

LUCAS DE GUSMÃO NOGUEIRA

**MODELAGEM AUTO-REGRESSIVA NA PREVISÃO DE DEMANDA DOS
PRODUTOS DE UMA EMPRESA DO SETOR QUÍMICO**

Guaratinguetá
2015

LUCAS DE GUSMÃO NOGUEIRA

MODELAGEM AUTO-REGRESSIVA NA PREVISÃO DE DEMANDA DOS
PRODUTOS DE UMA EMPRESA DO SETOR QUÍMICO

Trabalho de Graduação
apresentado ao Conselho de Curso de
Graduação em Engenharia de Produção
Mecânica da Faculdade de Engenharia
do Campus de Guaratinguetá,
Universidade Estadual Paulista, como
parte dos requisitos para obtenção do
diploma de Graduação em Engenharia de
Produção Mecânica.

Orientador (a): Dr - Aneirson
Francisco da Silva

Guaratinguetá
2015

N77
8m Nogueira, Lucas de Gusmão
Modelagem auto-regressiva na previsão de demanda dos produtos de
uma empresa do setor químico / Lucas de Gusmão Nogueira–
Guaratinguetá, 2015.

57 f : il.

Bibliografia: f. 50-52

Trabalho de Graduação em Engenharia de Produção Mecânica –
Universidade Estadual Paulista, Faculdade de Engenharia de
Guaratinguetá, 2015.

Orientador: Prof. Dr. Aneirson Francisco da Silva

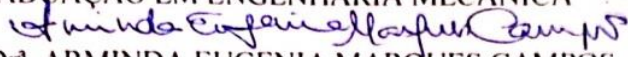
1. Administração da produção 2. Controle de estoque 3. Planejamento
da produção 4. Administração de material I. Título

CDU 658.5

LUCAS DE GUSMÃO NOGUEIRA


ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO PARTE
DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE "GRADUADO EM
ENGENHARIA DE PRODUÇÃO MECÂNICA"

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA MECÂNICA


Prof. Dr. ARMINDA EUGENIA MARQUES CAMPOS
Coordenador

BANCA EXAMINADORA:


Prof. Dr. ANEIRSON FRANCISCO DA SILVA
Orientador/UNESP-FEG


Prof. Dr. FRANCISCO ALEXANDRE DE OLIVEIRA
UNESP-FEG


Prof. Dr. JOSÉ ROBERTO DALE LUCHE
UNESP-FEG

Novembro 2015

AGRADECIMENTOS

Primeiramente agradeço a Deus por minha vida, família, amigos e por permitir que tudo isso acontecesse.

Agradeço ao meu orientador, *Prof. Dr. Aneirson Francisco da Silva* por todos os ensinamentos durante todas as disciplinas que tive oportunidade de ser seu aluno, por ser presente durante o desenvolvimento deste trabalho e por estar sempre disponível para ajudar. Aos meus pais *Paulo Roberto de Carvalho Nogueira* e *Ana Esther Gusmão Nogueira*, por serem minha referência de dedicação, companheirismo, disciplina, determinação e por sempre estarem comigo nos momentos fáceis e difíceis da minha caminhada.

À minha irmã *Carolina de Gusmão Nogueira*, por me incentivar a sempre buscar o melhor. E todos os membros da minha família que de alguma forma contribuíram para meu desenvolvimento.

Aos meus amigos e irmãos da *República Cevada & Kana*, por estarem comigo nos últimos seis anos de UNESP/FEG e que de diferentes formas contribuíram para que eu conseguisse alcançar meu objetivo. Em especial, *Pedro Henrique Mendes*, *Ricardo Henrique Strabelli* e *Guilherme Canosa*.

*“Independentemente das circunstâncias,
devemos ser sempre humildes, recatados e
despidos de orgulho.”*

Dalai lama

NOGUEIRA, L. G. **Modelagem auto-regressiva na previsão de demanda dos produtos de uma empresa do setor químico**. 2015. f. 57. Trabalho de Graduação (Graduação em Engenharia de Produção Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015.

RESUMO

Levando em consideração a alta competitividade no setor químico industrial, a previsão da demanda é fator relevante para tomada de decisões. Neste contexto, a aplicação de métodos quantitativos pode auxiliar na análise e definição da previsão. Nesse sentido, o objetivo desse trabalho é gerar a previsão para os produtos da indústria química estudada utilizando um modelo avançado de previsão, e assim verificar a confiabilidade do modelo de previsão. Por se tratar de séries temporais com sazonalidade, o modelo de médias móveis integradas sazonais auto-regressivas - SARIMA gerou previsões confiáveis e aderentes ao problema analisado, possibilitando assim, por meio da validação com os dados reais, melhorias na gestão e tomada de decisão da cadeia de suprimentos.

PALAVRAS CHAVE: SARIMA. Gestão da cadeia de suprimentos. Previsão. Demanda.

NOGUEIRA, L. G. Autoregressive modeling in demand forecasting of products from a chemical company. 2015. f. 57. Graduate work (Graduate in Production Engineering) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2015.

ABSTRACT

Considering the high competitiveness in the industrial chemical sector, demand forecast is a relevant factor for decision-making. There is a need for tools capable of assisting in the analysis and definition of the forecast. In that sense, the objective is to generate the chemical industry forecast using an advanced forecasting model and thus verify the accuracy of the method. Because it is time series with seasonality, the model of seasonal autoregressive integrated moving average - SARIMA generated reliable forecasts and acceding to the problem analyzed, thus enabling, through validation with real data improvements in the management and decision making of supply chain.

KEYWORDS: SARIMA. Supply chain management. Forecast. Demand.

LISTA DE FIGURAS

Figura 1 - Fluxograma - método de pesquisa.....	17
Figura 2 - Etapas da metodologia de Box-Jenkins.....	18
Figura 3 - Ruído branco	21
Figura 4 – Autocorrelação / Estacionariedade - COATINGS.....	28
Figura 5 - Teste Aumentado de Dickey-Fuller - COATINGS.....	28
Figura 6 – Correlograma série original - COATINGS.....	29
Figura 7 – Gráfico de sazonalidade - COATINGS	30
Figura 8 – Correlograma - COATINGS.....	31
Figura 9 - Modelo gerado - COATINGS	32
Figura 10 – Correlograma série original - AGRO	33
Figura 11 - teste aumentado de Dickey-Fuller - AGRO	33
Figura 12- Periodograma - AGRO	34
Figura 13 – Correlograma - AGRO	35
Figura 14 - Modelo gerado - AGRO	35
Figura 15 – Correlograma série original - HPC	36
Figura 16 - teste aumentado de Dickey-FulleR – HPC.....	37
Figura 17 - Correlograma - HPC.....	38
Figura 18 - Periodograma - HPC	38
Figura 19 - Correlograma - HPC.....	39
Figura 20 - Modelo Gerado - HPC.....	40
Figura 21 - Modelo SARIMA (0,2,2)X(2,1,1) - COATINGS	41
Figura 22- Modelo SARIMA (1,0,1)X(1,0,0) - AGRO	41
Figura 23 - Modelo SARIMA (2,2,1)X(0,0,1) - HPC.....	42
Figura 24 - Novo modelo SARIMA (0,1,1) X (2,1,1) - COATINGS.....	43
Figura 25 - Novo modelo SARIMA (1,2,2) X (1,0,0) - AGRO.....	43
Figura 26 - Novo modelo SARIMA (0,2,1) X (1,1,1) - HPC	44
Figura 27 - Curvas COATINGS	44
Figura 28 - Curvas AGRO	45
Figura 29 - Curvas HPC	45
Figura 30 - Teste efeito ARCH - COATINGS.....	46
Figura 31 - Teste ARCH - AGRO.....	46
Figura 32 - Teste ARCH - HPC	47

LISTA DE TABELAS

Tabela 1 - Série temporal dos produtos analisados.....	53
Tabela 2 - Dados reais dos produtos em 2015	54
Tabela 3 -Dados estimados pela empresa para 2015	55
Tabela 4 - Previsão do modelo sem derivação.....	56
Tabela 5 - Nova previsão gerada após derivação.....	56
Tabela 6 - Erros envolvidos na geração da previsão dos três produtos.	57

LISTA DE ABREVIATURAS E SIGLAS

ABIQUM	Associação Brasileira da Indústria Química
ACF	Funções de Autocorrelações
AMD	Apoio Multicritério à Decisão
AR	Auto-Regressivo
ARIMA	Auto-Regressivo Integrado de Médias Móveis
ARMA	Médias Móveis Auto Regressivas
DF	Dickey-Fuller
IBGE	Instituto Brasileiro de Geografia e Estatística
MA	Médias Móveis
PACF	Funções de Autocorrelações Parciais
SARIMA	Auto-regressivos Sazonais Integrados de Médias Móveis
ϕ	Coefficiente do filtro auto-regressivo não sazonal.
θ	Coefficiente do filtro de média não sazonal.
Φ	Coefficiente do filtro auto-regressivo sazonal.
Θ	Coefficiente do filtro de média sazonal

SUMÁRIO

1 INTRODUÇÃO.....	13
1.1 OBJETIVOS.....	15
1.1.1 Objetivos específicos.....	15
1.2 DELIMITAÇÃO E QUESTÕES DE PESQUISA	16
1.3 JUSTIFICATIVA	16
1.4 MATERIAL E MÉTODO	17
2 REFERENCIAL TEÓRICO.....	19
2.1 MODELOS DE PREVISÃO	19
2.1.1 Teste da raiz unitária – Dickey-Fuller	20
2.1.2 Modelos auto-regressivos Lineares Estacionários	21
2.1.2.1 Modelo Auto-Regressivo (AR(p)).....	22
2.1.2.2 Modelo Médias Móveis (MA (q))	22
2.1.2.3 Modelo Médias Móveis Auto Regressivas ARMA (p,q)	22
2.1.3 Modelos auto-regressivos Lineares Não-Estacionários.....	23
2.1.3.1 Modelo Auto-Regressivo Integrado Médias Móveis (ARIMA(p,d,q)).....	23
2.1.3.2 Modelo Médias Móveis Integradas Auto-Regressivas Sazonais SARIMA (p,d,q)X(P,D,Q)	24
2.2 ERROS DE PREVISÃO	25
3 DESCRIÇÃO DO PROBLEMA	27
3.1 CONTEXTUALIZAÇÃO	27
3.2 METODOLOGIA BOX-JENKINS PARA PRODUTO COATINGS.....	27
3.2.1 Identificação do modelo para produto COATINGS	27
3.2.2 Estimação do modelo para produto COATINGS.....	29
3.2.3 Verificação do modelo para produto COATINGS	31
3.3 METODOLOGIA BOX-JENKINS PARA PRODUTO AGRO.....	32
3.3.1 Identificação do modelo para produto AGRO.....	32
3.3.2 Estimação do modelo para produto AGRO	33
3.3.3 Verificação do modelo para produto AGRO	35
3.4 METODOLOGIA BOX-JENKINS PARA PRODUTO HPC	36
3.4.1 Identificação do modelo para produto HPC	36
3.4.2 Estimação do modelo para produto HPC.....	37
3.4.3 Verificação do modelo para produto HPC.....	39
3.5 PREVISÃO GERADA PELOS MODELOS ENCONTRADOS.....	40
4 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS.....	48

4.1 Verificação dos Objetivos	48
4.2 Recomendações para Futuras Pesquisas	49
REFERÊNCIAS	50
ANEXO A	53
APÊNDICE A.....	56

1 INTRODUÇÃO

A busca pelos melhores resultados e a crescente competitividade entre as empresas tem feito a alta gerência buscar ferramentas e métodos que possam diminuir o índice de erros e aumentar a confiabilidade dos fatores que influenciam na tomada de decisão (PELLEGRINI; FOGLIATO, 2001).

Segundo Chakraborty (2010), tomada de decisão é o estudo da identificação e escolha das alternativas baseadas nos valores e preferências do responsável. Uma boa tomada de decisão requer uma mistura de habilidades, como desenvolvimento criativo, identificação das opções e alternativas, clareza no julgamento, firmeza na decisão e por fim buscar uma aplicação efetiva.

Para auxiliar os tomadores de decisão, métodos como Apoio Multicritério à Decisão (AMD) têm provido bons resultados quando empregados corretamente. Esse tipo de análise proporciona entendimento amplo do contexto multidisciplinar do processo decisório, uma vez que os tomadores podem ter pontos de vista e valores conflitantes (PAMPLONA; FREITAS, 2012). Para o presente trabalho, viu-se como uma dificuldade extrair outras variáveis, além da série temporal.

Para Armstrong (2002), a pessoa responsável pela tomada de decisão precisa da previsão somente em casos nos quais existem incertezas. Logo, não é necessário previsão se o sol irá aparecer no dia seguinte, o mesmo ocorre para casos controlados, por exemplo, a necessidade de prever a temperatura de uma casa. Porém, a maioria dos casos envolvem incertezas e assim se faz necessário o uso de procedimentos formais de previsão. Nesse sentido, os métodos que geram previsão de demanda podem ser divididos em qualitativos e quantitativos. O primeiro é embasado em estimações subjetivas e contam com o conhecimento de especialista da área, já o segundo leva em consideração os dados históricos, para então prever eventos futuros (LEMOS, 2006).

Em termos gerenciais, pela ótica dos altos custos envolvidos em operações financeiras a previsão de demanda é fundamental para que recursos não fiquem ociosos, aumentando o desempenho organizacional, uma vez que os resultados refletem nos indicadores econômicos financeiros da empresa (VERRUK; BAMPI; MILAN, 2009). Neste cenário, definir a demanda futura de um produto com confiabilidade pode trazer benefícios para tomada de decisão gerencial (PINHEIRO; VIANA; CASTRO, 2013). Diante disso, viu-se uma oportunidade em buscar métodos e ferramentas que pudessem contribuir com a previsão de demanda.

Previsão refere-se a prever eventos futuros utilizando o histórico do banco de dados. Nesse sentido, modelos estatísticos têm contribuído para construir ferramentas de previsão, sendo que muitos são empregados computacionalmente tornando o trabalho mais rápido (YU; CHOI; HUI, 2011).

Diversas são as ferramentas que podem auxiliar na previsão demanda, sendo as mais tradicionais auto-regressiva e média móvel (ARMA), *fuzzy*, modelo de rede neural computacional, Sistema híbrido-neural-*fuzzy*, entre outras (LI; HU, 2012).

O estudo foi baseado em uma empresa multinacional do setor químico. Possui produção local que atende o mercado interno e externo e quando o produto solicitado não é nacional faz-se necessário a importação das outras unidades instaladas em outros países. Os dados utilizados no estudo foram coletados entre os anos de 2010 à 2014, e os de 2015 utilizados para validação do modelo de previsão.

Segundo Bastos e Costa (2013) o mercado doméstico é o grande motor da indústria química brasileira, ou seja, a produção está quase que inteiramente voltada para a economia interna. Exceto em períodos em que a retração doméstica é compensada pelas exportações, mesmo que as custas de preços desfavoráveis.

Segundo a Associação Brasileira da Indústria Química-ABIQUIM (2012) o faturamento líquido da indústria química brasileira em 2011 foi de US\$158,5 bilhões, com uma evolução de 23,4% (em dólares).

Segundo dados do IBGE (2009), o item “Produtos Químicos” está na quarta posição no Produto Interno Bruto industrial e ocupa a sétima posição no *ranking* mundial, atrás de países como Alemanha, Coréia e China.

Sobre as perspectivas em relação ao futuro do setor fora criado o Pacto Nacional da Indústria Química que tem como meta posicionar a indústria química brasileira entre as cinco maiores do mundo até 2020, tendo como meta tornar o país superavitário em produtos químicos, posicioná-lo como líder em química verde e gerar cerca de 2 milhões de empregos, nas modalidades direta, indireta e efeito renda (ABIQUIM, 2012)

Na busca de um método que melhor poderia contribuir com esse trabalho encontraram-se os modelos auto-regressivos lineares (MORETTIN, 2006). Os modelos ainda se dividem em Auto-regressivos lineares estacionários:

- Modelo Auto-Regressivo (AR(p));
- Modelo Médias Móveis (MA (q));
- Modelo Médias Móveis Auto Regressivas (ARMA (p,q));

E auto-regressivos lineares não estacionários:

- Auto-regressivo Integrado de Médias Móveis (ARIMA(p,d,q));
- Auto-regressivos Sazonais Integrados de Médias Móveis (SARIMA (p,d,q)X(P,D,Q));

Sendo:

p , parâmetros auto-regressivos; q , parâmetros médias-móveis; d , o nível de diferenciação, a partir do qual a série se torna estacionária. P , parâmetros auto-regressivos sazonais; Q , parâmetros médias-móveis sazonais; D , operador diferença sazonal.

A definição e explicação de cada modelo será tratada no Item 2.

1.1 OBJETIVOS

Por meio de um estudo quantitativo este trabalho buscou gerar a previsão da demanda mensal para três itens independentes de uma empresa do setor químico, por meio de métodos auto-regressivos a fim de evidenciar a utilização de séries temporais para estimar dados futuros. Pretende-se verificar a confiabilidade do estudo bem como o desempenho do método na análise das séries. Os dados coletados serão confrontados com os dados obtidos pelo método sensível a sazonalidade SARIMA. Dessa forma, comprovando a eficácia do método o estudo poderá contribuir com a aplicação do método em outros segmentos, e o aperfeiçoamento da ferramenta, além de auxiliar as empresas na tomada de decisão.

1.1.1 Objetivos específicos

Utilizar modelos de média móvel integradas auto-regressivas sazonais na previsão de demanda mensal de uma empresa do setor químico, por meio do estudo da série temporal coletada.

1.2 DELIMITAÇÃO E QUESTÕES DE PESQUISA

Neste trabalho serão estudados modelos de séries temporais lineares. Além disso, os dados são referentes a produtos químicos com características específicas de demanda.

Questão de Pesquisa: O método SARIMA gerará uma previsão mensal confiável para a produção de produtos de uma empresa do setor químico?

1.3 JUSTIFICATIVA

O trabalho baseou-se nos dados de uma empresa do setor químico. Segundo a Associação Brasileira da Indústria Química-ABIQUIM (2008), a indústria química brasileira posiciona-se na nona posição em relação ao faturamento líquido mundial, atrás de países como Estados Unidos, China e Japão. Além da participação do setor no PIB de 3.1%. Em relação ao PIB industrial, apresenta terceira maior participação setorial do Brasil, alcançando 10,3%, segundo a Pesquisa Industrial Anual do IBGE (2007). Enxerga-se dessa forma um setor de potencial e perspectivas de crescimento.

Entendendo o potencial do setor, vê-se necessário o rigor das previsões da demanda para sustentar as tomadas de decisão da alta gerência, bem como tornar a empresa competitiva. Nesse contexto, Porter (1986) define estratégia industrial como sendo a necessidade de um conjunto de ações ofensivas e defensivas para enfrentar as cinco forças competitivas. No meio industrial a tomada de decisão deve ser precisa e rápida devido ao alto grau de competitividade, dessa forma buscar métodos e ferramentas de alta qualidade se torna fundamental para resultados satisfatórios.

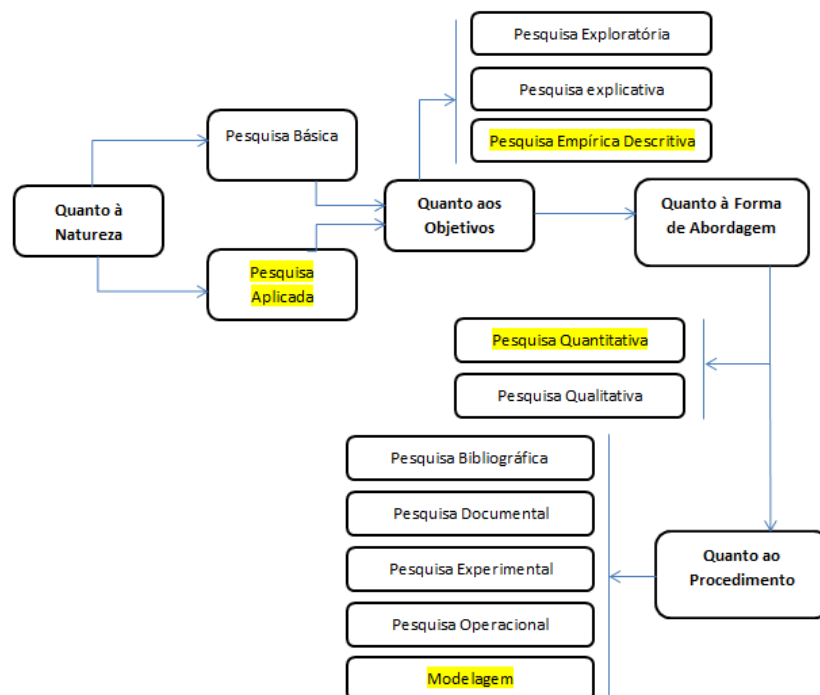
As empresas devem aprimorar as variáveis que possam diminuir as incertezas, dessa forma analisando uma dessas áreas encontra-se a previsão da demanda no suporte à tomada de decisão, e vê-se justificável o estudo de métodos auto-regressivos e sua contribuição para a análise de previsão (FAVARETTO, 2012).

Diversas são as técnicas de previsão, e a discussão e a aplicação de um desses métodos será objeto de estudo desse trabalho. Confrontar métodos quantitativos utilizando modelagem matemática pode evidenciar uma ferramenta capaz de auxiliar os tomadores de decisão (PELLEGRINI; FOGLIATO, 2001).

1.4 MATERIAL E MÉTODO

Quanto à natureza, segundo Rodrigues (2007), essa pesquisa se enquadra como aplicada, pois visa contribuir para literatura de previsão. Em relação aos objetivos esse trabalho se caracteriza como uma pesquisa empírica descritiva, uma vez que cria estratégias que melhoram uma situação atual, favorecendo a compreensão de processos reais e suas relações. Quanto à forma de abordagem trata-se de uma pesquisa quantitativa, pois os dados coletados e analisados são transformados em opinião e informação, sendo o método de pesquisa a modelagem e simulação. Segundo Bertrand e Fransoo (2002), em modelos quantitativos o conjunto de variáveis variam ao longo de um domínio específico, e as relações de causa estão definidas entre essas variáveis, além disso, o método/procedimento de pesquisa é a modelagem. A Figura 1 apresenta o fluxograma do método de pesquisa utilizado neste trabalho.

Figura 1 - Fluxograma - método de pesquisa



Fonte: (JUNG, 2003).

Neste estudo será aplicado o método SARIMA, sendo a modelagem matemática feita por meio *software* livre GRETL.

Coletou-se os dados da produção local da Indústria Química, os quais são referentes à três materiais, sendo que, são produtos de mercados diferente. A forma de escolha desse material orientou-se pela identificação daqueles que a Gerente da Produção julgou não ter controle sobre suas previsões. A série temporal enquadra-se entre os anos de 2010 e 2014 e utilizou-se os dados de 2015 para validação, os dados obtidos foram extraídos das planilhas de controle da produção da área de *Supply Chain*. Em posse dos dados o estudo seguiu com a aplicação dos métodos de previsão e em sequência concluiu-se com a análise e comparação com os dados do último ano para validação. Dessa forma o trabalho fora dividido em 3 macro etapas.

Utilizou-se a metodologia Box-Jenkins para modelagem do problema, tal metodologia tem como objetivo ajustar modelos auto-regressivos por meio de um ciclo iterativo. Os estágios do ciclo iterativo são (MORETTIN; TOLOI, 2006):

- a) Identificação
- b) Estimação
- c) Verificação

O ciclo, como mostrado na Figura 2, deve ser repetido caso o modelo não seja adequado. Utilizou-se o *software* GRETEL para obter a previsão.

Figura 2 - Etapas da metodologia de Box-Jenkins



Fonte: (SOUZA, 2006)

2 REFERENCIAL TEÓRICO

2.1 MODELOS DE PREVISÃO

Segundo Morettin (2006), processos estocásticos ou probabilísticos servem de base para os modelos descreverem as séries temporais. E vários são os fatores que interferem para a construção destes modelos, como por exemplo, o comportamento do fenômeno ou o pré conhecimento de sua natureza. Métodos de otimização e a previsão têm sido investigados por vários anos, e previsão de séries temporais é uma dessas aplicações estudadas. Gerentes de empresas usam geralmente dados históricos para prever vários tipos de variáveis como mudanças no estoque, tendência de vendas, entre outros. A confiabilidade da previsão dessas variáveis pode ajudar na tomada de decisão (LI; HU, 2012).

Segundo Yu, Choi e Hui (2011), alcançar os dados confiáveis depende muito da capacidade de selecionar o modelo correto e identificar as informações que podem estar escondidas no banco de dados. Esta pode ser uma limitação para muitas aplicações reais quando os tomadores de decisão não são suficientemente capacitados (YU; CHOI; HUI, 2011).

Ainda segundo o autor, o que se chama de série temporal é na verdade um pedaço da trajetória do comportamento do fenômeno dentro de outras possíveis, e além disso apresenta característica de linearidade e estacionaridade. Como delimitação não se abordou séries não lineares.

Dessa forma, médias móveis (MA), modelos-autoregressivos (AR) e médias móveis auto-regressivas (ARMA) são exemplos de modelos estacionários lineares, isso implica que o comportamento da média e variância são constantes ao longo do tempo. Já os modelos lineares não-estacionários são aqueles em que a média e a variância variam com o tempo (WERNER; RIBEIRO, 2003), como por exemplo: Auto-regressivo Integrado de Médias Móveis (ARIMA) e Auto-regressivos Sazonais Integrados de Médias Móveis (SARIMA).

Segundo Morettin e Tolo (1987), as etapas para o desenvolvimento do modelo de previsão auto-regressivo devem seguir o ciclo iterativo de Box-Jenkins (1976).

- Identificação do modelo: a identificação do modelo está diretamente relacionada com o comportamento das funções de autocorrelações (ACF) e das funções de autocorrelações parciais (PACF). Bem como confirmar a estacionariedade.

Segundo Box e Jenkins (1976), os testes de raízes unitárias são fortemente capazes de verificar a estacionariedade de um modelo, e o teste estudado por Dickey & Fuller (1979) são os mais clássicos;

- Estimação: nessa etapa estima-se os parâmetros dos componentes autoregressivos e os parâmetros dos componentes de médias móveis;
- Verificação: por fim, avalia-se se o modelo encontrado é adequado;

2.1.1 Teste da raiz unitária – Dickey-Fuller

Segundo Margarido e Medeiros (2005), o teste Dickey-Fuller (DF) estima, basicamente, a auto regressão expressada pela Equação 1.

$$\nabla_{y_t} = (\rho - 1)y_{t-1} + \varepsilon_t \quad (1)$$

Ou então,

$$\nabla_{y_t} = \gamma y_{t-1} + \varepsilon_t \quad (1a)$$

sendo $\nabla_{y_t} = (y_t - y_{t-1})$, ou seja é o operador diferença e $\gamma = \rho - 1$. Isso indica que quando se rejeita H_0 sinaliza que existe pelo menos uma raiz unitária, portanto trata-se série não estacionária e $\gamma = 0$. Porém, quando aceita-se H_0 indica que a série é estacionária, nesse caso não há nenhuma raiz unitária e conseqüentemente $\gamma < 0$.

Nos casos em que seja necessária incluir uma constante, a auto-regressão a ser utilizada é a seguinte (Equação 2):

$$\nabla_{y_t} = \alpha + \gamma y_{t-1} + \varepsilon_t \quad (2)$$

sendo α o intercepto. Caso, seja necessária a presença da tendência e do intercepto, a Equação 3 deve ser utilizada. Sendo que, o termo t representa a tendência linear.

$$\nabla_{y_t} = \alpha + \beta t + \gamma y_{t-1} + \varepsilon_t \quad (3)$$

Para incorporar defasagens em relação a variável que está sendo analisada o teste de Dickey-Fuller foi ampliado (ADF), conforme mostra a Equação 4.

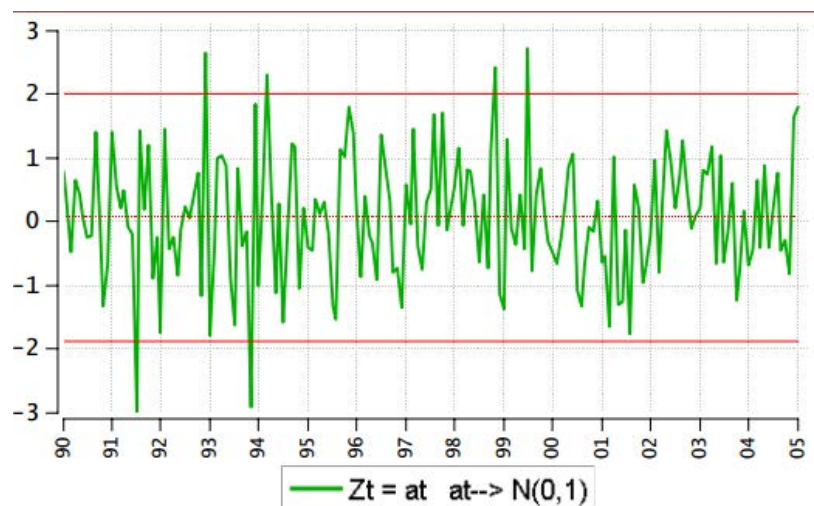
$$\nabla_{y_t} = \alpha + \beta t + \gamma y_{t-1} + \sum \rho_{j+1} \nabla_{y_{t-j}} + \varepsilon_t \quad (4)$$

O teste ADF é mais vantajoso que o DF, pois ao introduzir um número suficiente de defasagens pode-se garantir a ausência de autocorrelação.

2.1.2 Modelos auto-regressivos Lineares Estacionários

Segundo Tibulo (2014), o que garante média zero, variância constante e erros não correlacionando, ou seja, autocorrelação igual a zero é a presença de uma estrutura com ruído branco, sendo este uma sequência de variáveis aleatórias, não correlacionadas, e identicamente distribuídas, com média zero e variância constante, com distribuição normal, a Figura 3 representa um exemplo de ruído branco. Esse fator também garante um bom ajuste do modelo de Box-Jenkins.

Figura 3 - Ruído branco



Fonte: (DAVILA, 2006)

2.1.2.1 Modelo Auto-Regressivo (AR(p))

Morettin e Toloi (2006) definem modelos auto-regressivos de ordem p , conforme indicado na Equação 5.

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + \varepsilon_t \quad (5)$$

Os erros que não podem ser explicados pelo modelo são representados por ε_t . Os termos Z_{t-1} , Z_{t-2} , ..., Z_{t-p} não dependem de ε_t . E Z_t corresponde às observações históricas da série.

2.1.2.2 Modelo Médias Móveis (MA (q))

De acordo com Morettin e Toloi (2006), o processo de médias móveis de ordem q , MA(q), pode ser definida conforme indicado pela Equação 6.

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} + \varepsilon_t \quad (6)$$

Os erros que não podem ser explicados pelo modelo são representados por ε_t e a_t representa as ordens do modelo MA.

2.1.2.3 Modelo Médias Móveis Auto Regressivas ARMA (p,q)

O modelo auto-regressivo da média móvel (ARMA) é um dos mais usados para dados de séries temporais. O modelo ARMA é muito flexível pelo fato de analisar diferentes tipos de séries temporais, independentemente da ordem dos dados. Segundo Wu e Chan (2011) esse modelo se mostrou competente em previsões em que existem uma estrutura de correlação linear com séries temporais.

Morettin (2006) explica que quando não se possui um grande número de parâmetros, o que é comum em casos práticos de séries temporais, o modelos de ARMA se torna a solução mais adequada. Ele ainda define o modelo de acordo com Equação 7.

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (7)$$

Esse modelo é composto pelos operadores auto-regressivos e de médias móveis.

2.1.3 Modelos auto-regressivos Lineares Não-Estacionários

2.1.3.1 Modelo Auto-Regressivo Integrado Médias Móveis (ARIMA(p,d,q))

Para as séries Z_t , com um número finito de diferenças, d , que convertem-se em estacionárias, são chamadas não-estacionárias homogêneas se obedecerem a Equação 8.

$$W_t = \Delta d Z_t \quad (8)$$

Representa-se W_t por um modelo ARMA(p,q) como na Equação 9.

$$\varphi(X)W_t = \theta(X) a_t. \quad (9)$$

Se W_t é uma diferença de Z_t , então Z_t é uma integral de W_t , portanto pode-se dizer que Z_t possui um modelo auto-regressivo-integrado-médias-móveis, ARIMA(p,d,q), apresentado na Equação 10, de ordem (p,d,q), se p e q são as ordens de $\varphi(X)$ e $\theta(X)$, respectivamente.

$$\varphi(X)\Delta d Z_t = \theta(X) a_t \quad (10)$$

No modelo, todas as raízes de $\varphi(X)$ estão fora do círculo unitário. Entretanto deve-se considerar a equivalência demonstrada na Equação 11,

$$\xi(X)Z_t = \theta(X) a_t \quad (11)$$

Donde $\xi(X)$ é um operador auto-regressivo não-estacionário, de ordem p+d, com d raízes iguais a 1 (sobre o círculo unitário) e as restantes p estão fora do círculo unitário, logo deve-se representar como na Equação 12.

$$\xi(X) = \varphi(X)\Delta d = \varphi(X)(1 - X)d \quad (12)$$

2.1.3.2 Modelo Médias Móveis Integradas Auto-Regressivas Sazonais SARIMA (p,d,q)X(P,D,Q)

Quando $\{Z_t\}$ apresenta um comportamento sazonal determinístico com período 12, um modelo que pode ser útil é apresentado na Equação 13.

$$Z_t = \mu_t + N_t \quad (13)$$

Sendo que μ_t é uma função determinística periódica, $(\mu_t - \mu_{t-12} = 0$, ou $(1 - B^{12})\mu_t = 0$) e N_t é um processo estacionário que pode ser modelado por um ARIMA (p,d,q).

Dessa maneira, N_t satisfaz a Equação 14.

$$\phi(B)N_t = \theta(B)a_t \quad (14)$$

Sendo a_t tem ruído branco e μ_t tem solução dada pela Equação 15.

$$\left[j \left| \cos \frac{(2\pi jt)}{12} + \beta_j \operatorname{sen} \frac{(2\pi jt)}{12} \right| \right]^\alpha \quad (15)$$

$$\mu_t = \mu + \sum_{j=1}^6$$

Com $\mu, \alpha_j, \beta_j, j = 1, \dots, 6$, constantes desconhecidas.

Assim, para um modelo sazonal determinístico, aplicando a diferença sazonal $(1 - B^{12})$ à Equação (11), obteve-se a Equação 16.

$$(1 - B^{12})Z_t = (1 - B^{12})\mu_t + (1 - B^{12})N_t \quad (16)$$

E de acordo com (14), tem-se

$$(1 - B^{12})Z_t = (1 - B^{12})N_t \quad (17)$$

Substituindo (16) em (17), obteve-se

$$\phi(B)(1 - B^{12})Z_t = \theta(B)(1 - B^{12})a_t, \quad (18)$$

$$\phi(B)W_t = \theta(B)(1 - B^{12})a_t \quad (19)$$

Sendo $W_t = (1 - B^{12})Z_t$.

Na obra de Morettin e Toloí (2006) encontra-se maior detalhamento para definição de ARIMA E SARIMA.

2.2 ERROS DE PREVISÃO

Segundo Pellegrini e Fogliato (2001), para escolher o melhor modelo de previsão para cada série temporal é necessário levar em consideração o somatório dos erros gerados de cada modelo $e_t = z_t - \hat{z}_t$, onde e_t é o erro gerado no tempo t , z_t é o valor observado na série temporal para o tempo t e \hat{z}_t é o valor da previsão feita para o tempo t . Os erros podem gerar valores positivos e negativos, sendo possível zerar o somatório. Com isso, é possível empregar diferentes formas soma de erros.

- Média do quadrado dos erros (MQE) = $\frac{1}{n} \sum_{t=1}^n e_t^2$
- Média absoluta dos erros (MAE) = $\frac{1}{n} \sum_{t=1}^n |e_t|$
- Média absoluta percentual dos erros (MAPE) = $\frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{z_t} \times 100 \right|$

Assim, usando um dos critérios de cálculo, o modelo adequado será aquele que tiver o menor erro associado. A forma mais popular de medir a precisão do forecasting é a MAPE

(KAHN, 1998). Entretanto, a fórmula se tornar impossível de empregar quando a série temporal contem valores iguais à zero.

Os erros envolvidos na geração da previsão dos três itens estudados estão apresentados na Tabela 6 em Apêndice A.

3 DESCRIÇÃO DO PROBLEMA

3.1 CONTEXTUALIZAÇÃO

O departamento de *Supply Chain* da indústria química estudada forneceu os dados de três produtos de diferentes mercados de atuação. A escolha desses produtos baseou-se nos mercados de maior impacto e nos respectivos produtos em que a previsão não era controlada.

O primeiro produto pertence ao mercado COATINGS e a série temporal se inicia em setembro de 2010 até dezembro de 2014, total de 54 observações. O segundo produto pertence ao mercado AGRO com série temporal entre Julho 2010 e dezembro de 2014, total de 56 observações e terceiro produto pertence ao mercado HPC e os dados coletados iniciam em julho de 2011 e vão até dezembro de 2014 com um total de 42 observações.

Os dados obtidos de cada material foram agrupados de forma contínua e verticalmente, conforme mostra a Tabela 1 em Anexo A, para serem lidos pelo *Software* Gretl. Seguindo a metodologia Box-Jenkins (1976), primeiramente identificou-se o modelo, em seguida estimou-se e por fim verificou-se se a previsão gerada era coerente.

Utilizando a previsão gerada pelo método auto-regressivo, confrontou-se os valores encontrados com os dados reais de 2015, contemplados na Tabela 2 em Anexo A e os dados previstos pela empresa para o mesmo ano, conforme apresentado na Tabela 3 em Anexo A. Dessa forma, foi possível identificar se o método estudado neste trabalho conseguiu prever a demanda do ano de 2015, bem como comparar se a previsão foi mais satisfatória do que a feita pela empresa para o mesmo ano.

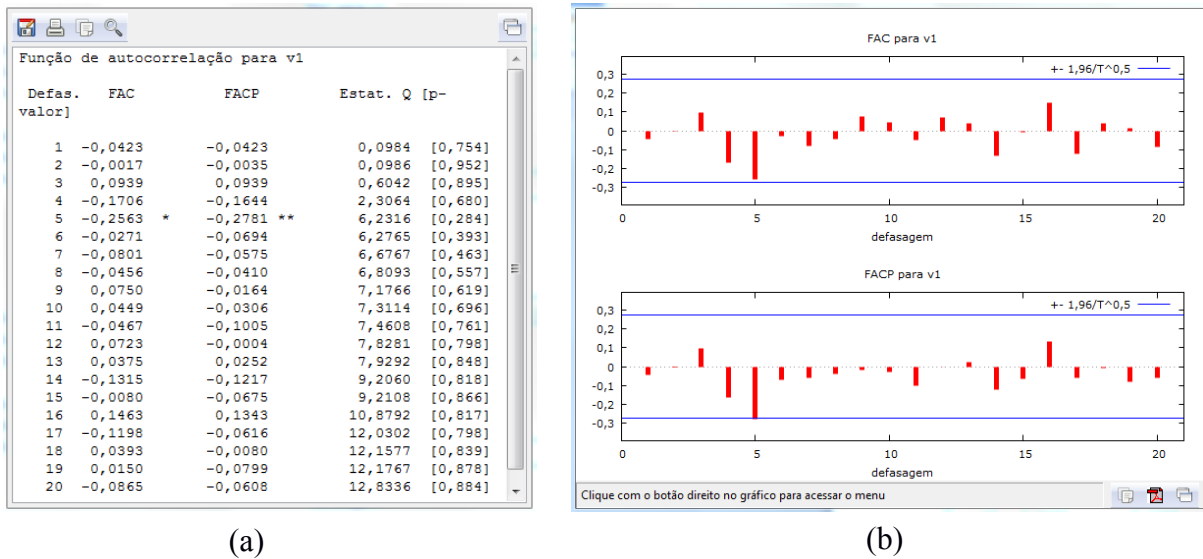
3.2 METODOLOGIA BOX-JENKINS PARA PRODUTO COATINGS

3.2.1 Identificação do modelo para produto COATINGS

As Figuras 4a e 4b apresentam os dados gerados pelo correlograma do *software* Gretl sobre a série original. A Figura 4b mostra o comportamento senoidal típico de modelos auto-regressivos. Considerando nível de significância de 5%, observou-se que os valores de p-valor (Figura 4a) estão acima de 0,05 o que evidencia a não estacionariedade do modelo. Para confirmar, utilizou-se o teste aumentado de Dickey-Fuller, para valores acima de 5% de

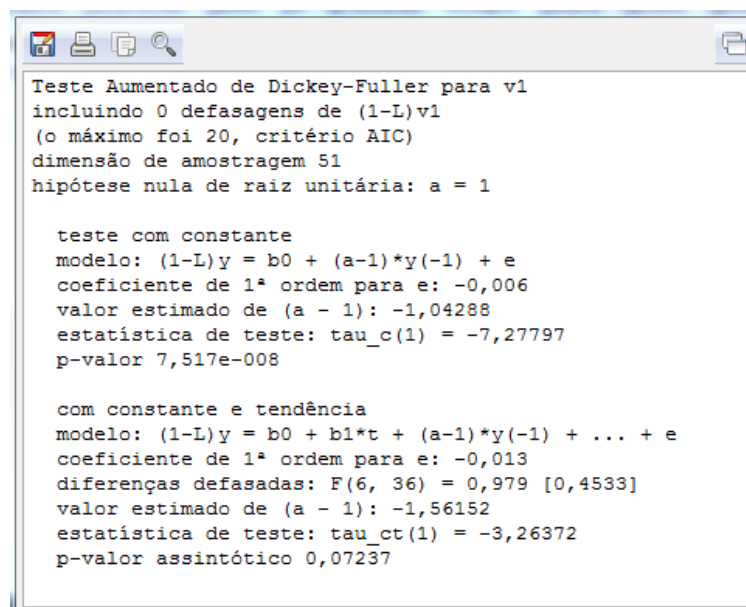
significância aceita-se a hipótese de não estacionariedade. Conforme indicado na Figura 5, p-valor é maior que 0,05, logo se trata de uma série não estacionária.

Figura 4 – Autocorrelação / Estacionariedade - COATINGS



Fonte: (GRETL, 2015)

Figura 5 - Teste Aumentado de Dickey-Fuller - COATINGS



Fonte: (GRETL, 2015)

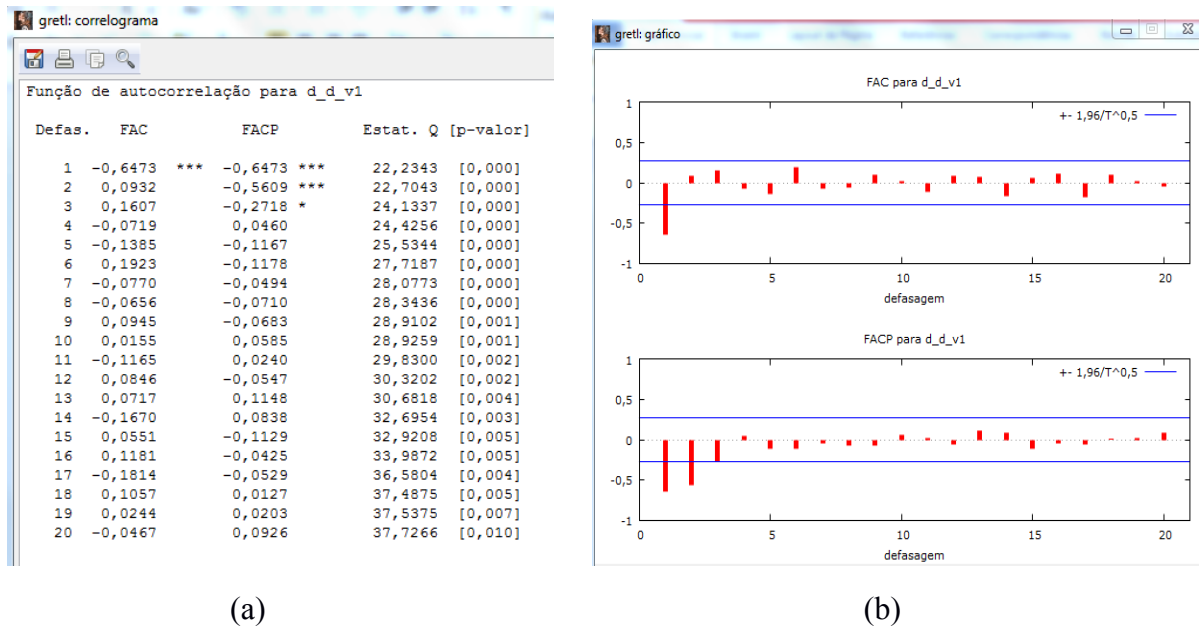
3.2.2 Estimação do modelo para produto COATINGS

Foram feitas duas diferenciações para se chegar a um valor satisfatório de p-valor. A Figura 6a mostra os valores encontrados depois da segunda diferenciação. Com isso $d=2$. Para encontrar o valor de p e q é necessário encontrar o ponto de inferência, de acordo com a Equação 20. Para esse produto foram analisados 52 dados, e como foram feitas duas diferenciações n passa a ser 50. O que fornece um ponto de inferência igual a 0,2828.

$$\pm \frac{2}{\sqrt{n}} = \pm \frac{2}{\sqrt{50}} = 0,2828 \quad (20)$$

Analisando FACP, encontrou-se que o último maior número que o ponto de inferência é 0,5609, sendo assim $p=2$. Para encontrar q deve-se analisar a coluna FAC e encontrar o primeiro valor menor que o ponto de inferência, para esse caso $q=2$. A Figura 6b mostra o ruído próximo de zero após duas diferenciações.

Figura 6 – Correlograma série original – COATINGS

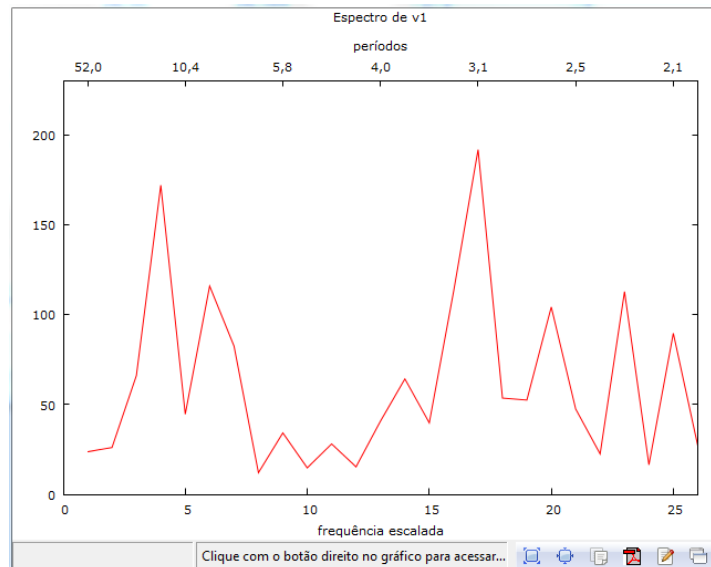


Fonte: (GRETL, 2015)

Por meio do períodograma foi possível verificar se existe sazonalidade. A característica de gráficos sazonais é a presença de picos e vales acentuados. A Figura 7 confirma que se

trata de um processo sazonal. Nesse momento, buscou-se identificar os filtros P, Q e D do modelo SARIMA (p,q,d)X(P,D,Q).

Figura 7 – Gráfico de sazonalidade - COATINGS



Fonte: (GRET, 2015)

Por meio da análise pelo correlograma, indicado na Figura 8, verificou-se a necessidade de apenas uma defasagem sazonal, pois p-valor é menor que 5%. Sendo assim, D é igual a 1. Nesse momento calculou-se um novo ponto de inferência, de acordo com a Equação 20. Na diferenciação sazonal, como os dados são mensais o decaimento são de 12 meses, sendo assim, n passa a ser 38. E o ponto de inferência igual a 0,3244.

Figura 8 – Correlograma - COATINGS

gretl: correlograma

Função de autocorrelação para sd_d_d_v1

Defas.	FAC		FACP		Estat. Q	[p-valor]
1	-0,7127	***	-0,7127	***	20,8692	[0,000]
2	0,2568		-0,5106	***	23,6531	[0,000]
3	0,0265		-0,1677		23,6836	[0,000]
4	-0,1075		-0,0532		24,2007	[0,000]
5	0,0753		-0,0294		24,4619	[0,000]
6	-0,0415		-0,0681		24,5437	[0,000]
7	-0,0148		-0,1523		24,5544	[0,001]
8	0,0329		-0,1539		24,6091	[0,002]
9	0,0498		0,1110		24,7390	[0,003]
10	-0,1520		-0,0165		25,9935	[0,004]
11	0,2547		0,2168		29,6450	[0,002]
12	-0,3362	**	-0,1383		36,2537	[0,000]
13	0,3408	**	0,0317		43,3135	[0,000]
14	-0,2412		0,0222		46,9991	[0,000]
15	0,0405		-0,1057		47,1073	[0,000]
16	0,1443		0,0597		48,5462	[0,000]
17	-0,2614		-0,1888		53,4925	[0,000]
18	0,2808	*	-0,0154		59,4862	[0,000]
19	-0,2243		-0,1174		63,5111	[0,000]
20	0,1711		0,0771		65,9819	[0,000]

Fonte: (GRET, 2015)

Analisando FACP, encontra-se que o último maior número que o ponto de inferência é 0,5106, sendo assim $P=2$. Para encontrar q deve-se analisar a coluna FAC e encontrar o primeiro valor menor que o ponto de inferência, para esse caso $Q=2$. Conclui-se que o modelo provável para rodar o modelo deve ser o SARIMA (2,2,2)X(2,1,2).

3.2.3 Verificação do modelo para produto COATINGS

Conforme mencionado anteriormente o modelo provável é SARIMA (2,2,2)X(2,1,2). Porém, verificou-se após ajustes por meio de tentativa e erro, observando os valores de p-valor encontrados no modelo gerado, conforme mostra a Figura 9, o melhor modelo é o SARIMA (0,2,2)X(2,1,1) pois são estatisticamente significativos por apresentarem p-valor menor que 0,05.

Figura 9 - Modelo gerado - COATINGS

Arquivo Editar Testes Salvar Gráficos Análise LaTeX				
Modelo 8: ARIMA, usando as observações 2011:11-2014:12 (T = 38)				
Estimado usando X-13-ARIMA (Máxima verossimilhança exata)				
Variável dependente: (1-L)^2(1-Ls) V1				
	coeficiente	erro padrão	z	p-valor
Phi_1	-0,393991	0,152623	-2,581	0,0098 ***
Phi_2	-0,449176	0,211462	-2,124	0,0337 **
theta_1	-1,96436	0,267920	-7,332	2,27e-013 ***
theta_2	0,998642	0,270825	3,687	0,0002 ***
Média var. dependente	-2,407895	D.P. var. dependente	69,91647	
Média de inovações	0,093114	D.P. das inovações	23,36623	
Log da verossimilhança	-180,9296	Critério de Akaike	371,8592	
Critério de Schwarz	380,0471	Critério Hannan-Quinn	374,7724	
	Real	Imaginária	Módulo	Frequência
AR (sazonal)				
Raiz 1	-0,4386	1,4262	1,4921	0,2975
Raiz 2	-0,4386	-1,4262	1,4921	-0,2975
MA				
Raiz 1	0,9835	0,1845	1,0007	0,0295
Raiz 2	0,9835	-0,1845	1,0007	-0,0295

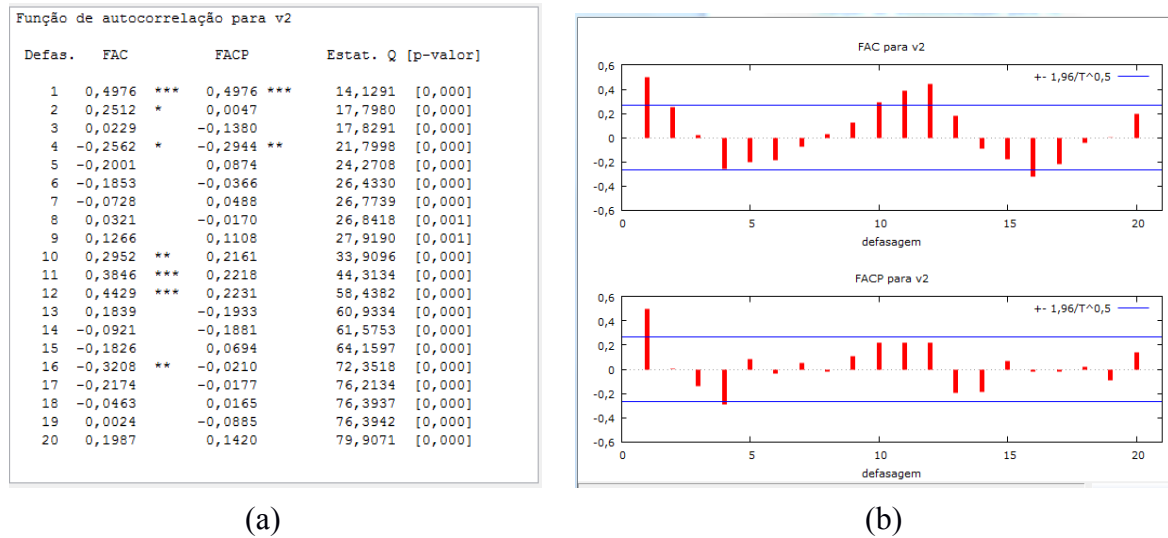
Fonte: (GRET, 2015)

3.3 METODOLOGIA BOX-JENKINS PARA PRODUTO AGRO

3.3.1 Identificação do modelo para produto AGRO

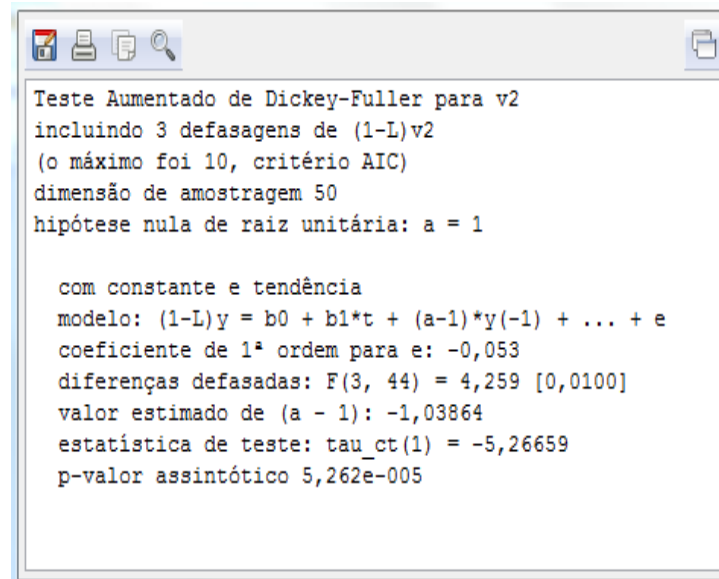
A Figura 10a apresenta a autocorrelação da série original, e como os valores de p-valor estão abaixo de 0,05 (nível de significância) fica evidente a estacionariedade. O teste aumentado de Dickey-Fuller comprova a estacionariedade, pois o valor de p-valor é menor que 0,05 e assim rejeita-se a hipótese de não estacionariedade, conforme indicado pela Figura 11. A Figura 10b mostra o comportamento senoidal típico de modelos auto-regressivos.

Figura 10 – Correlograma série original - AGRO



Fonte: (GRET, 2015)

Figura 11 - teste aumentado de Dickey-Fuller - AGRO



Fonte: (GRET, 2015)

3.3.2 Estimação do modelo para produto AGRO


O valor de d é zero, pois não houve necessidade de defasagem devido ao valor de p -valor ser menor que 5%. Para encontrar o valor de p e q é necessário encontrar o ponto de

inferência, de acordo com a Equação 20 Para esse produto foram analisados 55 dados, o que forneceu um ponto de inferência igual a 0,2697.

Analisando FACP (Figura 10a), encontrou-se que o último maior número que o ponto de inferência é 0,4976, sendo assim $p=1$. Para encontrar q deve-se analisar a coluna FAC (Figura 10a) e encontrar o primeiro valor menor que o ponto de inferência, para esse caso $q=2$.

A Figura 12 mostra a presença de picos o que evidencia sazonalidade.

Figura 12- Periodograma - AGRO



Fonte: (GRETL, 2015)

Por meio do da análise pelo correlograma, indicado na Figura 13, constatou-se a não necessidade de defasagem sazonal, pois p -valor é menor que 5%. Sendo assim, D é igual a zero. Nesse momento calculou-se um novo ponto de inferência, de acordo com a Equação 20. Na diferenciação sazonal, como os dados são mensais o decaimento são de 12 meses, sendo assim, n passa a ser 43. E o ponto de inferência igual a 0,3050. Sendo assim, $P=2$ e $Q=1$. E por fim, encontrou-se o modelo provável SARIMA (1,0,2)X(2,0,1).

Figura 13 – Correlograma - AGRO

Defas.	FAC	FACP	Estat. Q [p-valor]
1	0,3706 **	0,3706 **	6,1894 [0,013]
2	0,2744 *	0,1589	9,6676 [0,008]
3	0,0015	-0,1699	9,6677 [0,022]
4	-0,2235	-0,2684 *	12,0976 [0,017]
5	-0,2287	-0,0561	14,7105 [0,012]
6	-0,2501	-0,0495	17,9215 [0,006]
7	-0,0195	0,1622	17,9416 [0,012]
8	-0,1336	-0,2112	18,9114 [0,015]
9	-0,1201	-0,2143	19,7195 [0,020]
10	0,0018	0,1064	19,7197 [0,032]

Fonte: (GRETL, 2015)

3.3.3 Verificação do modelo para produto AGRO

Levando em consideração o modelo provável encontrado (SARIMA (1,0,2)X(2,0,1)), chegou-se ao modelo SARIMA (1,0,1)X(1,0,0). Validado pelos valores de p-valor abaixo de 0,05 (nível de significância), conforme indicado pela Figura 14.

Figura 14 - Modelo gerado - AGRO

Modelo 10: ARMA, usando as observações 2010:07-2014:12 (T = 54)
 Estimado usando X-13-ARIMA (Máxima verossimilhança exata)
 Variável dependente: v2

	coeficiente	erro padrão	z	p-valor
phi_1	0,915189	0,0590038	15,51	2,94e-054 ***
Phi_1	0,556795	0,128175	4,344	1,40e-05 ***
theta_1	-0,301534	0,153270	-1,967	0,0491 **

Média var. dependente	731,4741	D.P. var. dependente	303,2619
Média de inovações	48,95340	D.P. das inovações	234,3498
Log da verossimilhança	-374,3642	Critério de Akaike	756,7285
Critério de Schwarz	764,6844	Critério Hannan-Quinn	759,7968

	Real	Imaginária	Módulo	Frequência
AR				
Raiz 1	1,0927	0,0000	1,0927	0,0000
AR (sazonal)				
Raiz 1	1,7960	0,0000	1,7960	0,0000
MA				
Raiz 1	3,3164	0,0000	3,3164	0,0000

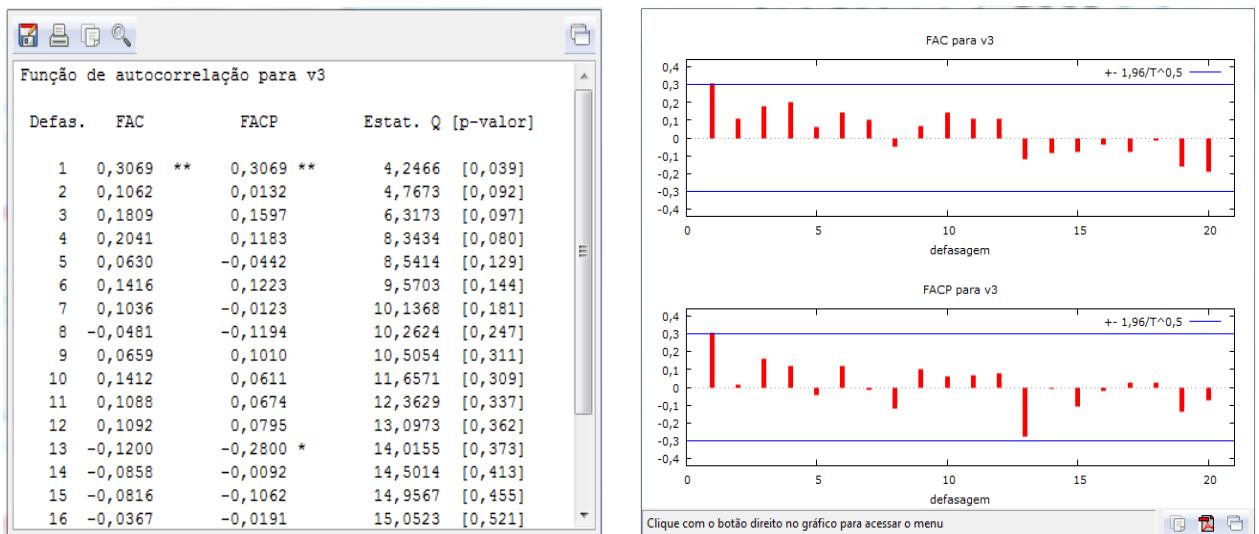
Fonte: (GRETL, 2015)

3.4 METODOLOGIA BOX-JENKINS PARA PRODUTO HPC

3.4.1 Identificação do modelo para produto HPC

Considerando nível de significância de 5%, a Figura 15a mostra que os valores de p-valor estão acima de 0,05 o que evidencia a não estacionariedade, para confirmar a não estacionariedade, utilizou-se o teste aumentado de Dickey-Fuller, em que valores acima de 5% de significância aceita-se a hipótese de não estacionariedade. Conforme indicado na Figura 16, p-valor é maior que 0,05, logo se trata de uma série não estacionária. A Figura 15b mostra o comportamento senoidal típico de modelos autoregressivos.

Figura 15 – Correlograma série original - HPC



(a)

(b)

Fonte: (GRETL, 2015)

Figura 16 - teste aumentado de Dickey-FulleR – HPC

```

Teste Aumentado de Dickey-Fuller para v3
incluindo 16 defasagens de (1-L)v3
(o máximo foi 18, critério AIC)
dimensão de amostragem 25
hipótese nula de raiz unitária: a = 1

teste com constante
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
coeficiente de 1ª ordem para e: -0,123
diferenças defasadas: F(16, 7) = 0,930 [0,5777]
valor estimado de (a - 1): -1,18093
estatística de teste: tau_c(1) = -1,96406
p-valor assintótico 0,3031

com constante e tendência
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
coeficiente de 1ª ordem para e: 0,069
diferenças defasadas: F(18, 2) = 0,559 [0,8042]
valor estimado de (a - 1): 11,2732
estatística de teste: tau_ct(1) = 0,583977
p-valor assintótico 0,9995

```

Fonte: (GRETL, 2015)

3.4.2 Estimação do modelo para produto HPC

Foram feitas três diferenciações para se chegar a um valor satisfatório de p-valor. A Figura 17 mostra os valores encontrados depois da terceira diferenciação. Com isso $d=4$. Utilizando a Equação 20, encontrou-se o valor do ponto de inferência igual a 0,3244 ($n=38$). Analisando FACP (Figura 17), encontrou-se que o último maior número que o ponto de inferência é 0,4698, sendo assim $p=3$. Para encontrar q deve-se analisar a coluna FAC (Figura 17) e encontrar o primeiro valor menor que o ponto de inferência, para esse caso $q=2$.

Figura 17 - Correlograma - HPC


Função de autocorrelação para d_d_d_d_v3

Defas.	FAC	FACP	Estat. Q [p-valor]
1	-0,6930 ***	-0,6930 ***	19,7313 [0,000]
2	0,1588	-0,6186 ***	20,7962 [0,000]
3	0,0858	-0,5135 ***	21,1160 [0,000]
4	0,0330	-0,0408	21,1647 [0,000]
5	-0,1974	0,0850	22,9605 [0,000]
6	0,1280	-0,1475	23,7384 [0,001]
7	0,1111	0,0284	24,3438 [0,001]
8	-0,2263	0,1174	26,9379 [0,001]
9	0,1023	0,0300	27,4860 [0,001]
10	0,0943	0,0498	27,9688 [0,002]
11	-0,2069	-0,2569	30,3791 [0,001]
12	0,2002	-0,0403	32,7212 [0,001]
13	-0,1116	0,1049	33,4782 [0,001]
14	0,0484	0,1337	33,6266 [0,002]
15	-0,0748	-0,0385	33,9964 [0,003]
16	0,1276	-0,0701	35,1216 [0,004]
17	-0,1186	0,0075	36,1396 [0,004]
18	0,0044	-0,1089	36,1410 [0,007]
19	0,1666	0,0820	38,3625 [0,005]
20	-0,2408	0,0316	43,2588 [0,002]

Fonte: (GRETL, 2015)

A Figura 18 apresenta o gráfico do periodograma da série, onde se pode notar a presença de um pico, o que é característico de séries com sazonalidade.

Figura 18 - Periodograma - HPC

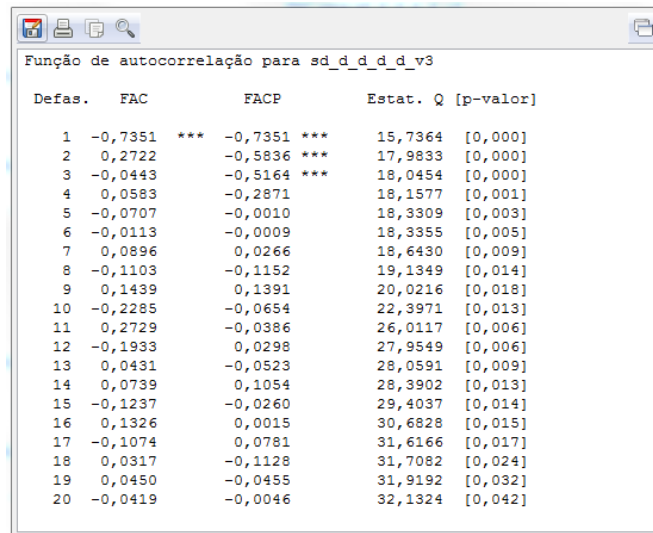


Fonte: (GRETL, 2015)

Por meio da análise pelo correlograma, indicado na Figura 19, constatou-se a não necessidade de defasagem sazonal, pois p-valor é menor que 5%. Sendo assim, D é igual a 0. Nesse momento calculou-se um novo ponto de inferência, de acordo com a Equação 20. Na

diferenciação sazonal, como os dados são mensais o decaimento são de 12 meses, sendo assim, n passa a ser 26. E o ponto de inferência igual a 0,3050. Sendo assim, $P=3$ e $Q=2$. E por fim, encontrou-se o modelo provável SARIMA (3,4,2)X(3,0,2).

Figura 19 - Correlograma - HPC



Fonte: (GRETL, 2015)

3.4.3 Verificação do modelo para produto HPC

Levando em consideração o modelo provável encontrado, SARIMA (3,4,2)X(3,0,2), chegou-se ao modelo SARIMA (2,2,1)X(0,0,1). Validado pelos valores de p-valor abaixo de 0,05 (nível de significância), conforme indicado pela Figura 20.

Figura 20 - Modelo Gerado - HPC

Arquivo Editar Testes Salvar Gráficos Análise LaTeX				
Modelo 8: ARIMA, usando as observações 2011:09-2014:12 (T = 40)				
Estimado usando X-13-ARIMA (Máxima verossimilhança exata)				
Variável dependente: (1-L)^2 v3				
	coeficiente	erro padrão	z	p-valor
-----	-----	-----	-----	-----
phi_1	-0,453165	0,136425	-3,322	0,0009 ***
phi_2	-0,384500	0,135745	-2,833	0,0046 ***
theta_1	-0,971875	0,0728646	-13,34	1,39e-040 ***
Theta_1	0,428405	0,144992	2,955	0,0031 ***
Média var. dependente	-10,56000	D.P. var. dependente	390,6533	
Média de inovações	-15,50068	D.P. das inovações	195,2200	
Log da verossimilhança	-270,8866	Critério de Akaike	551,7733	
Critério de Schwarz	560,2177	Critério Hannan-Quinn	554,8265	
	Real	Imaginária	Módulo	Frequência
-----	-----	-----	-----	-----
AR				
Raiz 1	-0,5893	1,5012	1,6127	0,3095
Raiz 2	-0,5893	-1,5012	1,6127	-0,3095
MA				
Raiz 1	1,0289	0,0000	1,0289	0,0000
MA (sazonal)				
Raiz 1	-2,3342	0,0000	2,3342	0,5000
-----	-----	-----	-----	-----

Fonte: (GRET, 2015)

3.5 PREVISÃO GERADA PELOS MODELOS ENCONTRADOS

Segundo Morettin (2006), a previsão de dados futuros são obtidos por meio da igualdade entre as Equações 21 e 22.

$$Z_t(h) = E[Z_{t+h} | Z_{t-1}, \dots] \quad (21)$$

$$\mu_{t+h} + E[n_t \vee Y_t, Y_{t-1}, \dots] \quad (22)$$


Chega-se então a Equação 23.

$$Z_t(h) = \mu_{t+h} + N_t(h) \quad (23)$$

Os dados mostrados na Tabela 4 em Apêndice A foram obtidos utilizando os modelos SARIMA (p,d,q) x (P,D,Q) após feita verificação e representam os valores previstos para o ano de 2015 de cada mercado, respectivamente. Já os dados da Tabela 2 em Anexo A representam os valores reais fornecidos pela empresa. Devido ao período de coleta de dados e qualificação do trabalho, foram coletados dados reais até Outubro de 2015. Os dados previstos pela empresa correspondem ao intervalo entre os meses de Maio até Dezembro de 2015.

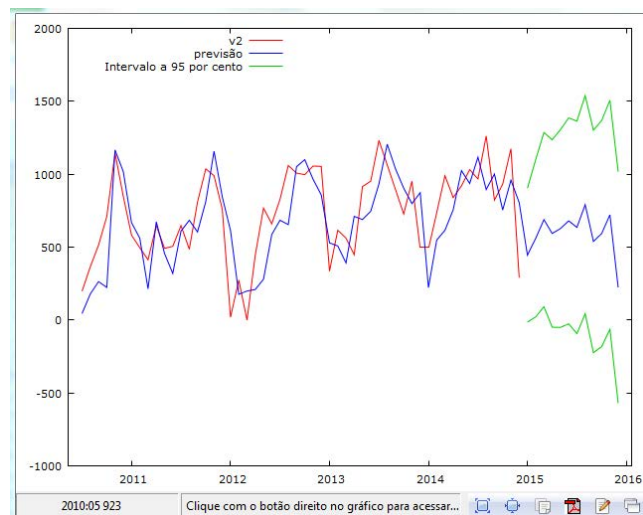
Levando em consideração o intervalo de confiança de 95%, as Figuras 21, 22 e 23 mostram de forma visual a aderência dos modelos sobre a série temporal dos respectivos produtos. Nota-se que a previsão para os três produtos encontram-se dentro dos intervalos de confiança. Entretanto, devido à escala dos dados originais coletados o intervalo de confiança para as três previsões apresentam valores negativos, o que não evidencia coerência de resultados.

Figura 21 - Modelo SARIMA (0,2,2)X(2,1,1) - COATINGS




Fonte: (GRETL, 2015)

Figura 22- Modelo SARIMA (1,0,1)X(1,0,0) - AGRO



Fonte: (GRETL, 2015)


Figura 23 - Modelo SARIMA (2,2,1)X(0,0,1) - HPC



Fonte: (GRET, 2015)

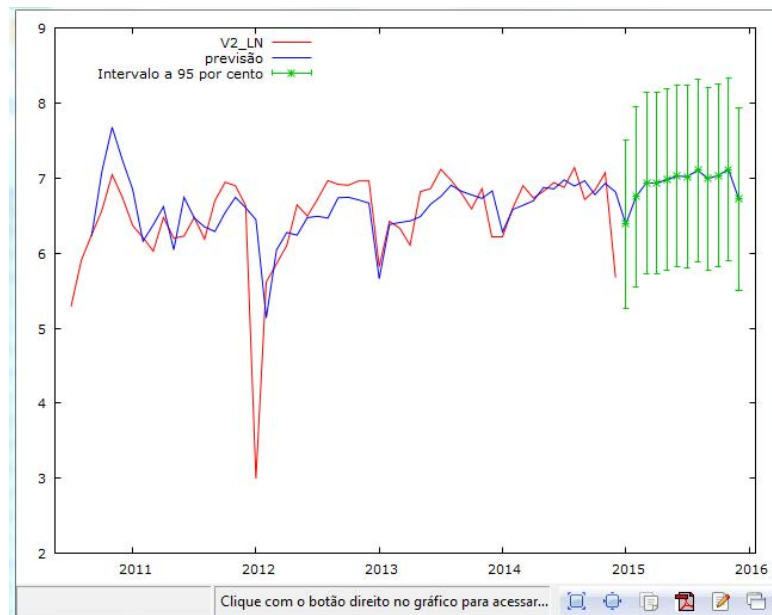
Para contornar essa incoerência utilizou-se da derivação aplicando logaritmo neperiano na série original de cada produto, e então analisou-se as séries seguindo os mesmos critérios explicados nos itens anteriores para encontrar o modelo de melhor ajuste. Por fim, utilizou-se da função exponencial para encontrar os valores reais para os dados gerados para a previsão. As Figuras seguintes 24, 25 e 26 apresentam os gráficos dos novos modelos adotados para cada produto após aplicação da derivação, e os novos valores da previsão encontram-se na Tabela 5 em Apêndice A.

Figura 24 - Novo modelo SARIMA (0,1,1) X (2,1,1) - COATINGS




Fonte: (GRETL, 2015)

Figura 25 - Novo modelo SARIMA (1,2,2) X (1,0,0) - AGRO



Fonte: (GRETL, 2015)

Figura 26 - Novo modelo SARIMA (0,2,1) X (1,1,1) - HPC




Fonte: (GRET, 2015)

Analisando as três últimas Figuras é possível concluir que o processo matemático foi capaz de eliminar intervalos de confiança negativos.


As Figuras seguintes, 27, 28 e 29 mostram um comparativo entre as curvas em relação aos dados reais, a previsão gerada pela empresa, a previsão gerada pelo modelo após sofrer derivação e por fim a previsão sem aplicação da derivação.

Figura 27 - Curvas COATINGS




Fonte: (O AUTOR, 2015)

Figura 28 - Curvas AGRO



Fonte: (O AUTOR, 2015)

Figura 29 - Curvas HPC



Fonte: (O AUTOR, 2015)

Observa-se que o produto COATINGS apresenta alguns pontos fora do intervalo de confiança, o dado mais afastado do intervalo de confiança, *outlier*, foi o mês de Março, igual a zero. Os outros dois pontos, Julho e Setembro se encontram mais próximos da curva de intervalo de confiança, esses dados muito fora da curva podem ser derivados de um ruído branco gaussiano, mas também podem prejudicar a modelagem por apresentarem volatilidade,

ou presença do efeito ARCH (FURRIEL, 2011). Conforme indicado pelas Figuras 30, 31 e 32 esse efeito não está presente nas três séries estudadas.

Figura 30 - Teste efeito ARCH - COATINGS

	coeficiente	erro padrão	razão-t	p-valor
alpha (0)	960,235	421,060	2,281	0,0401 **
alpha (1)	-0,208580	0,263575	-0,7914	0,4429
alpha (2)	-0,0124520	0,251526	-0,04951	0,9613
alpha (3)	-0,112861	0,248437	-0,4543	0,6571
alpha (4)	-0,202330	0,254930	-0,7937	0,4416
alpha (5)	-0,0451966	0,207738	-0,2176	0,8311
alpha (6)	0,125306	0,205496	0,6098	0,5525
alpha (7)	-0,167216	0,206159	-0,8111	0,4319
alpha (8)	-0,261142	0,211756	-1,233	0,2393
alpha (9)	-0,000208097	0,217279	-0,0009577	0,9993
alpha (10)	-0,0986792	0,219118	-0,4503	0,6599
alpha (11)	-0,313051	0,221149	-1,416	0,1804
alpha (12)	-0,271986	0,233123	-1,167	0,2643

Hipótese nula: efeito ARCH não está presente
 Estatística de teste: LM = 7,20306
 com p-valor = P(Qui-quadrado(12) > 7,20306) = 0,843907

Fonte: (GRET, 2015)

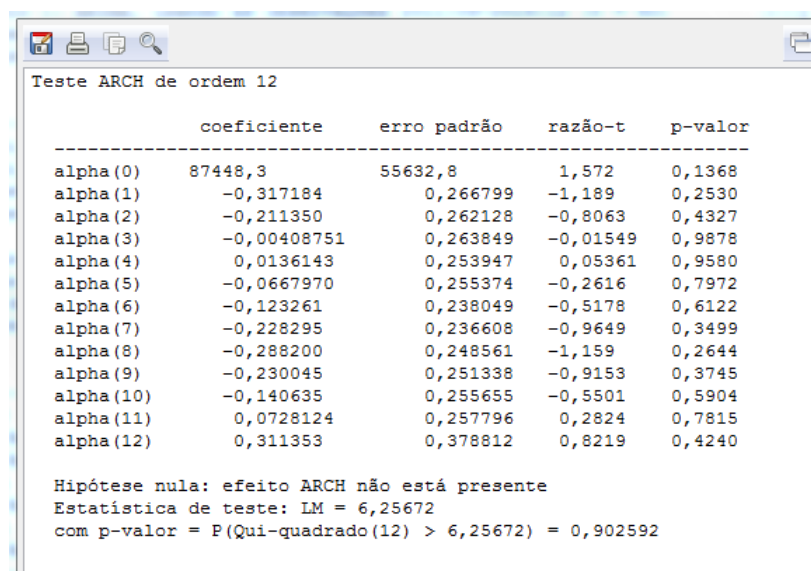
Figura 31 - Teste ARCH - AGRO

	coeficiente	erro padrão	razão-t	p-valor
alpha (0)	113674	45039,0	2,524	0,0173 **
alpha (1)	-0,323721	0,206342	-1,569	0,1275
alpha (2)	-0,174647	0,207970	-0,8398	0,4079
alpha (3)	0,0734934	0,205282	0,3580	0,7229
alpha (4)	0,281619	0,202104	1,393	0,1741
alpha (5)	-0,0314266	0,206181	-0,1524	0,8799
alpha (6)	-0,238660	0,201819	-1,183	0,2466
alpha (7)	0,00184009	0,202973	0,009066	0,9928
alpha (8)	-0,117110	0,207571	-0,5642	0,5770
alpha (9)	-0,0899893	0,184567	-0,4876	0,6295
alpha (10)	-0,187534	0,192215	-0,9756	0,3373
alpha (11)	-0,171071	0,195316	-0,8759	0,3883
alpha (12)	-0,0770881	0,190102	-0,4055	0,6881

Hipótese nula: efeito ARCH não está presente
 Estatística de teste: LM = 10,3302
 com p-valor = P(Chi-quadrado(12) > 10,3302) = 0,587014

Fonte: (GRET, 2015)

Figura 32 - Teste ARCH - HPC



	coeficiente	erro padrão	razão-t	p-valor
alpha (0)	87448,3	55632,8	1,572	0,1368
alpha (1)	-0,317184	0,266799	-1,189	0,2530
alpha (2)	-0,211350	0,262128	-0,8063	0,4327
alpha (3)	-0,00408751	0,263849	-0,01549	0,9878
alpha (4)	0,0136143	0,253947	0,05361	0,9580
alpha (5)	-0,0667970	0,255374	-0,2616	0,7972
alpha (6)	-0,123261	0,238049	-0,5178	0,6122
alpha (7)	-0,228295	0,236608	-0,9649	0,3499
alpha (8)	-0,288200	0,248561	-1,159	0,2644
alpha (9)	-0,230045	0,251338	-0,9153	0,3745
alpha (10)	-0,140635	0,255655	-0,5501	0,5904
alpha (11)	0,0728124	0,257796	0,2824	0,7815
alpha (12)	0,311353	0,378812	0,8219	0,4240

Hipótese nula: efeito ARCH não está presente
 Estatística de teste: LM = 6,25672
 com p-valor = P(Qui-quadrado(12) > 6,25672) = 0,902592

Fonte: (GRETL, 2015)

Já para os outros dois produtos dos mercados AGRO e HPC os pontos predominam dentro do intervalo de confiança.

Os modelos gerados para os produtos dos mercados COATINGS e AGRO, antes da série original sofrer derivação, se aproximam mais da curva real quando comparados com o modelo após derivação. Entretanto, ambas as curvas evidenciam a tendência do comportamento da série para o ano de 2015.

O melhor modelo foi o do mercado HPC, onde além de evidenciar a tendência da série, também conseguiu prever com confiabilidade os valores para os meses de 2015.

4 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

4.1 Verificação dos Objetivos

Segundo Morettin (2006), previsões geradas por modelos auto-regressivos lineares apresentam melhor desempenho com séries temporais acima de 60 dados, diante dessa consideração observou-se uma dificuldade na análise estudada, uma vez que todos os produtos abordados possuíam séries mensais com dados inferiores ao sugerido.

Entretanto, pode-se observar que a aderência e robustez dos modelos adotados atende aos objetivos do trabalho, uma vez que todas as previsões geradas apresentaram dados dentro do intervalo de confiança, como são apresentados nas Figuras 27, 28 e 29.

Outro ponto a considerar é a necessidade de percepção do analista em adotar os parâmetros p , d , q , P , D e Q , pois o método utilizado nesse trabalho serve para nortear e estimar um modelo ótimo, e por meio do método da tentativa e erro chegar ao provável modelo ótimo.

Sobre os dados coletados, não observou-se dificuldade na coleta das informações. Sobre os dados obtidos, ressalta-se que o modelo encontrado para o produto do mercado HPC apresentou melhor aderência do que os outros dois. Pode-se observar que a previsão gerada pelo modelo após os dados sofrerem derivação apresenta melhor desempenho que a previsão adotada pela empresa, conforme mostrado na Figura 28. Para o produto do mercado COATINGS e do mercado AGRO, nota-se que, conforme indicado pelas Figuras 27 e 28, respectivamente, embora os valores encontrados estejam dentro do intervalo de confiança, eles não acompanharam fielmente os valores reais, porém indicam a tendência do comportamento do produto.

Sendo assim, conclui-se que o objetivo do trabalho foi alcançado, pois o estudo em cima da série temporal de cada produto somado a confiabilidade da ferramenta e o método auto-regressivo linear SARIMA mostraram-se capazes de gerar dados dentro do intervalo de confiança de 95%.

O trabalho apresenta contribuição tecnológica, pois evidencia a importância do uso de métodos quantitativos de previsão no suporte à decisão empresarial. O modelo pode contribuir para a análise de séries temporal e colaborar com a geração de dados futuros, como por exemplo, estimar a previsão da demanda. A confiabilidade dos dados gerados pode proporcionar melhor ajuste no planejamento das operações, melhorar a qualidade do processo

decisório, influenciar diretamente no nível de serviço, no nível de estoque de segurança e no custo total da cadeia de suprimentos da empresa.

4.2 Recomendações para Futuras Pesquisas

- Recomenda-se realizar o estudo em séries temporais com dados superiores a 60 observações.
- Ressalta-se a importância do método estudado para aplicação em outros setores empresariais, e assim, verificar a aplicação do modelo auto-regressivo em outras séries temporais.
- Utilizar os dados obtidos na análise multicritério.

REFERÊNCIAS

ARMSTRONG, J. S. Principles of Forecasting. **A handbook for researchers and practitioners**. New York Kluwer Academic Publishers, 2002.

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA QUÍMICA. Pacto Nacional da Indústria Química. Disponível em: < <http://canais.abiquim.org.br/pacto/introducao.asp>>. Acesso em: 25 mai. 2015.

BERTRAND, J. W. M.; FRANSOO, J. C. Modelling and simulation: operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, 2002.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. San Francisco. HoldenDay, Edição revisada. 1976.

CHAKRABORTY, S. Applications of the MOORA method for decision making in manufacturing environment. **The International Journal of Advanced Manufacturing Technology**. London, UK. 2010.

DICKEY, D.; FULLER, W. Distribution of the estimators for autoregressive time series with a unit root, **Journal of the American Statistical Association**. 1979. Disponível em: < http://www.jstor.org/stable/2286348?seq=1#page_scan_tab_contents>. Acesso em: 15 out. 2015.

DAVILA, V. H. L. **Introdução às séries temporais**: Notas de aula. f. 51. Disponível em: < <http://www.ime.unicamp.br/~hlauchos/MaterialSeries.pdf>>. Acesso em: 21 nov. 2015.

FAVARETTO, F. **Impacto das incertezas da previsão da demanda no planejamento detalhado da produção**. P&D em Engenharia de Produção. Itajubá, v. 10, n. 1, 2012.

FULLER, W. A. **Introduction to the statistical time series**. 2nd Edition. John Wiley & Sons, New York, 2008. Disponível em < <http://onlinelibrary.wiley.com/doi/10.1002/9780470316917.fmatter/pdf>>. Acesso em: 20 jul. 2015.

FURRIEL, A. M. Q. S. **Modelos Heterocedásticos – ARCH e GARCH**. 2011. 69 f. Dissertação (Mestrado em Métodos Quantitativos para Economia e Gestão) – Faculdade de Economia, Universidade do Porto, 2011.

GRETLL 2015. Disponível em:< http://gretl.sourceforge.net/win32/index_pt.html>. Acesso em: mai 10. 2015.

JUNG, C. F. **Metodologia Científica**: Ênfase em pesquisa tecnológica. 3ed. Difusão Tecnológica Gratuita, 2003. Disponível em:<<http://www.jung.pro.br>>. Acesso em: 05 abr. 2015.

KAHN, K. B. **Benchmarking sales forecasting performance measures**.Disponível em:<<http://onlinelibrary.wiley.com/doi/10.1002/9780470316917.fmatter/pdf>>. Acesso em: 05 set. 2015.

LI, C.; HU, J. H. **A new ARIMA-based neuro-fuzzy approach and swarm intelligence for time series forecasting.**, National Central University, Taiwan (R.O.C). 2011. Disponível em:< <http://www.sciencedirect.com/science/article/pii/S095219761100203X>>. Acesso em> 10 set. 2015.

MARGARIDO, M. A; MEDEIROS, H. J. **Teste para mais de uma Raíz unitária: Uso do Software SAS® na elaboração de uma rotina para o teste Dickey**. PESQUISA & DEBATE, São Paulo. 2005.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries**. 2ed. São Paulo: Editora Edgar Blucher, 2006.

PAMPLONA, B. L.; FREITAS, F. F. T. **Aplicação do método AHP na escolha do tipo de concreto a ser utilizado na construção civil**. ENCONTRO NACIONAL DE ENGENHARIA DE PRODUCAO, 32., 2012, Bento Gonçalves, RS, Brasil, 2012.

PELLEGRINI, F. R; FOGLIATO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda Técnicas e Estudo de Caso**. Revista PRODUÇÃO, v. 11 n. 1, 2001. Disponível em:< <http://www.scielo.br/pdf/prod/v11n1/v11n1a04.pdf>>. Acesso em> 05 set. 2015.

PEREIRA, M. B. **Teste de Dickey-Fuller Robusto Baseado nos Ranks Para séries Temporais com Observações atípicas**. Vitória, ES. 2010. Disponível em: < http://www.ime.unicamp.br/sinape/sites/default/files/ConcursoIC_Monografia.pdf>. Acesso em: 20 out. 2015.

PINHEIRO, A. R.; VIANA, F. L. E.; CASTRO, E. A. L. **Aplicação de técnicas de previsão de demanda na indústria de confecções**. ENCONTRO NACIONAL DE

ENGENHARIA DE PRODUÇÃO, 33., 2013, Salvador. ABEPRO, 2013. Disponível em:<http://www.abepro.org.br/biblioteca/enegep2013_TN_STO_177_008_22171.pdf>. Acesso em: 02 set. 2015.

RODRIGUES, W. C. **Metodologia Científica**. FAETEC/IST, Paracambi. 2007. Disponível em: < http://unisc.br/portal/upload/com_arquivo/metodologia_cientifica.pdf>. Acesso em: 01 abr. 2015.

VERRUK, F.; BAMPI, R. E.; MILAN, G. S. **Previsão de demanda em operações de serviços: Um estudo em uma empresa do setor de transportes**. In: SIMPÓSIO DE ADMINISTRAÇÃO DA PRODUÇÃO, LOGÍSTICA E OPERAÇÕES INTERNACIONAIS, 12., 2009, São Paulo. Disponível em:<http://www.simpoi.fgvsp.br/arquivo/2009/artigos/E2009_T00125_PCN53633.pdf>. Acesso em: 20 jul. 2015

YU, Y.; CHOI, T. M.; HUI, C. L. **An intelligent fast sales forecasting model for fashion products**. Institute of Textiles and Clothing, Hong Kong. 2010. Disponível em:<<http://www.sciencedirect.com/science/article/pii/S0957417410014521>>. Acesso em: 20 set. 2015.

WERNER, L.; RIBEIRO, J. L. D. **Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais**. Revista Gestão & Produção, vol.10, n.1, p. 47-67. 2003. Disponível em: < <http://www.scielo.br/pdf/gp/v10n1/a05v10n1>>. Acesso em: 15 jul. 2015.

WU, J.; CHAN, C. K. **Prediction of hourly solar radiation using a novel hybrid model of ARMA and TDNNs**. Nanyang Technological University, Singapore. 2010. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0038092X11000259>>. Acesso em: 12 jun. 2015.

ANEXO A

Tabela 1 - Série temporal dos produtos analisados

Série temporal			
Mercado	COATING	AGRO	HPC
Produto	V1	V2	V3
Ago'10	0	366	0
Set'10	53	514	0
Out'10	42	710	0
Nov'10	20	1146	0
Dez'10	36	848	0
Jan'11	39	582	0
Fev'11	23	496	0
Mar'11	0	414	0
Abr'11	42	648	0
Mai'11	0	492	0
Jun'11	0	506	0
Jul'11	41	648	28
Ago'11	77	486	224
Set'11	42	810	464
Out'11	75	1037	700
Nov'11	50	990	348
Dez'11	16	760	232
Jan'12	66	20	580
Fev '12	33	274	472
Mar'12	33	0	324
Abr'12	30	446	574
Mai'12	29	768	560
Jun'12	35	660	341
Jul'12	35	828	574
Ago'12	65	1060	812
Set'12	17	1008	580
Out'12	68	997	348
Nov'12	50	1056	464
Dez'12	0	1054	464
Jan'13	44	336	340
Fev'13	50	616	812
Mar'13	31	562	568
Abr'13	30	448	580
Mai'13	45	916	812
Jun'13	45	952	616
Jul'13	45	1232	812

Ago'13	0	1064	696
Set'13	45	896	688
Out'13	0	727	336
Nov'13	45	952	696
Dez'13	45	504	464
Jan'14	50	504	910
Fev'14	47	736	1120
Mar'14	45	990	696
Abr'14	0	840	580
Mai'14	30	920	812
Jun'14	33	1032	775
Jul'14	16	968	684
Ago'14	32	1262	448
Set'14	47	823	564
Out'14	48	932	336
Nov'14	63	1175	560
Dec'14	15	291	334

Tabela 2 - Dados reais dos produtos em 2015

Dados Reais			
Mercado	COATING	AGRO	HPC
Produto	V1	V2	V3
Jan'15	48	348	672
Fev'15	16,5	226	1020
Mar'15	0	758	692
Abr'15	48	990	340
Mai'15	30	864	868
Jun'15	33	562	784
Jul'15	49,5	248	572
Ago'15	40,5	362	548
Set'15	55,5	788	200
Out'15	28,5	624	668
Nov'15			
Dez'15			

Tabela 3 -Dados estimados pela empresa para 2015

Previsão empresa			
Mercado	COATING	AGRO	HPC
Produto	V1	V2	V3
Jan'15			
Fev'15			
Mar'15			
Abr'15			
Mai'15	30	910,4	1000
Jun'15	30	715,2	632
Jul'15	45	728	832
Ago'15	60	784	580
Set'15	33	900	928
Out'15	33	900	928
Nov'15	33	900	928
Dez'15	33	900	928

APÊNDICE A

Tabela 4 - Previsão do modelo sem derivação.

Previsão sem derivação GRETL			
Mercado	COATING	AGRO	HPC
Produto	V1	V2	V3
Jan'15	58	445	576
Fev'15	41	561	614
Mar'15	40	689	443
Abr'15	12	594	400
Mai'15	28	628	466
Jun'15	32	680	466
Jul'15	22	636	403
Ago'15	47	791	339
Set'15	32	539	373
Out'15	58	593	308
Nov'15	56	722	354
Dez'15	4	224	304

Tabela 5 - Nova previsão gerada após derivação.

Previsão modelo após derivação - <i>Gretl</i>			
Mercado	COATING	AGRO	HPC
Produto	V1	V2	V3
Jan'15	50	593	567
Fev'15	40	857	883
Mar'15	32	1030	582
Abr'15	24	1024	466
Mai'15	23	1073	735
Jun'15	27	1124	773
Jul'15	18	1116	689
Ago'15	30	1216	425
Set'15	24	1087	517
Out'15	40	1137	301
Nov'15	41	1226	596
Dez'15	24	830	396

Tabela 6 - Erros envolvidos na geração da previsão dos três produtos.

Estatísticas de avaliação da previsão						
	Sem derivação da série original			Com derivação da série original		
	COATINGS	AGRO	HPC	COATINGS	AGRO	HPC
Erro Médio	2,0933	48,95	-15,501	-0,003694	-0,08	-0,00294
Erro Quadrado Médio	399,49	54814	33324	0,061163	0,331	0,15162
Erro Unitário Médio Quadrado	19,987	234,1	182,55	0,24731	0,575	0,38938
Erro Absoluto Médio	13,126	196,8	140,48	0,20876	0,304	0,27426
Erro Percentual Médio	-	-	-10,823	-0,46791	-2,51	-0,09126
Erro Percentual Médio Absoluto	-	-	27,427	5,8881	5,89	4,2599
U de Theil	-	-	0,73032	0,41402	0,577	0,91513