

---

## **PREVISÃO DO PREÇO DA GASOLINA PARA A REGIÃO SUL DO BRASIL**

### **GASOLINE PRICE FORECASTING TO SOUTHERN REGION OF THE BRAZILIAN**

#### **Francisca Mendonça Souza**

Universidade Federal de Santa Maria  
Mestre em Engenharia de Produção  
Santa Maria/RS – Brasil.  
[kikamatcom@yahoo.com.br](mailto:kikamatcom@yahoo.com.br)

#### **Silvana Gonçalves de Almeida**

Universidade Federal de Santa Maria  
Mestranda em Engenharia de Produção  
Santa Maria/RS – Brasil.  
[silmtm@yahoo.com.br](mailto:silmtm@yahoo.com.br)

#### **Prof. Adriano Mendonça Souza**

Universidade Federal de Santa Maria  
Departamento de Estatística e Programa de Pós-graduação em Engenharia de Produção  
Santa Maria/RS – Brasil.  
[amsouza.sm@gmail.com](mailto:amsouza.sm@gmail.com)

#### **Prof. Luis Felipe Dias Lopes**

Universidade Federal de Santa Maria  
Departamento de Estatística e Programa de Pós-graduação em Engenharia de Produção  
Santa Maria/RS – Brasil.  
[lflopes@smail.ufsm.br](mailto:lflopes@smail.ufsm.br)

#### **Prof.<sup>a</sup> Roselaine Ruviano Zanini**

Universidade Federal de Santa Maria  
Departamento de Estatística  
Santa Maria/RS – Brasil  
[rrzanini@terra.com.br](mailto:rrzanini@terra.com.br)

**RESUMO:** A gasolina A é produzida pelas refinarias de petróleo e entregue diretamente às companhias distribuidoras. Essa gasolina constitui-se basicamente de uma mistura de naftas numa proporção tal que enquadre o produto na especificação prevista. A partir desta afirmativa, torna-se necessário fazer uma previsão do preço deste produto a fim de auxiliar os órgãos competentes nas tomadas de decisões necessárias para um gerenciamento eficaz e de qualidade. Para a realização das previsões, foram usados os modelos ARFIMA, chamados comumente de modelos de memória longa, os quais permitem o conhecimento, a curto prazo, dos valores futuros desta variável. O modelo que melhor explicou a série em estudo foi um ARFIMA (1; 0,3995; 0). Com os valores previstos é possível ter uma melhor perspectiva, além de auxiliar os órgãos competentes na administração das medidas gerenciais que melhorem o fluxo de atendimento ao cliente e a produção de equipamentos.

**Palavras-chave:** Previsão de gasolina. Modelos de Memória Longa. Análise de Séries Temporais.

**ABSTRACT:** The gasoline is produced by oil refineries and delivered directly to distributors. This gasoline is basically a mixture of naphtha to an extent that outlines the product specification provided. From this statement, it is necessary to forecast the price of oil to assist the competent bodies in decision-making necessary for effective management and quality. To carry out the forecasts, we use the ARFIMA models, i.e. 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 is a model ARFIMA (1, 0.3995, 0). With the figures you can get a better perspective, and assist the competent bodies in the administration of management measures to improve the flow of customer service and production equipment.

**Keywords:** Forecasting. Long Memory Models. Time Series Analysis.

## 1 Introdução

A gasolina é uma mistura de hidrocarbonetos líquidos inflamáveis e voláteis, derivados do petróleo. Além de ser utilizada como combustível em motores de combustão interna é também usada como solvente na indústria para óleos e gorduras. Originalmente, a gasolina era um produto colateral e indesejado da indústria de refinamento de petróleo - que estava interessada principalmente no querosene. As refinarias desprezavam toda a gasolina obtida. Com o advento dos motores de combustão, a gasolina foi logo eleita como a melhor opção para combustível, devido a algumas de suas características: alta energia de combustão, alta volatilidade e sua compressibilidade.

A gasolina A é produzida pelas refinarias de petróleo e entregue diretamente às companhias distribuidoras. Essa gasolina constitui-se basicamente de uma mistura de naftas numa proporção tal que enquadre o produto na especificação prevista. Este produto é à base da gasolina disponível nos postos revendedores. Concorrendo com o álcool hidratado e com o GNV, a gasolina abastece hoje cerca de 60% dos veículos de passeio no Brasil. Por isso, é importante que o consumidor conheça como funciona o mercado desse produto, desde o produtor até o consumidor final, e ainda saiba como é formado o seu preço.

Em relação ao preço nos mercados de produção e de revenda no período entre setembro de 2005 e abril de 2008, não houve reajustes dos preços da gasolina “A” nas unidades produtoras. O estado do Rio Grande do Sul não apresenta produção de petróleo, sendo responsável somente pelo refinamento, através das refinarias Alberto Pasqualini S.A. – REFAF e Ipiranga. Nessas refinarias ocorre o processamento do petróleo bruto originando diversos derivados, entre eles o óleo diesel. Esta pesquisa engloba dados médios ponderados semanais de preços, por litro, pago pelos produtores de gasolina A no período janeiro de 2002 a agosto de 2009, obtidos junto à ANP – Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, para a região Sul, não se estendendo às demais regiões do Brasil.

Pretende-se, ao desenvolver esta pesquisa, mostrar a aplicabilidade dos modelos ARIMA (*Auto Regressive Integrated Moving Averages*), desenvolvidos por Box e Jenkins (1976), na previsão do preço semanal da gasolina “tipo A” na região Sul.

A realização de previsões para os setores produtivos da economia e consumidores em geral é de grande auxílio para a sua programação no trabalho, na empresa e na sua rotina diária.

## 2 REVISÃO DE LITERATURA

Nesta seção serão apresentadas as definições de séries temporais, os modelos de Box e Jenkins e os critérios de seleção dos modelos concorrentes, denominados de critérios penalizadores, além de conceitos fundamentais para uma melhor compreensão da metodologia utilizada para realizar previsões do preço da gasolina A.

### 2.1 Séries Temporais

A série temporal, também denominada série histórica, é uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico. Este conjunto pode ser obtido com as observações periódicas do evento de interesse como, por exemplo, o valor máximo diário da concentração de ozônio no ar no município de São Paulo, ou pelos processos de contagem como o total mensal de óbitos por câncer no Rio Grande do Sul. Se a série histórica for denominada como  $Z$ , o valor da série no momento  $t$  pode ser escrito como  $Z_t$  ( $t = 1, 2, \dots, n$ ).

Os modelos utilizados para descrever séries temporais são processos estocásticos, isto é, processos controlados por leis probabilísticas. Um processo estocástico é dito ergódico se apenas uma realização dele é suficiente para se obter todas as estatísticas.

Conforme Morettin e Toloí (2004), uma das suposições mais frequentes que se faz a respeito de uma série temporal é que ela seja estacionária, ou seja, desenvolve-se no tempo, aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável. Todavia, a maior parte das séries que encontramos na prática apresenta alguma forma de não-estacionariedade, geralmente justificada devido à presença de quatro componentes:

- i.* Tendência: verifica o sentido de deslocamento da série ao longo do tempo.
- ii.* Sazonalidade: movimento ondulatório de curta duração, em geral, inferior a um ano;  
Ciclo: movimento ondulatório que ao longo de vários anos tende a ser periódico.
- iii.* Ruído Aleatório: compreende a variabilidade intrínseca aos dados e que os seus efeitos não são captados pelo modelo proposto.

A previsão é uma das principais razões da popularidade dos modelos Box e Jenkins, genericamente conhecidos por modelos ARIMA (*Auto Regressive Integrated Moving Averages*). 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, possibilita realizar previsões futuras. Principalmente em

curto prazo, estas previsões são melhores que as obtidas com base nos modelos econométricos tradicionais.

Segundo Fava (2000), os modelos ARIMA resultam da combinação de três componentes denominados “filtros”, a componente autoregressivo (AR), a componente de integração (I) e a componente de médias móveis (MA). Uma série pode ser modelada pelos três filtros ou apenas por um subconjunto deles.

Uma variante dos modelos ARIMA, os modelos fracionários, denominados de ARFIMA, são responsáveis por capturar e modelar processos com longa dependência serial nos dados, comumente chamada de memória longa. Os modelos ARFIMA são caracterizados por um processo estacionário, onde a função de autocorrelação decresce hiperbolicamente para zero lentamente.

Estes modelos são capazes de descrever as dinâmicas de memória curta e longa de processos fracionários, onde  $d$  deve explicar a estrutura de correlação de ordens altas enquanto  $e$  explicam a estrutura de correlação de ordens baixas.

Outras características dos modelos de memória longa, segundo Morettin (2008), é que estas séries apresentam persistência nas autocorrelações amostrais, isto é, dependência significativa entre as observações por um longo intervalo de tempo. Outra característica desse tipo de série é 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.

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 segunda ordem. Estes modelos são adequados para a modelagem do comportamento de séries temporais à curto prazo. A partir dos anos 80, Granger e Joyeux e 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  $(p,d,q)$ , em que F significa a ordem de diferenciação fracionária ou "*fractional*" do inglês.

O processo  $X_t$  é um ARFIMA  $(p,d,q)$  se este é a solução da equação de diferenças, segundo Equação (1):

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

Em que:

$\phi(B)$  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:  $B_j X_t = X_{t-j}$ .

O termo  $(1 - B)^d$  é definido pela expansão Binomial, como mostra a Equação (2).

$$(1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-1)^k B^k \quad (2)$$

$\{a_t\}$  é um processo *ruído branco* onde o valor esperado de  $a_t$  é zero,  $E(a_t) = 0$ , e a variância do processo é constante,  $\sigma_a^2$ .

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  $\phi$  e  $\theta$  decaem exponencialmente. Então,  $d$  deve ser escolhido com o objetivo de explicar a estrutura de correlação de ordens da série, enquanto os parâmetros  $\phi$  e  $\theta$  explicam a estrutura de correlação de ordens baixas.

Se os polinômios  $\phi(Z)$  e  $\theta(Z)$  têm suas raízes fora do círculo unitário, e não possuem raízes comuns, o processo  $(1-B)^d X_t$  é estacionário de 2ª ordem e invertível. A estacionariedade garante que os parâmetros estimados sejam representativos ao longo de todo o período amostral e a invertibilidade garante que seja possível escrever um modelo finito autorregressivo em termos de um modelo de médias móveis infinito e vice-versa.

Quando  $d = 0$ ,  $X_t$  é um modelo autorregressivo médias móveis, ARMA (p, q). Se  $d \neq 1$  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*". Neste caso, 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 Processo estacionário ARFIMA (p,d,q)

O processo geral com integração fracionária, ARFIMA (p,d,q) são processos autorregressivos integrados de médias móveis em que d (grau de diferenciação) assume valores não inteiros. Hosking (1982) foi um pioneiro nos estudos destes processos. Este modelo caracteriza-se por ter longa dependência (*long-memory*) quando  $d \in (0,0;0,5)$  e pequena dependência quando se observa  $d \in (-0,5;0,0)$ .

A longa dependência (ou em outra denominação, “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 tempos distantes, ou seja, uma dependência temporal em períodos longos. Se  $d \in (0,0;0,5)$ , o processo tem aspecto de longa dependência e exhibe 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 exhibir dependências negativas, no domínio do tempo, entre distantes observações. O modelo de memória longa possui 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 X(t), é definido como um processo que satisfaz a Equação (3), dada por:

$$\Phi(B)(1-B)^d = \Theta(B)e_t \text{ para } d \in (-0,5;0,0) \quad (3)$$

Em que o erro assumido pelo processo de modelagem  $e_{t|t}$  é um processo *ruído branco*, isto é, com  $E[e_{t|t}] = 0$ , que representa média zero ao longo do período de análise t e,  $\text{var}[e_{t|t}] = e_e^2$ , que representa variância constante; B é o operador de defasagem em que  $BZ_t = Z_{t-1}$ , de forma que,  $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$  e  $\theta(B) = 1 - \theta_1 B - \dots - \theta_p B^p$ .

Logo, quando  $\phi(B) = \theta(B) = 1$ , tem-se o processo definido como *ruído branco* como diferenciação fracionária, uma extensão do modelo ARIMA para o caso de d não inteiro. Na Equação (4):

$$(1-B)^d X_t = e_t \quad (4)$$

Sendo o termo  $(1-B)^d$  a expansão binomial, Equação (5):

$$(1-B)^d = 1 - dB - \binom{d}{2}(1-d)B^2 = e, \quad (5)$$

Salienta-se que os modelos ARIMA e ARFIMA mostram-se importante no processo de modelagem, pois são capazes de capturar as dependências existentes entre as observações. O primeiro modelo é mais utilizado para representar processo de curto prazo e o segundo para processo em que a dependência seja de longo de prazo. O importante a observar é que tanto o ARIMA quanto o ARFIMA, devem ser definidos baseando-se na estrutura temporal dos dados.

### 2.3 Processo ARFIMA não estacionário

É importante verificar o parâmetro de diferenciação para as séries em nível e na sua primeira diferença. Segundo Olbermann (2006), uma propriedade desejável do parâmetro fracionário estimado é a invariância em processos não estacionários. Sendo assim, um processo autoregressivo integrado de médias móveis de memória longa pode ser representado pela Equação (6) com o parâmetro  $d^* = d+1$ , sendo  $d \in (0,0;0,5)$ .

$$\phi(B)(1-B)^{d^*} X(t) = \theta(B)e_t, t \in Z \quad (6)$$

A Equação (6) 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  $d^* \geq 0,5$ .

De acordo com Segundo Morretin e Tolo (2004), é aconselhado identificar vários modelos que captam a autocorrelação serial entre as observações. Após esta etapa de identificação, deve-se escolher o melhor modelo que tenha gerado um ruído branco, mas que produziu os menores valores para o critério penalizador AIC (*Akaike Information Criteria*). Desta forma busca-se encontrar modelos parcimoniosos, ou seja, aqueles com menor número de parâmetros.

O critério AIC sugere escolher o modelo cujas ordens dos modelos  $p$  e  $q$  minimizam o critério, onde  $\hat{\sigma}_{p,q}^2$  é a variância do modelo encontrado. Na Equação (7) mostra-se como é encontrado o AIC, onde  $N$  é o número de observações na série em estudo, e  $p$  e  $q$  as ordens do modelo.



$$AIC(p, q) = \ln \hat{\sigma}_{p,q}^2 + \frac{2(p+q)}{N} \quad (7)$$

O processo de modelagem exige o conhecimento e a perícia do pesquisador, pois não é tarefa fácil encontrar um modelo que melhor represente um conjunto de dados. Na maioria dos casos encontram-se vários modelos com característica de ruído branco que são representativos do processo em estudo, a qual é uma condição necessária para a utilização do modelo e que mostra que nos resíduos não mais existe uma estrutura de dependência. Para auxiliar a decisão de qual modelo utilizar entre os modelos que forneceram *ruído branco*, pode-se recorrer ao critério penalizador.

### 3 Metodologia

Neste item apresentam-se os aspectos metodológicos utilizados para que se cumpram os objetivos descritos nesta pesquisa. Caracteriza-se a variável modelada e a sequência utilizada nas etapas do estudo.

#### 3.1 Etapas metodológicas

Para o desenvolvimento desta pesquisa, serão utilizados os modelos ARFIMA, que são modelos responsáveis por capturar e modelar processos com longa dependência serial nos dados, denominados de memória longa.

As observações foram consultadas na Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) e são referentes ao preço semanal da gasolina A, praticada pelos produtores da região Sul do Brasil, em litros, durante o período de 1º de janeiro de 2002 a 9 de agosto de 2009, totalizando 403 valores na série temporal.

As seguintes etapas foram seguidas para a realização da pesquisa:

1. Analisar e descrever a série do preço da gasolina, verificando a sua função de autocorrelação, autocorrelação parcial e a sua estacionariedade;
2. Estimar diversos modelos ARFIMA, denominados de modelos concorrentes, pelo fato de produzirem resíduos com característica de ruído branco, sendo que na sequência escolhe-se o melhor modelo mediante o critério penalizador;
3. Traçar resultados gráficos da estimação dada pelo melhor modelo ARFIMA encontrado, assim como as previsões 7 passos à frente.

Estas etapas metodológicas estão desenvolvidas nos itens 4.1, 4.2 e 4.3, apresentadas na próxima seção.

Para o desenvolvimento desta pesquisa fez-se necessário a utilização do *Software Statistica 7.0*. Dessa forma, pretende-se, ao desenvolver o estudo, mostrar a aplicabilidade dos modelos ARFIMA na previsão do preço da gasolina na região sul do País.

## 4 RESULTADOS E DISCUSSÕES

Nesta seção apresenta-se o desenvolvimento dos passos metodológicos de forma que seja possível alcançar o objetivo proposto.

### 4.1 Análise gráfica e análise descritiva

Com a finalidade de conhecer o comportamento do preço da gasolina A no decorrer do período analisado, apresenta-se na Tabela 1 algumas estatísticas descritivas da série do preço da gasolina, assim como se evidencia na Figura 1 o seu gráfico temporal.

Tabela 1 – Estatísticas descritivas da série do preço da gasolina

<b>Estatística</b>	<b>Série da gasolina em nível</b>
Média	1,3529
Mediana	1,5297
Desvio padrão	0,2337
Coefficiente de variação	0,1728
Mínimo	0,8059
Máximo	1,5991
Curtose	-0,4268
Coefficiente de assimetria de Pearson	1,5447

Fonte: Resultados da pesquisa (2010)

Pela análise descritiva, percebe-se que os dados possuem uma assimetria forte, pois o módulo do Coeficiente de Pearson (C.A) apresentou-se maior que 1,0. Podemos classificar o grau de curtose dos dados como leptocúrtica, uma vez que a curtose apresentou-se menor que 0,263, observa-se pouca variabilidade do preço no decorrer do período, pois o valor mínimo é R\$ 0,806, e o valor máximo é R\$ 1,599.

Na Figura 1 observa-se a média de produção mensal de derivados do petróleo no Rio Grande do Sul (em barris), com ênfase para a produção de gasolina A.

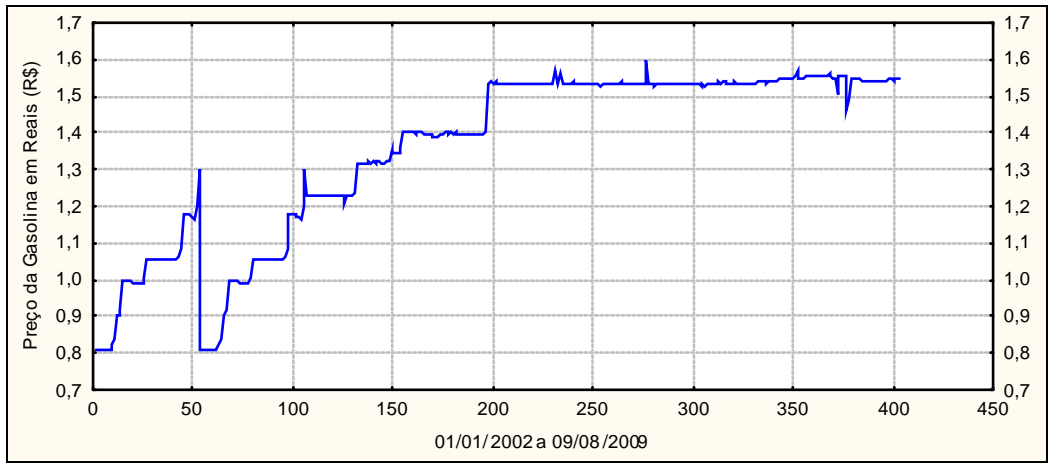


Figura 1– Série do preço da gasolina no período analisado  
 Fonte: Resultado da pesquisa (2010)

Pela inspeção visual da Figura 1, a série parece ter um comportamento não estacionário em relação à média, apresentando uma tendência crescente até a observação 200, onde visualmente percebe-se um período de maior variabilidade. A partir da observação 200, a série parece tornar-se estacionária.

Uma análise importante a ser realizada na identificação da estacionariedade é a análise da Função de Autocorrelação (FAC) da série de preços da gasolina, representada na Figura 2.

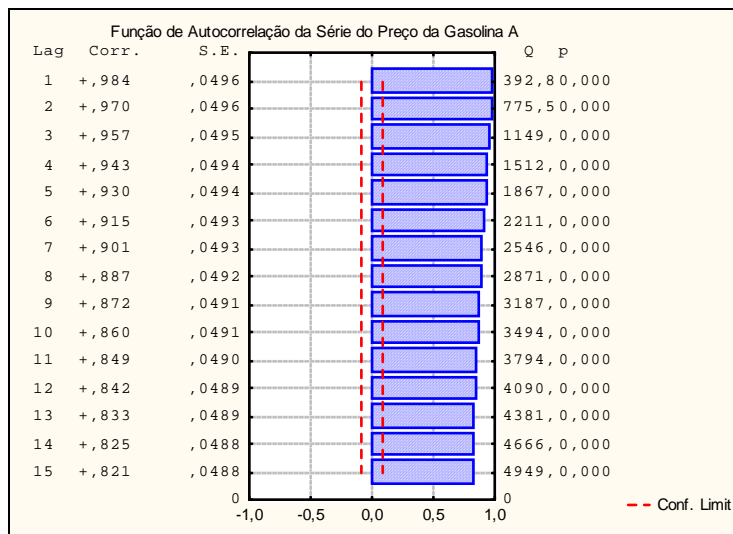


Figura 2 – FAC do preço da gasolina A  
 Fonte: Resultado da pesquisa (2009)

A FAC amostral apresenta um decaimento muito lento, mostrando que a série é não estacionária e ainda indica a presença de longa dependência serial, mostrando a persistência nos dados. Portanto, pela inspeção da Figura 1 sugere-se a utilização dos modelos ARFIMA para capturar e modelar essa dependência serial nos dados.

## 4.2 Estimação de modelos concorrentes e escolha do melhor modelo

Com o intuito de encontrar o melhor modelo que represente corretamente o processo gerador de cada série, estimaram-se diversos modelos, os quais foram denominados de modelos concorrentes, pois os mesmos apresentaram a condição de ser ruído branco. Após a estimação dos modelos concorrentes utilizou-se o Critério de Informação de Akaike (AIC) para a escolha do modelo representativo da série em estudo. O AIC é uma medida de qualidade do ajuste estimado ponderando o número de parâmetros do modelo, desta forma leva-se em consideração o princípio da parcimônia, onde se decide por um modelo com um menor número de parâmetros para representar a série em análise.

Tabela 2 – Modelos ARFIMA (p,d,q) concorrentes para o preço da gasolina A

Modelos	Parâmetros estimados	Estimativa do erro	Significância dos Modelos	AIC
ARFIMA (1,d,0)	d=0,499 φ <sub>1</sub> =0,625	0,0001 0,039	< 0,001 < 0,001	-3,955
<b>ARFIMA (1,d,1)</b>	<b>d=0,497</b> φ <sub>1</sub> =0,936 θ <sub>1</sub> =-0,595	0,005 0,025 0,057	< 0,001 < 0,001 < 0,001	<b>-4,08</b>
ARFIMA (0,d,1)	d=0,499 θ <sub>1</sub> =0,451	0,003 0,045	< 0,001 < 0,001	-3,764
ARFIMA (2,d,0)	d=0,499 φ <sub>1</sub> =0,459 φ <sub>2</sub> =0,459	0,002 0,048 0,048	< 0,001 < 0,001 < 0,001	-4,022
ARFIMA (0,d,2)	d=0,499 θ <sub>1</sub> =0,463 θ <sub>2</sub> =0,277	0,0003 0,049 0,043	< 0,001 < 0,001 < 0,001	-3,852

Fonte: Resultado da pesquisa (2009)

Utilizando o critério de Informação de Akaike, o melhor modelo ajustado para o preço da gasolina A é denotado por meio da Equação (8).

$$(1 - B)^{0,497} (1 - 0,936B) (1 + 0,595 B) X_t = a_t \quad (8)$$

O modelo representado na Equação 8 pode ser visto como um modelo autoregressivo de médias móveis de primeira ordem fracionário o qual forneceu resíduos com características *ruído branco*. Confirma-se que  $X_t$  é estacionário e invertível, pois  $|d| = 0,497 < 0,5$ ,  $|\phi| = 0,936 < 1$  e  $|\theta| = 0,595 < 1$ .

### 4.3 Resultados gráficos e previsão do modelo ARFIMA (1,d,1)

Pela análise gráfica da Figura 3 do modelo ajustado, pode-se perceber o bom ajuste do modelo, mostrando-se bom para realizar previsões.




Figura 3 – Valores reais e ajustados do preço da gasolina  
Fonte: Resultado da pesquisa (2010)

As previsões, sete passos à frente para o preço da gasolina, utilizando o modelo ARFIMA (1; 0,497; 1), estão expostas graficamente na Figura 4 e, em valores, na Tabela 3.




Figura 4 – Previsão para o preço da gasolina A, na região Sul do Brasil.  
Fonte: Resultado da pesquisa (2009)

Juntamente com o resultado gráfico da previsão, encontram-se os intervalos de confiança. Percebe-se que à medida que as previsões distanciam-se do intervalo amostral, os intervalos de confiança alargam-se, isto é diminuindo a qualidade e a confiança dos resultados, ocorrendo que modelos econométricos, de um modo geral, obtêm melhores resultados em previsões de curto prazo.

Tabela 3 – Valores previstos do preço da gasolina utilizando-se o modelo ARFIMA (1, 0,497,1)

<b>Previsão do Preço da Gasolina A</b>		
<b>Horizonte</b>	<b>Previsão</b>	<b>Erro Padrão</b>
10/08/09-16/08/09	1,544	0,031
17/08/09-23/08/09	1,542	0,040
24/08/09-30/08/09	1,541	0,048
31/08/09-06/09/09	1,539	0,055
07/09/09-13/09/09	1,537	0,062
14/09/09-20/09/09	1,535	0,069
21/09/09-27/09/09	1,533	0,075

Fonte: Resultado da pesquisa (2009)

Percebe-se pouca variabilidade para os preços da gasolina A para as próximas semanas. No entanto, essa variabilidade é importante de ser observada, pois nos últimos anos o preço da gasolina se manteve ao redor da média conforme mostrou o gráfico da série original do preço da gasolina na Figura 1, indicando a confiabilidade nas previsões.

## 5 CONCLUSÕES

A pesquisa foi realizada por meio da análise de séries temporais, utilizando dados do preço da gasolina A praticado na região Sul do Brasil, no período de janeiro de 2002 a agosto de 2009. Com este estudo, pretende-se fornecer subsídios gerenciais importantes, propiciando às empresas e aos órgãos governamentais alocar recursos financeiros, humanos e materiais de forma adequada nos setores petrolíferos. Assim, conhecendo o comportamento desta variável antecipadamente, medidas gerenciais poderão ser implementadas pelos setores responsáveis da economia da região Sul.

Os passos da metodologia de Box e Jenkins (1976) foram apresentados e também se mostrou a aplicabilidade dos modelos ARFIMA, pois ao invés de se tomar diferenças para estacionarizar a série temporal e, utilizar somente as características de curto prazo, optou-se por utilizar um modelo de memória longa e também privilegiar as características de longo prazo. Para a série do preço da gasolina, o modelo que melhor ajustou a estrutura da autocorrelação entre os dados, apresentando o melhor valor no critério penalizador AIC, foi o modelo ARFIMA (1; 0,497; 1), que captou bem o comportamento da série em estudo.

Dessa forma, deixa-se como sugestão para futuros trabalhos, a modelagem dos resíduos do preço da gasolina A com o objetivo de modelar a volatilidade da série e captar as demais características desse produto.

## REFERÊNCIAS BIBLIOGRÁFICAS

AKAIKE, H. 1970. **Stastistical predictor identification**. Ann. Statis. Math, v. 22, p. 203-217.

ANP – **Agência Nacional de Petróleo, Gás Natural e Biocombustíveis**. 2009. Disponível em < <http://www.anp.gov.br>>. Acesso em: 15 abr./2009.

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

FAVA, V. L. **Manual de Econometria**. In: VASCONCELOS, M. A. S.; ALVES, D. São Paulo: Editora Atlas, 2000.

MORETTIN, P. A.; TOLOI, C. M. **Análise de séries temporais**. 1. ed., São Paulo: Edgar Blücher, 2004.

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

SCHWARZ, G. Estimating the dimension of a model. **The Annals of Statistics**. v. 6, p. 461-464, 1978.

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**, v. 10, n. 1, p. 47-67, 2003.