

PREVISÃO DO CONSUMO DE CIMENTO NO ESTADO DO RIO GRANDE DO SUL

Francisca Mendonça Souza

kikamatcom@yahoo.com.br

PPGEP-UFSM

Silvana Gonçalves de Almeida

silmtm@yahoo.com.br

PPGEP-UFSM

Jean Paulo Guarneri

jpguarneri@gmail.com

PPGEP-UFSM

Adriano Mendonça Souza

amsouza.sm@gmail.com

DE-UFSM

Luis Felipe Dias Lopes

lflopes@smail.ufsm.br

DE-UFSM

Resumo

O cimento é um insumo básico da indústria de construção, utilizado em grandes quantidades na produção de habitações, de infra estrutura, de estradas, de pontes, de saneamento e de hidrelétricas. O volume da produção brasileira tem a mesma ordem de grandeza do consumo, ou seja, a produção nacional possui um dimensionamento ajustado à demanda interna, com excedentes da ordem de apenas 0,3% a 0,4% da produção. O objetivo desta pesquisa é realizar previsões de curto prazo do consumo de cimento no Rio Grande do Sul e também realizar a monitoração dessa variável. Para o seu desenvolvimento, são utilizados os modelos Auto-regressivos Integrados de Médias Móveis – ARIMA por meio da metodologia Box & Jenkins e gráficos de controle aplicados aos resíduos. As observações foram consultadas na Fundação de Economia e Estatística e são referentes à quantidade mensal de produção de cimento no Rio Grande do Sul, em toneladas, durante o período de janeiro de 1998 a dezembro de 2008. Ao encontrarem-se os modelos concorrentes que explicaram o fenômeno em estudo, realizou-se a análise dos resíduos, procurando-se sempre por modelos que forneçam ruído branco, isto é, com média zero, variância constante e não-autocorrelacionados. O modelo selecionado será aquele que satisfizer os critérios do AIC e BIC, o menor valor destes critérios sinalizará para o modelo mais propício para as previsões desejadas. A partir do melhor modelo, foram realizadas previsões para o consumo de cimento de janeiro a junho de 2009. Para monitorar o comportamento desta variável, foi construído um gráfico de controle de observações individuais para a média. O melhor modelo encontrado foi um SARIMA (2,1,0)(1,0,0)₁₂ e por meio dos gráficos de controle não foi possível comprovar instabilidade na série em estudo.

Palavras-chave: Modelos de Memória Longa (ARFIMA), Cimento, Gráfico de Controle.

Abstract

Cement is a basic input for the construction industry, used in large quantities in the production of housing, infrastructure, roads, bridges, sanitation and hydroelectric. The volume of Brazilian production has the same order of magnitude of consumption, i.e., domestic production has a size adjusted to

domestic demand, with surpluses in the order of only 0.3% to 0.4% of production. The objective of this research is to forecast short-term consumption of cement in Rio Grande do Sul and also carry out monitoring of this variable. For the development of this research an Auto-regressive integrated moving averages - ARIMA will be used applying the Box & Jenkins methodology and control charts to control residues of the ARIMA model. The data were collected at the Foundation of Economics and Statistics in Rio Grande do Sul, the data collected is the quantity of monthly production of cement, in tons, during the period January, 1998 to December, 2008. The competing models that explain the phenomenon studied, the residues were analyzed and the white noise was searched in the models. The model selected is that which meets the AIC and BIC criteria, showing the lower value to these criteria, to showing the model is appropriate to forecast future values. The best consumption of cement estimated model, forecasting values were done to period from January, 2009 to June, 2009. To monitor the behavior of this variable a mean control chart to individual observations was applied to the residues series from the best model found. The SARIMA (2,1,0)(1,0,0)₁₂ was the best model found and the control chart do not show any evidence about the process instability.

Keywords: Long Memory Models (ARFIMA), Cement, Control Charts.

1. Introdução

O cimento é um insumo básico da indústria de construção, utilizado em grandes quantidades na produção de habitações, de infra-estrutura, de estradas, de pontes, de saneamento e de hidrelétricas. O setor de construção civil, que é um grande demandante deste produto, tem demonstrado interesse particular nessa questão. A indústria do cimento e a de artefatos de cimento participam com 2,55% da composição do macro-setor da construção, empregando em torno de 140 mil trabalhadores e gerando renda no montante aproximado de R\$ 3 bilhões/ano (aproximadamente \$ 6 bilhões/ano). O volume da produção brasileira tem a mesma ordem de grandeza do consumo, ou seja, a produção nacional possui um dimensionamento ajustado à demanda interna, com excedentes da ordem de apenas 0,3% a 0,4% da produção. O volume produzido corresponde muito mais à capacidade de absorção do mercado do que à capacidade instalada. Neste aspecto, destaca-se uma preocupação, dado que o consumo *per capita* é crescente e vem evoluindo nos últimos anos. A escassez de recursos para grandes obras e a falta de investimentos em construção vêm reduzindo a participação das empresas construtoras, empreiteiras e consumidores industriais na distribuição do consumo de cimento nacional. Contudo, a partir de 2000, houve uma inflexão na curva de produção e consumo do cimento. Registra-se queda acumulada nesses últimos 4 anos de 16,5% no consumo nacional do produto que em 2003 atingiu apenas 33.563 toneladas. O consumo *per capita* foi de 190 kg/hab., aproximando-se das cifras registradas no início dos anos 90. Dado que o volume de produção está bem próximo ao da capacidade de absorção do mercado, os excedentes exportáveis têm sido inexpressivos nos últimos anos. Além disso, devido à perecibilidade do produto e ao alto custo relativo do transporte, o comércio internacional é relativamente pouco representativo no Brasil. As importações do produto, que não têm ultrapassado 1,5% da produção, pouco têm contribuído como incentivo à indústria nacional na fixação de preços menores, dados os seus níveis insignificantes (CBI, CÂMARA BRASILEIRA DA INDÚSTRIA DA CONSTRUÇÃO).

Esta pesquisa engloba dados mensais de janeiro de 1998 a dezembro de 2008, obtidos junto à FEE – Fundação de Economia e Estatística, para o estado do Rio Grande do Sul. O estudo delimita-se a produção e consumo de cimento.

Pretende-se mostrar a aplicabilidade dos modelos ARIMA (*Auto Regressive Integrated Moving Average*) na previsão de demanda de produção de cimento no Rio Grande do Sul, aplicando a metodologia de Box & Jenkins (1976). Será encontrado o melhor modelo que representa a série em estudo, consumo de cimento, e aplicado de um gráfico de controle X-barra nos resíduos do melhor modelo encontrado, pois os dados originais são autocorrelacionados. Desta forma, o melhor modelo ajustado produzirá resíduos que representam o componente da série e que são não-autocorrelacionados.

Segundo Makridakis et al. (1998), realizar previsões para os setores produtivos da economia é importante para auxiliar, tanto o governo como as empresas que compõem esse setor, na determinação dos recursos necessários. As previsões do consumo de cimento fornecerão mais um subsídio para algumas tomadas de decisões no gerenciamento da produção futura. Assim, conhecendo o comportamento desta variável antecipadamente, medidas gerenciais poderão ser implementadas pelos setores responsáveis. O objetivo desta pesquisa é realizar previsões de curto prazo do consumo de cimento no Rio Grande do Sul e também realizar a monitoração dessa variável.

2. Revisão de Literatura

Nesta seção serão apresentadas as definições de Séries Temporais, os Modelos de Box & Jenkins, os critérios de seleção penalizadores e um breve comentário sobre gráficos de controle, fundamentais para a previsão da produção de cimento no Estado do Rio Grande do Sul.

2.1 Séries Temporais

Uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo. A característica mais importante desse tipo de dados é que as observações vizinhas são dependentes e o interesse é analisar e modelar essa dependência. Enquanto em modelos de regressão, por exemplo, a ordem das observações é irrelevante, para a análise em séries temporais, a ordem dos dados é crucial. Como a maior parte dos procedimentos estatísticos foi desenvolvida para analisar observações independentes, o estudo de séries temporais requer o uso de técnicas específicas.

Algumas características são particulares a esse tipo de dados, por exemplo:

- Observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas;
- É necessário levar em conta a ordem temporal das observações;
- Fatores complicadores como presença de tendências e variação sazonal ou cíclica, podem ser difíceis de estimar ou remover;
- A seleção de modelos pode ser bastante complicada, e as ferramentas podem ser de difícil interpretação;
- É mais difícil lidar com observações perdidas e dados discrepantes devido à natureza sequencial.

2.2 Modelos Box & Jenkins

Os modelos de Box & Jenkins consistem em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA (p,d,q), a um conjunto de dados.

Nesta modelagem consideram-se somente os processos chamados não-estacionários homogêneos, isto é, aquela classe de processos não-estacionários para os quais as diferenças sucessivas produzem um processo estacionário. Segundo Morettin & Tolo (2004), a hipótese de erros não-correlacionados introduz sérias limitações na validade dos modelos do tipo $z_t = f(t) + a_t; t = 1, \dots, N$ para descrever o comportamento de série econômicas e sociais, em que as observações são autocorrelacionadas e influenciam a evolução do processo. Então, para esses casos, os modelos ARIMA são úteis para os propósitos desta pesquisa.

Uma das características fundamentais da metodologia Box & Jenkins é interpretar uma série temporal como sendo uma realização de um vetor aleatório multivariado, cuja dimensão é equivalente à série disponível. A partir de uma única realização do processo e com os argumentos de estacionariedade e ergodicidade do processo subjacente, procura-se detectar o sistema gerador da série através das informações nela contidas. Deve-se escolher um modelo com o menor número de parâmetros possíveis para uma adequada representação matemática. A estratégia para a construção do modelo é baseada nos seguintes itens: Considera-se uma classe geral de modelos para análise; analisam-se as autocorrelações e autocorrelações parciais para ajudar a identificar o modelo; estimam-se os parâmetros do modelo identificado; realiza-se a

verificação ou diagnóstico do modelo ajustado através de uma análise de resíduos para saber se é adequado para fins deste estudo.

Como uma série temporal tem os dados coletados sequencialmente ao longo do tempo, espera-se que ela apresente correlação seriada no tempo. Os modelos de Box & Jenkins, genericamente conhecidos por Auto-regressivos Integrados de Médias Móveis (ARIMA – Auto Regressive Integrated Moving Average), são modelos matemáticos que visam captar o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal. Se essa estrutura de correlação for bem modelada, fornecerá boas previsões. Quando os modelos apresentam sazonalidade, temos definido um modelo SARIMA (p,d,q)(P,D,Q)s, onde p e q referem-se, respectivamente, às ordens auto-regressiva e de média móvel; enquanto que P e Q referem-se, respectivamente, à ordem auto-regressiva sazonal e de média móvel sazonal (VICINI & SOUZA, 2007). Segundo Fava (2000), os modelos ARIMA resultam da combinação de três componentes denominados filtros: o componente Auto-regressivo (AR), o filtro de Integração (I) e o componente de Médias Móveis (MA). Uma série pode ser modelada pelos três filtros ou por apenas um subconjunto deles, resultando em vários modelos. Os modelos ARIMA exploram a autocorrelação entre os valores da série em instantes sucessivos, mas quando os dados são observados em períodos inferiores a um ano, a série também pode apresentar autocorrelação para uma estação de sazonalidades. Os modelos que contemplam as séries que apresentam autocorrelação sazonal são conhecidos como SARIMA. O componente sazonal (St) mostra as flutuações ocorridas em subperíodos (como anos), ocorrendo por exemplo, mensalmente, trimestralmente ou diariamente (Ferraz M. I. F., Sáfadi, T., 2009).

2.3 Critérios de Seleção Penalizadores

Morretin e Tolo (2004) aconselham na etapa de identificação do modelo, encontrar não somente um único modelo, mas sim, vários modelos significativos, para que posteriormente possa ser escolhido o melhor, através dos critérios penalizadores AIC (*Akaike Information Criteria*) e SBC (*Schwartz Bayesian Criteria*), que buscam encontrar modelos parcimoniosos, ou seja, aqueles com menor número de parâmetros.

Dessa forma, o AIC sugere escolher o modelo cujas ordens p e q minimizam o critério, onde $\hat{\sigma}_{p,q}^2$ é o estimador de máxima verossimilhança de σ^2 para um modelo ARMA(p, q). Na equação 2.1 demonstra-se como é encontrado o AIC.

$$AIC(p, q) = \ln \hat{\sigma}_{p,q}^2 + \frac{2(p+q)}{N} \quad \text{Equação 2.1}$$

Assim, minimizar corresponde a identificar as ordens p e q que equilibrem esse comportamento.

Akaike (1970) e Schwarz (1978) sugerem minimizar o SBC, que, em um modelo ARMA, é dado por:

$$BIC(p, q) = \ln \hat{\sigma}_{p,q}^2 + (p+q) \frac{\ln N}{N} \quad \text{Equação 2.2}$$

que $\hat{\sigma}_{p,q}^2$ é a estimativa de máxima verossimilhança da variância residual do modelo ARMA(p,q).

2.4 Gráficos de Controle

O gráfico de controle de Shewhart é uma regra de decisão estatística tomada com base nas observações de um processo para determinar se a característica de qualidade que está sendo monitorada desviou-se de seu valor-alvo. Essa forma de monitoramento é comum na indústria, pois serve para distinguir causas comuns de causas especiais de variação, identificar o instante em que o processo foi alterado, entender a causa raiz do desajuste e melhorar o processo prevenindo reincidências (CLARO et al., 2007). Cartas de controle são habitualmente planejadas e avaliadas assumindo que observações consecutivas do processo são independentes

e identicamente distribuídas (*i.i.d.*), entretanto, essa hipótese é frequentemente violada na prática, pois a maioria dos processos apresenta autocorrelação (MONTGOMERY, 2001).

Uma estratégia frequentemente utilizada consiste em ajustar as observações da característica de qualidade a um modelo de previsão apropriado e monitorar o processo com cartas de controle para os resíduos *i.i.d.* resultantes (MONTGOMERY; MASTRANGELO, 1991; SUPERVILLE; ADAMS, 1994; BOX & LUCEÑO (1997); TESTIK, 2005). Essa forma de monitoramento, entretanto, apresenta inconvenientes:

a) cartas de controle de Shewhart que utilizam resíduos como estatística de monitoramento têm baixo desempenho quando o modelo do processo é AR(1), pois logo após o desajuste há grande discrepância entre os valores previstos e observados. Entretanto, no instante seguinte, os valores previstos acompanham o deslocamento da média, e os resíduos diminuem significativamente;

b) o gráfico não é adequado para a detecção de pequenos deslocamentos em processos com correlação média e positiva;

c) sua interpretação é difícil para uma boa parte dos técnicos que atuam no “chão-de-fábrica”;

d) ajustar e manter um modelo de séries temporais apropriado para cada variável do processo requer considerável esforço (FALTIN et al., 1997).

3. Metodologia

Para o desenvolvimento desta pesquisa, serão utilizados os modelos Auto-regressivos Integrados de Médias Móveis – ARIMA por meio da metodologia Box & Jenkins (BOX & JENKINS, 1976) e gráficos de controle.

As observações analisadas foram obtidas na Fundação de Economia e Estatística e referem-se à quantidade mensal de produção de cimento no Rio Grande do Sul, em toneladas, durante o período de janeiro de 1998 a dezembro de 2008.

Logo após ao encontrarem-se os modelos concorrentes que explicariam o fenômeno em estudo, realizou-se a análise dos resíduos, procurando-se sempre por modelos que fornecessem ruído branco, isto é, com média zero, variância constante e não-autocorrelacionados. O modelo selecionado será aquele que satisfaça os critérios do AIC e BIC, em que o menor valor do AIC e/ou BIC sinalizará para o modelo mais propício para as previsões desejadas. Também, leva-se em consideração o modelo mais parcimonioso, facilitando, assim, a escolha do modelo mais adequado para as séries em estudo e tornando possíveis as previsões necessárias (BOX & LUCEÑO, 1997).

Encontrado o melhor modelo, este será utilizado para realizar previsões a fim de auxiliar no aumento do desempenho das medidas gerenciais. Para verificar se o modelo captou o comportamento da série, será construído um gráfico de controle X-barra a partir dos resíduos do modelo escolhido.

4. Resultados e Discussão

O volume da produção brasileira tem a mesma ordem de grandeza do consumo, ou seja, a produção nacional possui um dimensionamento ajustado à demanda interna, com excedentes da ordem de apenas 0,3% a 0,4% da produção. O volume produzido corresponde muito mais à capacidade de absorção do mercado do que à capacidade instalada. Nesse aspecto, destaca-se uma preocupação, quanto produção e consumo deste produto dado que o consumo *per capita* é crescente, assim as previsões disponibilizam subsídios para planejamentos necessários.

4.1 Consumo de Cimento

Para identificar o modelo apropriado que representa a série de consumo de cimento (em toneladas) em uma série temporal, o primeiro passo é a inspeção gráfica, que mostra o comportamento da série analisada. Portanto na Figura 1, mostra-se o gráfico do consumo de

cimento no Rio Grande do Sul na linha contínua, onde a mesma possui uma média constante até a observação 40 e, após este período, ocorrem variações no nível da série.

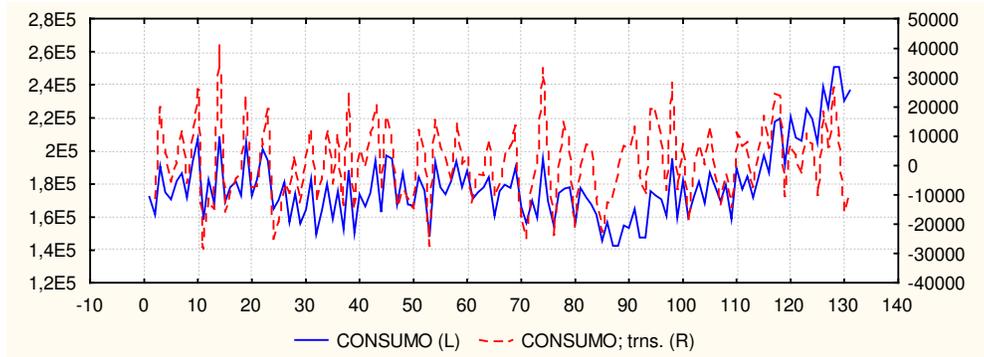


Figura 1 – Série original e diferenciada do consumo de cimento, no RS, de jan/98 a dez/08.

Logo, pode-se observar que até a observação 40, que corresponde ao ano de 2001, o consumo era perfeitamente previsível, pois embora houvesse uma variabilidade na série, a média de consumo se mantinha constante. Após este período, houve um declínio e posteriormente um crescimento de consumo do produto. Dessa forma, não mais é suficiente uma expectativa baseada no consumo médio para se conhecer o comportamento futuro.

O próximo passo consiste em analisar as funções de autocorrelação (FAC) e autocorrelação parcial (FACP). Pelo do comportamento dessas funções, tem-se informações do tipo de filtro que será utilizado (AR, MA, ARMA ou ARIMA) assim como a possibilidade de se fazer uma inspeção visual da estacionariedade da série. As figuras 3a e 3b apresentam respectivamente a FAC e a FACP da série de produção de cimento, nota-se que a mesma possui características de não estacionariedade, pois apresenta um decaimento lento da FAC.

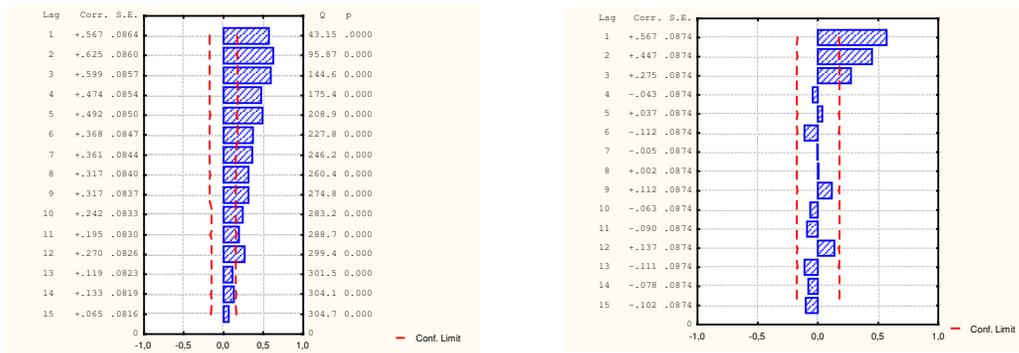


Figura 2 – (a) Função de Autocorrelação e (b) Autocorrelação Parcial da série original do consumo de cimento.

As figuras apresentam respectivamente a FAC e a FACP da série de consumo de cimento, que possui características de não-estacionariedade, pois apresenta um decaimento lento para zero.

O próximo procedimento metodológico é a identificação dos modelos significativos que representem o comportamento da série do consumo de cimento no RS. Através da análise da Tabela 1, é possível observar os modelos significativos encontrados, uma vez que todos apresentam coeficientes com nível de significância (*p-value*) menor que 5% e respeitam as condições de estacionariedade e invertibilidade, porque seus valores, em módulo, são menores que um.

Tabela 1 – Modelos encontrados para a série do consumo de Cimento

Modelo	Coefficientes Estimados	Nível de Significância (<i>p</i> -valor) dos Coeficientes	AIC
SARIMA(2,1,0)(1,0,0) ₁₂	$\phi_1 = -0,840260$ $\phi_2 = -0,418199$ $\Phi_1 = 0,291275$	0,0001 0,0001 0,0014	19,061
SARIMA(2,1,0)(0,0,1) ₁₂	$\phi_1 = -0,8052$ $\phi_2 = -0,3812$ $\theta_1 = 0,88959$ $\Theta_1 = -0,2164$	0,0001 0,0003 0,0001 0,0101	19,214
SARIMA(2,1,0)(0,0,1)₁₂	$\phi_1 = -0,847138$ $\phi_2 = -0,416041$ $\Theta_1 = -0,224873$	0,0001 0,0001 0,0067	19,066
SARIMA(2,1,1)(0,1,1) ₁₂	$\phi_1 = -0,7910$ $\phi_2 = -0,4334$ $\theta_1 = 0,41101$ $\Theta_1 = 0,46237$	0,0001 0,0005 0,0011 0,0001	19,602

O melhor modelo encontrado foi o SARIMA (2,1,0)(0,0,1)₁₂, porque apresenta menores valores para o critérios AIC e condiz com a realidade de que existem períodos de flutuação do consumo de cimento neste período. Os resíduos oriundos deste modelo são não-correlacionados, com distribuição aleatória em torno de zero e variância aproximadamente constante, caracterizando-se, portanto, como ruído branco. Nas figuras 4a e 4b, estão demonstradas a FAC e a FACP dos resíduos do modelo escolhido, SARIMA (2,1,0)(0,0,1)₁₂.

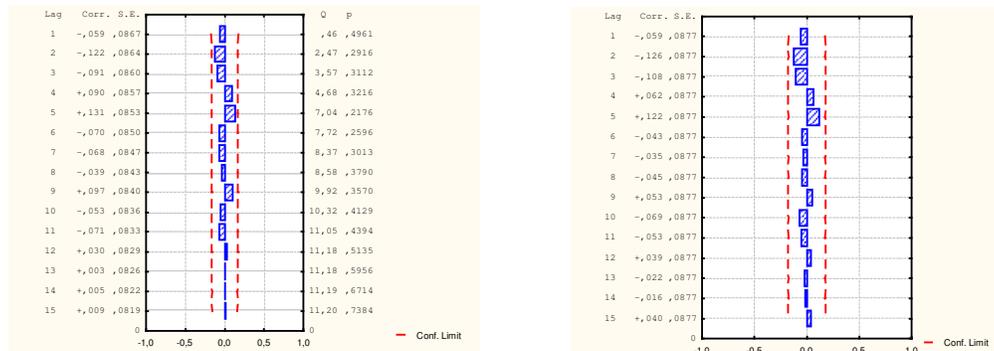


Figura 3 – (a) Função de Autocorrelação e (b) Autocorrelação Parcial dos resíduos do modelo SARIMA (2,1,0)(0,0,1)₁₂.

A FAC residual do modelo mostra que a autocorrelação dos resíduos estão dentro dos limites de confiabilidade de 95%, assim como ocorre na FACP. Logo, esses resíduos são não-autocorrelacionados. Encontrado o modelo mais adequado, o próximo passo é utilizá-lo para que seja possível realizar previsões para um período de seis meses. Através da tabela 2, é possível visualizar as previsões mensais de janeiro a junho de 2009, o erro padrão e os limites com 95% de confiabilidade.

Tabela 2 – Previsão da série do consumo de cimento no RS (em toneladas), para o período de jan/09 a jun/09

Meses	Previsões	Limites Inferior 95%	Limites Superior 95%	Erro Padrão
Jan/09	241.581,9	245.410,1	268.753,6	13.731,28
Fev/09	235.659,1	208.171,8	263.146,5	13.890,78
Mar/09	237.886,1	207.250,7	268.020,1	15.228,13
Abr/09	240.903,7	207.250,7	274.556,7	17.006,60
Mai/09	239.077,8	204.152,2	274.003,3	17.649,88
Jun/09	237.112,5	199.837,4	274.387,5	18.837,02

A série original de consumo de cimento no Rio Grande do Sul apresentava-se autocorrelacionadas, o que era um entrave para a aplicação de gráficos de controle, representou a não-autorrelação das observações. Pelo modelo ajustado adequadamente na série em estudo, foi possível eliminar esta autocorrelação e também obter um conjunto normal, possibilitando a aplicação de gráficos de controle.

Para verificar se o modelo expressou o comportamento da série, foi construído um gráfico de controle X-barra, a partir dos resíduos do modelo escolhido. Este serve para captar a variação apresentada pelo consumo de cimento no Rio Grande do Sul. A figura 6 apresenta o gráfico de controle X-barra com $n=1$ para os resíduos do modelo $SARIMA(2,1,0)(0,0,1)_{12}$.

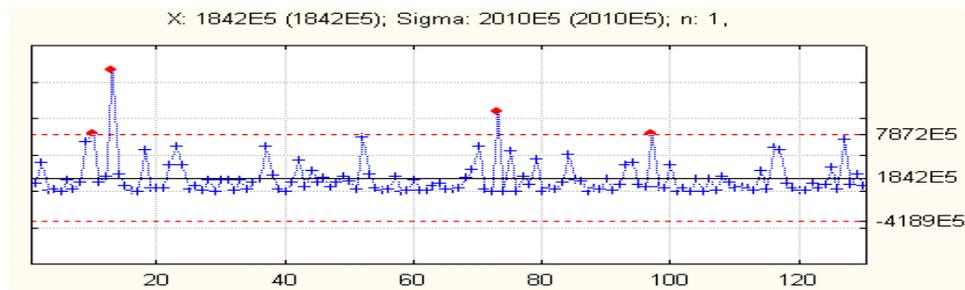


Figura 4 – Gráfico de Controle X-barra para os resíduos do modelo $SARIMA(2,1,0)(0,0,1)_{12}$.

Observa-se que os resíduos estão sob controle, pois apenas alguns pontos ultrapassaram os limites de controle. Esses pontos refletem respectivamente outubro de 1998, fevereiro de 1999, janeiro de 2004 e fevereiro de 2006. Também se pode observar que, após o instante 40, como mostrado na Figura 1, o gráfico de controle não captou a mudança de nível da série, considerando a amplitude de mais ou menos três desvios padrões. Já após o instante 90, houve um aclave na série, que foi captado pelo gráfico de controle, mostrando que a série reflexo de algum agente externo, o que acarretou este ponto fora de controle teve reflexo para o período posterior da série.

5. Conclusão

Ao desenvolver este estudo sobre a previsão do consumo de cimento procura-se fornecer subsídios para que as decisões no gerenciamento da produção futuras sejam tomadas em bases científicas e criteriosas. Assim, conhecendo o comportamento dessas variáveis antecipadamente, medidas gerenciais poderão ser implementadas pelos setores responsáveis. O modelo que melhor representa a série do consumo de cimento entre os modelos testados é um $SARIMA(2,1,0)(0,0,1)_{12}$. Também, observa-se que o gráfico de controle aplicado foi capaz de apontar que algum fator externo estava ocorrendo na série e que era de grande importância. Esta distinção que o gráfico de controle possibilita, de ver e analisar as observações, facilitando o entendimento e a compreensão da variável em estudo, identificando ou sugerindo quando necessários outros tipos de análise na série, como a utilização de uma análise intervenção.

Espera-se que as previsões encontradas auxiliem tanto governo como as empresas que compõem esse setor no dimensionamento da capacidade de produção de cimento e sirvam para gerenciar, junto aos órgãos competentes, a otimização de recursos necessários e sirvam para melhorar o gerenciamento. Logo, deixa-se como sugestão para futuros trabalhos a aplicação de uma análise de intervenção nos pontos que se encontram fora dos limites de controle, como ocorreu com a série em estudo.

Agradecimento. À CAPES, pelo apoio financeiro.

Referências

- AKAIKE, H. (1970). Statistical predictor identification. *Ann. Statis. Math.* 22, 203-217.
- BOX, G. E. P. e JENKINS, G. M. (1976). *Time series analysis forecasting and control*. Edição revisada. Holden-Day, San Francisco.
- BOX, G. E. P. e LUCENÓ, A. (1997). *Statistical control by monitoring and feedback adjustment*.: Wiley Interscience, New York.
- CLARO, F. A. E., COSTA, A. F. B. e MACHADO, M. A. G. (2007). Gráficos de controle de EWMA e \bar{X} de para monitoramento de processos autocorrelacionados. *Revista Produção*, 17,3, 536-546.
- FALTIN, F. MASTRANGELO, C. M., RUNGER, G. C. e RYAN, T. P. (1997). Considerations in the monitoring of autocorrelated and independent data. *Journal of Quality Technology*, v. 29, p. 131-133,.
- FAVA, V. L. (2000). *Manual de Econometria*. In: VASCONCELOS, M. A. S. e ALVES, D. Editora Atlas,. São Paulo.
- FERRAZ, M. I. F., SÁFADI, T. e LAGES, G. (1999). Uso de modelos de séries temporais na previsão de séries de precipitação pluviiais no município de Lavras – MG. *Revista Brasileira de Agrometeorologia*, 7, 2, 259-267.
- MAKRIDAKIS, S., WHEELWRIGHT, S. e HYNDMAN, R.J. (1998). *Forecasting methods and applications*, 3 Ed. John Wiley e Sons, New York.
- MONTGOMERY, D. C. (2001) *Introduction to Statistical Quality Control*, 4. ed. John Wiley and Sons, New York.
- MONTGOMERY, D. C. e MASTRANGELO, C. M. (1991). Some statistical process control methods for autocorrelated data. *Journal of Quality Technology*, 23, 179-193.
- MORETTIN, P. A.; TOLOI, C. M. (2004). *Análise de Séries Temporais*. 1ª ed. E. Blücher, São Paulo.
- SCHWARZ, G. (1978) Estimating the dimension of a model. *Annals of Statistics*. 6, p.461 – 464.
- SUPERVILLE, C. R. e ADAMS, B. M. (1994). An evaluation of forecast-based quality control schemes. *Communications in Statistics-Simulation and computation*, 23, 645-661,.
- TESTIK, M. C. (2004). Model Inadequacy and Residual Control Charts for autocorrelated processes. *Quality and Reliability Engineering International*, 21, 115-130.
- VICINI, L. e SOUZA, A. M. (2007). Geração de subsídios para a tomada de decisão na cadeia produtiva da bovinocultura do Brasil. *Gestão de Produção, Operações e Sistemas*, 4, 49-64.
- WERNER, L. e RIBEIRO, J. L. D. Previsão de Demanda: Uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. *Gestão & Produção*, 10, 1, 47-67.