteroskedasticity With Estimates of The Variance of United Kingdom Inflation. *Econometria*, 50(4), 987-1008.
- Hwang, S., Park, M., Lee, H. S. & Kim, H. (2012). Automated Time-Series Cost Forecasting System for Construction Materials. *Journal of Construction Engineering and Management*, 138, 1259-1269.
- Montgomery, D.C. (1997). *Introduction to statistical quality control* (3a ed.). New York: John Wiley & Sons, Inc.
- Morettin, P. A. & Toloi, C. M. C. (2004). *Análise de séries temporais* (2a ed.). São Paulo: Edgard Blücher.
- Moura, G. C. de. (2017). *Previsão do custo unitário básico por meio de modelos de previsão da classe geral ARIMA*. Monografia (Graduação em Engenharia Civil), Universidade Regional do Noroeste do Estado do Rio Grande do Sul – UNIJUÍ, Santa Rosa, RS, Brasil. Disponível: <http://bibliodigital.unijui.edu.br:8080/xmlui/handle/123456789/5077>
- Reichert, B. & Souza, A. M. (2016, outubro). *Análise do comportamento futuro do preço do cimento Portland CP IV*. Pôster apresentado no XXXVI Encontro Nacional de Engenharia de Produção, João Pessoa, PB, Brasil. Recuperado em 6 maio, 2018, de http://www.abepro.org.br/biblioteca/TN_STP_231_347_28799.pdf
- Schneider, D. L. (2018). *Análise dos custos e receitas sobre as vendas na construção civil*. Monografia (Graduação em Ciências Contábeis), Universidade do Vale do Taquari - Univates, Lajeado, RS, Brasil. Disponível: <http://hdl.handle.net/10737/1973>.

Schwarz, G. E. (1978). Estimating the dimension of a model. *Annals of Statistics*, 6(2), 461-464.

Souza, A. M, Souza, F. M., Zanini, R. R. & Menezes, R. (2012). *Modelagem ARIMA-ARCH para a obtenção de resíduos aptos à aplicação de gráficos de controle na presença de correlação e auto-correlação*. Pôster apresentado no XXXII Encontro Nacional de Engenharia de Produção, Bento Gonçalves, RS, Brasil. Recuperado em 6 maio, 2018, de http://abepro.educacao.ws/biblioteca/enegep2012_TN_STO_162_943_19695.pdf

Souza, F. M., Almeida, S. G. de, Guarnieri, J. P., Souza, A. M. & Lopes, L. F. D. (2010). Previsão do consumo de cimento no Estado do Rio Grande do Sul. *Pesquisa operacional para o Desenvolvimento*, 2(1), 3-11.

Souza, F.M. (2016). *Modelos de previsão: aplicações à energia elétrica ARIMA-ARCH-AI e ACP* (1a ed.). Curitiba: Appris.

Souza, P. V. S. de, Costa, J. R. B. da & Silva, E. J. da. (2017). A relação dos fatores econômico-financeiros das empresas do setor de construção civil com os preços no mercado imobiliário. *Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ*, 22(3), 17.

Vrieze, S. I. (2012). Model selection and psychological theory: A discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC). *Psychological Methods*, 17(2), 228-243.

Recebido em: 03 out. 2018 / **Aprovado em:** 01 abr. 2019

Para referenciar este texto

American Psychological Association (APA)

Reichert, B., & Souza, A. M. (2020). Impacto da volatilidade no preço do cimento Portland. *Exacta*, 18(3), 475-488. <https://doi.org/10.5585/ExactaEP.v18n3.10660>.