

APLICAÇÃO DA METODOLOGIA BOX- JENKINS E DE MÉTODOS DE SUAVIZAÇÃO EXPONENCIAL NA PREVISÃO DA PRODUÇÃO DE CONCRETO NA REGIÃO NORTE DE SANTA CATARINA



Adriane Pczieczek (UDESC)

adriane_sbs@hotmail.com

Elisa Henning (UDESC)

elisa.henning@udesc.br

Carmeane Effting (UDESC)

carmeane.effting@udesc.br

Cesar Eduardo Petersen (UDESC)

cesar.e.p@hotmail.com

O concreto é um material largamente utilizado no mundo inteiro e, o seu consumo e demanda está diretamente relacionada com a situação econômica do país. Estudos mostram que o concreto é o segundo produto mais consumido do mundo, perdendo apenas para o consumo de água potável, e a tendência é de aumento em sua produção. Devido à importância do concreto no setor da construção civil, este estudo busca um modelo adequado para a previsão da demanda de concreto para a região norte de Santa Catarina. O objetivo deste estudo é aplicar a metodologia Box-Jenkins e métodos de suavização exponencial para encontrar o modelo de previsão mais adequado.

Constatou-se que, para esta série, o modelo autorregressivo integrado de média móvel ARIMA (1,1,1) apresentou erros menores comparado com os outros modelos analisados. A previsão realizada com o melhor modelo indicou um aumento na produção de concreto para a região norte de Santa Catarina.

Palavras-chave: Concreto, Metodologia Box-Jenkins, Suavização Exponencial

1. Introdução

O concreto é um material construtivo amplamente disseminado, podendo ser encontrado em diversas obras de engenharia como: pontes, edifícios, usinas hidrelétricas e nucleares, obras de saneamento, etc. O concreto se destaca como material construtivo devido a duas propriedades importantes: resistência à água e plasticidade. Diferente do aço e da madeira, o concreto sofre menos deterioração quando exposto à água e permite certa flexibilidade na obtenção de formas construtivas devido a sua plasticidade (PEDROSO, 2009).

O concreto, por ser um dos materiais de construção mais utilizado, corresponde a uma taxa de consumo mundial aproximada de 25 bilhões de toneladas por ano. Consequentemente, o seu impacto ambiental é significativo em termos de utilização dos recursos naturais e emissões de gases poluentes (GURSEL *et al.*, 2014; BLANKENDAAL; SCHUUR; VOORDIJK, 2014).

O consumo e a demanda de concreto estão diretamente relacionados com a economia financeira do país. Em se tratando de um mercado no qual o poder de compra dos consumidores é fator primordial, os efeitos em seus resultados são rapidamente sentidos na construção civil (MIYAGI, 2009).

A maioria dos estudos similares está voltada a análise de séries da indústria do cimento, que para Blankendaal, Shuur e Voordjik (2014) é o componente mais importante do concreto. Uwasu, Hasa e Yabar (2014) analisaram a produção mundial de cimento em vários países no período de 1985 a 2007. A partir de um modelo de regressão concluíram que há uma relação quadrática (*inverted-U*) entre o PIB (Produto Interno Bruto) do país e a produção de cimento. Isto significa que a produção aumenta durante certo período e depois tende a diminuir e estabilizar. Para o Brasil a produção de cimento apresentava uma leve tendência positiva, mas não significativa ao nível de 5%, durante o período de estudo. Este comportamento (*inverted-U*) também foi observado por Cao *et al* (2017) ao ajustarem modelos não lineares ao consumo de cimento na China no período de 2005 a 2013.

No Brasil Novaes (2015) apresenta uma revisão da literatura abordando modelos de previsão para este setor Novaes (2015) ainda avaliou o consumo de cimento dos estados brasileiros, por meio de um modelo econométrico dinâmico multivariado utilizando dados de séries temporais. Seus resultados apontam o próprio consumo de cimento defasado justifica a demanda e, para a maioria das regiões, incluindo a região sul, foi prevista uma deterioração para o mercado de cimento a partir de 2016.

Souza *et al.* (2010) aplicaram os modelos de Box-Jenkins e gráficos de controle para realizar a previsão da demanda de cimento no estado do Rio Grande do Sul. O período analisado foi de 1998 a 2008 e o comportamento apresentava um crescimento no consumo ao final da série.

Devido à importância do concreto na indústria da construção civil, este estudo tem como objetivo buscar um modelo adequado para a previsão da demanda de concreto para a região norte de Santa Catarina. Estudar a demanda do concreto pode auxiliar a obter uma visão mais ampla do que apenas a indústria do cimento. Deseja-se compreender o comportamento da série, a verificação da existência de tendência de crescimento ou queda na produção e variações sazonais. Segundo Simionescu (2012), os métodos de suavização exponencial e os métodos de Box-Jenkins, são dois métodos de previsão quantitativos com bons resultados na prática, sendo assim escolhidos para este trabalho.

2. Fundamentação teórica

A previsão de demanda por séries temporais utiliza um conjunto de observações ordenadas no tempo, por meio de modelos descritos e ajustados das variáveis em questão (MORETTIN; TOLOI, 2006).

Segundo Latorre e Cardoso (2001), uma série temporal, também conhecida como série histórica, consiste em uma sequência de dados obtidos durante um período de tempo específico. Para analisar uma série temporal, inicialmente procura-se modelar o fenômeno estudado para então descrever o seu comportamento e fazer estimativas.

2.1. Metodologia de Box-Jenkins

Na análise de séries temporais, a metodologia de Box-Jenkins aplica o modelo Autorregressivo Integrado de Médias Móveis – Autoregressive Integrated Moving Average (ARIMA) para encontrar o melhor ajuste da série tempo, a fim de fazer previsões. Os modelos ARIMA têm como objetivo captar o comportamento da autocorrelação entre os valores da série temporal e realizar previsões baseando-se neste comportamento (MIHAI; MEGHEA, 2011).

Um modelo ARIMA é representado por $ARIMA(p,d,q)$, com p correspondendo ao número de termos auto-regressivos; d , o número de vezes que se deve diferenciar uma série antes que ela se torne estacionária e q , o número de termos de médias móveis (GUJARATI; PORTER, 2011; MARTIN *et al.*, 2016).

Estes modelos resultam da combinação de três componentes: o auto-regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Nos modelos $AR(p)$ a série é descrita por seus valores passados e pelo ruído aleatório. A componente $MA(q)$ explora a estrutura de autocorrelação dos resíduos de previsão do período atual com aqueles ocorridos em períodos anteriores. Os modelos $ARMA(p, q)$ apresentam processos mistos $AR(p)$ e $MA(q)$ e se apoiam no pressuposto de que a série é estacionária (HANKE; WICHERN; REITSCH, 2001; GUJARATI, PORTER, 2011). Entretanto, quando a série é não-estacionária é empregada uma componente de integração $I(d)$, resultando então no modelo $ARIMA(p, d, q)$. São tomadas “ d ” diferenças de uma série não estacionária com o objetivo em torná-la estacionária, ou seja, com a média e a variância constantes ao longo do tempo (OLIVEIRA; SOBRINHO, 2009; GUARNIERI *et al.*, 2009).

Para identificar os modelos, são analisadas a função de autocorrelação amostral (ACF) e função de autocorrelação amostral parcial (PACF). Por meio da Tabela 1 pode-se visualizar as informações de identificação dos modelos (MARTIN *et al.*, 2016).

Tabela 1 - Comparativo entre os modelos $AR(p)$, $MA(q)$ e $ARMA(p,q)$

Modelo	Padrão típico ACF	Padrão típico PACF
AR(p)	Declina exponencialmente ou com um padrão de onda senóide amortecida ou ambos	Picos significativos até p defasagens
MA(q)	Apresentam picos significativos até q defasagens	Declina exponencialmente
ARMA(p, q)	Queda exponencial	Queda exponencial

Fonte: Adaptado de Martin et al. (2016) e Gujarati e Porter (2011)

Além destes modelos, existem outras variações como o modelo SARIMA, que é usado para captar a sazonalidade da série (LOURENÇO; NASCIMENTO, 2012).

De acordo com Leroy (2006), a escolha do melhor modelo para a metodologia Box-Jenkins deve seguir os seguintes critérios:

- Identificação: análise do comportamento das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP);
- Estimação: comparação dos modelos ajustados seguindo o critério da parcimônia;
- Checagem: análise dos resíduos. Se os resíduos apresentarem autocorrelação, a dinâmica da série não foi completamente explicada pelos coeficientes do modelo ajustado;
- Previsão: as previsões podem ser ex-ante ou ex-post. A previsão ex-ante calcula valores futuros de curto prazo e a previsão ex-post gera valores dentro do período amostral.

2.3. Métodos de Suavização Exponencial

Os modelos de suavização exponencial representam uma importante ferramenta de previsão, tanto nos negócios quanto na macroeconomia. Esses métodos utilizam dados da própria série para fazer previsões de curto prazo de forma rápida (SBRANA; SILVESTRINI, 2014).

De forma geral, são quatro os métodos mais utilizados na suavização exponencial: Médias Móveis Simples (MMS), Suavização Exponencial Simples (SES), Suavização Exponencial de Holt (SEH) e Suavização Exponencial Sazonal de Holt-Winters (HW).

O método de Médias Móveis Simples (MMS) é utilizado para séries que não apresentam sazonalidade e nem tendência. Este método adota a suposição que todas as observações são de igual importância, logo o peso atribuído a elas é o mesmo, e as previsões serão a média simples dos dados observados. Para alguns autores, este método não é muito adequado, pois para realizar previsões, acredita-se que as observações mais recentes são de grande importância (MORETTIN; TOLOI, 2006).

O método de Suavização Exponencial Simples (SES) é utilizado em séries sem tendência ou sazonalidade. Este método admite que as observações possuam pesos distintos, sendo atribuídos valores maiores às observações mais recentes. Assim, menores pesos proporcionam previsões mais estáveis (MORETTIN; TOLOI, 2006).

O método de Suavização Exponencial de Holt (SEH) além de suavizar o nível, modela a tendência da série. Assim, para as previsões serão atribuídos pesos para as duas componentes (MORETTIN; TOLOI, 2006).

O método de Suavização Exponencial Sazonal de Holt-Winters (HW) considera a presença de tendência e sazonalidade na série. Este método possui três componentes: nível, crescimento e sazonalidade. A sazonalidade pode ser aditiva ou multiplicativa. Quando o método for aditivo, a sazonalidade é somada à tendência da série; quando o método for multiplicativo, a sazonalidade é multiplicada pela tendência (MORETTIN; TOLOI, 2006).

2.3. Avaliação dos modelos de previsão

Para a avaliação dos modelos de previsão é necessário fazer o diagnóstico do modelo e analisar os erros. O diagnóstico do modelo consiste na análise dos resíduos, na qual irá informar se o modelo proposto atende as condições estabelecidas. A normalidade dos resíduos pode ser analisada por meio de testes, como por exemplo, o teste de Shapiro-Wilk. A

verificação da autocorrelação residual pode ser realizada através dos testes Box-Pierce e Ljung-Box. Após comprovada a adequação do modelo através da análise dos resíduos, estima-se os erros de previsão. O melhor modelo é aquele que apresentar menor erro (MARTIN *et al.*, 2016).

Dentre os critérios mais utilizados para a seleção de modelos de previsão encontra-se o Akaike's Information Criterion (AIC) e o Bayesian Information Criterion (BIC).

O AIC é uma probabilidade penalizada e por isso requer que a probabilidade seja maximizada antes de poder ser calculada. Não é possível comparar o AIC de um modelo ETS com o AIC de um modelo ARIMA, pois os dois modelos tratam valores iniciais de forma diferentes. Por exemplo, um modelo ARIMA, depois da diferenciação, é calculado com menos observações, já um modelo ETS é calculado sobre um conjunto completo de dados (HYNDMAN, 2013).

O critério BIC penaliza os modelos com muitos parâmetros, sendo um critério de verossimilhança penalizada. Vale ressaltar que o BIC não deve ser utilizado de forma isolada, mas em conjunto com outros parâmetros na comparação dos modelos (LOURENÇO; NASCIMENTO, 2012).

Os índices de erros das previsões mais conhecidos são: o Erro Médio (ME), o Erro Absoluto Médio (MAE), o Erro Quadrático Médio (MSE) e o Erro Médio Percentual Absoluto (MAPE).

O Erro Médio (ME) é considerado a medida de erro mais simples e frágil para avaliar um modelo, pois como os erros possuem valores positivos e negativos, a sua soma será próxima de zero. O Erro Absoluto Médio (MAE) considera o erro como uma distância de valor absoluto, sendo mais adequado que o ME para a verificação de um modelo. O Erro Quadrático Médio (MSE) é similar ao MAE, mas ao invés de considerar o erro em termos absolutos, ele utiliza o erro quadrado. A desvantagem de usar MSE é que ele valoriza os erros menores e penaliza os métodos que possuem erros um pouco maiores. O Erro Médio Percentual Absoluto (MAPE) é o critério mais utilizado, pois além de considerar os valores

absolutos, ele considera os erros em termos percentuais (SOUZA; SAMOHYL; MIRANDA, 2008).

3. Metodologia

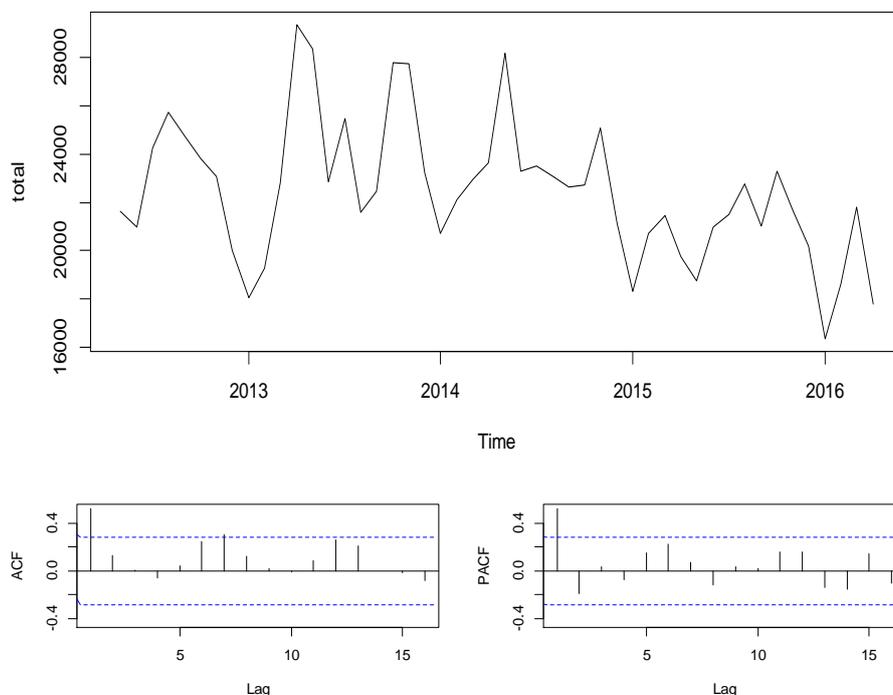
Os dados foram obtidos por meio de contatos com empresas fornecedoras de concreto da região. As informações utilizadas neste trabalho são observações mensais desde maio de 2012 a abril de 2016. A análise estatística foi efetuada com o software R (R CORE TEAM, 2016) com auxílio do pacote *forecast* (HYNDMANN, 2017). Foram analisados os resíduos para verificar a adequação dos modelos e avaliados os erros de previsão. Ao final, um modelo foi escolhido e a partir deste geradas as previsões.

4. Resultados e Discussões

A série temporal considerada para o estudo corresponde ao conjunto de observações mensais da produção de concreto da região norte de SC no período de maio de 2012 a abril de 2016. A Figura 1 apresenta o comportamento dos dados ao longo do tempo, bem como os gráficos das funções de autocorrelação amostral (ACF) e autocorrelação parcial (PACF).

Figura 1 – Apresentação da Série Temporal





Fonte: Os autores (2017)

Por meio da Figura 1, pode-se observar que a série apresenta uma pequena tendência de diminuição a partir de 2015 e não tem sazonalidade. De acordo o correlograma (Figura 1) a série aparenta apresentar autocorrelação.

Pode-se verificar ainda que a produção média de concreto é de 22450 m³/ano. A menor produção ocorreu em janeiro de 2016 com aproximadamente 16000 m³ e a maior produção foi em abril de 2013 com 29380 m³ (Tabela 2).

Tabela 2 – Estatística descritiva

Mínimo	1° Quartil	Mediana	Média	3° Quartil	Máximo
16340	20920	22540	22450	23540	29380

Fonte: Os autores (2017)

Por meio da análise das funções de autocorrelação amostral (ACF) e de autocorrelação amostral parcial (PACF) dois modelos sugeridos para a metodologia de Box-Jenkins são: ARIMA (1,0,1) e ARIMA (1,1,1). Após o ajuste, foram analisados os valores de AIC e BIC e os erros, para então verificar qual modelo seria mais adequado para a série. Os resultados dos dois modelos encontram-se nas Tabelas 3 e 4.

Tabela 3 – Comparativo entre os modelos ARIMA (1,0,1) e ARIMA (1,1,1)

	ARIMA (1,0,1)	ARIMA (1,1,1)
AIC	888,83	873,75
AICc	889,76	874,31
BIC	896,32	879,30

Fonte: Os autores (2017)

Tabela 4 – Comparativo dos erros entre os modelos ARIMA (1,0,1) e ARIMA (1,1,1)

	ARIMA (1,0,1)	ARIMA (1,1,1)
ME	0,844	-224,249
MAE	1821,297	1836,631
MAPE	8,166	8,268
MASE	0,729	0,735

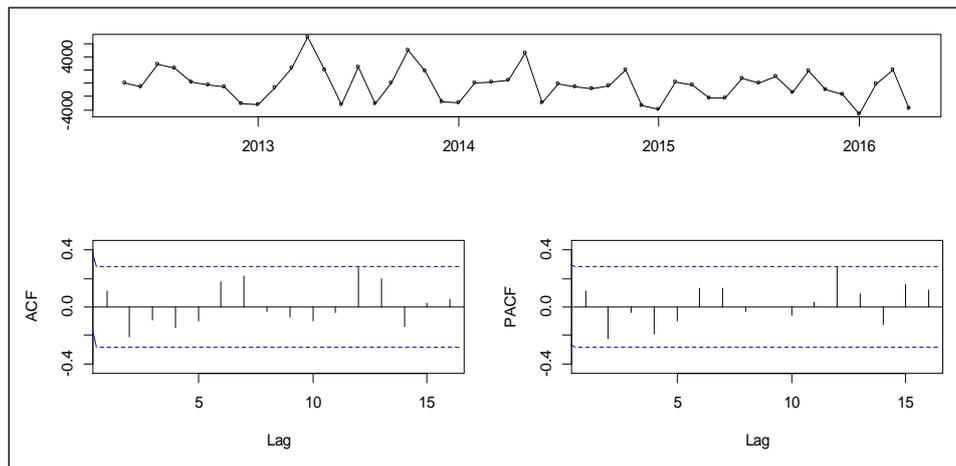
Fonte: Os autores (2017)

A partir desta primeira análise, pode-se dizer que o modelo ARIMA (1,1,1) é o mais adequado, pois apresenta menores valores para os critérios AIC e BIC, além de apresentar

menores erros. Mas, além disso, é necessário fazer a análise dos resíduos para a verificação do modelo.

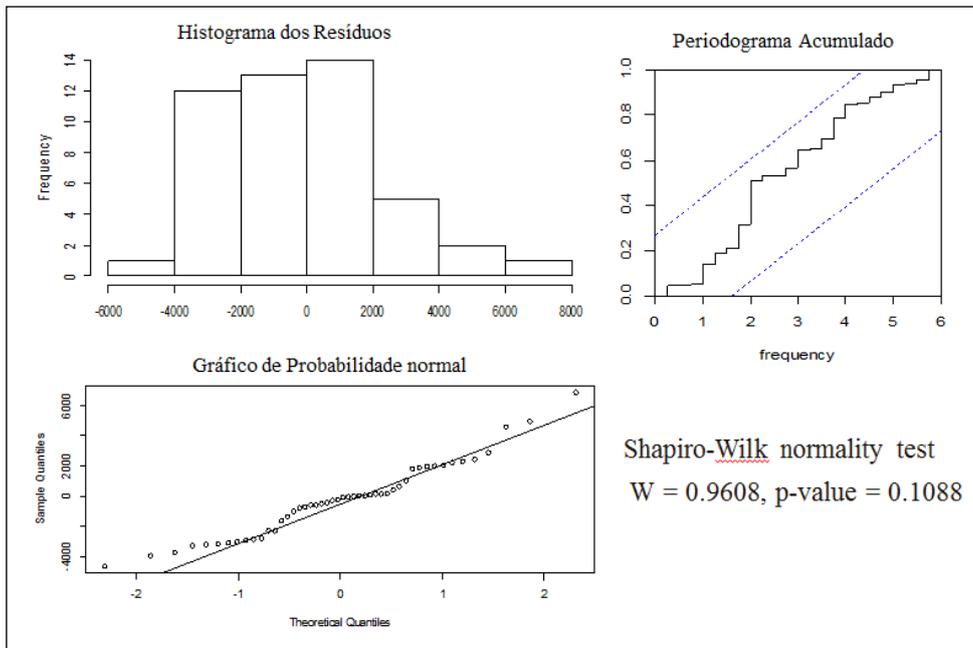
As Figuras 2 e 3 mostram o comportamento dos resíduos do modelo ARIMA (1,1,1).

Figura 2 – Modelo ARIMA (1,1,1) - comportamento dos resíduos



Fonte: Os autores (2017)

Figura 3 – Modelo ARIMA (1,1,1) – Histograma, Gráfico de probabilidade dos resíduos e Periodograma Acumulado



Fonte: Os autores (2017)

Analisando o comportamento dos resíduos do modelo ARIMA (1,1,1), verificou-se que os resíduos não apresentam autocorrelação (Figura 2). Foi aplicado o teste Shapiro-Wilk, que confirma a normalidade dos resíduos para o nível de significância de 5% ($p\text{-valor} = 0,1088$). Por meio do periodograma acumulado (Figura 3), a estatística plotada encontra-se dentro dos limites de confiança, indicando o modelo ser adequado. Logo, o modelo ARIMA (1,1,1) é apropriado, pois os resíduos se apresentam como ruído branco.

Para o Método da Suavização Exponencial, foi aplicado inicialmente o pacote *forecast* que permite gerar automaticamente um modelo de suavização exponencial. O modelo retornado pelo software foi um ETS (M, N, N), ou seja, erro multiplicativo, sem tendência e sem sazonalidade. Na Tabela 5 encontram-se os resultados para este modelo.

Tabela 5 – Resultados do modelo ETS (M,N,N)

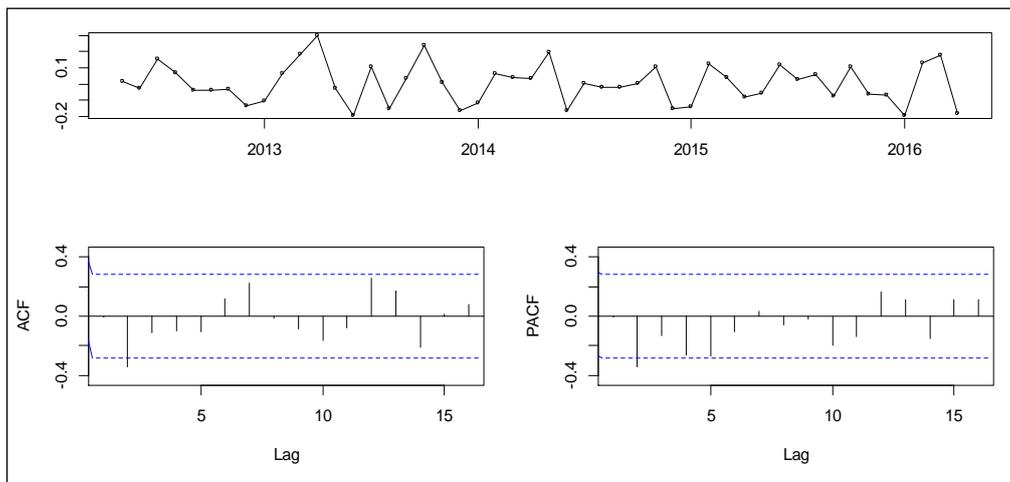
AIC	BIC	MAPE	MASE	ACF1
-----	-----	------	------	------

946,466 950,208 9,722 0,864 -0,026

Fonte: Os autores (2017)

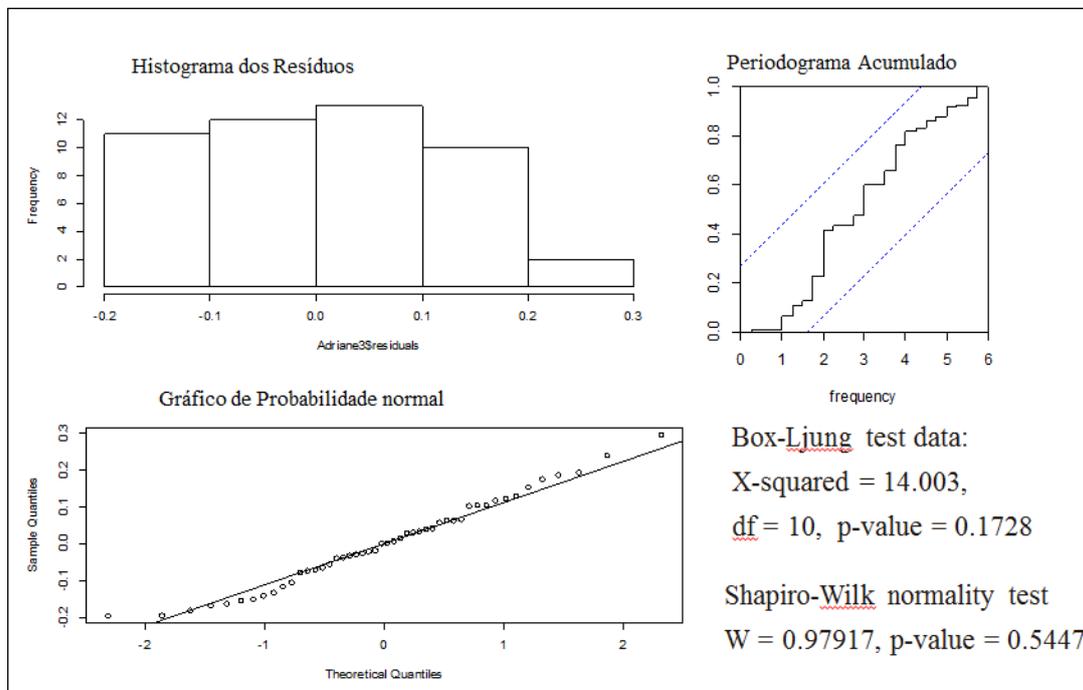
Os resíduos também foram analisados e apresentaram distribuição normal todavia, a ACF e PACF deixa dúvida com relação a a presença de autocorrelação. No entanto, por meio dos testes Shapiro-Wilk e Box-Ljung, além do periodograma acumulado, confirma-se a normalidade e independência dos resíduos. O comportamento dos resíduos descritos está apresentado nas Figuras 4 e 5.

Figura 4 – Modelo ETS (M,N,N) - comportamento dos resíduos



Fonte: Os autores (2017)

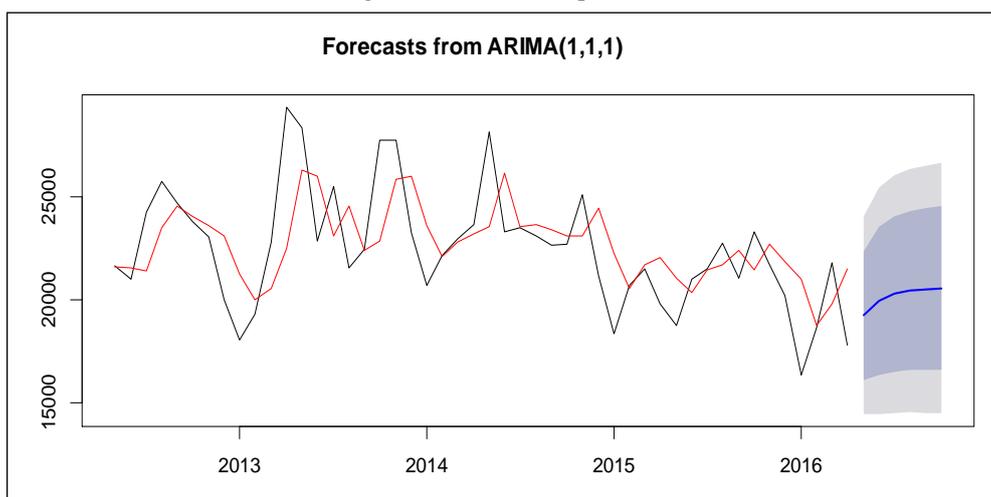
Figura 5 – Modelo ETS (M, N, N) – Histograma, Gráfico de probabilidade dos resíduos e Periodograma Acumulado



Fonte: Os autores (2017)

Dentre os modelos analisados, o modelo ARIMA (1,1,1) foi o que melhor representou a série temporal da produção de concreto da região norte de SC e, portanto, o mais indicado para realizar previsões. Assim, a série da produção de concreto não apresenta indícios de uma tendência de crescimento ou retração acentuados, nem tampouco sazonalidade. A previsão foi feita para seis meses considerando intervalo de confiança de 80% a 95% (Figura 6). Verificou-se que, segundo a previsão pontual, há um pequeno aumento na demanda de concreto. Seus valores observados encontram-se na Tabela 6. Todavia, observa-se que a partir de 2014 há um declínio na demanda de concreto, talvez associado a recessão na qual se encontra o setor. Para a continuidade dos trabalhos avaliar uma série mais longa seria recomendável. Assim, os ciclos da economia do país poderiam auxiliar na interpretação dos padrões de demanda. Modelos econométricos podem auxiliar a encontrar características e indicadores regionais que influenciem a produção. Ao final, considera-se importante avaliar se a produção de concreto na região também segue o padrão observado na indústria do cimento.

Figura 6 – Gráfico de previsão



Fonte: Os autores (2017)

Tabela 6 – Valores observados para a previsão

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
May 2016	19235.69	16097.92	22373.47	14436.88	24034.51
Jun 2016	19937.82	16326.40	23549.24	14414.63	25461.01
Jul 2016	20274.40	16487.07	24061.74	14482.17	26066.63
Aug 2016	20435.75	16558.39	24313.10	14505.84	26365.65
Sep 2016	20513.09	16576.22	24449.96	14492.17	26534.01
Oct 2016	20550.17	16566.22	24534.11	14457.25	26643.08

Fonte: Os autores (2017)

5. Conclusões

A partir dos métodos de previsão, é possível encontrar modelos que irão fornecer informações importantes sobre vendas futuras, se existe um acréscimo ou decréscimo na produção de um determinado produto. Neste artigo foram ajustados modelos ARIMA e de Suavização Exponencial aos dados da produção de concreto na região norte de Santa Catarina.

Ao se avaliar as medidas de erro de previsão os resíduos, o modelo ARIMA (1,1,1) foi considerado o mais adequado para a série estudada. A série não apresenta indícios de uma tendência de crescimento ou retração acentuados, nem tampouco sazonalidade. A análise da série apontou para um leve declínio da produção de concreto entre 2014 e 2016. Por meio da previsão, foi possível verificar uma possível tendência de aumento na produção de concreto para a região norte de SC projetada para o final de 2016.

Para a série temporal de demanda de concreto na região norte de SC, a previsão é importante na tomada de decisões, pois pode servir para escolha de novas estratégias no mercado construtivo. Além disso, os resultados podem auxiliar na gestão de resíduos sólidos da construção civil. Complementa-se que, ao se avaliar a série temporal pode-se identificar padrões que permitam buscar possíveis variáveis explicativas como o PIB, por exemplo, para a construção de um modelo econométrico.

6. Agradecimentos

Os autores agradecem às empresas da região pelo fornecimento dos dados.

7. Referências

BLANKENDAAL, Tom; SCHUUR, Peter; VOORDIJK, Hans. Reducing the environmental impact of concrete and asphalt: a scenario approach. **Journal of Cleaner Production**, v. 66, p. 27-36, 2014.

CAO, Zhi et al. Analysis on major drivers of cement consumption during the urbanization process in China. **Journal of Cleaner Production**, v. 133, p. 304-313, 2016.

GUARNIERI, J. P.; SOUZA, A. M.; ALMEIDA, S. G.; SOUZA, F. M.; OLIVEIRA, J. N. D. Análise do Impacto da Crise Econômica na Previsão de Produção de Automóveis no Mercado Brasileiro, via modelos Box & Jenkins. **In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 29, 2009, Salvador. Anais... Salvador/BA, 2009.

GUJARATI, D. N.; PORTER, D.C. **Econometria Básica**. 5 ed. Porto Alegre: AMGH, 2011.

GURSEL, A. Petek; MASANET, Eric; HORVATH, Arpad; STADEL, Alex. Life-cycle inventory analysis of concrete production: A critical review. **Cement & Concrete Composites**, v.51, p. 38-48, 2014.

HANKE, J. E.; WICHERN, D.; REITSCH, A. **Business Forecasting**. 7.ed. New Jersey: Prentice Hall, 2001.

HYNDMAN, Rob. **Facts and fallacies of the AIC**. R-bloggers. 2013. Disponível em: <<http://www.r-bloggers.com/facts-and-fallacies-of-the-aic/>>. Acesso em: 04 jul. 2016.

HYNDMAN, Rob. 2017. forecast: Forecasting functions for time series and linear models. R package version 8.0. Disponível em: <<http://github.com/robjhyndman/forecast>>. Acesso em 28/04/2017.

LATORRE, Maria do Rosário Dias de Oliveira; CARDOSO, Maria Regina Alves. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. **Revista Brasileira de Epidemiologia**, v.4, n.3, p. 145-152, 2001.

LEROY, Felipe Lacerda Diniz. Projeção do preço future de uma ação da Usiminas: uma abordagem econométrica. **Revista da Faculdade de Ciências Administrativas de Curvelo**, p. 37-60, 2006.

LOURENÇO, Isaac dos Santos; NASCIMENTO, Luis de Oliveira. **Métodos de previsão aplicados a uma série de volume de produção de caminhões**. 2012. 64f. Trabalho de conclusão de curso (Curso de Métodos Estatísticos Computacionais). Universidade Federal de Juiz de Fora, Minas Gerais, 2012.

MARTIN, Amanda Caroline; HENNING, Elisa; WALTER, Olga Maria Formigoni Carvalho; KONRATH, Andrea Cristina. Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville. **Revista ESPACIOS**. V.37, n.6, 2016.

MIHAI, Mihaela; MEGHEA, Irina. Box Jenkins methodology applied to the environmental monitoring data. **Applied Sciences**, v.13, p. 74-81, 2011.

MIYAGI, Samara. **Concreto: material construtivo mais consumido no mundo**. Revista concreto e construções. n°53, São Paulo: IBRACON, 2009. p.20-22.

MORETTIN, P. A.; TOLOI, C. **Análise de Séries Temporais**. São Paulo. Ed Edgar Blucher, 2006.

NOVAES, Maria Eduarda Pereira dos Santos. Monografia. Insper - Insper Instituto de Ensino e Pesquisa Faculdade de Economia e Administração. São Paulo. **Históricos e perspectivas: qual o potencial de expansão para o mercado de cimento?**. 2015.

OLIVEIRA, A. M. B.; SOBRINHO, M. J. V. M. Previsão de preço de venda da uva Itália e da manga Tommy produzidas no vale do São Francisco via análise de séries temporais: um estudo de caso. **In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 29, 2009, Salvador. Anais... Salvador/BA, 2009.

PEDROSO, Fábio Luís. **Concreto: material construtivo mais consumido no mundo**. Revista concreto e construções. n°53, São Paulo: IBRACON, 2009. p.14-19.

R CORE TEAM. 2017. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<https://www.R-project.org>>. Acesso em 28/04/2017.

SBRANA, Giacomo; SILVESTRINI, Andrea. Random switching exponential smoothing and inventory forecasting. **International Journal of Production Economics**, v.156, p. 283-29, 2014.

SIMIONESCU, Bratu Mihaela. Predicting Macroeconomic Indicators in the Czech Republic Using Econometric Models and Exponential Smoothing Techniques. **South East European Journal of Economics and Business**, v.7, n.2, p. 89-99, 2012.

SOUZA, G. P.; SAMOHYL, R. W.; MIRANDA, R. G. **Métodos Simplificados de Previsão Empresarial**. Rio de Janeiro. Ed Ciência Moderna, 2008.



UWASU, Michinori; HARA, Keishiro; YABAR, Helmut. World cement production and environmental implications, **Environmental Development**, v. 10, p. 36-47, 2014.