


ET-68



UNIVERSIDADE EDUARDO MONDLANE
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE MATEMÁTICA E INFORMÁTICA

TRABALHO DE LICENCIATURA EM ESTATÍSTICA

Tema:

**Modelagem do Índice de preço da Gasolina para Veículos de
Transporte Pessoal na Cidade de Maputo 2000-2007,
Aplicando a Metodologia de Box-Jenkins**

Francisco, Cardoso Nhongo



UNIVERSIDADE EDUARDO MONDLANE
FACULDADE DE CIÊNCIAS
DEPARTAMENTO DE MATEMÁTICA E INFORMÁTICA

TRABALHO DE LICENCIATURA EM ESTATÍSTICA

Tema:

**Modelagem do Índice de preço da Gasolina para Veículos de
Transporte Pessoal na Cidade de Maputo 2000-2007,
Aplicando a Metodologia de Box-Jenkins**

Autor: Francisco Cardoso Nhongo
Supervisor: dr. Milagre Mula
Co-Supervisor: dr. Moreno

Maputo, Novembro de 2008

Declaração

Declaro que este trabalho é da minha autoria e resulta da minha investigação. Esta é a primeira vez que o submeto para obter um grau académico numa instituição de ensino educacional.

Maputo, aos _____ de Novembro de 2008

Francisco Cardoso Nhongo

Dedicatória

Aos meus pais, Cardoso Tomo Nhongo e
Anita Colaço Bande.

Agradecimentos

- * Ao meu orientador, dr. Milagre Mula, pelo seu apoio e orientação neste trabalho;
- * Ao meu pai, Cardoso Tomo Nhongo pelo apoio moral;
- * A minha mãe, Anita Colaço Bande, pela força e muita presença durante o trabalho;
- * A todos os professores do Departamento de Matemática e Informática, pela contribuição fornecida durante cada semestre;
- * A todo o pessoal de apoio do Departamento e em especial a senhora Zulmira pelo incentivo e pela força;
- * A todos os meus colegas do curso, pelo acolhimento, convívio e calor proporcionado e sobretudo pela amizade demonstrada durante o percurso que o nosso curso levou;
- * E finalmente, a todas as pessoas que, directa ou indirectamente contribuíram para a realização deste trabalho.

Resumo

O presente trabalho tem como objectivo principal a análise do índice do preço da Gasolina para veículos de transporte pessoal na Cidade de Maputo, aplicando os modelos de Box-Jenkins, onde, com base na análise feita encontrou-se o modelo que melhor descreve o índice do preço para os anos em estudo.

O presente trabalho é composto por três principais capítulos: A revisão da literatura onde é feita a abordagem da série temporal no geral e os possíveis modelos de previsão; A metodologia que aborda todas as etapas que deve ser feita com uma série temporal, para que ela seja projectada, e por fim temos os resultados, onde mostra que o comportamento da Série Índice do preço da gasolina para veículos de Transporte pessoal na Cidade de Maputo entre Janeiro de 2000 a Dezembro de 2007 é estacionária em primeiras diferenças.

De acordo com o modelo obtido apartir da metodologia de Box-Jenkins, prevê, para os meses de Novembro e Dezembro do ano 2008, índices 0.105 e 0.235 respectivamente.

Palavras chave: Índice de preço da gasolina; Método de Box-Jenkins; Estacionaridade de uma série temporal.

índice

Declaração	iii
Dedicatória	4
Agradecimentos	5
Resumo	6
Lista de tabelas	9
Lista de figuras	10
Anexos.....	11
Lista de abreviaturas	12

Capítulo I

1 INTRODUÇÃO	13
1.1 Estrutura do Trabalho	14
1.2 Definição do Problema e Justificativa.....	15
1.3 Questões de Estudo.....	15
1.4 Objectivos.....	16
1.4.1 Geral	16
1.4.2 Específicos.....	16

Capítulo II

2 REVISÃO DA LITERATURA E METODOLOGIA	17
2.1 Análise das séries temporais.....	17
2.2 Método de decomposição clássica de séries temporais	18
2.3 Movimentos característicos das séries temporais.....	19
2.4 Previsão de uma série temporal	20
2.4.1 Métodos de previsão de uma série temporal	21
2.4.2 Métodos simples de previsão de série temporal	22
2.4.3 Métodos avançados de previsão de séries temporais.....	26
2.5 Diferenciação de uma série temporal	28
2.7 Função autocorrelação e autocorrelação parcial de uma série temporal.	29
2.8 Modelos estacionários e não estacionários em séries temporais	30
2.9 Testes para autocorrelação e normalidade.....	31
2.11 Análise dos resíduos	33
2.12 Critérios de informação de uma série temporal.....	33
2.13 Correlação de uma série temporal	34
2.14 Índice de preço.....	35

Capítulo III

3 METODOLOGIA.....	38
3.1 Material e fonte.....	38
3.2 Metodologia de Box-Jenkins.....	38
3.2.1 Identificação da estrutura do modelo.....	39
3.2.2 Estimação dos parâmetros do modelo ARIMA	40
3.2.3 Verificação da adequação do modelo	41
3.2.4 Análise dos resíduos	42

3.2.5	Previsão	42
-------	----------------	----

Capitulo IV

4	RESULTADOS E DISCUSSÃO	43
4.1	Estatísticas descritivas	43
4.1.1	Decomposição da série em componentes	44
4.2	Análise da estacionaridade da série em estudo	47
4.3	Identificação	49
4.4	Estimação dos modelos ARIMA	49
4.5	Verificação da adequação dos modelos	50
4.6	Escolha do modelo adequado	53
4.7	Previsão	54

Capitulo V

5	CONCLUSÕES E RECOMENDAÇÕES	55
5.1	Conclusões	55
5.2	Recomendações	56
5.3	Limitações do estudo	56
Bibliografia:		57
Anexos		59

Lista de tabelas

Tabela 1. Resumo das principais características dos modelos AR(p), MA(q) e ARMA(p,q)	40
Tabela 2: Teste de Kolmogorov Smirnov	47
Tabela 3: Teste de Sazonalidade para a série do Índice do preço da gasolina	47
Tabela 4: Teste de raiz unitária de Dickey fuller para a serie do Índice do preço da gasolina.....	48
Tabela 5. Teste de raiz unitária de Dickey-Fuller para a série do índice do preço da gasolina em primeiras diferenças.	49
Tabela 6. Estimação da Série índice de preço da gasolina segundo um AR(1)	49
Tabela 7. Estimação da Série índice de preço da gasolina segundo um AR(2)	49
Tabela 8. Estimação da Série índice de preço da gasolina segundo um MA(1).....	49
Tabela 9. Estimação da Série índice de preço da gasolina segundo um ARIMA(1,1,1).....	50
Tabela 10. Estimação da Série índice de preço da gasolina segundo um ARIMA(2,1,1).....	50
Tabela 11. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo AR(1) 52	
Tabela 12. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo AR(2) 52	
Tabela 13. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo MA(1) 53	
Tabela 14. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo ARMA(1,1,1)	53
Tabela 15. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo ARMA(2,1,1)	53
Tabela 16: Estatísticas da estimação dos modelos AR(1), AR(2), MA(1),ARIMA(1,1,1) e ARIMA(2,1,1)	54
Tabela 17: previsão do índice de preço da gasolina	54

Lista de figuras

Figura 1. Serie cronológica do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.	43
Figura 2. Série cronológica da componente Cíclica do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.	44
Figura 3. Série cronológica da componente Irregular do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.	44
Figura 4. Série cronológica da Componente Sazonal do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.	45
Figura 5. Série cronológica da Tendência do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.....	45
Figura 6. Histograma do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.....	46
Figura 7. correlograma em nível do índice de preço da gasolina para veículos de transporte pessoal na Cidade de Maputo, entre Janeiro de 2000 e Dezembro de 2007. .	47
Figura 8. correlograma em primeiras diferenças do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.	48
Figura 9. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo AR(1).....	50
Figura 10. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo AR(2).....	51
Figura 11. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo MA(1).....	51
Figura 12. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo ARIMA(1,1,1)	51
Figura 13. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo ARIMA(2,1,1)	52

Anexos

A 1. Dados do índice do preço da gasolina para veículos de transporte pessoal na Cidade de Maputo (2000-2007).....	59
A2. Estatísticas descritivas do índice de preço da gasolina para veículos de transporte pessoal de Janeiro de 2000 a Dezembro de 2007.....	60
A3. Serie cronológica dos resíduos do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007. .	60
A4. Resultados da estimação do modeloAR(1).....	60
A5. Resultados da estimação do modeloAR(2).....	61
A6. Resultados da estimação do modelo MA(1).....	61
A7. Resultados da estimação do modelo ARIMA(1,1,1).....	61
A8. Resultados da estimação do modelo ARIMA(2,1,1).....	62
A9. Resultados da decomposição da serie original em componentes	62

Lista de abreviaturas

AIC	Akaike Information Criteria - Critério de Informação Akaike
AR	Auto-regressivo
ARMA	Autoregressive Moving Average - Auto-regressivo de médias moveis
ARIMA	Autoregressive Integrated Moving Average - Auto-regressivo integrado de médias moveis
ADF	Aumentado de Dickey Fuller
BIC	Bayesian Information Criterion - Critério de Informação Bayesian
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
IP	Índice de Preço
IPC	Índice de Preço no Consumidor
INE	Instituto Nacional de Estatística
MA	Moving Average-Médias Móveis
MQO	Mínimos Quadrados Ordinários
PNB	Produto Nacional Bruto
SIC	Schwarz Information Criteria- Critério de Informação Schwarz

1 INTRODUÇÃO

Moçambique é um país que contém várias Cidades onde pode-se notar maior circulação de transportes. Dentre as várias Cidades existentes, a Cidade de Maputo é a que apresenta maior quantidade de viaturas automóveis, em circulação, segundo o Instituto Nacional de Estatística (INE).

Grande parte dos transportes para que possam se movimentar precisam de ser abastecidos de gasolina ou *diesel*. Existem Bombas de abastecimento de combustível para os transportes em diferente parte da Cidade de Maputo, Bombas estas que para cada litro de gasolina abastecida em diferentes transportes tem o seu preço correspondente.

De acordo com os dados obtidos no (INE), pode-se notar que para o período de Janeiro de 2000 á Dezembro de 2007 os preços da gasolina por litros teve uma tendência crescente e trouxe várias consequências a população da Cidade, obrigando algumas delas a preferirem usar os transportes públicos como o meio de transporte diário ou mesmo deslocar a pé para os seus locais de trabalho.

Em Moçambique, o sector responsável pela divulgação das estatísticas oficiais que incluem o índice de preço da gasolina é o INE.

Segundo (Paul A.Samuelson & William D.Nordhaus,1999), dados de índice de preço em função de tempo são exemplos práticos de uma série temporal, onde o índice de preço seria uma média ponderada dos preços de um certo número de bens e serviços. Uma análise feita por (N.Gregory,1993) diz que, um índice de preços (IP) é uma medida do custo geral de todos os bens e serviços comprados por um consumidor.

1.1 Estrutura do Trabalho

O presente trabalho está dividido em 5 capítulos, cuja abordagem de cada um é informada abaixo.

- Capítulo 1: Faz referência a introdução do trabalho, onde são englobados a definição do problema e a justificativa para a escolha do tema, a importância, o objectivo geral e específico;
- Capítulo 2: Engloba a revisão da literatura e a metodologia, onde são abordados métodos para a previsão em séries temporais e é dada uma atenção especial para a metodologia de Box-Jenkins, que constitui o principal método para a elaboração do presente trabalho.
- Capítulo 3: É apresentado o material usado para a realização do presente trabalho;
- Capítulo 4: São apresentados os resultados da investigação, o modelo estimado e as previsões do índice do preço da gasolina para os meses de Novembro e Dezembro de 2008;
- Capítulo 5: Apresenta as conclusões e recomendações para futuros trabalhos.

1.2 Definição do Problema e Justificativa

O Índice de Preço no consumidor mede a média aritmética simples dos preços de um determinado bem e serviços de consumo, incluindo os preços dos alimentos, vestuários, alojamentos, combustíveis, transportes, cuidados médicos, propinas e outros bens adquiridos no dia-a-dia.

De acordo com os dados obtidos no (INE), no sector responsável pelos índices de preço no consumidor, verifica-se que anualmente os índices de preço da gasolina vem aumentando em percentagens muito superiores, aumento este que já começa a preocupar a todas as entidades responsáveis pela planificação das importações da gasolina para o curto, médio e longo prazo. O índice do preço, é essencial para os planificadores e operadores de transportes.

Esta pesquisa tem como justificativa a necessidade da criação de um modelo de previsão do Índice de preços da gasolina para veículos de transporte pessoal na Cidade de Maputo.

1.3 Questões de Estudo

As questões da presente pesquisa são:

- Quais são as características da série do Índice do preço da gasolina para veículos de Transporte pessoal na Cidade de Maputo no período de Janeiro 2000 á Dezembro de 2007.
- Qual é o modelo que melhor descreve a série do Índice de Preço da Gasolina para veículos de transporte pessoal na Cidade de Maputo no período de Janeiro 2000 á Dezembro de 2007.
- Qual será o índice de preço da gasolina nos períodos de Novembro e Dezembro de 2008.

1.4 Objectivos

1.4.1 Geral

- Estudar a série temporal índice de preço da gasolina para veículos de transporte pessoal, aplicando as técnicas de Box-Jenkins.

1.4.2 Específicos

- Descrever as características da série do índice de preço da gasolina para veículos de transporte pessoal na Cidade de Maputo no período de Janeiro (2000) a Dezembro (2007).
- Modelar a série do índice do preços da gasolina dos veículos de transporte pessoal que circulam na Cidade de Maputo, no período de Janeiro de 2000 a Dezembro de 2007.
- Fazer previsão da série para os meses de Novembro e Dezembro de 2008.

2 REVISÃO DA LITERATURA E METODOLOGIA

Para o presente trabalho a análise da série temporal é a principal técnica estatística escolhida.

Segundo (Spiegel,1993), uma série temporal é um conjunto de observações tomadas em tempos determinados, comumente em intervalos iguais.

Matematicamente, uma série temporal é definida pelos valores x_1, x_2, \dots , de uma variável X (temperatura, valor de fechamento de uma acção, etc) nos tempos t_1, t_2, \dots portanto, X é uma função de t simbolizada por $X=F(t)$.

(Toledo Geraldo Luciano,1985) diz que a série temporal pode ser igualmente chamada de série cronológica, histórica, evolutiva ou marcha. Estas séries identificam-se pelo carácter variável do factor cronológico.

Existem outras séries como é o caso de séries geográficas, cronológicas, espaciais, etc.

2.1 Análise das séries temporais

A análise das séries temporais consiste em uma descrição (geralmente matemática) dos movimentos das componentes que se apresentam, como explicação dos processos implicados nessa descrição (Spiegel,1993). Uma análise feita por (Da Fonseca Jairo Simon, Gilberto de Andrade e Toledo Geraldo Luciano,1985), diz que o método para analisar uma série temporal consiste em decompor a série nos quatro movimentos característicos. A variável dependente X será função das componentes: T,C,S,I que representam respectivamente os movimentos a longo prazo ou seculares, movimentos ou variações cíclicas, movimentos ou variações estacionais e movimentos irregulares ou aleatórios.

2.1.1 Objectivos da análise de séries temporais

(Ehler,2003), diz que em algumas situações com objectivo da análise da série temporal pode-se fazer previsões de valores futuros, enquanto que em outras a estrutura da série ou sua relação com outras séries pode ser o interesse principal. De um modo geral, os principais objectivos em se estudar séries temporais podem ser os seguintes:

Descrição: Propriedades da série, o padrão da tendência, existência da variação sazonal, *outliers*, alterações estruturais, etc.

Explicação: Usar a variação em uma série para explicar a variação em outra série.

Predição: Predizer valores futuros com base em valores passados.

Controle de Processos: Por exemplo controle estatístico de qualidade.

2.1.2 Técnicas descritivas da análise de séries temporais

Ao se analisar uma ou mais séries temporais a representação gráfica dos dados sequencialmente ao longo do tempo é fundamental revelar padrões de comportamentos importantes, tais como: tendências de crescimento (ou decrescimento), padrões cíclicos, alterações estruturais, observações aberrantes, etc, são muitas vezes facilmente identificados. Sendo assim, o gráfico temporal deve ser sempre o primeiro passo e anteceder qualquer análise (Ehler,2003,3), segundo (Murteira e Joseph Black, 1983), um dos aspectos fundamentais nas séries temporais, reside no facto de as sucessivas observações não serem independentes. Por exemplo tratando-se de uma série de preço de um dado produto, verifica-se no geral que o preço no momento t , está algo relacionado com o preço no momento $t-1$ e com o preço no momento $t-2$. Por outras palavras o preço no momento t depende (em parte) do preço nos momentos $t-1$, $t-2$, etc.

2.2 Método de decomposição clássica de séries temporais

Segundo (Murteira e Joseph Black,1983), a nomenclatura tradicional das componentes compreende-se melhor recordando o carácter dinâmico das sucessões. As componentes normalmente recolhidas são quatro, assim agrupadas:

Movimentos Sistemáticos:

T_t : Representa o termo tendência

S_t : Representa os movimentos sazonais

C_t : Representa os movimentos oscilatórios

R_t : Representa os movimentos aleatórios, onde:

$$X_t = T_t + C_t + R_t + S_t, \quad (2.1)$$

2.3 Movimentos característicos das séries temporais

Os movimentos de uma série temporal podem ser provocados por uma combinação de forças económicas, sociológicas, psicológicas e outras.

Experiências realizadas com algumas séries temporais revelaram certos movimentos ou variações características, alguns dos quais, ou todos, estão presentes em graus diversos. A análise desses movimentos é de grande valor em vários casos, um dos quais é o problema da previsão de movimentos futuros.

Em consequência não deve constituir surpresa o facto de muitas indústrias e sectores governamentais estarem profundamente interessados nesse importante assunto (Spiegel,1993).

Movimentos a longo prazo ou seculares

Para alguns autores tem um significado intuitivo e pode definir-se como inércia da sucessão, marcha principal, variação “em média “ ao longo do tempo, ou ainda mudança sistemática do nível com carácter permanente, tendência que compreende os movimentos que se manifestam suavemente e consistentemente ao longo de um largo período de tempo (Murteira e Joseph Black ,1983).

Não existe uma definição precisa de tendência e diferentes autores usam este termo de diferentes formas. Pode-se pensar em tendência como uma mudança de longo prazo no nível médio da série. A forma mais simples de tendência é:

$$X_t = \alpha + \beta t + \varepsilon_t \quad (2.2)$$

Onde α e β são constantes a serem estimados e ε_t denota um erro aleatório de média zero (Ehler,2003).

Movimentos sazonais

São variações em relação a tendência, que ocorre em geral dentro de um ano. Numa sucessão trimestral, por exemplo, os valores do primeiro trimestre podem ser sistematicamente elevados do que os valores do segundo trimestre, etc.

De um modo geral podia ter-se falado em movimentos periódicos com periodicidade igual a um ano ou superior.

Os movimentos sazonais podem pois descrever-se como oscilações de ritmo forçado, que se repetem todos os anos (ou com uma periodicidade curta), embora nem sempre seguindo um padrão rígido (Murteira e Joseph Black ,1983).

Movimentos ou variações cíclicas

Referem-se as oscilações a longo prazo ou aos desvios em torno da recta ou da curva de tendência. Esses ciclos como são frequentemente denominados, podem ser ou não periódicos, isto é, podem ou não seguir exactamente padrões análogos depois de intervalos de tempo iguais (Spiegel,1993).

Movimentos aleatórios

São de carácter casual e origem desconhecida, é completamente irregular sem estrutura de formação reconhecível ou carácter episódico como: guerras, epidemias, greves, secas, etc.

Sob o ponto de vista prático, estes movimentos são de natureza residual e aparecem depois de identificadas e eliminadas da sucessão original as três componentes anteriormente referidas. Trata-se de algo que não se sabe ou incapaz de se explicar (Murteira e Joseph Black,1983).

2.4 Previsão de uma série temporal

A previsão constitui um meio de fornecer informações e subsídios para uma consequente tomada de decisão, visando atingir determinados objectivos (Morettin e Tolo,2004). Segundo (Barbancho,1970), uma previsão é uma manifestação relativa a sucessos desconhecidos em um futuro determinado.

Dependendo do valor assumido pelo horizonte de previsão, (Souza,1989) classifica as previsões dos valores futuros de uma série temporal como de curto, médio ou longo prazo.

Deste modo, diante da possibilidade de existência de diferentes horizontes de previsão (Refenes,1993), especifica técnicas distintas para prognosticar os valores futuros de uma série temporal, que são:

Previsão Múltiplo Passo: Esta abordagem é adotada para longos horizontes de previsão, procura identificar as tendências gerais e os pontos de inflexão mais relevantes na série temporal. O conjunto de valores correntes são empregues na realização para determinado instante, esta, é então introduzida entre as observações passadas, compondo desta forma um novo conjunto de dados sobre o qual será obtida a previsão do tempo subsequente.

Previsão Simples Passo: Nesta técnica não há incorporação de previsões aos dados utilizados para encontrar a próxima previsão, sendo esta independente dos valores anteriormente previstos. A previsão é feita apenas para o período de tempo imediatamente posterior ao actual, a partir das observações da série temporal.

A garantia da precisão das previsões de uma série temporal somente é alcançada adotando como horizonte de previsão o instante de tempo imediatamente subsequente a origem t , (Souza,1989).

Assim, se t é o período corrente estamos interessados em prever os valores de X_{t+1}, X_{t+2}, \dots , a previsão de X_{t+k} , para $k=1,2,\dots$, será denotado por $\hat{X}_t(k)$ e é definida como a presença condicional de X_{t+k} dados todos os valores passados, isto é,

$$\hat{X}_t(k) = E(x_{t+k} / x_t, x_{t-1}, \dots) \quad (2.3)$$

A equação (2.3) é chamada de função de previsão e o inteiro k é chamado de horizonte de previsão, Onde podemos notar que se tivermos uma série temporal observada x_1, \dots, x_n , as previsões podem ser feitas dentro do período amostral e comparadas com os valores observados. Esta é uma prática bastante comum para verificar a qualidade preditiva do modelo. Onde a diferença entre os valores previstos é observado, $\hat{X}_t(k) - X_{t+k}$ é chamada de erro de previsão k passos a frente e será denotado por e_{t+k} (Ehler,2003,36).

2.4.1 Métodos de previsão de uma série temporal

Segundo (Preisthey,1979), não há algo chamado método de previsão ou algo chamado método de previsão ARMA (ou Box-Jenkins). Há algo chamado métodos de previsão de Mínimos quadrados, e este fornece a base para virtualmente todos os estudos teóricos. Para (Morretin e Tolo, 2004), todos os métodos de previsão são simplesmente diferentes procedimentos computacionais para calcular a mesma quantidade, a saber a previsão de mínimos quadrados de um valor futuro a partir de combinações lineares de valores passados.

(Wheelwright e Makridakis,1985), definem um método de previsão como sendo o conjunto de procedimentos usados no desenvolvimento de uma determinada previsão, e faz referência que os métodos de previsão de séries temporais, classificados como métodos quantitativos, baseiam suas previsões na extrapolação de características de observações passadas e no inter-relacionamento entre estas observações, fornecendo observações apuradas se o futuro apresentar um comportamento similar ao do passado.

Para (Curthbertson,1992), a maioria dos métodos de previsão de séries temporais baseia-se na suposição de que observações passadas contêm todas as informações sobre o padrão de comportamento da série temporal e esse padrão é recorrente no tempo.

Apesar de quase a totalidade dos métodos de previsão de séries temporais estarem fundamentadas apenas na análise das observações, alguns procedimentos de previsão tenta explicar o comportamento de uma série temporal pela evolução dos fenómenos observacionais de outra série, desta forma dependendo do número de séries temporais envolvidas na modelagem, (Souza,1989), classifica os métodos de previsão em Univariados, Funções de transferência e Multivariados.

Métodos Univariados: São aqueles que compreendem a maior parte dos métodos de previsão de séries temporais, considera somente uma única série para a realização dos prognósticos. As previsões decorrentes da aplicação de métodos univariados podem estar relacionadas apenas com as informações contidas na série histórica de interesse (métodos baseados na estatística clássica), ou também além de incorporarem essas informações, consideram outras supostamente relevantes e que não estão contidas na série analisada (método baseado na estatística bayesiana).

Função de transferência: Nesta metodologia a série de interesse é explicada não só pelo seu passado histórico, mas também por outras séries temporais não correlatas entre si. Esta classe de métodos envolve, portanto, mais de uma série temporal, com a ressalva de que a relação de causalidade entre estas séries é conhecida.

Métodos Múltivariados: Neste método a metodologia abrange os procedimentos de previsão que associam mais de uma série temporal na efectivação de prognósticos, sem no entanto, qualquer imposição com relação a causalidade entre estas séries. Diante disso há uma variedade enorme de métodos de previsão de séries temporais, cada qual com suas capacidades e limitações. Qualquer que seja a classificação destes métodos é possível usar um número muito grande de métodos diferentes para descrever o comportamento de uma série particular Weelwrigth e Makridakis (1985).

2.4.2 Métodos simples de previsão de série temporal

(Morettin e Tolo,1981), associam a grande popularidade destes métodos a simplicidade, a eficiência computacional e a razoável previsão obtida. Entre os

métodos simples de previsão destacam-se o da Média Móvel, a Suavização Exponencial simples, a Suavização Exponencial Linear e a Suavização Exponencial Sazonal e Linear de Winter (Weelwrigth e Makridakis,1985), os quais são apresentados sucintamente na sequência:

2.4.2.1 Médias móveis

Esse método considera como previsão para o período futuro a média das observações passadas recentes (Weelwrigth e Makridakis, 1985).

Segundo (Morettin e Toloi,2004), a média móvel para o período de tempo t é definida por:

$$M_t = \frac{Z_t + Z_{t-1} + \dots + Z_{t-n}}{n} \quad (2.4)$$

ou

$$M_t = M_{t-1} + \frac{Z_t - Z_{t-n}}{n} \quad (2.5)$$

Onde n representa o número de observações incluídas na média M_t .

O termo média móvel é utilizado porque a medida da próxima observação se torna disponível, a média das observações é recalculada, incluindo essa observação no conjunto de observações e desprezando a observação mais antiga (Morettin e Toloi, 2004).

Segundo (Nelson,1973), quanto maior o número de observações incluídas na média móvel, maior é o efeito de alisamento na previsão. Assim, caso a série temporal apresente muita aleatoriedade ou pequenas mudanças nos padrões dessa série, um número maior de valores podem ser utilizados no cálculo da média móvel, obtendo-se uma previsão mais suavizada.

2.4.2.2 Suavização exponencial simples

A inovação introduzida pela suavização Exponencial Simples advém do facto deste método atribuir pesos diferentes a cada observação da série. Enquanto que na média móvel as observações usadas para encontrar a previsão do valor futuro contribuem em igual proporção para o cálculo dessa previsão, na Suavização Exponencial Simples as informações mais recentes são evidenciadas pela aplicação de um factor que determina essa importância (Morettin e Toloi,1981).

Segundo (Moretin e Toloi,2004), o argumento para o tratamento diferenciado das observações da série temporal é fundamentado na suposição de que as últimas observações contem mais informações sobre o futuro, e portanto, são mais relevantes para a previsão.

(Moretin e Toloi,2004) especificam o método Suavização Exponencial simples através da equação:

$$\bar{Z}_t = \alpha Z_t + (1 - \alpha) \bar{Z}_{t-1}, \quad t = 1, 2, 3, \dots, N \quad (2.6)$$

Onde:

\bar{Z}_t : é denominado valor exponencialmente suavizado,

α : é a constante de suavização, com $0 \leq \alpha \leq 1$.

De acordo com (Granger e Newbold,1977), quanto menor for o valor da constante mais estáveis serão as previsões, visto que a utilização de baixo valor implica na atribuição de peso maior às observações passadas, e conseqüentemente, qualquer flutuação aleatória no presente contribui com menor importância para a obtenção da previsão. Contudo não há metodologia que oriente quanto a selecção de um valor apropriado sendo normalmente encontrado por tentativas de erro (Weelwrigth e Makridakis,1985).

2.4.2.3 Suavização exponencial linear (ou de Holt)

Quando o método de Suavização Exponencial simples é aplicado na previsão de séries temporais que apresentam tendência entre as observações passadas, os valores prognosticados subestima os valores reais (Moretin e toloi,1981). Desta forma a qualidade das previsões fica prejudicada.

Para evitar esse erro sistemático, um dos métodos aplicáveis é a Suavização Exponencial Linear que foi desenvolvido procurando reconhecer a presença de tendência na série de dados (Moretin e Toloi,2004), o valor da previsão obtido através deste método é alcançado pela aplicação da seguinte equação:

$$Z_{t+h} = Z_t + hT_t, \quad \forall h > 0 \quad (2.7)$$

Onde:

Z_t : corresponde a previsão no tempo t;

T_t : corresponde a componente de tendência;

h : é o horizonte de previsão.

2.4.2.4 Suavização exponencial sazonal de Holt-Winter

Este método produz resultados similares ao da Suavização Exponencial Linear (Holt), sendo, no entanto, capaz de manipular séries temporais que além de apresentarem tendência nos dados, apresentam também sazonalidade (Morettin e Toloí, 2004).

Para o referido método de previsão são indicadas as seguintes equações:

$$S_t = \alpha \frac{z_t}{l_{t-1}} + (1 - \alpha)(S_{t-1} + T_{t-1}), \text{ onde } 0 < \alpha < 1, \text{ para } t=1,2,\dots,N \quad (2.8)$$

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}, \text{ onde } 0 < \beta < 1, \text{ para } t=1,2,\dots,N \quad (2.9)$$

$$l_t = \gamma \frac{z_t}{S_t} + (1 - \gamma)l_{t-1}, \text{ onde } 0 < \gamma < 1, \text{ para } t=1,2,\dots,N \quad (2.10)$$

$$Z_{t+h} = (S_t + hT_t)l_{t+h}, \text{ onde } 0 < h < 1, \text{ para } t=1,2,\dots,N \quad (2.11)$$

Onde:

l_t : corresponde a suavização do factor da sazonalidade $\frac{Z_t}{S_t}$;

l : é o intervalo de sazonalização;

γ : corresponde ao peso atribuído ao factor de Sazonalidade.

2.4.2.5 Método de Holt-Winters

O procedimento de alisamento exponencial pode ser generalizado para séries que contenham tendência e variação sazonal. Suponhamos que as observações são mensais e sejam L_t, I_t e T_t o nível, a tendência e o nível sazonal no tempo t . Assim, T_t é o aumento ou redução esperada por mês no nível actual da série.

Suponhamos que no tempo t os termos $(L_t, T_t, I_t), \dots, (L_{t-1}, T_{t-1}, I_{t-1})$ sejam conhecidos.

Então, após observar x_t os termos L_t, I_t e T_t são actualizados via alisamento exponencial. Se a variação sazonal for multiplicada, isto é, com amplitudes que tenderá a crescer ao longo do tempo, as equações de actualizações na forma de recorrência são dadas por:

$$L_t = \alpha(x_t / I_{t-12}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2.12)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (2.13)$$

$$I_t = \delta(x_t / L_t) + (1 - \delta)I_{t-12} \quad (2.14)$$

E as previsões k períodos a frente são dadas por:

$$\hat{X}_t(k) = (L_t + kT_t)I_{t-12+k}, k=1,2,\dots \text{ (Ehler,2003,38)} \quad (2.15)$$

2.4.3 Métodos avançados de previsão de séries temporais

No universo, dos métodos de previsão de séries temporais mais complexos encontra-se os modelos Autoregressivos e Médias Móveis (ARMA), modelos Autoregressivos Integrados de Médias Moveis (ARIMA), Filtros de Kalman e AEP, Modelos ARARMA de Parzen, Modelos ARMA multivariáveis (MARMA), entre outros (Curthbertson at al,1992).

Os modelos AR,MA,ARMA e ARIMA são descritos a seguir:

2.4.3.1 Modelos autoregressivos e de médias móveis

(Curthbertson e tal,1992), descreve três procedimentos capazes de representar as observações de uma série temporal estacionária: Modelo Autoregressivo(AR), Modelo de Médias Móveis (MA) e o modelo Autoregressivo e de Médias Móveis(ARMA).

2.4.3.2 Modelo autoregressivo

A especificação de um modelo Autoregressivo de ordem p , ou seja, AR(p) é dado pela equação (Curthbertson e tal.,1992).

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.16)$$

Onde:

Z_t : corresponde a observação da série temporal no instante t ;

ϕ_p : corresponde ao parâmetro do modelo AR de ordem p ;

a_t : representa o ruído branco presente no modelo, com $a_t \sim \eta(0, \sigma_a^2)$

2.4.3.3 Modelo de médias móveis de ordem q ou seja MA(q)

Um modelo de médias móveis de ordem q , ou seja, MA(q), fica definido conforme a equação (Curthbertson e tal.,1992).

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.17)$$

Onde:

a_t : representa o ruído branco presente no modelo, com $a_t \sim \eta(0, \sigma_a^2)$

ϕ_i : corresponde ao parâmetro do modelo MA(q), para $i = 1, 2, 3, \dots, N$.

A equação do modelo de médias móveis de ordem q , é similar a equação do modelo Autoregressivo, excepto o facto de que o valor previsto para a observação Y depende dos valores dos erros observados em cada período passado, ao invés das observações propriamente ditas (Curthbertson et al., 1992).

2.4.3.4 Modelo autoregressivo e de médias móveis

(Curthbertson et al., 1992), explicam que o modelo misto Autoregressivo e de Médias Móveis ARMA(p, q), surge da combinação dos Modelos Autoregressivo (AR) e de Médias Móveis (MA), conforme ilustra a equação.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t + \phi_1 a_{t-1} + \phi_2 a_{t-2} + \dots + \phi_q a_{t-q} \quad (2.18)$$

O modelo ARMA(p, q) é geralmente, mais parcimonioso do que os AR's e MA's puros, pois o modelo ARMA, relaciona os valores das observações passadas e presentes, e também com os erros passados apurados.

2.4.3.5 Modelo ARIMA

O modelo ARIMA para a análise e previsão de séries temporais engloba os modelos AR, MA e ARMA em uma única classe de modelos denominada de Modelo ARIMA (p, d, q), desta forma p significa a ordem autoregressiva do modelo, q a ordem média móvel do modelo e d o grau de diferença usado para alcançar a estacionariedade da série. A estacionariedade de uma série é condição exigida para a aplicação deste modelo, e muitas vezes são alcançadas com a diferenciação da série. A estacionariedade é em termos de médias e variâncias constantes, ou seja, $E(Z_t) = \mu$ e $Y(Z_t) = \sigma_a^2$, $\forall t$.

O modelo ARIMA consiste na busca de equações de parâmetros (p, d, q) (*Autoregressive integrate Moving Avarage*) que represente o processo estocástico gerador da série temporal a partir de um modelo ARMA aplicável na descrição de séries temporais estacionárias, estendendo este conceito para séries temporais não estacionárias (Nelson, 1973).

De acordo com (Box e Jenkins, 1976) e (Cuthbertson et al., 1992), a estratégia para a construção de um modelo ARIMA envolve uma abordagem iterativa obedecendo as seguintes etapas: identificação da estrutura do modelo, estimação dos parâmetros do modelo e verificação da adequação do modelo.

Uma vez proposta a classe do modelo $ARIMA(p,d,q)$ há a necessidade de identificar a estatística deste modelo. O objectivo da identificação é determinar os valores de p , d e q do modelo $ARIMA$ (Cuthbertson e tal.,1992). Inicialmente, a série temporal Z_t é diferenciada para se obter uma série estacionária na média e variância, com isso fica identificado o parâmetro d . Em seguida a ordem do processo $ARMA(p,q)$ é identificada pela análise dos coeficientes de autocorrelação e autocorrelação parcial nos gráficos FAC e $FACP$.

Após a identificação do modelo, se for uma representação adequada a estimação dos parâmetros é efectuada. (Judge, et al,1988) colocam que os parâmetros do processo AR são estimados através de métodos de regressão, caso o processo MA esteja envolvido, a estimação dos parâmetros deste modelo é obtida pela aplicação de alguns algoritmos de optimização não linear.

Estimado o modelo, a verificação da sua habilidade em representar os fenómenos observáveis da série temporal é confirmada pela análise dos resíduos. Caso a inadequação fique evidenciada o ciclo de identificação, estimação e verificação, são novamente aplicados, até que a representação apropriada seja encontrada.

Na prática, a selecção de modelos é feita analisando o valor do (*Bayesian Information Criterion* ou *Akaike Information Criteria*) para todos os modelos $ARIMA$ associados aos valores de p , d e q de forma que $p,q = 0,1,2,3,4,5$ e $d = 0,1$. Assim, selecciona-se o modelo que apresenta o menor valor do BIC ou SIC (Brockwell & Davis, 1996).

Após a validação do modelo, a previsão dos valores futuros da série temporal modelada pode ser obtida. O modelo $ARIMA$ pode ser aplicado para tamanho de série no mínimo $n = 50$ períodos.

2.5 Diferenciação de uma série temporal

Diferenciação significa calcular as diferenças entre pares de observações num intervalo temporal, onde a diferença dum intervalo temporal é calculado através da subtracção do primeiro valor com o segundo depois o segundo com o terceiro e assim sucessivamente.

Um tipo especial de filtro, muito útil para remover uma componente de tendência, consiste em diferenciar a série até que ela se torne estacionária, além disso independentemente do seu uso para induzir estacionariedade, a diferenciação pode ser muito útil como ferramenta exploratória. Observações discrepantes por exemplo podem

ter um efeito negativo na série diferenciada e uma representação gráfica em geral é suficiente para identificar tais pontos (Portola,2004).

2.6 Correlograma de uma série temporal

Um gráfico com os k primeiros coeficientes de Autocorrelação como função de k é chamado de correlograma e pode ser uma ferramenta útil para identificar características da série temporal. Porém isto requer uma interpretação adequada do correlograma, isto é, deve-se associar certos padrões do correlograma como determinadas características de uma série temporal (Ehler,2003).

2.7 Função autocorrelação e autocorrelação parcial de uma série temporal.

A função Autocorrelação teórica (FAC) de um processo estocástico estacionário é uma ferramenta importante para acessar suas propriedades, que são as seguintes;

- A correlação entre $\rho(x_t)$ e $\rho(x_{t+1})$ é a mesma e entre $\rho(x_t)$ e $\rho(x_{t-1})$ ou seja $\rho(\tau) = \rho(-\tau)$
- $-1 < \rho(\tau) < 1$

Embora um processo estocástico tenha uma estrutura de autocovariância única o contrário não é verdadeiro em geral. É possível encontrar vários processos com a mesma função de Autocorrelação, o que dificulta ainda mais a interpretação do correlograma. (Ehler,2003,17).

A função de Autocorrelação parcial (FACP) é definida como a sequência de correlações entre $(X_t$ e $X_{t-1})$, $(X_t$ e $X_{t-2})$, $(X_t$ e $X_{t-3})$ e assim por diante, desde que os efeitos de desfasagens anteriores sobre x_t permaneçam constantes (Hill, Griffiths & Judge, 1999).

Para um processo $AR(p)$, o último coeficiente α_p mede a correlação na desfasagem p que não é levado em conta por um modelo $AR(p-1)$. Este é chamado de p -ésimo coeficiente de correlação parcial assim variando $k = 1, 2, \dots$, temos a chamada função de Autocorrelação parcial (FACP) (Ehler,2003).

A função Autocorrelação parcial é também usada para detectar tendências e sazonalidade. No geral a FACP é o valor da correlação entre as variáveis (portola,2004).

O gráfico das FAC e FACP é chamado de correlograma. Tal gráfico apresenta valores que serão utilizados para caracterizar as propriedades lineares ou não do mecanismo gerador do processo (Granger & Newbold, 1986).

2.8 Modelos estacionários e não estacionários em séries temporais

Quando uma série temporal apresenta média e variância dependentes do tempo, é porque ela não é estacionária. A não-estacionariedade de uma série implica que:

- i. Os dados apresentam uma tendência, não permanecendo ao redor de uma linha horizontal ao longo do tempo.
- ii. A variação dos dados não permanece essencialmente constante sobre o tempo, isto é, as flutuações aumentam ou diminuem com o passar do tempo, indicando que a variância está a alterar-se.

Para verificar a não-estacionariedade de uma série, o comportamento temporal pode ser analisado graficamente, buscando padrões (i) e (ii) ou, então, aplicando o teste de raiz unitária. O teste de raiz unitária mais usado é o de Dickey-Fuller (Dickey e Fuller, 1981).

Um modelo é dito não estacionário se suas médias e variâncias não forem constantes ao longo do tempo e o valor da covariância entre dois períodos de tempo depender apenas da distância ou defasagem entre os dois períodos, e não do período de tempo efectivo em que a covariância é calculada (Gujarath,2005).

(Makridakis e Hibon,1979) verificaram que os dados transformados têm pouco efeito na melhoria da previsão, e, sob bases mais teóricas, (Granger e Newbold,1976) afirmaram que as previsões dos antilogaritmos dos dados transformados são estimadores viesados e deveriam, portanto, ser ajustados, mas isto não é feito em alguns programas de computador, o que significa que, depois de os dados serem transformados, um viés é introduzido nas previsões, decorrente de tal transformação. Além disso, Granger e

Newbold (1986) observaram que a heterocedasticidade não afecta a adequação da previsão, pois ela não implica em estimadores viesados, como no caso de regressão múltipla.

Uma das razões para se transformar os dados originais é a presença de não estacionariedade. A transformação mais comum consiste em tomar diferenças sucessivas da série original, até obter-se uma série estacionária.

Para determinar a ordem de integração das variáveis, pode-se utilizar dois modelos: um consiste em analisar a FAC da série original e se este não diminuir rapidamente para zero, a série possui tendência estocástica e deve ser diferenciada; o outro é denominado teste de raiz unitária, inicialmente desenvolvido por (Fuller,1976), (Dickey e Fuller 1979,1981). Este teste verifica se a série possui raiz unitária. Para tanto, testa-se as seguintes hipóteses:

H₀: a série possui raiz unitária

vs.

H₁: a série não possui raiz unitária.

Como na maioria dos casos ε_t não é ruído branco, utiliza-se uma correcção. O teste de Dickey-Fuller Aumentado (Said e Dickey, 1984), sugere aumentar a regressão adicionando termos suficientes em ΔX_{t-i} para branquear os resíduos. Então o teste ADF é a estatística usada para testar o coeficiente de ΔX_{t-i} em:

$$X\Delta_t = (\rho - 1)X_{t-1} + \sum \theta_i X\Delta_{t-i} + \varepsilon_t \quad (2.19)$$

que tem a mesma distribuição assintótica de Dickey-Fuller e não depende de θ_i . No entanto, é necessário trocar a ordem do componente autoregressivo através de um método automático como o AIC ou por alguma outra especificação.

A hipótese nula de uma raiz unitária ($H_0: \rho - 1 = 0$) é baseada no teste- t com uma distribuição não normal.

2.9 Testes para autocorrelação e normalidade

Teste para a Autocorrelação

A estatística de teste usa o resíduo de Mínimos quadrados ordinários (MQO) e é dada por:

$$d = \frac{\sum (e_i - e_{i-1})^2}{\sum e_{i-1}^2} \quad (2.20)$$

Observe que a estatística d está relacionada ao coeficiente de Autocorrelação amostral de primeira ordem.

Porque valores calculados da estatística d depende de uma certa matriz X , Darbin-Watson obteve limites inferiores (d_l) e superiores (d_u) de tal forma que;

$d < d_l$ rejeitamos a hipótese nula (presença de Autocorrelação),

$d > d_u$ não rejeitamos a hipótese nula.

$d_l < d < d_u$ então o teste é inclusivo.

Razões para autocorrelação

Segundo Valls (2000) temos as seguintes razões:

- Amostragem não independente;
- Falta de especificação ou de dinâmica.

Teste para a normalidade

O teste de Kolmogorov-Smirnov (K-S) é o teste estatístico adequado para determinar com uma certa margem de erro, se uma amostra é proveniente de uma população com distribuição contínua. A distribuição **Normal** é pela sua importância nos modelos aquela que com maior frequência pretendemos testar. As tabelas de K-S para testar a validade do modelo normal com estimação de parâmetros, foram corrigidas por *Lillifors* e é essa correção que aparece na determinação do *p-value* (sig. nas tabelas).

O que se pretende testar é se:

H₀: A população tem distribuição normal

vs.

H₁: A população não tem distribuição normal

O *p-value* é o menor valor do nível de significância que conduz à rejeição da hipótese nula. Assim, valores “grandes” do *p-value* conduzem à “não rejeição” da hipótese nula e valores pequenos do *p-value* à sua rejeição (Edite, 1999).

2.10 Adequação do modelo de uma série temporal

Após identificar a ordem e estimar eficientemente os parâmetros de um modelo é necessário verificar sua adequação antes de utilizá-lo por exemplo para fazer previsões. Pode-se fazer testes de ajuste, que consiste em incluir parâmetros extras no modelo e verificar suas significâncias estatísticas. No caso do modelo ARIMA deve-se incluir um parâmetro de cada vez para evitar o problema de cancelamento de raízes, também pode-se usar modelos que contem menor valor de Akaike's (AIC) e Schwarz's Bayesian , comparativamente com os outros (Ehler,2003).

2.11 Análise dos resíduos

Após um modelo ter sido ajustado a uma série temporal deve-se verificar se ele fornece uma descrição adequada dos dados. Assim como em outros modelos estatísticos a ideia é verificar o comportamento dos resíduos (*Resíduo = observação-valor ajustado*) (Ehler,2003,33), onde deve ser *white noise* em nível (Gujarath,2005).

2.11.1 Testes sobre os resíduos

Ao invés de olhar para as Autocorrelações residuais individualmente pode-se testar se um grupo de Autocorrelações é significativamente diferente de zero através das chamadas estatísticas Q, onde para modelos ARIMA (Box -Jenkins) sugeriram o uso do teste Box-Pierce onde a estatística do teste é dada por:

$$Q = n \sum_{k=1}^m r_k^2 \quad (2.21)$$

Se o modelo ajustado for apropriado então Q terá distribuição aproximadamente qui-quadrado com $m-p-q$ graus de liberdade (Ehler,2003,34).

A estatística Q de Box-Pierce é baseada no quadrado das primeiras p Autocorrelações dos resíduos de MQO é definida por:

$$Q = n \sum_{j=1}^p r_j^2 \text{ com } r_j = (\sum_{t=j+1}^n e_t - j) / (\sum_{t=1}^n e_t) \quad (2.22)$$

Uma modificação desta estatística devido a *Ljung-Box* é dada por:

$$Q = n(n+2) \sum_{j=1}^p r_j^2 / (n-j) \quad (\text{valls,2000}). \quad (2.23)$$

2.12 Critérios de informação de uma série temporal

Segundo (Ehler,2000), em muitas aplicações vários modelos podem ser julgados adequados em termos de comportamento dos resíduos, uma forma de “discriminar”

entre estes modelos competidores é utilizar os chamados critérios de informação que levam em conta não apenas a qualidade do ajuste mas também penalizam a inclusão de parâmetros extras. Assim, um modelo com mais parâmetros pode ter um ajuste melhor mas não necessariamente será preferível em termos de critério de informação. A regra básica consiste em seleccionar o modelo cujo critério de informação calculado seja mínimo.

A regra mais usada em séries temporais é chamada **critério de informação de Akaike**, denotada por AIC. A definição mais comumente utilizada é:

$$AIC = -2 \log \hat{L} + 2(p + q) \quad (2.24)$$

Onde \hat{L} representa a verossimilhança máxima.

Existem outros critérios de informação que são basicamente modificações do AIC na forma de penalizar a inclusão de parâmetros extras. O mais usado deles é o critério de informação Bayesiano, denotado por:

$$BIC = -2 \log \hat{L} + (p + q) \log T \quad (2.25)$$

Onde T representa o número de observações.

É sempre bom lembrar que estas medidas não tem nenhum significado quando olhadas individualmente, isto é, considerando-se um único modelo. Assim, tanto AIC quanto o BIC podem assumir valores quaisquer, inclusive valores negativos já que eles dependem da forma da função de verossimilhança.

2.13 Correlação de uma série temporal

Correlação de curto prazo

Uma série temporal na qual uma observação acima da média tende a ser seguida por uma ou mais observações acima da média, similarmente para observações abaixo da média é dita ter correlação a curto prazo. Um correlograma desta série deverá exibir um valor grande de coeficiente de *pierson* (r_k) seguido de valores que tendem a ficar sucessivamente menores. A partir de uma certa defasagem k os valores de r_k tendem a ser aproximadamente zero (Ehler,2003,9).

Correlação negativa

Se os valores de uma série temporal tendem a se alternar acima e abaixo de um valor médio, o correlograma também tende a se alterar. O valor de r_1 será negativo, enquanto

que o valor de r_2 será positivo já que as observações desfasadas de dois períodos tendem a estar do mesmo lado da média (Ehler,2003,9).

Observações discrepantes

Se uma série temporal contém uma ou mais observações discrepantes (*outliers*) o correlograma pode ser seriamente afectado. No caso de uma única observação discrepante, o gráfico X_t contra X_{t+k} terá pontos extremos o que pode *viesar* os coeficientes de correlação para zero. Com dois valores discrepantes o efeito pode ainda ser mais negativo, além de gerar uma correlação espúria quando é igual a distância entre os valores (Ehler,2003,13).

2.14 Índice de preço

Segundo (Paul A.Samuelson & William D.Nordhaus,1999) e (Hall.R,2003), um índice de preços é uma média ponderada dos preços de um certo número de bens e serviços.

Na elaboração de índices de preços, os economistas ponderam os preços individuais através da importância económica de cada bem. Os índices de preços mais importantes são: O índice de preço no consumidor, o deflator do PNB e o índice de preço no produtor.

Como o presente trabalho tem como finalidade fazer um estudo do índice de preço da gasolina, que é um índice de preço no consumidor, irei abordar com mais relevância o índice de preço no consumidor.

2.14.1 Índice de preço ao consumidor

Segundo (Fazenda,2007), geralmente o índice de preço ao consumidor é a média aritmética simples dos preços do produto registados no estabelecimento de cada uma delas.

É um indicador que tem como objectivo medir a evolução no tempo, dos preços de um conjunto de bens e serviços que se consideram representativos de uma estrutura de consumo num determinado espaço geográfico e de um ou vários estratos populacionais.

Os índices de preços mais usados são os seguintes:

2.14.1.1 Complexos não ponderados

➤ **De Sauerbeck**

É uma média aritmética sem ponderar os índices simples:

$$S_p = \frac{\sum_{i=1}^N \frac{P_{it}}{P_{i0}}}{\sum_{i=1}^N P_{i0}} \quad (2.26)$$

➤ **De Brandstreet-Dutot:** É uma média agregativa sem ponderar os índices

$$B - D_p = \frac{\sum_{i=1}^N \frac{P_{it}}{P_{i0}}}{\sum_{i=1}^N P_{i0}} \quad (2.27)$$

2.14.2 Índices ponderados

As ponderações mais usadas são:

$$w_i = P_{i0} \times q_{i0} \text{ (preço por quantidade consumida no período base)}$$

$$w_i = P_{i0} \times q_{it} \text{ (preço por quantidade consumida no período actual)}$$

➤ **Índice de Laspeyres**

É uma média aritmética ponderada que usa como ponderador $w_i = P_{i0} \times q_{i0}$, esse índice apresenta a vantagem da sua implementação ser fácil, uma vez determinados os ponderadores, o cálculo do índice exige apenas a recolha de dados.

A ponderação em função dos preços e quantidades do período base, tende a aumentar, por considerar as quantidades ou preços iguais aos do período base.

Índice de preço de Laspeyres:

$$L_p = \frac{\sum_{i=1}^N I_i w_i}{\sum_{i=1}^N w_i} = \frac{\sum_{i=1}^N \frac{P_{it}}{P_{i0}} P_{i0} q_{i0}}{\sum_{i=1}^N P_{i0} q_{i0}} = \frac{\sum_{i=1}^N P_{it} q_{i0}}{\sum_{i=1}^N P_{i0} q_{i0}} \quad (2.28)$$

Índice de quantidades de Laspeyres:

$$L_p = \frac{\sum_{i=1}^N I_i w_i}{\sum_{i=1}^N w_i} = \frac{\sum_{i=1}^N \frac{q_{it}}{q_{i0}} q_{i0} P_{i0}}{\sum_{i=1}^N q_{i0} P_{i0}} = \frac{\sum_{i=1}^N q_{it} P_{i0}}{\sum_{i=1}^N q_{i0} P_{i0}} \quad (2.29)$$

➤ **Índice de preço de Paasche**

É uma média aritmética ponderada que usa como ponderador $\omega_i = q_{i0} + q_{it}$

$$P_p = \frac{\sum_{i=1}^N I_i \omega_i}{\sum_{i=1}^N \omega_i} = \frac{\sum_{i=1}^N \frac{p_{it}}{p_{i0}} p_{i0} q_{it}}{\sum_{i=1}^N p_{i0} q_{it}} = \frac{\sum_{i=1}^N p_{it} q_{it}}{\sum_{i=1}^N p_{i0} q_{it}} \quad (2.30)$$

➤ **Índice de preço de Edgeworth**

É uma média agregativa ponderada que usa como ponderador $\omega_i = q_{i0} + p_{i0}$

$$E_p = \frac{\sum_{i=1}^N p_{it} (q_{i0} + q_{it})}{\sum_{i=1}^N p_{i0} (q_{i0} + q_{it})} \quad (2.31)$$

➤ **Índice de preço de Fisher**

O índice ideal de Fisher é a média geométrica dos índices de Paasche e de Laspeyres.

$$F_p = \sqrt{L_p \times P_p} \quad (2.32)$$

Destes índices o usado pelo INE é o de Laspeyres, dado que é um índice ponderado que verifica a propriedade de proporcionalidade. Ele usa como ponderador preços e quantidades do período base, com o qual não é necessário analisar o ponderador em cada período e é menos trabalhoso calcular.

3 METODOLOGIA

Neste capítulo apresento a metodologia e o material que usei para a realização do presente trabalho. Dentre os vários tipos de metodologia, a metodologia de Box-jenkins foi seleccionada e faz-se a sua descrição neste capítulo. Pode notar que nesta metodologia os dados tem de ser submetidos a um ciclo iterativo, cujo o processo consiste em submete-los a quatro etapas distintas, que são: identificação, estimação, verificação e previsão. Estas quatro etapas são descritas no presente capítulo.

3.1 Material e fonte

Para a realização do presente trabalho foi usada uma base de dados, fornecida pelo Instituto Nacional de Estatística.

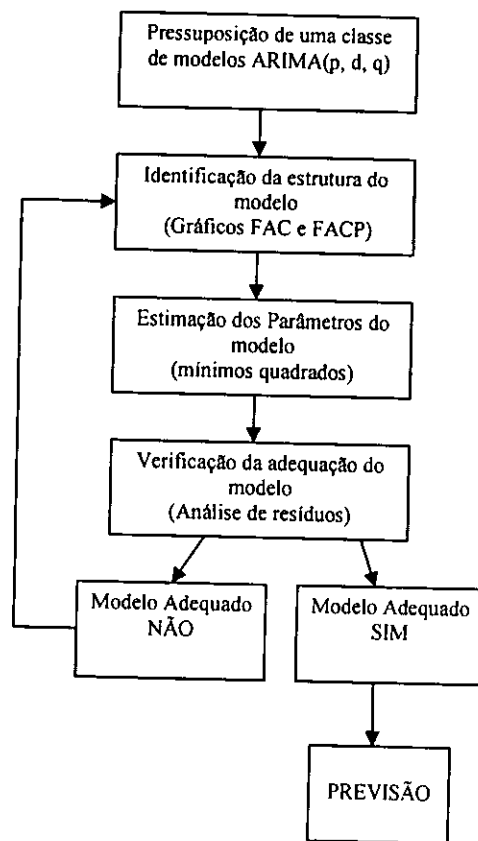
Com o efeito, usou-se a série temporal mensal do Índice de preço da gasolina para veículos de transporte pessoal na Cidade de Maputo, no período de Janeiro de 2000 a Dezembro de 2007, com um total de 96 observações.

Os resultados empíricos do estudo foram obtidos através dos *Softwares* estatísticos *Eviews*, versão 4.0 e o pacote SPSS, versão 13.0, no nível de significância de 5%.

3.2 Metodologia de Box-Jenkins

Segundo (Box,Jenkins,1976), os modelos e as técnicas de análise de séries temporais podem ser generalizados para levar em conta a sazonalidade e também para analisar como a série temporal está relacionada, de modo que os futuros valores da série possam ser preditos da informação do seu próprio passado.

A metodologia de Box-Jenkins que também pode ser chamada modelo ARIMA é um processo iterativo que se divide em quatro etapas, como se pode ver no seguinte fluxograma:



Fonte: Box e Jenkins, 1976

A etapa de identificação consiste em selecionar valores para p , d , q e P , D , Q (no caso de modelos sazonais). Essa etapa envolve subjetividade e julgamento pessoal. Na etapa de estimação, os coeficientes identificados na etapa anterior são estimados usando técnicas estatísticas. A última etapa indica se o modelo identificado e estimado descreve adequadamente o comportamento dos dados da série $\{X_t\}$. Caso o modelo não seja adequado, o ciclo deve começar novamente (Cribari-Neto, 2000).

3.2.1 Identificação da estrutura do modelo

Segundo (Box, Jenkins, 1976), esta etapa é baseada em estatísticas que são prontamente calculadas dos dados disponíveis, onde o analista selecciona um modelo específico que poderá ser apropriado da classe geral.

Esta etapa consiste em descobrir os valores apropriados de p (ordem da componente auto-regressivo), d (grau de diferenciação da série) e q (ordem da componente de média móvel), através da análise da função autocorrelação (FAC) e autocorrelação parcial (FACP) no correlograma.

As principais ferramentas da identificação são: a função autocorrelação, a função autocorrelação parcial e os correlogramas resultantes, que são simplesmente as representações gráficas das FACs e FACP contra o tamanho da defasagem. Para o uso desta etapa é obrigatório conhecer os modelos AR, MA e ARMA por meio das características da FAC e da FACP. A tabela abaixo, sugerida por (Gujarath, 2000), dá orientações gerais sobre o comportamento das FAC e FACP relativamente ao modelo que este sugere (Gujarath,2000).

Tabela 1. Resumo das principais características dos modelos AR(p), MA(q) e ARMA(p,q)

Tipo de modelo	Padrão típico de FAC	Padrao típico de PACF
AR(p)	Declina exponencialmente ou com padrão de onda senoidal amortecida, ou ambos	Picos significativos através das defasagens p
MA(q)	Picos significativos através das defasagens q	Declina exponencialmente
ARMA(p,q)	Declínio exponencial	Declínio exponencial

Segundo (Ehler, 2003), as duas ferramentas básicas para a identificação de modelos da classe ARIMA são as autocorrelações e autocorrelações parciais amostrais. Esta etapa envolve algum grau de arbitrariedade por parte do pesquisador ao interpretar estas funções, isto é, comparar subjectivamente os seus valores amostrais com os correspondentes valores teóricos.

Uma abordagem alternativa consiste em usar os critérios de informação de forma mais abrangente. Neste caso, um conjunto de possíveis modelos competidores e definido a priori é aquele que minimiza o critério de informação de Akaike (AIC) ou o critério de informação de Bayesiano (BIC) e seleccionado.

3.2.2 Estimação dos parâmetros do modelo ARIMA

Segundo (Box,Jenkins, 1976), o modelo específico escolhido na etapa de identificação da estrutura do modelo, terá quase invariavelmente alguns coeficientes desconhecidos, onde esses deverão ser previstos.

De acordo com (Ehler, 2003), combinando-se modelos AR e MA pode-se obter uma representação adequada com o número de parâmetros. Os processos auto-regressivos de

médias móveis (ARMA) formam uma classe de modelos muito úteis e parcimoniosos para descrever dados de séries temporais. O modelo ARMA (p, q) é dado por:

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + e_t + \beta_1 e_{t-1} + \dots + \beta_q e_{t-q} \quad (2.33)$$

Onde e_t é um processo puramente aleatório com média zero e variância σ_e^2 .

Os problemas de estimação para modelos ARIMA são similares para MA, no sentido de que um processo iterativo precisa de ser utilizado. Isto ocorre porque os erros $\{\epsilon_t\}$ são funções não lineares de todos os coeficientes $\alpha_1, \dots, \alpha_p, \beta_1, \dots, \beta_q$. Uma outra dificuldade específica de modelos ARIMA é o problema de cancelamento de raízes, onde por exemplo, se considerarmos o modelo ARIMA(2,0,1),

$$X_t = 2\theta X_{t-1} - \theta^2 X_{t-2} - \theta \epsilon_{t-1} + \epsilon_t \quad (2.34)$$

que pode ser reescrito da seguinte maneira:

$$(1 - \theta B)^2 X_t = (1 - \theta B) \epsilon_t \quad (2.35)$$

Nota-se que $\theta = \theta$ o que implica a um modelo AR(1) $X_t = \theta X_{t-1} + \epsilon_t$ (2.36)

Ou seja, ambos os modelos implicam exactamente o mesmo comportamento para a série temporal X_t . Desta forma, este é um problema de identificação que fica ainda mais difícil em modelos de ordem mais alta.

Em termos práticos é difícil identificar o problema de cancelamento de raízes, a não ser que o procedimento iterativo tenha que ter uma convergência lenta. No caso particular de um modelo ARMA(1,1), deve-se desconfiar quando as estimativas de α e β são muito similares. Para os outros valores de p e q , a única solução para tentar minimizar o problema é não incluir muitos parâmetros no modelo.

3.2.3 Verificação da adequação do modelo

De acordo com (Prentice, 1995), esta é a etapa final, onde são feitas as devidas análises no modelo previsto, para certificar se realmente o modelo fornece uma representação adequada dos dados da série temporal disponível. Qualquer efeito negativo revelada nesta etapa pode sugerir alguma especificação alternativa e o processo é repetido até obter-se um modelo satisfatório.

Segundo os pressupostos de (Ehler, 2003), após identificar o modelo e estimar eficientemente os parâmetros é necessário verificar a sua adequação antes de utilizá-lo, por exemplo para fazer previsões.

3.2.4 Análise dos resíduos

Após um modelo ter sido ajustado a uma série temporal deve-se verificar, se ele fornece ou não uma descrição adequada dos dados. Assim, como em outros modelos estatísticos, a ideia é verificar o comportamento dos resíduos.

Se o modelo tiver um “bom” ajuste, espera-se que os resíduos se distribuam aleatoriamente em torno de zero com variância aproximadamente constante e não correlacionados. Se a variância dos resíduos for crescente, uma transformação logarítmica nos dados pode ser apropriada.

Em modelos de série temporais os resíduos estão ordenados no tempo e é portanto natural tratá-los também como uma série temporal. Consequentemente, duas maneiras óbvias de verificar a adequação de modelos consistem em representar graficamente os resíduos e o seu correlograma.

3.2.4.1 Teste sobre os resíduos

Ao invés de olhar para as autocorrelações residuais individualmente, pode-se testar se um grupo de autocorrelações é significativamente diferente de zero através das chamadas estatísticas Q. Assim, valores altíssimos de Q fornecem indicação contra a hipótese de que as autocorrelações são todas nulas, em favor da hipótese de que ao menos uma delas é diferente de zero.

3.2.5 Previsão

De acordo com (Box, Jenkins, 1976), a metodologia de Box-Jenkins à previsão, tem a grande vantagem de apresentar uma boa flexibilidade e precisão nos resultados. Em modelos ARMA as previsões podem ser obtidas usando-se directamente a equação do modelo. Assumindo que a equação do modelo seja conhecida, a previsão $\hat{x}_n(k)$ é obtida substituindo valores futuros dos erros ε por zero, valores futuros da série X_{n+1}, X_{n+2}, \dots pela sua esperança condicional, e valores passados de X e de ε pelos seus valores observados. Os intervalos de confiança 95% são construídos para as estimativas dos pontos preditos pelo modelo, que são calculados assumindo a normalidade dos erros-padrão das estimativas, sendo que neste caso, para uma série temporal X_t :

Onde $SE(x_i)$ é o erro-padrão associado ao estimador x_i

$$IC\ 95\% = x_i \pm 1.96 * SE(x_i) \quad (2.37)$$

4 RESULTADOS E DISCUSSÃO

Neste capítulo é feita uma análise da série em estudo, tendo como principais objectivos o comportamento da série, a escolha de um modelo que melhor se ajuste aos dados, a comparação entre os modelos e selecção do melhor com o propósito de realizar previsões.

4.1 Estatísticas descritivas

O gráfico da figura 1 ilustra a evolução do índice do preço da gasolina ao longo dos oito anos considerados e permite concluir que o índice do preço da gasolina apresentou uma tendência crescente ao longo do período em análise. O maior índice de preço da gasolina atingido no período em estudo foi de 5.335474, observado no mês de Julho de 2007. O menor índice de preço foi de 1.042520 observado no mês de Janeiro de 2000. A média geométrica do índice do preço da gasolina neste período foi de aproximadamente 2.463617 e o desvio padrão de 1.275666. A partir da figura também pode-se suspeitar que a série se desenvolve aleatoriamente ao longo do tempo, em redor de uma média e variância volátil, sugerindo que ela seja não estacionária em nível.

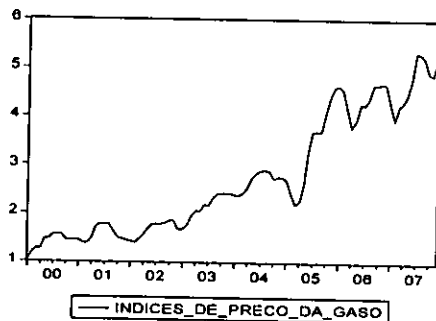


Figura 1. Serie cronológica do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

4.1.1 Decomposição da série em componentes

O gráfico da figura 2 ilustra a evolução da Componente Cíclica do índice do preço da gasolina ao longo dos oito anos considerados e permite sugerir que a componente cíclica apresenta um comportamento não periódico ao longo dos oito anos considerados, isto é, a componente cíclica não segue exactamente padrões análogos depois de intervalos de tempo iguais.




Figura 2. Série cronológica da componente Cíclica do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

O gráfico da figura 3 ilustra as diferentes variações da Componente irregular do índice do preço da gasolina ao longo dos oito anos considerados e permite sugerir que a componente Irregular sob o ponto de vista prático, apresenta movimentos de natureza residual, isto é, tem média zero e variância constante.

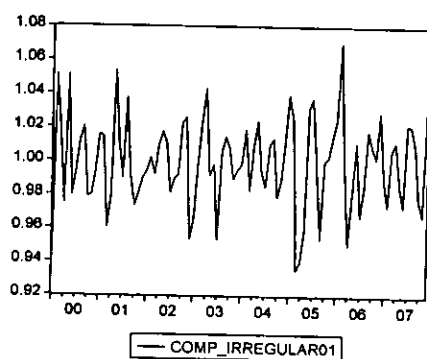


Figura 3. Série cronológica da componente Irregular do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

O gráfico da figura 4 ilustra as diferentes variações da Componente sazonal do índice do preço da gasolina ao longo dos oito anos considerados e permite sugerir que a componente sazonal descreve oscilações de ritmo forçado, que se repetem ao longo dos oito anos considerados.

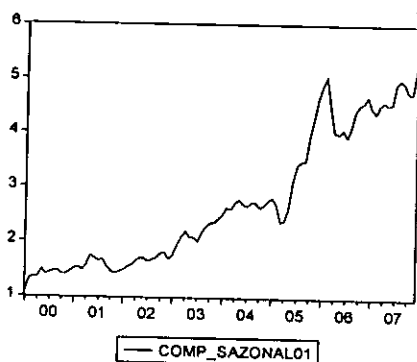


Figura 4. Série cronológica da Componente Sazonal do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

O gráfico da figura 5 ilustra a evolução da Tendência do índice do preço da gasolina ao longo dos oito anos considerados e permite sugerir que o índice do preço da gasolina apresentou uma tendência crescente ao longo do período em análise.




Figura 5. Série cronológica da Tendência do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

O índice de preço da gasolina apresenta um coeficiente percentilico de curtose igual à 1.905 (menor do que 3), o que significa que apresenta um grau de achatamento superior ao da distribuição normal, isto é, uma curva de distribuição de frequências platicúrtica, como se pode ver na figura 6 abaixo.




Figura 6. Histograma do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

Para poder-se avaliar a qualidade do ajustamento da distribuição normal á distribuição empirica foi feito o teste de Kolmogorov Smirnov. Onde as estatísticas dos resultados obtidos estão apresentadas na tabela 2.

Tabela 2. Teste de Kolmogorov Smirnov

		índice do preço da gasolina
N		96
Normal Parameters ^{a,b}	Geometric mean	2.4
	Std. Deviation	1.2
Most Extreme Differences	Absolute	,159
	Positive	,159
	Negative	-,110
Kolmogorov-Smirnov Z		1,557
Asymp. Sig. (2-tailed)		,016

a. Test distribution is Normal.

b. Calculated from data.

Fonte: Adaptação do Autor

Tendo em conta o valor do teste e a probabilidade (0.016), pode-se concluir que existem evidências suficientes para afirmar que a série do índice do preço tem uma distribuição normal.

Tabela 3: Teste de Sazonalidade para a série do Índice do preço da gasolina

	Teste para Sazonalidade		Quadrado Da media	Teste F
	Quadrado Da Soma	Graus de Liberdade		
Anos Intermédios	142.2635	7	20.32335	1.492
Erro	1048.571	77	13.6178	

Com base nos resultados obtidos na tabela 3, tendo em conta o valor do teste F(1.492), pode-se concluir que existem evidências suficientes para rejeitar a hipótese do Índice do preço apresentar um movimento sazonal.

4.2 Análise da estacionaridade da série em estudo

Para avaliar a estacionaridade da série do índice de preço da gasolina para veículo de transporte pessoal na Cidade de Maputo, fez-se primeiramente uma análise do correlograma da respectiva série em nível, respectivamente a função autocorrelação (FAC) e autocorrelação parcial (FACP) que sugeriu não ser estacionária em nível.




Figura 7. correlograma em nível do índice de preço da gasolina para veículos de transporte pessoal na Cidade de Maputo, entre Janeiro de 2000 e Dezembro de 2007.

Fonte: Adaptação do Autor

Para certificar a não estacionaridade da série, procedeu-se ao teste de raiz unitária de ADF. Sendo o t -calculado menor que os t -críticos em valores absolutos, concluindo-se assim que a série não é estacionária em nível.

Tabela 4: Teste de raiz unitária de Dickey fuller para a serie do Índice do preço da gasolina

Hipótese Nula: A série do índice do preço tem uma raiz unitária		
	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	0.010277	0.9566
Valores críticos:	1% level	-3.502238
	5% level	-2.892879
	10% level	-2.583553

Fonte: Adaptação do Autor

Como a série em estudo não é estacionária em nível, então procedeu-se a análise do correlograma da respectiva série em primeiras diferenças onde a função autocorrelação (FAC) e autocorrelação parcial (FACP) sugeriram que a série é estacionária em primeiras diferenças.




Figura 8. correlograma em primeiras diferenças do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.

Fonte: Adaptação do Autor

Para certificar a estacionaridade da série, procedeu-se ao teste de raiz unitária de ADF, onde o valor do t -calculado é maior que os t -críticos em valores absolutos, concluindo-se assim que a série é estacionária em primeiras diferenças.

Tabela 5. Teste de raiz unitária de Dickey-Fuller para a série do índice do preço da gasolina em primeiras diferenças.

Hipótese Nula: A série do índice do preço tem uma raiz unitária		
	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	-6.928306	0.0000
Valores críticos:	1% level	-3.502238
	5% level	-2.892879
	10% level	-2.583553

Fonte: Adaptação do Autor

4.3 Identificação

A análise do correlograma da figura 8 sugere que a série pode ser descrita por um modelo AR(1,1,0), AR(2,1,0), MA(0,1,1), ARIMA(1,1,1) e ARIMA(2,1,1) pois ao analisar as FAC e FACP, pode-se verificar um comportamento típico de um modelo ARIMA, apresentando um pico na defasagem 1 e 2.

4.4 Estimação dos modelos ARIMA

As tabelas abaixo apresentam os resultados da estimação dos modelos AR(1), MA(1), MA(2), ARIMA(1,1,1) e ARIMA(2,1,1).

Tabela 6. Estimação da Série índice de preço da gasolina segundo um AR(1,1,0)

Variável	Coefficiente	Erro Padrao	Estatistica t	Prob.
C	0.043745	0.030857	1.417654	0.1597
AR(1)	0.462425	0.093503	4.945555	0.0000

Fonte: Adaptação do Autor

Tabela 7. Estimação da Série índice de preço da gasolina segundo um AR(2,1,0)

Variável	Coefficiente	Erro Padrao	Estatistica t	Prob.
C	0.042057	0.017919	2.347031	0.0211
AR(2)	-0.051178	0.105733	-0.484037	0.6295

Fonte: Adaptação do Autor

Tabela 8. Estimação da Série índice de preço da gasolina segundo um MA(0,1,1)

Variável	Coefficiente	Erro Padrao	Estatistica t	Prob.
C	0.044706	0.024391	1.832878	0.0700
MA(1)	0.544133	0.086982	6.255680	0.0000

Fonte: Adaptação do Autor

Tabela 9. Estimação da Série índice de preço da gasolina segundo um ARIMA(1,1,1)

Variável	Coefficiente	Erro Padrao	Estatistica t	Prob.
C	0.044099	0.027785	1.587151	0.1159
AR(1)	0.171225	0.184552	0.927784	0.3560
MA(1)	0.444319	0.165749	2.680675	0.0087

Fonte: Adaptação do Autor

Tabela 10. Estimação da Série índice de preço da gasolina segundo um ARIMA(2,1,1)

Variável	Coefficiente	Erro Padrao	Estatistica t	Prob.
C	0.043137	0.025459	1.694355	0.0937
AR(2)	0.010091	0.117449	0.085921	0.9317
MA(1)	0.560285	0.095119	5.890387	0.0000

Fonte: Adaptação do Autor

4.5 Verificação da adequação dos modelos

Após identificar a ordem e estimar os parâmetros de um modelo é necessário verificar sua adequação antes de utilizá-lo para fazer previsões.

Para que o modelo seja considerado adequado é necessário que os resíduos do modelo estimado ε_t , sejam estimativas do ruído branco, ou seja, as suas autocorrelações devem comportar-se de maneira aleatória e devem ser não significativas, analisando o comportamento das FAC e FACP dos resíduos estimados, e através do teste de raiz unitária de Dickey-Fuller Aumentado.




Figura 9. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo AR(1)

Fonte: Adaptação do Autor




Figura 10. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo AR(2)

Fonte: Adaptação do Autor




Figura 11. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo MA(1)

Fonte: Adaptação do Autor




Figura 12. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo ARIMA(1,1,1)

Fonte: Adaptação do Autor

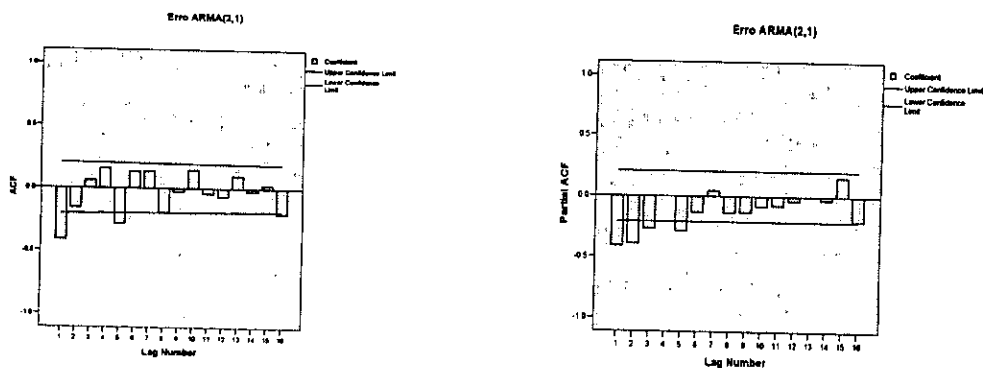


Figura 13. Correlograma da função de autocorrelação e autocorrelação parcial dos resíduos do modelo ARIMA(2,1,1)

Fonte: Adaptação do Autor

Fazendo uma análise nos correlogramas, podemos notar que eles parecem não apresentar problemas de autocorrelação serial, mostrando que os resíduos são ruído branco, o que pode ser provado fazendo o teste de Dickey-Fuller aumentado.

Tabela 11. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo AR(1,1,0)

Hipótese Nula: A série do índice do preço tem raiz unitária		
	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	-7.509980	0.0000
Valores críticos:	1% level	-3.510259
	5% level	-2.896346
	10% level	-2.585396

Fonte: Adaptação do Autor

Tabela 12. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo AR(2,1,0)

Hipótese Nula: A série do índice do preço tem uma raiz unitária		
	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	-8.631743	0.0000
Valores críticos:	1% level	-3.519050
	5% level	-2.900137
	10% level	-2.587409

Fonte: Adaptação do Autor

Tabela 13. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo MA(0,1,1)

Hipótese Nula: A série do índice de preço da gasolina tem uma raiz unitária

	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	-8.003825	0.0000
Valores críticos:	1% level	-3.524233
	5% level	-2.902358
	10% level	-2.588587

Fonte: Adaptação do Autor

Tabela 14. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo ARMA(1,1,1)

Hipótese Nula: A série do índice de preço da gasolina tem uma raiz unitária

	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	-9.555857	0.0000
Valores críticos:	1% level	-3.528515
	5% level	-2.904198
	10% level	-2.589562

Fonte: Adaptação do Autor

Tabela 15. Teste de raiz unitária de Dickey-Fuller para os resíduos do modelo ARMA(2,1,1)

Hipótese Nula: A série do índice de preço da gasolina tem uma raiz unitária

	Estatística t	Prob.*
Estatística do teste de Dickey-Fuller aumentado	-7.356618	0.0000
Valores críticos:	1% level	-3.538362
	5% level	-2.908420
	10% level	-2.591799

Fonte: Adaptação do Autor

Para todos os modelos rejeita-se a hipótese das séries apresentarem raiz unitária, o que significa que elas são ruído branco.

4.6 Escolha do modelo adequado

Para a escolha dos vários modelos estimados é necessário fazer a comparação dos modelos, onde, deve-se tomar em conta os critérios de selecção de modelos, que permite num conjunto de vários modelos estimados seleccionar aquele que melhor possui o poder explicativo dos dados de uma determinada série temporal.

Dos modelos estimados, ARIMA (0,1,1) é melhor porque apresenta todos coeficientes significativos, valor de *Akaike* e *Schwarz* muito próximos em comparação com os

outros modelos, tem também maior R^2 ajustado, e menor erro padrão, isto é, este modelo tem melhor explicabilidade comparativamente com os Modelos AR(1,1,0), AR(2,1,0), MA(0,1,1) e ARIMA(2,1,1). Ver as Tabelas no anexo .

Tabela 16: Estatísticas da estimação dos modelos AR(1), AR(2), MA(1), ARIMA(1,1,1) e ARIMA(2,1,1)

Modelos	Estatísticas			R^2 ajustado
	Erro padrão	AIC	SIC	
ARIMA(1,1,1)	0.15	-0.86	-0.78	0.259
ARIMA(2,1,1)	0.16	-0.85	-0.76	0.255
AR(1,1,0)	0.16	-0.796	-0.742	0.201
AR(2,1,0)	0.18	-0.552	-0.497	-0.008
MA(0,1,1)	0.15	-0.88	-0.83	0.259

Fonte: Adaptação do Autor

4.7 Previsão

Como dentre os modelos propostos o escolhido foi o modelo ARIMA(0,1,1), passa-se a fase final do processo que é fazer a previsão do Índice do preço da gasolina para veículos de transporte pessoal na Cidade de Maputo para os meses de Novembro e Dezembro de 2008, com um nível de significância de 5%, como ilustra a tabela 17 a baixo.

Tabela 17: previsão do índice de preço da gasolina

Ano	Meses	Previsão do índice do preço	Resultados obtidos pelo INE
2008	Julho	0.143	1.522128
2008	Agosto	0.268	1.522128
2008	Setembro	0.200	1.522128
2008	Outubro	0.049	1.522128
2008	Novembro	0.105	-----
2008	Dezembro	0.235	-----

fonte: Adaptação do Autor

5 CONCLUSÕES E RECOMENDAÇÕES

5.1 Conclusões

O presente trabalho analisou a série do Índice de preço da gasolina para veículos de transporte pessoal na Cidade de Maputo, usando a metodologia de Box-Jenkins, onde chegou-se as seguintes conclusões:

- A série do Índice do preço da gasolina entre Janeiro de 2000 e Dezembro de 2007 é estacionária em primeiras diferenças isto é série do Índice do preço da gasolina não é estacionária em nível.
- Foram analisados vários modelos tendo o modelo ARIMA (0,1,1) evidenciado melhor desempenho estatístico, apresentando melhores resultados no que diz respeito as previsões dentro da amostra, sendo portanto considerado o modelo adequado para representar a série do Índice do preço da gasolina para veículos de transporte pessoal na Cidade de Maputo entre Janeiro de 2000 e Dezembro de 2007.
- No período de Novembro e Dezembro de 2008, a previsão indica que o Índice de preço da gasolina para veículos de transporte pessoal será de 0.105 e 0.235 respectivamente.

5.2 Recomendações

Recomenda-se para os estudos futuros desta natureza que sejam feitos abrangendo não só uma única Cidade, mas sim o país inteiro de forma a dar uma ideia do comportamento do índice do preço da gasolina a nível do país, tendo em conta factores consideráveis que permitam descrever o comportamento do índice do preço.

Recomenda-se ainda que a comparação dos resultados de previsões obtidas seja realizada utilizando mais de um método, e por fim que as previsões feitas sejam comparadas com as já existentes, de forma a fornecer a escolha do modelo adequado para a série do índice do preço da gasolina.

5.3 Limitações do estudo

A limitação deveu-se ao facto de que inicialmente pretendia-se prever o índice de preço da gasolina para o país, o que não foi possível devido a complexidade do tema.

Bibliografia:

- Box, G.E.P., Jenkins, G.M., and Reinsel, G.C (1994). Time Series Analyses. 3ª Edicao. Nj.
- Box G.E.P., Jenkins, G.M. (1976). Time Series Analysis Forecasting and Control. Sam Francisco, Holden.
- Brockwell, P.J. & Davis, R.A (1996). Introduction to Time Series and Forecasting, New York: Spring-Verlag.
- Barbancho, Alfonso G. (1970). Fundamentos e possibilidades da Econometria, Forum Editora. Rio de Janeiro.
- Curthbertson, Keith; Hall, Stephen; Taylor, Mark. Applied Econometric Techniques, 1992, Harvester Wheatsheaf.
- Cribari-Neto, F. (2000). Método de Previsão de Arrecadação Tributária. Mimeo.
- Dickey D.A. & W.A. Fuller. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root, Journal of American and Statistical Association 74, 366, pp 427-431.
- Da Fonseca Jairo Simon, Martins Gilberto de Andrade e Toledo Geraldo Luciano (1985), Estatística Aplicada, 2ª Edicao, Atlas, Brazil.
- Dickey, D.A. & Fuller, A.F. (1981), Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root, Econometrica, Vol. 49, No. 4, pp. 1057-1072.
- Ehlers, Ricardo Sandes. Análises de Series Temporais. 2003. 2ª Edicao. Brazil
- Edite, Manuela Da G.P., Fernandes (1999). Estatística Aplicada, Universidade do Minho, Braga.
- Fuller, W.A. (1976). Introduction to Statistical Time Series, New York, John Wiley.
- Fazenda, Rodrigues, Zicai (2007). Estatística Econômica, Universidade Pedagógica, Maputo.
- Gujarath, Damodar. Econometria Básica (2000). Milton Mira de Assunção Filho. 3ª Edicao. Brazil (Tradução).
- Granger, C.W.J., Newbold, Paul. Forecasting Economic Time Series, 1977, Academic Press, New York.
- Granger, C. W. J. & Newbold, Paul. (1986). Forecasting Economic Time Series, New York, Academic Press.
- Granger, C. W. J. & Newbold, Paul. (1976). Forecasting Transformed Series, Journal of the Royal Statistics Society, Serie B, n.38, pp 189-203, Washington.

- Hill, R.C. Griffiths, W.E. & Judge, G.G.(1999). Econometria, São Paulo, Editora Saraiva.
- Judge,G.G.,Carter-Hill,R.,Griffths,W.E.,Lutke Pohl, H. and Lee, T.C.(1988).Intoduction to the theory and practice of econometrics , New York.: Wiley.
- Mankiw,N.Gregory(1993). Principios de Macroeconomia, 3ªEdicao,Norte-Americana.
- Morettin,Pedro Alberto; Toloj, Clélia Maria de Castro. Modelos Para Previsao de Séries Temporais,1981, 13ª Colóquio Brasileiro de Matemática, Rio de Janeiro.
- Murteira,Ferreira J.F. & Black, Joseph Georje Humberto (1983). Estatistica Descritiva, McGrow-Hell,Portugal.
- Morettin,Pedro Alberto; Toloj, Clélia Maria de Castro. Análize de Séries Temporais,2004, Editora Edgard Blucher, São Paulo.
- Makridakis, S. & M. Hibon (1979). Accuracy in forecasting: An empirical investigation, *Journal of the Royal Statistical Society*, pp 97-145, Series A, Vol.142.
- Nelson,Charles.R.Applied time series analysis for managerial Forecasting,1973, Sam Francisco, Holden-Day.
- Paul A.Samuelson & William D.Nordhaus (1999), Economia, 14ªEdicao,America.
- Prentice,Hall, Statistics for business and Economics, 1995. 4ª Edição,América.
- Pristhey, J. Theory of Electricity and Magntisn Princiton,1979, University
- Refenes, A.N.,Constructive Learning and its application to currency exchange rate forecasting,1993,In:Trippi,R.R.;Turban,E.Networks in Finance and investing.Chicago.
- Souza, Reinaldo Castro. Modelos Estruturais para Previsao de séries temporais Abordagem Classica e Bayesiana,1989, 17ª Colóquio Brasileiro de Matemática, Rio de Janeiro.
- Spiegel,Murray R.(1993), Estatistica , 3ªEdicao,Daisy Pereira Daniel,Brazil.
- Said, S.E. & Dickey, D.A. (1984). Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order, *Biometrika*, v. 7, pp 599-607.
- Toledo, Geraldo Luciano(1985),Estatistica Basica , 2ª Edicao,Atlas,Brazil.
- Valls,pedro.Autocorrelacao,p.1-42,2000.Brazil
- Varian,Hall.R(2003).Microeconomia Principios-basicos, 7ªEdicao, Editora Campus America.
- Wheelwright,Steven.C.; Makridakis, Spyros.Forecasting methods for Management, 1985,4th edition, John Wiley & Sons Inc, New York.

Anexos


A 1. Dados do índice do preço da gasolina para veículos de transporte pessoal na Cidade de Maputo (2000-2007).

MÊS	Índice	MÊS	Índice	MÊS	Índice
Jan-00	1.04	Jan-03	1.68	Jan-06	4.65
Feb-00	1.19	Feb-03	1.74	Feb-06	4.57
Mar-00	1.27	Mar-03	1.95	Mar-06	4.18
Apr-00	1.27	Apr-03	2.06	Apr-06	3.78
May-00	1.47	May-03	2.05	May-06	3.94
Jun-00	1.47	Jun-03	2.19	Jun-06	4.27
Jul-00	1.55	Jul-03	2.17	Jul-06	4.26
Aug-00	1.55	Aug-03	2.32	Aug-06	4.38
Sep-00	1.55	Sep-03	2.42	Sep-06	4.67
Oct-00	1.44	Oct-03	2.42	Oct-06	4.67
Nov-00	1.44	Nov-03	2.42	Nov-06	4.70
Dec-00	1.44	Dec-03	2.42	Dec-06	4.68
Jan-01	1.44	Jan-04	2.39	Jan-07	4.26
Feb-01	1.39	Feb-04	2.38	Feb-07	3.95
Mar-01	1.39	Mar-04	2.43	Mar-07	4.23
Apr-01	1.47	Apr-04	2.55	Apr-07	4.31
May-01	1.72	May-04	2.74	May-07	4.46
Jun-01	1.78	Jun-04	2.83	Jun-07	4.79
Jul-01	1.78	Jul-04	2.89	Jul-07	5.34
Aug-01	1.78	Aug-04	2.90	Aug-07	5.32
Sep-01	1.62	Sep-04	2.89	Sep-07	5.22
Oct-01	1.50	Oct-04	2.72	Oct-07	4.92
Nov-01	1.47	Nov-04	2.76	Nov-07	4.88
Dec-01	1.44	Dec-04	2.76	Dec-07	5.18
Jan-02	1.42	Jan-05	2.69		
Feb-02	1.40	Feb-05	2.42		
Mar-02	1.47	Mar-05	2.20		
Apr-02	1.55	Apr-05	2.26		
May-02	1.68	May-05	2.60		
Jun-02	1.78	Jun-05	3.30		
Jul-02	1.78	Jul-05	3.70		
Aug-02	1.78	Aug-05	3.70		
Sep-02	1.81	Sep-05	3.70		
Oct-02	1.85	Oct-05	4.07		
Nov-02	1.86	Nov-05	4.40		
Dec-02	1.68	Dec-05	4.62		

A2. Estatísticas descritivas do índice de preço da gasolina para veículos de transporte pessoal de Janeiro de 2000 a Dezembro de 2007.

Estatísticas	Valores
Observações	96
Média Geométrica	2.46361721
Mediana	2.405197
Máximo	5.335474
Mínimo	1.042520
Desvio Padrão	1.275666
Assimetria	0.592839
Curtose	1.905453

A3. Serie cronológica dos resíduos do índice de preço da gasolina para veículos de transporte pessoal na cidade de Maputo, entre Janeiro de 2000 a Dezembro de 2007.



A4. Resultados da estimação do modeloAR(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.043745	0.030857	1.417654	0.1597
AR(1)	0.462425	0.093503	4.945555	0.0000
R-squared	0.210019	Mean dependent var		0.042400
Adjusted R-squared	0.201432	S.D. dependent var		0.179947
S.E. of regression	0.160805	Akaike info criterion		-0.796202
Sum squared resid	2.378958	Schwarz criterion		-0.742089
Log likelihood	39.42150	F-statistic		24.45851
Durbin-Watson stat	1.654040	Prob(F-statistic)		0.000003

A5. Resultados da estimação do modelo AR(2)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.042057	0.017919	2.347031	0.0211
AR(2)	-0.051178	0.105733	-0.484037	0.6295
R-squared	0.002568	Mean dependent var		0.042077
Adjusted R-squared	-0.008393	S.D. dependent var		0.180895
S.E. of regression	0.181652	Akaike info criterion		-0.552177
Sum squared resid	3.002769	Schwarz criterion		-0.497712
Log likelihood	27.67623	F-statistic		0.234292
Durbin-Watson stat	1.041238	Prob(F-statistic)		0.629523

A6. Resultados da estimação do modelo MA(1)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.044706	0.024391	1.832878	0.0700
MA(1)	0.544133	0.086982	6.255680	0.0000
R-squared	0.267658	Mean dependent var		0.043545
Adjusted R-squared	0.259783	S.D. dependent var		0.179334
S.E. of regression	0.154292	Akaike info criterion		-0.879112
Sum squared resid	2.213959	Schwarz criterion		-0.825346
Log likelihood	43.75782	F-statistic		33.98977
Durbin-Watson stat	1.844071	Prob(F-statistic)		0.000000

A7. Resultados da estimação do modelo ARIMA(1,1,1)

Variavel	Coefficient	Std. Error	t-Statistic	Prob.
C	0.044099	0.027785	1.587151	0.1159
AR(1)	0.171225	0.184552	0.927784	0.3560
MA(1)	0.444319	0.165749	2.680675	0.0087
R-squared	0.275241	Mean dependent var		0.042400
Adjusted R-squared	0.259313	S.D. dependent var		0.179947
S.E. of regression	0.154868	Akaike info criterion		-0.861096
Sum squared resid	2.182546	Schwarz criterion		-0.779927
Log likelihood	43.47150	F-statistic		17.27953
Durbin-Watson stat	1.952561	Prob(F-statistic)		0.000000

A8. Resultados da estimação do modelo ARIMA(2,1,1)

Variável	Coefficiente	Erro Padrão	Estatística-t	Prob.
C	0.043137	0.025459	1.694355	0.0937
AR(2)	0.010091	0.117449	0.085921	0.9317
MA(1)	0.560285	0.095119	5.890387	0.0000
R-squared	0.271909	Mean dependent var		0.042077
Adjusted R-squared	0.255729	S.D. dependent var		0.180895
S.E. of regression	0.156060	Akaike info criterion		-0.845429
Sum squared resid	2.191919	Schwarz criterion		-0.763732
Log likelihood	42.31245	F-statistic		16.80543
Durbin-Watson stat	1.865834	Prob(F-statistic)		0.000001

A9. Resultados da decomposição da serie original em componentes

DATE	Original Series	Moving Average Series	Ratio of Original Series to Moving Average Series (%)	Seasonal Factor (%)	Seasonally Adjusted Series	Smoothed Trend-Cycle Series	Irregular (Error) Component
Jan-00	1,043			95,2	1,095	1,171	,935
Feb-00	1,194			90,2	1,324	1,259	1,052
Mar-00	1,266			93,2	1,358	1,335	1,018
Apr-00	1,266			93,6	1,352	1,387	,975
May-00	1,468			98,3	1,493	1,420	1,051
Jun-00	1,468			104,7	1,401	1,430	,980
Jul-00	1,551	139,002,624,671,916	111,6	108,1	1,435	1,444	,994
Aug-00	1,551	142,322,834,645,670	109,0	106,2	1,461	1,444	1,012
Sep-00	1,551	143,923,884,514,436	107,8	105,4	1,471	1,441	1,021
Oct-00	1,441	144,921,259,842,520	99,4	103,0	1,399	1,429	,979
Nov-00	1,441	146,614,173,228,347	98,3	102,6	1,404	1,433	,980
Dec-00	1,441	148,700,787,401,575	96,9	99,4	1,450	1,458	,995
Jan-01	1,441	151,325,459,317,586	95,2	95,2	1,513	1,489	1,016
Feb-01	1,386	153,254,593,175,853	90,4	90,2	1,537	1,514	1,015
Mar-01	1,386	155,183,727,034,121	89,3	93,2	1,487	1,548	,960
Apr-01	1,469	155,759,842,519,686	94,3	93,6	1,569	1,602	,980
May-01	1,718	156,219,160,104,987	110,0	98,3	1,747	1,658	1,054
Jun-01	1,783	156,455,380,577,428	113,9	104,7	1,702	1,683	1,011
Jul-01	1,783	156,468,503,937,008	113,9	108,1	1,650	1,666	,990
Aug-01	1,783	156,284,776,902,888	114,1	106,2	1,679	1,618	1,038
Sep-01	1,620	156,363,517,060,368	103,6	105,4	1,537	1,550	,991
Oct-01	1,496	157,104,986,876,641	95,2	103,0	1,452	1,491	,974
Nov-01	1,469	157,813,648,293,964	93,1	102,6	1,431	1,459	,981
Dec-01	1,443	157,456,692,913,386	91,6	99,4	1,452	1,466	,990
Jan-02	1,419	157,443,569,553,806	90,1	95,2	1,490	1,498	,995
Feb-02	1,395	157,430,446,194,226	88,6	90,2	1,548	1,544	1,002
Mar-02	1,475	157,417,322,834,646	93,7	93,2	1,582	1,595	,992
Apr-02	1,554	158,968,503,937,008	97,8	93,6	1,660	1,645	1,010
May-02	1,675	161,921,259,842,520	103,5	98,3	1,704	1,674	1,018
Jun-02	1,781	165,154,855,643,045	107,8	104,7	1,701	1,683	1,011
Jul-02	1,781	167,110,236,220,473	106,6	108,1	1,648	1,680	,981
Aug-02	1,781	169,262,467,191,602	105,2	106,2	1,678	1,695	,990
Sep-02	1,806	172,129,921,259,843	104,9	105,4	1,713	1,727	,992
Oct-02	1,850	176,068,241,469,817	105,1	103,0	1,796	1,755	1,023
Nov-02	1,857	180,272,965,879,266	103,0	102,6	1,809	1,763	1,026
Dec-02	1,677	183,410,761,154,856	91,4	99,4	1,688	1,770	,954
Jan-03	1,677	186,826,771,653,544	89,8	95,2	1,761	1,824	,965
Feb-03	1,739	190,081,364,829,397	91,5	90,2	1,929	1,931	,999
Mar-03	1,947	194,612,860,892,389	100,1	93,2	2,089	2,041	1,023
Apr-03	2,059	199,694,225,721,785	103,1	93,6	2,199	2,108	1,043
May-03	2,052	204,458,005,249,344	100,4	98,3	2,087	2,105	,991
Jun-03	2,191	209,164,041,994,751	104,8	104,7	2,092	2,095	,998

Jul-03	2,172	215,371,391,076,116	100,8	108,1	2,010	2,108	953
Aug-03	2,325	221,346,456,692,914	105,0	106,2	2,190	2,179	1,005
Sep-03	2,416	226,687,664,041,995	106,6	105,4	2,292	2,258	1,015
Oct-03	2,422	230,682,414,698,163	105,0	103,0	2,351	2,331	1,008
Nov-03	2,422	234,791,338,582,678	103,2	102,6	2,360	2,384	990
Dec-03	2,422	240,545,931,758,531	100,7	99,4	2,437	2,450	995
Jan-04	2,394	245,895,013,123,360	97,4	95,2	2,514	2,518	998
Feb-04	2,380	251,868,766,404,200	94,5	90,2	2,640	2,591	1,019
Mar-04	2,427	256,698,162,729,659	94,5	93,2	2,604	2,650	983
Apr-04	2,552	260,645,669,291,339	97,9	93,6	2,726	2,701	1,009
May-04	2,742	263,133,858,267,717	104,2	98,3	2,789	2,723	1,024
Jun-04	2,833	265,916,010,498,688	106,5	104,7	2,705	2,722	994
Jul-04	2,889	268,698,162,729,659	107,5	108,1	2,673	2,714	985
Aug-04	2,904	271,154,855,643,045	107,1	106,2	2,736	2,709	1,010
Sep-04	2,890	271,514,435,695,538	106,4	105,4	2,741	2,704	1,014
Oct-04	2,721	269,664,041,994,751	100,9	103,0	2,641	2,698	979
Nov-04	2,756	267,215,223,097,113	103,1	102,6	2,685	2,716	988
Dec-04	2,756	266,068,241,469,817	103,6	99,4	2,773	2,740	1,012
Jan-05	2,689	269,958,005,249,344	99,6	95,2	2,823	2,716	1,040
Feb-05	2,423	276,727,034,120,735	87,6	90,2	2,688	2,625	1,024
Mar-05	2,205	283,363,517,060,368	77,8	93,2	2,365	2,530	935
Apr-05	2,258	290,120,734,908,137	77,8	93,6	2,412	2,567	940
May-05	2,605	301,400,262,467,192	86,4	98,3	2,649	2,762	959
Jun-05	3,300	315,060,367,454,069	104,7	104,7	3,150	3,055	1,031
Jul-05	3,701	330,611,548,556,431	111,9	108,1	3,425	3,301	1,038
Aug-05	3,701	346,953,412,073,491	106,7	106,2	3,486	3,492	998
Sep-05	3,701	364,841,207,349,082	101,4	105,4	3,510	3,680	954
Oct-05	4,074	381,301,837,270,342	106,8	103,0	3,955	3,954	1,000
Nov-05	4,395	393,984,251,968,504	111,6	102,6	4,282	4,272	1,002
Dec-05	4,622	405,111,548,556,431	114,1	99,4	4,651	4,589	1,013
Jan-06	4,650	413,231,097,037,871	112,5	95,2	4,882	4,761	1,025
Feb-06	4,570	417,879,544,881,890	109,4	90,2	5,069	4,737	1,070
Mar-06	4,180	423,563,649,868,767	98,7	93,2	4,485	4,506	995
Apr-06	3,780	431,626,611,998,501	87,6	93,6	4,038	4,250	950
May-06	3,940	436,578,025,571,804	90,2	98,3	4,007	4,076	983
Jun-06	4,274	439,100,669,891,264	97,3	104,7	4,081	4,034	1,012
Jul-06	4,259	439,545,609,523,810	96,9	108,1	3,941	4,075	967
Aug-06	4,383	436,320,752,380,953	100,5	106,2	4,128	4,193	985
Sep-06	4,668	431,133,990,476,191	108,3	105,4	4,428	4,347	1,019
Oct-06	4,668	431,576,085,714,286	108,2	103,0	4,531	4,493	1,009
Nov-06	4,698	435,969,228,571,429	107,8	102,6	4,577	4,567	1,002
Dec-06	4,675	440,343,323,809,524	106,2	99,4	4,705	4,570	1,029
Jan-07	4,263	444,641,257,142,858	95,9	95,2	4,476	4,524	989
Feb-07	3,948	453,615,200,000,001	87,0	90,2	4,379	4,497	974
Mar-07	4,233	461,422,057,142,858	91,7	93,2	4,542	4,511	1,007
Apr-07	4,307	465,982,628,571,429	92,4	93,6	4,601	4,547	1,012
May-07	4,465	468,059,200,000,000	95,4	98,3	4,541	4,606	986
Jun-07	4,790	469,587,714,285,715	102,0	104,7	4,573	4,699	973
Jul-07	5,335	473,786,857,142,858	112,6	108,1	4,937	4,830	1,022
Aug-07	5,320			106,2	5,011	4,905	1,022
Sep-07	5,216			105,4	4,947	4,900	1,010
Oct-07	4,918			103,0	4,773	4,883	978
Nov-07	4,881			102,6	4,755	4,913	968
Dec-07	5,179			99,4	5,212	4,999	1,043