

USO DE MODELO DE MEMÓRIA LONGA: PREVISÃO DE EQUIPAMENTOS PARA A AGROINDÚSTRIA

USE OF LONG MEMORY MODEL: FORECAST OF EQUIPMENT FOR AGROBUSINESS

Francisca Mendonça Souza

Mestranda em Engenharia de Produção - PPGEP-UFSM; Santa Maria/RS - Brasil
kikamatcom@yahoo.com.br

Silvana Gonçalves de Almeida

Mestranda em Engenharia de Produção - PPGEP-UFSM; Santa Maria/RS - Brasil
silmtm@yahoo.com.br

Acássio Valente Feliciani

Graduando Tecnólogo em Irrigação e Drenagem - IFET-São Vicente do Sul/RS - Brasil
acassio27@ibest.com.br

Dr. Adriano Mendonça Souza

Prof. Dr. do Departamento de Estatística e do PPGEP-UFSM; Santa Maria/RS - Brasil
amsouza.sm@gmail.com

RESUMO: A empresa Limana Poliserviços fabrica equipamentos para agroindústrias responsáveis pelo processamento de derivados de cana-de-açúcar como alambiques em cobre para a produção de cachaça e álcool hidratada, bem como microdestilarias de álcool hidratado. A partir desta afirmativa, torna-se necessário fazer uma previsão por equipamentos demandados para manter de forma satisfatória o fluxo de atendimento aos clientes e as tomadas de decisões necessárias para um gerenciamento eficaz e de qualidade. A previsão do número de equipamentos a serem fabricados pela empresa para atender a demanda foi realizada pelo modelo ARFIMA, ou seja, comumente chamado, modelo de memória longa, o qual permitirá o conhecimento a curto prazo, dos valores futuros do número de pedidos de alambiques a ser produzidos pela empresa. O modelo que melhor explicou a série em estudo foi um modelo ARFIMA (1;0,3995;0). Com os valores previstos será possível à administração da Limana Poliserviços tomar medidas gerenciais que melhorem o fluxo de atendimento ao cliente e a produção de equipamentos.

Palavras Chave: Previsão de pedidos, modelos de memória longa, agroindústria, análise de séries temporais.

ABSTRACT: Limana Poliserve Company manufactures equipment for agribusiness in general derived from sugar cane as copper pot stills for the production of rum and hydrated alcohol as well as micro-distilleries for hydrous ethanol. From this statement, it is necessary to forecast the number of requests for equipment to maintain a satisfactory flow of customer service and decision making necessary for effective management and quality. The allocation of equipment manufactured by the company was held by the ARFIMA models, ie models of long memory commonly called, which will allow the knowledge in the short term, the future values of this variable. The model that best explained the series under study was a model ARFIMA (1;0,3995;0). With the values can be provided for the administration of Limana Poliserve take management measures to improve the flow of customer service and production equipment.

Keywords: Forecasting applications, long memory models, agro-industry, time series analysis.

1 INTRODUÇÃO

Agroindústria, atualmente, é sinônimo de agregação de valor, de adequação de matérias primas, de preservação e segurança dos alimentos, de desenvolvimento de processos e produtos, de desenvolvimento de equipamentos, de construção e aperfeiçoamento de modelos de gestão, de conveniência no consumo e de sistemas de produção construídos em bases sustentáveis. A funcionalidade da agroindústria, portanto, constitui uma dimensão econômica, social e ambiental de grande importância para a sociedade brasileira (LEITE, 2005).

A agroindústria, de acordo com Silveira (2005), é um dos principais segmentos da economia brasileira com importância tanto no abastecimento interno como no desempenho exportador do Brasil. Uma avaliação recente estima que sua participação no Produto Interno Bruto (PIB) seja de 12%, tendo uma posição de destaque entre os setores da economia, junto com o químico e petroquímico.

Quando se usa o conceito moderno de *agribusiness* (que abrange a soma total das operações de produção e distribuição de insumos e novas tecnologias agrícolas, produção propriamente dita, armazenamento, transporte, processamento e distribuição dos produtos agrícolas e seus derivados), a participação do complexo agroindustrial alcança mais de 35% do PIB, evidenciando o efeito multiplicador que esse setor exerce sobre a economia como um todo e sobre o interior do País em particular.

As agroindústrias podem representar um elemento chave para introduzir opções de atividades nas comunidades do interior, com efeito indireto no emprego rural, podendo assim melhorar o uso dos recursos materiais, humanos e diversificar fontes de renda das zonas rurais, promovendo os objetivos do desenvolvimento e da prosperidade material da vida rural.

O aprimoramento tecnológico computacional dos últimos 30 anos facilitou e, ao mesmo tempo, incentivou a aplicação de técnicas estatísticas com o objetivo de prever e melhor

gerenciar a demanda por produtos e/ou serviços prestados. Segundo Makridakis *et al.* (1998), a realização de previsões de demanda é importante para auxiliar na determinação dos recursos necessários para o bom desempenho de uma empresa e, em tempos de abertura de mercado, essa atividade torna-se fundamental.

A empresa Limana Poliserviços – Jaguari/RS fabrica equipamentos, em geral, para agroindústrias responsáveis pelo processamento de derivados de cana-de-açúcar como alambiques, extratores de óleos especiais e suqueiras, pipas de madeiras e barris de carvalho entre outros equipamentos e pequenas vinícolas, bem como microdestilarias de álcool hidratado. A empresa possui também produtos usados na fermentação da cachaça, como fermento, nutriente, nutriente com bactericida e antiespuma, assim como termômetros, alcoômetros, sacarímetros, provetas, proporcionando a sustentabilidade do homem no meio que está inserido pelo uso de equipamentos, processos e soluções economicamente viáveis.

Sabendo-se que a produção de alambiques é o propulsor na produção da empresa, faz-se necessário fazer uma previsão sobre o número de pedidos destes equipamentos a serem fabricados, buscando, por meio da análise de séries temporais, ajustar um modelo para obter uma previsão dos pedidos para manter o processo de fabricação sincronizados com os prazos de entrega, já que estes alambiques são fabricados em cobre, material este comprado fora da região que se localiza a empresa. Embora os métodos estatísticos descritivo sejam de grande importância para avaliação, a empresa sentiu a necessidade de utilizar uma metodologia mais robusta como os métodos de previsão para embasar a sua tomada de decisão e planejamento, onde a análise descritiva e de previsão serão úteis.

Assim, esta pesquisa está relacionada com a previsão de séries temporais, com a aplicação dos modelos de memória longa (ARFIMA) no setor de produção de equipamentos para a agroindústria de Jaguari - RS, que fabrica equipamentos para os derivados de cana-de-açúcar e pequenas vinícolas, bem como microdestilarias de álcool hidratado. O estudo engloba dados mensais de pedidos de alambiques de janeiro de 2006 à janeiro de 2008, obtidos junto ao setor de estatística da empresa Limana Poliserviços.

Os modelos lineares de previsão englobam os modelos de memória curta representado pelos modelos ARIMA, e os modelos de memória longa, os ARFIMA. O primeiro é responsável por capturar as curtas dependências da série e o segundo é responsável por capturar e modelar processos com longa dependência. Tem-se especial interesse pelos modelos ARFIMA, pois eles são capazes de congregam tanto as baixas quanto as altas dependências. Logo, conhecendo-se o comportamento da solicitação de produção de alambiques antecipadamente e sabendo-se que estão dentro das expectativas, ações gerenciais

poderão ser implementadas pelos setores responsáveis, e evitando-se custos desnecessários com a entrega de produtos em atraso ou pelo descumprimento das necessidades demandadas pelo cliente.

2 REVISÃO DE LITERATURA

Nesta seção, serão apresentadas as definições de séries temporais, os modelos de Box e Jenkins, sendo que partir dos anos 80, Granger e Joyeux e ainda Hosking (1981) propõem uma generalização desta modelagem em relação ao parâmetro d , podendo este assumir não só valores inteiros, mas também representar graus de diferenciação fracionários (modelo ARFIMA). Para seleção do melhor modelo será usado o critério penalizador *Akaike Information Criteria* (AIC). Estes são conceitos fundamentais para uma melhor compreensão da metodologia utilizada para realizar previsões de pedidos de alambiques produzidos pela empresa Limana.

2.1 Séries Temporais

Segundo Nelson (1973), Box e Jenkins (1976), Granger e Newbold (1977), Box e Luceño (1997), Morettin e Tolo (2004), uma série temporal é uma sequência de dados obtidos em intervalos de tempo regular durante um período específico, e que apresentam uma dependência seriada entre as observações. Isto é, o valor de uma observação mostra-se correlacionado com outro valor em instantes equiespaçados de tempo. A notação utilizada para representar uma série temporal Z no instante t será Z_t , em que $t=1,2,\dots,n$ indica o tamanho da série.

A previsão é uma das principais razões que popularizaram os modelos Box e Jenkins, genericamente conhecidos por ARIMA (*Auto Regressive Integrated Moving Averages*), que segundo Werner e Ribeiro (2003) são modelos matemáticos que captam o comportamento da correlação seriada ou autocorrelação entre os valores da série temporal, e com base nesses comportamentos possibilitam realizar previsões futuras. Os modelos ARFIMA são uma generalização dos modelos ARIMA e são responsáveis por capturar e modelar processos com longa dependência serial, comumente chamada de memória longa. É um processo estacionário em que a função de autocorrelação decresce hiperbolicamente para zero, isto é, $\rho_j \sim C_j^{-\alpha}, j \rightarrow \infty$ onde $C > 0$ e $0 < \alpha < 1$, conforme Moretin (2008).

Estes modelos são capazes de descrever as dinâmicas de memória curta e longa de processos fracionários, onde o parâmetro que corresponde à integração no modelo

representado pelo parâmetro I este é representado pelo número de diferenciações d . As diferenciações são necessárias para estacionarizar a série e deve explicar a estrutura de correlação de ordens altas. A parte autorregressiva do modelo é representada pelo parâmetro ϕ e a parte de médias móveis é representada por θ . Desta forma tem-se um modelo ARIMA $(p; d; q)$; se a integração for inteira tem-se um modelo ARIMA e se a integração for fracionária tem-se um modelo ARFIMA.

Segundo Morettin (2008), a razão da escolha dessa família de processos, para fins de modelagem das séries com o comportamento de memória longa, é que o efeito do parâmetro d em observações distantes decai hiperbolicamente conforme a distância aumenta, enquanto os parâmetros ϕ e θ decaem exponencialmente. Então, d deve ser escolhido com o objetivo de explicar a estrutura de correlação de ordens da série, enquanto os parâmetros ϕ e θ explicam a estrutura de correlação de ordens baixas.

Outras características dos modelos de memória longa, são as de que estas séries apresentam persistência nas autocorrelações amostrais, isto é, dependência significativa entre as observações por um longo intervalo de tempo e que sua função densidade espectral é não limitada na frequência zero, o que equivale a dizer que sua função de autocorrelação não é absolutamente somável. (MORETTIN, 2008).

Os modelos ARIMA (p,d,q) , introduzidos por Box e Jenkins (1970), incluem o parâmetro d , um inteiro que estabelece o nível de diferenciações necessárias para tornar uma série temporal estacionária de 2ª ordem. Estes modelos são adequados para a modelagem do comportamento de séries temporais em curto prazo. A partir dos anos 80, Granger e Joyeux e ainda Hosking (1981) propõem uma generalização desta modelagem em relação ao parâmetro d , podendo este assumir não só valores inteiros, mas também representar graus de diferenciação fracionários.

Modelos com esta propriedade permitem estudar séries caracterizadas por longas dependências temporais. Estes modelos intitulam-se ARFIMA (p,d,q) , onde o parâmetro d significa uma diferenciação de ordem fracionária, sendo este motivo a denominação em inglês de *fractional*.

De acordo com Figueiredo e Marques, (2009), o processo Z_t (Equação 1) é um ARFIMA (p,d,q) se este é a solução da equação de diferenças:

$$\phi(B)(1-B)^d Z_t = \theta(B)a_t \quad (1)$$

Onde:

$\phi(B)$ e $\theta(B)$ representam os polinômios $\phi(Z) = 1 - \phi_1 Z - \dots - \phi_p Z^p$ e $\theta(Z) = 1 - \theta_1 Z - \dots - \theta_q Z^q$ no operador retardo $B : B^j Z_t = Z_{t-j}$.

O termo $(1 - B)^d$ é definido pela expansão binomial $(1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k$.

$\{e_t\}$ é um processo ruído branco em que $E(e_t) = 0$, σ_e^2 .

Se os polinômios $\phi(B)$ e $\theta(B)$ têm suas raízes fora do círculo unitário e não possuem raízes comuns, o processo $(1-B)^d Z_t$ é estacionário (de 2ª ordem) e invertível.

Quando $d = 0$, Z_t segue um modelo autorregressivo de médias móveis, ARMA (p, q) . Quando $d \neq 1$ e é não inteiro, a função de autocorrelação $\rho(k)$ tem um decaimento hiperbólico, $\rho(k) \sim e^{-|k|^{2d-1}}$, $|k| \rightarrow \infty$. As autocorrelações originadas de um modelo ARMA (p, q) têm um decaimento exponencial $\rho_k \sim a^k$, $0 < a < 1$ (Box e Jenkins, 1976). Tem-se então, no caso do ARFIMA, um processo de "longa dependência", "longa persistência" ou "*long memory*", se $0 < d < 0,5$. No caso de $-0,5 < d < 0$, o processo é de dependência intermediária ou "*intermediate memory*". Assim, a função de autocorrelação exibirá dependências negativas entre observações mais distantes. No domínio da frequência, a característica fracionária de " d " é detectada pelo comportamento da função espectral, que tende ao infinito quando a frequência se aproxima de zero.

2.2 Estimação de "d"

Na literatura existem vários métodos para estimar o parâmetro d do modelo ARIMA (p, d, q) , sendo os métodos paramétricos os mais usuais. Reisen (1995) apresenta alguns desses métodos e suas respectivas propriedades. O autor destaca três, os quais são: o método da regressão utilizando o periodograma; o método da regressão utilizando o periodograma suavizado; e o método utilizando o coeficiente de Hurst.

Dentre os métodos destacados, dois são baseados na utilização do periodograma, pois este é estimador da função espectral de uma série temporal. Neste caso, é importante apresentar a função espectral, a função periodograma e algumas propriedades associadas.

Até o presente momento foi abordado os modelos ARIMA (p, d, q) , onde o valor do parâmetro de integração d é considerado um valor inteiro, isto é, um ou dois. A partir de agora

discute-se a versão fracionária do modelo ARIMA, onde o o valor de d corresponde a um valor fracionário.

Seja $\{Z_t\}$ um processo ARFIMA (p,d,q) com $d \in (-0,5;0,5)$, representado por $(1-B)^d Z_t = U_t$, onde $\phi(B)U_t = \theta(B)a_t$, e $\{e_t\}$ é um processo ruído branco.

A função espectral de $\{Z_t\}$ é dada pela Equação 2:

$$f(w) = f_u(w)(2\text{sen}(w/2))^{-2d}, w \in [-p, p] \quad (2)$$

onde $f_u(w)$ é a função espectral de U_t .

Logaritmando-se a Equação 2, obtém-se a Equação 3:

$$\ln f(w) = \ln f_u(w) - d \ln(2\text{sen}(w/2))^2 \quad (3)$$

Logo temos a Equação 4:

$$\ln f(w) = \ln f_u(0) - d \ln(2\text{sen}(w/2))^2 + \ln\{f_u(w)/f_u(0)\} \quad (4)$$

Da Equação 4, obtém-se as duas equações de regressão que serão usadas no processo de estimação de d , usando o periodograma e o periodograma suavizado.

2.3 Processo estacionário ARFIMA (p,d,q)

Com integração fracionária, ARFIMA (p,d,q) é um processo autorregressivo integrado de média móveis em que d (grau de diferenciação) assume valores não inteiros. Hosking (1982) foi um pioneiro nos estudos desses processos. Este modelo caracteriza-se por ter longa dependência (*long memory*) quando $d \in (0,0;0,5)$ e pequena dependência (*short-memory*) quando se observa $d \in (-0,5;0,0)$.

A longa dependência (também chamada, persistência) é uma característica que tem sido observada em diversas áreas de estudo, sobretudo nas séries temporais econômicas. A persistência consiste em uma significativa dependência presente na série mesmo para *lags* distantes, ou seja, uma dependência temporal em períodos longos. Se $d \in (0,0;0,5)$, o

processo tem aspecto de longa dependência e exibe forte dependência positiva entre observações distantes no domínio do tempo. O comportamento do correlograma associado é de lento decréscimo, ou seja, $\rho_k \sim k^{-d}$. A função de autocorrelação para o processo de curta dependência é caracterizada por exibir dependências negativas, no domínio do tempo, entre distantes observações. Tem a propriedade de $d \in (-0,5;0,0)$. Logo, o tipo de dependência é identificado pelo valor do grau de diferenciação fracionária d .

O processo geral com diferenciação fracionária, ARFIMA (p,d,q) , para uma variável Z_t , é definido como um processo que satisfaz a Equação 5, dada por:

$$\Phi(B)(1-B)^d Z_t = \Theta(B)e_t \text{ para } d \in (-0,5;0,0) \quad (5)$$

Em que a_t é um processo ruído branco, $E[a_t]=0$, $\text{var}[a_t] = a_e^2$; B é o operador de defasagem de forma que, $\Phi(B) = 1 - \Phi_1 B - \dots - \Phi_p B^p$ e $\Theta(B) = 1 - \Theta_1 B - \dots - \Theta_p B^p$.

A diferenciação é obtida pela expansão binomial, ou seja Equação 6, onde $(1-B)^d$ com $d \in \mathbb{R}$.

$$(1-B)^d = \sum_{j=0}^{\infty} \binom{d}{j} (-B)^j \quad (6)$$

Desta forma, obtêm-se a Equação 7,

$$= 1 - dB - \frac{d(1-d)}{2!} B^2 - \frac{d(1-d)(2-d)}{3!} B^3 - \dots; \quad (7)$$

Detalhes podem ser vistos em Beran (1994). Os parâmetros da diferenciação fracionária d variam de -1 a 1 e podem ser interpretados de acordo com Hosking (1981), Jin e Frechete (2004) e Lima *et al.* (2007).

2.4 Processo ARFIMA não estacionário

É importante verificar o parâmetro de diferenciação para as séries em nível e na primeira diferença. Segundo Olbermann (2006), uma propriedade desejável do parâmetro fracionário estimado é a invariância em processos não estacionários. Sendo assim, o processo

(7), ou seja a equação, com o parâmetro $d^* = d+1$, sendo $d \in (0,0;0,5)$, torna o modelo como segue:

$$\Phi(B)(1-B)^{d^*} Z_t = \Theta(B)e_t, t \in Z \quad (8)$$

O processo (8) é não-estacionário onde $d^* \leq 0,5$; porém, ainda persistente. Para $d^* \in (0,5;1,0)$, é nível-revertível e não há impacto de inovação de longo prazo no valor do processo. A propriedade nível-reversão não é garantida quando $d^* \geq 0,5$.

2.5 Adequação do Modelo

A identificação é uma das etapas mais difíceis na modelagem de uma série temporal e não são raros os casos em que não se consegue identificar um único, mas vários modelos candidatos a explicar o processo gerador da série. Isto porque, trabalhando com a função de autocorrelação (FAC) e a função de autocorrelação parcial (FACP) amostrais, fica difícil, muitas vezes, decidir se os valores das funções de autocorrelações estão decrescendo ou se são truncadas. Para auxiliar na identificação, muitos pesquisadores preferem utilizar outros procedimentos de identificação que dependem menos do julgamento de quem está analisando a série de tempo. Esse procedimento faz uso de critérios de seleção de modelos construídos com base na variância estimada dos resíduos, no tamanho da amostra e nos valores de p e q . O critério utilizado nesta pesquisa será o critério *Akaike Information Criteria* (AIC). Este critério considera o número de parâmetros envolvidos na estimação dos modelos e o número de observações e também são denominados de critérios penalizadores.

Segundo Moretin e Tolo (2004), é aconselhável identificar vários modelos que captam a autocorrelação serial dos dados. Após esta etapa de identificação deve-se escolher o melhor modelo com base no critério penalizador *Akaike Information Criteria* (AIC), que busca encontrar modelos parcimoniosos, ou seja, aqueles com menor número de parâmetros conforme mostrado a seguir em 9.

$$AIC = \ln \hat{\sigma}_\epsilon^2 + \frac{2(p+q)}{n} \quad (9)$$

A seleção dos modelos se dará com base no critério penalizador AIC *apud* Souza (2009) e Vicini (2007), nos quais, em vez de estabelecer p e q precisamente, estimam-se os modelos

correspondentes a vários pares (p, q) e escolhe-se aquela especificação que apresentar o menor valor para AIC.

A presença de p e q nas fórmulas dos critérios AIC tem por objetivo levar em consideração o número de parâmetros utilizados para representar a série em estudo e desta forma penalizar os modelos com muitos parâmetros. Sendo assim modelos parcimoniosos devem ser privilegiados por apresentarem menor número de parâmetros a ser estimado. A crítica que se faz a esse critério é que ele pode conduzir a modelos super especificados, ou seja, modelos com valores de p e/ou q maiores do que o correto. Assim sendo, o critério AIC deve ser usado como procedimento complementar e não alternativo aquele baseado na *FAC* e na *FACP*.

3 METODOLOGIA

Para a execução desta pesquisa, serão consultados os relatórios elaborados no setor de estatística da empresa Limana Poliserviços. Após a coleta dos números de alambiques produzidos, serão analisadas as pressuposições básicas para a aplicação da análise de séries temporais, identificados e estimados os modelos concorrentes, posteriormente será verificada a adequação por meio da análise dos resíduos. Para aplicação dos modelos ARFIMA, utilizouse uma amostra formada por 36 observações do ano de 2000 a 2004 dos pedidos de alambiques fabricados na empresa.

O trabalho seguirá as seguintes etapas: na primeira, realizar-se-á a coleta de dados e conhecimento dos mesmos no setor de estatística da empresa e então as informações serão transpostas para uma tabela simples com a utilização de planilha eletrônica, na segunda etapa, realizar uma análise descritiva dos dados, pois a mesma mostra o comportamento de uma situação ou problema, na terceira etapa, grafou-se a série em estudo e realizou-se a modelagem, com o auxílio do programa estatístico *Statistic 7.0*. A *FAC* e *FACP* serão utilizadas para verificar a estacionariedade da série e o tipo de modelo que será utilizado. Na terceira etapa, após encontrar um modelo representativo da série, faz-se a análise dos resíduos e, para decidir entre os modelos concorrentes utiliza-se o critério AIC para decidir qual o melhor modelo para representar a série em estudo. Finalmente, realiza-se previsões para os meses vindouros com um horizonte de previsão de 6 meses.

4 RESULTADOS E DISCUSSÕES

Para identificar o modelo apropriado que representa a série em estudo, o primeiro passo consistiu em observar se a série temporal apresenta tendência ou alteração na variância. Na

Figura 1, observa-se que até a observação de número 19 a série apresenta-se estável e que da observação 20 até a observação 30 há uma tendência crescente. E, da observação 31 a 36 há uma tendência decrescente na série.

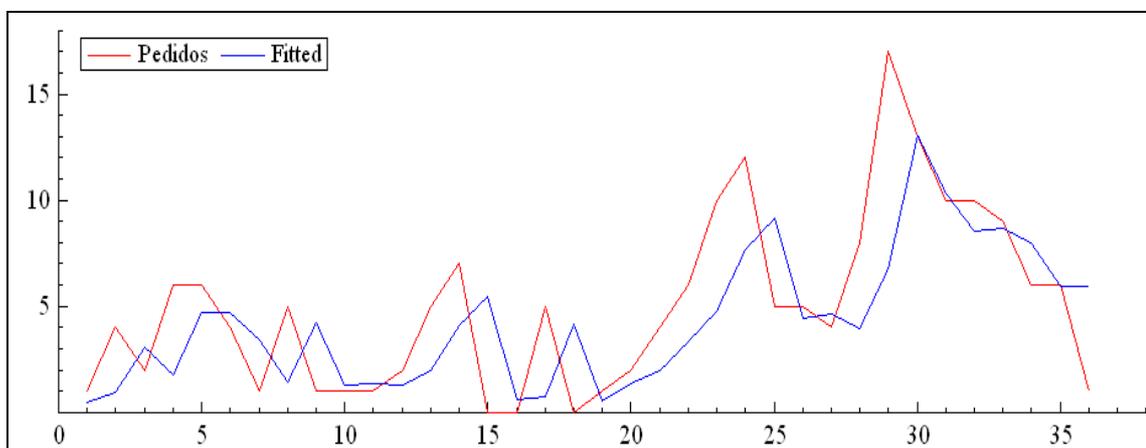


Figura 1 – Série original e diferenciada dos números dos pedidos de alambiques da empresa Limana Poliserviços – Jaguari/RS, de jan/06 a jun/08.
Fonte: Resultado da pesquisa

Observa-se pela Figura 1 que a série ajustada apresenta-se mais estável que a série original, logo, ela deve ser utilizada para se estimar o modelo que represente a série em estudo.

Para Farias, Rocha e Lima (2000), a análise dos resíduos de modelos concorrentes ajustados é importante na escolha final do modelo que melhor explica a dinâmica da variável em estudo. Procura-se por resíduos com característica de ruído branco, isto é, média zero, variância constante. Também se espera que os resíduos sejam não autocorrelacionados, pois se o forem, a dinâmica da série não é completamente explicada pelos coeficientes estimados para o modelo ajustado. Uma análise da existência da autocorrelação serial de resíduos é feita com base nas funções de autocorrelação residual.

Portanto, o próximo passo foi estimar os modelos concorrentes e escolher o melhor entre eles. Na tentativa de encontrar o melhor modelo que represente o processo gerador da série, diversos modelos concorrentes foram estimados e como medida de seleção entre os modelos escolheu-se aquele que apresentasse um menor valor para o critério de informação de Akaike (AIC).

Tabela 1 – Modelos concorrentes encontrados para a série de pedidos de alambiques da empresa Limana Poliserviços – Jaguari/RS

Modelos	Parâmetros	Erro-Padrão	t-prob.	AIC
<i>ARFIMA(1,d,1)</i>	$d = 0,4213$	0,088	0,000	5,4357
	$\phi_1 = -0,1197$	0,641	0,853	
	$\theta_1 = 0,4240$	0,559	0,454	
<i>ARFIMA(2,d,1)</i>	$d = 0,4131$	0,104	0,000	5,4902
	$\phi_1 = -0,2315$	0,772	0,766	
	$\phi_2 = 0,064$	0,343	0,853	
	$\theta_1 = 0,5502$	0,763	0,476	
<i>ARFIMA(2,d,0)</i>	$d = 0,4187$	0,103	0,000	5,4397
	$\phi_1 = -0,2970$	0,771	0,853	
	$\phi_2 = -0,0769$	0,853	0,454	
<i>ARFIMA(1,d,0)</i>	$d = 0,3995$	0,1130	0,001	5,3890
	$\phi_1 = 0,3007$	0,2328	0,205	

Fonte: Resultado da pesquisa

Observa-se na Tabela 1, os modelos encontrados para os pedidos de alambiques para empresa Limana Poliserviços, Jaguari/RS, o melhor modelo ajustado é dado por ARFIMA (1;0,3995;0); isto é, um modelo autoregressivo de primeira ordem com uma diferenciação fracionária com $d = 0,3995 < 0,5$, $|\theta_1| = 0,3007 < 1$. Este modelo apresentou resíduo com características de ruído branco e o menor valor para o critério AIC entre os modelos concorrentes estimados.

4.1 Análises dos Resíduos

Na Figura 2, observa-se que a autocorrelação e a autocorrelação parcial dos resíduos do modelo ARFIMA (1; 0,3995; 0). Com base nos resíduos estimados foram calculadas as funções FAC e a FACP e com base nestes resultados, foram calculados os limites de confiabilidade, geralmente $1,96 * 1/(T)^{1/2}$, onde valores fora destes limites de controle mostram que as funções de autocorrelações são significativas. O que se espera de resíduos com características ruído branco é que as correlações residuais estejam dentro dos limites de controle. Desta forma os resíduos são não correlacionados, mostrando que o modelo estimado conseguiu captar todas as informações contidas no conjunto de dados. Salienta-se também que

para a avaliação da autocorrelação residual de 15 a 20 por cento das *FAC* e *FACP* já são necessárias para a sua avaliação.

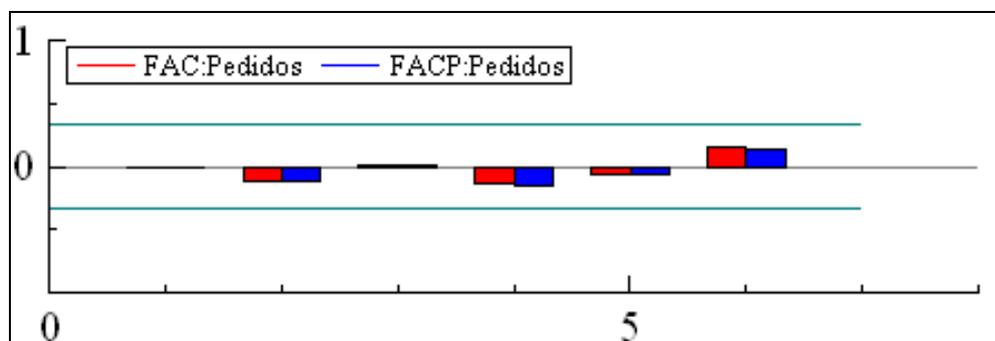


Figura 2 – FAC e FACP dos resíduos da série dos pedidos de alambiques da empresa Limana Poliserviços – Jaguari/RS.
Fonte: Resultado da pesquisa

Encontrado o modelo mais adequado, o próximo passo foi realizar a previsão da série em estudo. Na Tabela 2 e Figura 3, é possível visualizar as previsões mensais de janeiro a junho de 2009 e o erro-padrão.

Tabela 2 – Previsões para o número de pedidos de alambiques produzidos pela empresa Limana Poliserviços – Jaguari/RS , de jan a jun/09, usando o modelo ARFIMA(1;0.3995;0)

Previsão do Número de Alambiques		
Horizonte	Previsão	Erro-Padrão
Jan/09	2,097	3,21
Fev/09	2,812	3,92
Mar/09	3,135	4,23
Abr/09	3,254	4,39
Mai/09	3,276	4,50
Jun/09	3,253	4,57

Fonte: Resultado da pesquisa

O período de análise foi de janeiro de 2006 a dezembro de 2008 e a previsão foi realizada com um horizonte de seis meses, correspondendo ao período de janeiro a junho de 2009. Analisando a Tabela 2, observa-se que há um pequeno crescimento de pedidos para os três últimos meses, sugerindo um aumento na produção da empresa.

Observa-se na Figura 3 o gráfico das previsões dos pedidos para os meses de janeiro a junho de 2009, como está representado na Tabela 2.

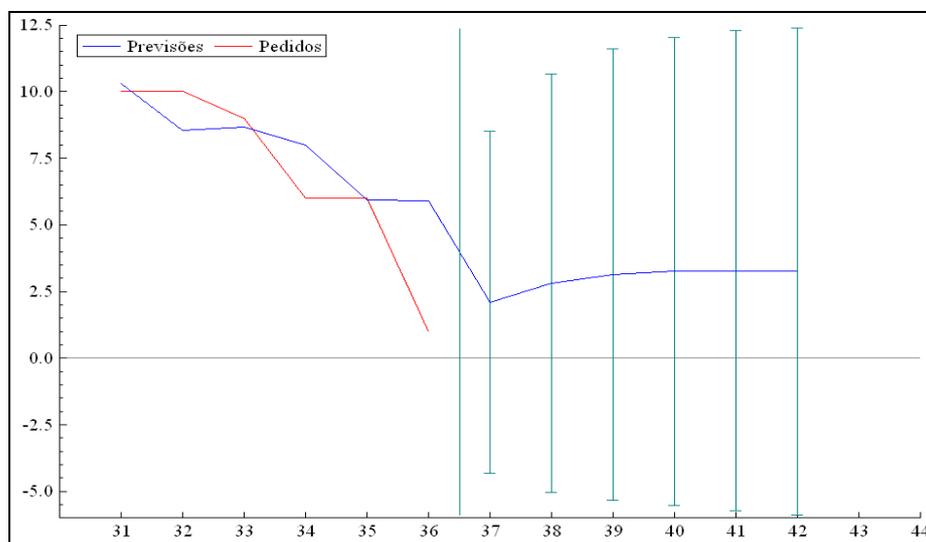


Figura 3 – Previsão do número de pedidos de alambiques produzidos pela empresa Limana Polisserviços – Jaguari/RS, de jan a jun/09.
Fonte: Resultado da pesquisa

Na Figura 3, apresenta-se graficamente os valores previstos com base no modelo ARFIMA (1;d;0), onde se verifica um crescimento do número de pedidos. As barras verticais representam os intervalos de confiança para os valores previstos. A previsão torna-se importante, pois, é possível acompanhar o movimento futuro da variável em análise e desta forma se precaver em termos de estoques e materiais necessários para a produção, principalmente, para o cumprimento dos prazos com os clientes. Sob outro aspecto, as previsões são úteis para que a gerência possa tomar medidas de expansão ou retração de seus produtos industrializados.

5 CONCLUSÕES

Ao estudar sobre a previsão do número de alambiques fabricados pela empresa Limana Polisserviços de Jaguari-RS, procurou-se fornecer um subsídio a mais no gerenciamento das atividades da empresa, pois no momento se tem o conhecimento do comportamento da variável estudada pode-se antecipar medidas gerenciais com base nas previsões.

As previsões são importantes para auxiliar na determinação dos recursos necessários para o bom desempenho da empresa e em tempos de grande concorrência comercial, a ferramenta de precisão torna-se importante.

A metodologia empregada para a análise foi a de modelos de longa dependência ARFIMA e observou-se que o modelo ARFIMA(1;0,3995;0) foi o que melhor explicou a demanda dos pedidos de alambiques para agroindústria, podendo-se assim realizar previsões apropriadas ao escopo de produção da empresa. As previsões encontradas para os meses futuros foram executadas por meio de um ferramental criterioso que possibilitará a organização de estoques de matérias de consumo, mão-de-obra especializada, entre outras rotinas que são envolvidas dentro da empresa. Também podem auxiliar a direção da empresa no dimensionamento da capacidade de produção, assim como para gestionar junto aos órgãos de competência mais recursos para a ampliação, tanto dos recursos humanos que ali trabalham quanto dos recursos físicos.

Sugere-se, para estudos futuros, a utilização de técnica de modelagem em outros setores da empresa e a aplicação de estudos de controle estatístico do processo de produção, como forma de torná-la mais competitiva frente à concorrência.

REFERÊNCIAS BIBLIOGRÁFICAS

BERAN, JAN. Statistics for long-memory process. New York: Chapman & Hall, 1994. 315 p.

BOX, G. E. P.; JENKINS, G.M. **Time Series Analysis, forecasting and control**. San Francisco: Holden Day, 1970. 315p

BOX, G. E. P.; TIAO, G. C. Comparison of forecast and actuality Applied Statistica, **Journal of the American Statistical Association**, Madison, v.25, p 195-200, out., 1976.

BOX, G. E. P.; TIAO, G. C. Intervention analysis with applications to economic and environmental problems. **Journal of the American Statistical association**, Los Angeles, v.70, p.70-79, mar., 1975.

BOX, G. E. P.; PIERCE, D. A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. **Journal of the American Statistical Association**, Madison, v. 65, p. 1509-1526, dez., 1970.

FARIAS, E. R.; ROCHA, F. J. S; LIMA, R. C. Critérios de seleção de modelos sazonais de séries temporais: uma aplicação usando a taxa de desemprego da região metropolitana de Recife. In: **III Encontro Regional de Estudos do Trabalho – ABET**, 22 a 24 de novembro de 2000 – Recife, PE. Disponível em: <<http://www.race.nuca.ie.ufrj.br/abet/3reg/39.DOC>>. Acesso em: 20 set. 2009.

HOSKING, J. **Some models of persistence in time series analysis: theory and practice 1**. North Holland Publishing Company, p. 641-653, 1982.

JENKINS, J. ET AL. **Statistical analysis of multiple time series associated with air quality data**. New Jersey: Madison, 1978. 419 p.

JIN, H. J. e FRECHETE, D. L. Fractional integration in agricultural futures prices volatilities. **American Journal of Agricultural Economics**, v. 86, n. 2, mai., 2004.

LIMA, C.H.R.; FRISCHKORN, H.; BURTE, J. Avaliação da interação rio-aquífero a partir de dados experimentais e de um modelo analítico. **Revista Brasileira de Recursos Hídricos**, v. 12, n. 1, p. 217-230, jan/mar., 2007.

MAKRIDAKIS, S; WHEELWRIGHT,S.; HYNDMAN,R J. **Forecasting methods and applications**. 3 ed. New York; John Wiley e Sons, p. 45, 1998.

MORETTIN, P. A.; TOLOI, C. M. C. **Modelos de função de transferência**. In: 3ª Escola e séries temporais econometria, 2004, Rio de Janeiro. Anais. Rio de Janeiro: EPGE/FGV,2004.

MORETTIN, P. A. **Econometria financeira: um curso em séries temporais financeiras**. 1 ed.São Paulo: Blucher, 2008.

NELSON, C. R. **Applied time series analysis for forecasting**. San Francisco: Holden- Day, p. 902-907, 1973.

REISEN, V. A. Estimation of the fractional difference parameter in the ARIMA (p,d,q) model using the smoothed periodogram. **Journal of the Time Series Analysis**. v.15, n. 3, p. 335-350, mai., 1994.

OLBERMANN, B. P., LOPES, S. R. C., REISEN, V. A. Invariance of the first difference in ARFIMA models. **Computational Statistics**. Porto Alegre. v. 21, n. 3-4, p. 445-461, dez. 2006.

GRANGER, C. W. J.; JOYEUX, R. An introduction to long-memory time series models and fractional differencing. **Journal of Time Series Analysis**, v. 1, p. 15-29, 1980.

SOUZA, F. M., SOUZA, A. M.; LOPES, L. F. D. Previsão da demanda de leitos hospitalares por meio da análise de séries temporais. **Revista do Centro de Ciências: Ciência e Natura Exatas**, UFSM, v. 31, n. 1, p. 33-47, jun-jul, 2009.

VICINI, L.; SOUZA, A. M. Geração de subsídios para a tomada de decisão na cadeia produtiva da bovinicultura no Brasil, **Revista GREPOS**, v. 4, jul-set, 49-64 p, 2007.

WERNER, L.; RIBEIRO, J. L. D. Demand forecasting: an application of the Box-Jenkins models in the technical assistance of personal computer. **Gestão e Produção**, v.10, n.1, p.47-67, 2003.

SILVEIRA, M. J. In: **Tendências internacionais no setor agroalimentar**. Viçosa: Intec solução em informática e tecnologia, 2005. Disponível em: <http://www.mre.gov.br/cdbrasil/itamary/web/port/economia/agroind/tendint/index.htm>. Acesso em: 18 de julho de 2009.

LEITE. In Estudo de viabilidade técnica e econômica para abertura de uma agroindústria processadora de polpa de frutas no Município Aimorés-MG, 2005. Disponível em: http://www.institutoterra.org/doc/06_EVTE_IND_STRIA_DE_POLPAS_AI.PDF. Acesso em 20 de julho de 2009. (Leite, 2005).

BIBLIOGRAFIA COMPLEMENTAR

ABDEL-AAL, R. E.; AL-GARNI, Z. Forecasting monthly electric energy consumption in eastern Saudi Arabia using univariate times-series analysis. **Energy**, Saudi Arabia, v. 22, n. 11, p. 1059-1069. nov., 1997.

HARVEY, A. C. DURBIM, J. The Effects of Seat Belt Legislation on British Casualties: A case Study in Structural Time Series Modeling. **Journal Royal Statistical Society**, v. 149, p. 187-227, mar., 1986.

PACK, D. J. Forecasting time series affected by identifiable isolated events. Working Paper Series, **College of Adm. Sciences**, Ohio State, v. 16. n. 4. p. 1748-1749. abr., 1977.

PELLEGRINI, F. R.; FOGLIATTO, F. Estudo comparativo entre modelos de Winters e de Box & Jenkins para a previsão da demanda sazonal. **Revista Produto e Produção**, v. 4, número especial, p. 72-85, abr., 2000.

PINO, F. A. **Análise de intervenção e séries temporais:** aplicações em economia agrícola. 1980. 80 f. Dissertação (Mestrado em Economia) – Universidade de São Paulo, SP.