

**ET
84**

IV 001

SG

UNIVERSIDADE EDUARDO MONDLANE
Faculdade de Ciências
Departamento de Matemática e Informática

Trabalho de Licenciatura em Estatística

Tema :

**Estudo da série temporal de concessão de terra para habitação no
período de Janeiro de 1996 a Abril de 2008**

Caso: província de Inhambane

Autor: Mussagy Ismael Savai Ibraimo

Novembro de 2008

UNIVERSIDADE EDUARDO MONDLANE
Faculdade de Ciências
Departamento de Matemática e Informática

Trabalho de Licenciatura em Estatística

Tema :

**Estudo da série temporal de concessão de terra para habitação no
período de Janeiro de 1996 a Abril de 2008**

Caso: província de Inhambane

Autor: Mussagy Ismael Savai Ibraimo
Supervisor: Dr. Bonifácio José

Novembro de 2008

R.E.11.099

AGRADECIMENTOS

Louvado seja ALLAH o todo Poderoso que me deu a vida, saúde e oportunidade para que chegasse este momento;

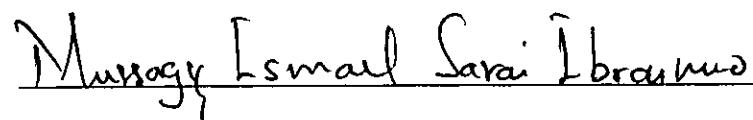
Especial agradecimento ao meu orientador Dr. Bonifácio José, pelo seu apoio e orientação neste trabalho, a todos os professores do DMI – do curso de Estatística e funcionários pela amizade;

À dra. Alima da Direcção Nacional de Terras e à dra. Pércida Langa,

Aos meus Pais, irmãos, primos Bachir e Ayat, amicíssimos Daia, Abdala, Zimba e às respectivas esposas, colegas de Estatística que me queriam o bem e todos que directa ou indirectamente contribuiram moral e materialmente para o meu sucesso.

DECLARAÇÃO DE HONRA

Declaro que o presente trabalho é resultado da minha investigação, e que não foi submetido a um outro grau que não seja o indicado: Licenciatura em Estatística na Faculdade de Ciências da Universidade Eduardo Mondlane.



Mussagy Ismael Savai Ibraimo

DEDICATÓRIA

Aos meus pais Insa Ibraimo e Assimana Ibraimo, Daúde Dulá e Fátima Dulá, meu tio Abdul Bicá, meus irmãos Dânia, Juleica, Saquina, Nilza e Ansuar meus cunhados Fígas e Mussá.

RESUMO

Este trabalho apresenta aplicação dos modelos ARIMA genericamente conhecidos por Box-Jenkins para analisar o comportamento do nível de concessão de terras para habitação da província de Inhambane, de requerentes que solicitam espaço até 5.000 metros quadrados, e a partir dele apresentar um modelo adequado para fazer previsão fora da amostra para o período de Maio a Dezembro de 2008. A série não apresenta componentes sazonais no período em análise e não é estacionária em nível, pois foi necessário diferenciá-la por forma a estabilizar a variância. Estimaram-se vários modelos dos quais o que melhor se ajustou aos dados foi o modelo ARIMA(3,1,1), a partir dele foram geradas previsões, que mostram uma tendência estacionária.

Palavras-chaves: Série temporal, previsão, estacionaridade, ARIMA.

LISTA DE FIGURAS

Figura.1: Representação gráfica da Série em nível de Concessão de terras em metros quadrados no período em análise	27
Figura 2: Correlogramas da Função autocorrelação e autocorrelação parcial em nível da série de concessão de terras.	28
Figura.3: Representação gráfica da Série em primeiras diferenças de concessão de terras em metros quadrados no período em análise.....	30
Figura 4: Correlogramas da Função autocorrelação e autocorrelação parcial em primeiras diferenças da série de concessão de terras.....	32
Figura 5: Série de resíduos do modelo ARIMA (3,1,1) ajustado	35
Figura 8: Série de resíduos do modelo ARIMA (1,1,2) ajustado	36
Figura 9: Histograma dos resíduos do modelo ARIMA (1,1,2)	37
Figura 10: Correlograma da função autocorrelação parcial da série de resíduos do modelo ARIMA (1,1,2) ajustado.....	37
Figura 11: Série de resíduos do modelo ARIMA (0,1,1) ajustado	38
Figura 12: Correlograma da função autocorrelação parcial da série de resíduos do modelo ARIMA (0,1,1) ajustado	38
Figura 13:Histograma dos resíduos do modelo ARIMA (0,1,1)	39
Figura 14: Série de resíduos do modelo ARIMA (9,1,0) ajustado	39
Figura 16:Histograma dos resíduos do modelo ARIMA (9,1,0)	40

LISTA DE TABELAS

Tabela.1-Principais características das FAC e FACP teóricas dos processos estacionários não sazonais.....	19
Tabela.2- Algumas particularidades das FAC e FACP teóricas dos processos estacionários não sazonais e sazonais mais comuns	20
Tabela 3: Teste de Raiz unitária para a série AEMM2 em nível usando o teste de ADF.....	29
Tabela 4: Equação do teste de Dickey-Fuller Aumentado da série AEMM2 em nível.....	29
Tabela 5: Teste de Raiz unitária para a série AEMM2 em nível usando o teste de KPSS.....	30
Tabela 7: Teste de Raiz unitária para a série AEMM2 em primeiras diferenças pelo teste de ADF.....	31
Tabela 8: Equação do teste de Dickey-Fuller Aumentado da série AEMM2 em primeiras	31
Tabela 9: Teste de Raiz unitária para a série AEMM2 em primeiras diferenças usando o teste de KPSS.....	31
Tabela 10: Equação do teste de KPSS da série AEMM2 em primeiras diferenças.....	32
Tabela 11: Estatísticas da estimativa do modelo ARIMA (3,1,1)	33
Tabela 12: Estatísticas da estimativa do modelo ARIMA (1,1,2)	33
Tabela 13: Estatísticas da estimativa do modelo ARIMA (0,1,1)	34
Tabela 14: Estatísticas da estimativa do modelo ARIMA (9,1,0)	34
Tabela 15: Estatísticas de normalidade de resíduos de K-S	40
Tabela 16: Estatísticas de desempenho dos modelos na previsão	41
Tabela 17: Previsão de concessão de terra para habitação para o período de Maio-08 a Dezembro-08 e os respectivos intervalos de confiança.....	41

ÍNDICE

1. INTRODUÇÃO.....	5
1.2. Problema em estudo.....	6
1.3. Objectivos.....	7
2. REVISÃO BIBLIOGRÁFICA.....	8
2.1. Séries Temporais	8
2.2. Testes de Estacionaridade.....	14
2.3. Metodologia ARIMA	17
3. MATERIAL E MÉTODO.....	26
3.1. Material.....	26
3.2. Métodos	26
4. RESULTADOS E DISCUSSÃO.....	27
4.1. Testes de Estacionaridade.....	28
4.2. Identificação	32
4.3. Estimação dos Modelos	33
4.4. Avaliação do Diagnóstico.....	34
4.5. Selecção e comparação de modelos.....	41
4.6. Previsão	41
5. CONCLUSÕES E RECOMENDAÇÕES.....	42
5.1 Conclusões.....	42
5.2. Recomendações	43
5.3. Limitações	43
6. BIBLIOGRAFIA.....	44
Anexos.....	46

Lista de Abreviaturas

ADF	Dickey Fuller Aumentado
AEMM2	Área em metros quadrados
AIC	Critério de Informação Akaike
AR	Auto-regressivo
ARIMA	Auto-regressivo integrado de médias moveis não sazonal
ARMA	Auto-regressivo de médias moveis
BIC	Critério de Informação Bayesiano
DAEMM2	Área em metros quadrados em diferenças
EAM	Erro Absoluto Médio
EAMP	Erro Absoluto Médio Percentual
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
KPSS	Kwiatkowski-Phillips-Schmidt-Shin
MA	Médias Móveis
PP	Phillips Perron
REQM	Raiz do Erro Quadrático Médio
SARIMA	Auto-regressivo integrado de médias móveis sazonal
SIC	Critério de Informação de Schwarz

1. INTRODUÇÃO

Moçambique é um país que possui uma grande extensão de terra e onde a principal actividade é a agricultura. Esta extensão de terra tem gerado múltiplos conflitos entre os usuários e o Estado.

Como meio universal de criação de riqueza e bem-estar social, o uso e aproveitamento de terra deve ser um direito de todo o cidadão de uma forma concensual e bem direcccionada.

Para solucionar os conflitos existentes no país, foi aprovada a Nova Lei de Terra 19/97 em Julho de 1997, de forma a adequá-la à nova conjuntura política, económica e social e garantir o acesso e a segurança da posse de terra, tanto aos camponeses moçambicanos, como de investidores nacionais e estrangeiros.

Entretanto a lei de terra ainda é muito pouco conhecida pelo público em geral o que dificulta o processo de aquisição de terra para qualquer que seja o fim.

O presente trabalho pretende, a partir dos objectivos predefinidos no âmbito da aplicação de séries temporais, fazer análise dos dados com recurso à informação dos dados históricos de concessão de terra de 1996 a 2008, aplicando-as na previsão de valores futuros de nível de ocupação de terra com vista a fornecer mais informação sobre o processo de concessão.

O estudo foi feito na província de Inhambane e constituirá uma mais valia para a Direcção Nacional de Terras uma vez que a partir dela se poderá fazer uma melhor planificação do espaço que se pretende conceder para determinados fins de utilização no período em que se pretende fazer a previsão. A estrutura do trabalho comprehende quatro parte a referir:

A parte introdutória, que faz uma abordagem geral sobre a lei de terra, a revisão da literatura que se debruça sobre aspectos teóricos ligados à metodologia de Box & Jenkins, e sobre as séries temporais, materiais e métodos usados para o estudo, resultados e a respectiva discussão, e conclusões.

1.2. Problema em estudo

A lei de terras em Moçambique é um conjunto de disposições legais que abrange todos os aspectos chave da ocupação, uso e aproveitamento de terra. A terra é concedida a pessoas ou instituições e para diversos fins de utilização ou ajustados. Geralmente, a concessão é feita de acordo com os critérios estabelecidos por lei, tornando mais fácil o registo da terra cedida aos requerentes.

O processo de planificação, cedência e gestão do espaço é complexo e requer alguns cuidados para que este resulte limpo e transparente.

Deste modo surge a seguinte questão:

- **Como prever a área da terra que o Governo irá conceder para diversos fins na província de Inhambane com base nos seus dados históricos?**

1.3. Objectivos

1.3.1. Objectivo Geral

- Estudar a série temporal de concessão de terra no período de Janeiro de 1996 a Abril de 2008.

1.3.2. Objectivos específicos

- Identificar a tendência Global (Padrão de tendência ou existência de sazonalidade);
- Identificar o modelo adequado à série correspondente;
- Fazer previsão para o período de Maio de 2008 a Dezembro de 2008.

2. REVISÃO BIBLIOGRÁFICA

2.1. Séries Temporais

Uma série temporal é uma colecção de observações feitas sequencialmente ao longo do tempo (Elher 2003). Estas observações têm uma particularidade das observações vizinhas serem dependentes, de tal forma que há um grande interesse em analisar e modelar essa dependência.

Segundo Murteira *et al.* (1993), uma série temporal é definida como sendo um conjunto de observações em pontos ou períodos sucessivos de tempo durante um determinado intervalo, e acrescentando o pensamento destes autores Morettin e Toloi (1987) afirmam que, é um conjunto de observações ordenadas no tempo e são compostas por quatro elementos:

Tendência – comprehende os movimentos da série que se manifestam suavemente e consistentemente durante vários anos.

Ciclo - movimento ondulatório que ao longo de vários anos tende a ser periódico.

Sazonal - variações em relação à tendência com que ocorrem, em geral, no decorrer de um ano (periodicidade inferior a um ano); na maioria dos casos estão associadas a mudanças climáticas.

Ruído aleatório ou erro – onde os métodos menos sofisticados colocam tudo o que não conseguem definir ou modelar.

As séries temporais podem ser estacionárias e não estacionária (fracamente estacionárias). Segundo Gujarati (2000:719), são séries estacionárias se a sua média e variância forem constantes ao longo do tempo e o valor da covariância entre os 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, com as seguintes propriedades:

$$\text{Média: } E(Y_t) = \mu$$

$$\text{Variância: } \text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

$$\text{Covariância: } \gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$$

Onde γ_k representa covariância ou auto covariância na defasagem k , entre os valores de Y_t e Y_{t+k} , ou seja entre dois valores Y separados por k períodos.

Se a série temporal não for estacionária, pode também ser considerada de fracamente estacionária e que se deve a mudança da média.

Para a modelação de toda a série temporal temos que nos preocupar não só com a estacionaridade, pois esta é condição necessária mas não suficiente. Neste processo é também fundamental que a série de resíduos apresente uma média e variância constantes no tempo, esta série é conhecida como Ruído Branco.

Segundo Murteira et al. (1993), Ruído Branco ou “white noise” é um processo fracamente estacionário até segunda ordem, cuja importância não advém de si próprio mas do papel fundamental que representa na construção de outros processos estacionários particularmente relevantes na modelação de sucessões cronológicas.

Apesar de quase a totalidade dos métodos de previsão de séries temporais estar fundamentada apenas na análise das observações da série de interesse para a especificação de algum modelo que descreva essas observações, alguns procedimentos de previsão tentam explicar o comportamento de uma série temporal pela evolução dos fenómenos observacionais de outras séries. Desta forma, dependendo do número de séries temporais envolvidas na modelagem, classificam-se os métodos de previsão em univariados, funções de transferência e multivariados. (Souza, 1989), citado por Mueller (1996).

Os métodos univariados, que compreendem a maior parte dos métodos de previsão de séries temporais, consideram 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 (métodos baseados na estatística bayesiana), Mueller (1996).

Os métodos univariados são métodos avançados de previsão que consistem em processos estacionários com vários filtros ou componentes:

Quando o processo estocástico é descrito apenas pelos seus valores históricos o modelo resultante é auto regressivo (AR), onde a série é descrita regredindo os seus valores passados e o termo erro

“ruído branco” que irá captar a parte não explicada, ficando deste modo representada por AR (p), e dada pela equação (1):

$$X_t = c + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \varepsilon_t \quad (1)$$

Onde: X_t - corresponde à observação da série temporal no tempo t ; α_p -corresponde ao parâmetro do modelo AR de ordem p e ε_t -representa o erro de eventos aleatórios que não podem ser explicados pelo modelo.

Segundo Ehlers (2003), usando o operador de retardo B^l podemos reescrever a equação (1) em:

$$(1 - \alpha_1 B - \alpha_2 B^2 - \dots - \alpha_p B^p) X_t = c + \varepsilon_t \quad (2)$$

Assim, os processos autoregressivos podem ser usados como modelos se for razoável assumir que o valor actual de uma série temporal depende do seu passado imediato e mais um termo erro.

Por simplicidade, começamos por estudar detalhadamente os processos de primeira ordem, AR(1), dada pela equação (3):

$$X_t = c + \alpha_1 X_{t-1} + \varepsilon_t \quad (3)$$

Segundo Pandit e Wu (1983), a função autocovariância é definida por:

$$\gamma_k = E(X_t X_{t-k}) \quad (3.1)$$

Que é autocovariância na defasagem k , se $k=0$ teremos variância de X_t . Quando a autocovariância γ_k é dividida pela variância, teremos função autocorrelação ρ_k , na defasagem k dada por:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (3.2)$$

A autocovariância ou função autocorrelação expressam a dependência de X_t sobre X_{t-k} .

Segundo Gujarati (2000) e Murteira et al. (1993), um processo de médias móveis é simplesmente uma combinação linear dos termos de erro ruído branco. O processo puramente aleatório ou white noise, que continua a ser fundamental, é de facto o mais simples, embora considerado complicado por outros autores. Este modelo implica que os efeitos produzidos pelas inovações perduram por um curto período de tempo o que contrasta com o processo autoregresivo, e é representado pela equação (4):

$$X_t = \mu + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q} \quad (4)$$

Onde ε_t - representa o erro de eventos aleatórios que não podem ser explicados pelo modelo e β_q corresponde ao parâmetro do modelo médias móveis (MA) de ordem q .

Ou ainda pode ser reescrito usando o operador de retardo ficando representado pela equação (5):

$$X_t = (1 + \beta_1 B + \dots + \beta_q B^q) \varepsilon_t \quad (5)$$

A equação (4) é similar à equação (1), excepto pelo facto de que o valor previsto para a observação α depende dos valores dos erros observados em cada período passado, ao invés das observações propriamente ditas que são da série observada X_t .

A forma mais simples deste modelo é quando $q=1$, que é a média móvel de primeira ordem MA (1) representada pela equação (6):

$$X_t = \mu + \varepsilon_t - \beta_1 \varepsilon_{t-1} \quad (6)$$

Para este modelo teremos as autocovariâncias em defasagens 0, 1 e k , representadas por:

$$\begin{cases} \gamma_0 = (1 + \beta_1^2) \sigma_\varepsilon^2 \\ \gamma_1 = -\beta_1^2 \sigma_\varepsilon^2 \\ \gamma_k = 0, k \geq 2 \end{cases} \quad (6.1)$$

Daí as funções autocorrelações tomam as seguintes formas nas diferentes defasagens:

$$\rho_0 = 1, \rho_1 = -\frac{\beta_1}{(1 + \beta_1^2)}, \rho_k = 0 \text{ para } k \geq 2$$

Para este modelo, a função ρ_k ou γ_k apresentam a primeira defasagem não nula e as restantes iguais a zero (Pandit e Wu 1983).

Segundo Murteira et al. (1993:66), um processo estacionário e invertível pode se representar na forma autoregressiva ou na forma de médias móveis. Contudo, pode bem acontecer que o processo gerador da sucessão cronológica observada tenha uma estrutura que resulte da combinação das duas representações. Se assim for, qualquer ensaio para utilizar uma aproximação baseada exclusivamente num modelo autoregressivo, ou médias móveis, pode exigir um número excessivo de parâmetros.

Os processos mistos autoregressivos e médias móveis surgem então como modelos parcimoniosos (com poucos parâmetros) mas de elevada potencialidade. Segundo Muller (1996), é possível verificar que os modelos ARMA relacionam os valores futuros com as observações passadas, assim como também com os erros passados, apurados entre os valores reais e os previstos.

Um processo diz-se misto ARMA (p,q), quando satisfaz a equação às diferenças estocásticas, com seguinte representação, equação (7):

$$X_t = c + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q} \quad (7)$$

Onde α_p e β_q são os parâmetros dos processos Autoregressivo e de Média Móvel de ordem p e q (ARMA (p,q)).

Os modelos discutidos até agora, são baseados na hipótese de que a série temporal envolvida é fracamente estacionária ou seja não-estacionária, deste modo eles podem ser convertidos em estacionários com o cálculo das diferenças. Daí surge outro filtro, que é o de integração, que segundo Ehlers (2003:26), para ajustar modelos não estacionários a uma série temporal observada, é necessário remover as fontes da variação. Se a série observada for não estacionária na média pode se tentar remover a tendência tomando-se uma ou mais diferenças.

Um modelo ARMA no qual X_t é substituído pela sua d -ésima diferença $\nabla^d X_t$, é capaz de descrever alguns tipos de séries não estacionárias. Denotando a série diferenciada por:

$$W_t = \nabla^d X_t = (1 - B)^d X_t$$

Criando deste modo uma combinação de três componentes que é o processo autoregressivo integrado de médias móveis, ARIMA (p, d, q), dada por:

$$W_t = \alpha_1 W_{t-1} + \dots + \alpha_p W_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} + c \quad (8)$$

Onde α_p e β_q são os parâmetros do processo Autoregressivo e da Média Móvel de ordem p e q , e d é a ordem de integração.

Segundo Elhers (2003:31,32), muitas séries temporais contêm uma componente periódica sazonal que se repete a cada s observações ($s > 1$), se os dados forem mensais, $s=12$ tipicamente espera-se que X_t depende de X_{t-12} e talvez de X_{t-24} além de X_{t-1}, X_{t-2}, \dots . Neste caso, tomar a primeira diferença $X_t - X_{t-1}$ não é suficiente para tornar a série aproximadamente estacionária.

A forma apropriada de diferenciar dados com padrão sazonal acentuada, é tomar diferenças no período sazonal. Por exemplo para dados mensais a primeira diferença sazonal é dada por:

$$\nabla_{12} = (1 - B^{12}) X_t = X_t - X_{t-12}$$

E terá variabilidade menor do que a primeira diferença não sazonal $\nabla X_t = X_t - X_{t-1}$, sendo, portanto, mais fácil de identificar e estimar. Em geral, uma diferença sazonal é denotada por ∇_s onde s é o período sazonal.

A D-ésima diferença sazonal é denotada por ∇_s^D . Combinando-se os dois tipos de diferenciação obtém-se o operador $\nabla^d \nabla_s^D$.

Box and Jenkins (1970) citada por Elhers (2003: 32) pelo mesmo autor, generalizaram o modelo ARIMA para lidar com sazonalidade e definiram um modelo ARIMA sazonal multiplicativo de ordem $(p, d, q)x(P, D, Q)_s$, denominado SARIMA, dado por:

$$\phi(B)\Phi(B^s)W_t = \theta(B)\Theta(B^s)\varepsilon_t \quad (9)$$

Onde:

$\Phi(B^s) = (1 - \phi_1 B^s - \dots - \phi_p B^{ps})$, é a parte autoregressiva sazonal de ordem P e estação sazonal s;

$\Theta(B^s) = (1 + \theta_1 B^s + \dots + \theta_q B^{qs})$, é a parte sazonal de médias móveis de ordem Q e estação sazonal s;

$\phi(B) = (1 - \alpha_1 B - \dots - \alpha_p B^p)$, é a parte autoregressiva não sazonal de ordem p;

$\theta(B) = (1 + \beta_1 B + \dots + \beta_q B^q)$, é a parte não sazonal de médias móveis de ordem q;

$W_t = \nabla^d \nabla_s^D X_t$, é a parte de integração sazonal de ordem D e estação sazonal s e integração não-sazonal de ordem d.

A identificação destes modelos é feita a partir das funções autocorrelação e autocorrelação parcial. Esta tarefa não fácil, dado o considerável número de parâmetros a identificar. Para os modelo SARIMA $(p,d,q)x(P,D,Q)_s$, há sete parâmetros por identificar dos quais tem-se quase sempre $0 \leq d, D \leq 2$ e os valores de p, q, P, Q raramente ultrapassam 2, (Murteira *et al*, 1993).

2.2. Testes de Estacionaridade

Para modelar uma série temporal é necessário que a série seja estacionária e para detectar a não estacionaridade usamos alguns testes de natureza qualitativa e quantitativa. O primeiro trabalho empírico baseado em dados de séries temporais supõe que as séries envolvidas são estacionárias.

O estudo com dados de séries temporais, logo *a priori* é necessário que se faça uma representação gráfica de tal forma que nos possa ajudar a ilustrar o seu comportamento, se é de tendência estacionária ou não. Se apresentar uma tendência crescente ou decrescente estaremos diante da não estacionaridade ou estacionaridade fraca. Esta é uma avaliação qualitativa pois não podemos tirar conclusões a partir deste método, para tal recorremos a testes mais "robustos" ou do tipo quantitativo, que a seguir são descritos:

2.2.1. Correlograma

Um gráfico com os k primeiros coeficientes de autocorrelação como função de k é chamado de correlograma e pode ser uma ferramenta poderosa para identificar características da série temporal. Porém isto requer uma interpretação adequada do correlograma, i.e. deve-se associar certos padrões do correlograma como determinadas características de uma série temporal. Esta nem sempre é uma tarefa simples e a seguir são dadas algumas indicações. (Ehlers, 2003).

Este teste baseia-se numa avaliação qualitativa da disposição da função autocorrelação (FAC), não se podendo tirar nenhuma conclusão a partir do mesmo, apenas sugere quanto a estacionaridade. Segundo Gujarati (2000), a FAC na defasagem k , indicada por ρ_k , é definida pela equação (3.2).

Existem dois tipos de correlograma: amostral e populacional.

Num correlograma Populacional, a variância e a covariância são medidas na mesma unidade de medida, ρ_k é um número sem unidade, ou puro e fica entre -1 e +1 como qualquer outro coeficiente de correlação. Enquanto o correlograma amostral é a razão entre a covariância e a variância amostral.

Podemos a partir do correlograma ter uma visão empírica sobre se uma série temporal é estacionária ou não. Para uma série completamente estacionária os valores defasados são não correlacionados e espera-se que $\rho_k = 0$.

Supondo que X_1, \dots, X_n , sejam variáveis aleatórias independentes e identicamente distribuídas com média arbitrárias, então, pode-se mostrar que o coeficiente de autocorrelação amostral é assimptótica e normalmente distribuído, com média e variância dadas por:

$$E(\rho_k) = -\frac{1}{n} \text{ e } \text{var}(\rho_k) = \frac{1}{n} \rho_k$$

Portanto, os limites de confiança aproximados de 95% são dados por $-\frac{1}{n} \pm \frac{1.96}{\sqrt{n}}$, que são

frequentemente ainda mais aproximados para $\pm \frac{1.96}{\sqrt{n}}$. (Ehlers:2003;8).

2.2.2. Teste de Raiz unitária

Da Silva et al. (2005), afirma que, para testar se uma série temporal é integrada ou não, é necessário realizar os chamados testes de raízes unitárias. Os mais conhecidos são os testes Dickey-Fuller (DF) e Dickey-Fuller Ampliado (ADF), que são detalhados a seguir. Considerando um modelo autoregressivo de primeira ordem ou $AR(1)$, o seguinte:

$$X_t = \rho X_{t-1} + \varepsilon_t \quad (10)$$

Diz-se que uma série temporal tem uma raiz unitária caso $\rho = 1$, contra hipótese alternativa $|\rho| < 1$. Subtraindo X_{t-1} em ambos os lados da equação (10), obtém-se a seguinte expressão matemática:

$$\Delta X_t = c + (\rho - 1)X_{t-1} + \varepsilon_t \quad (11)$$

A hipótese nula do teste Dickey-Fuller é a existência de uma raiz unitária, e segundo Gujarati (2000), o termo ε_t de erro estocástico segue hipóteses clássicas, tem média zero, variância constante e é não-autocorrelacionado, e é também conhecido como termo de ruído branco. Visto agora que na equação (10), se o coeficiente do valor regredido for de facto igual a um $\rho = 1$, defrontamo-nos com o problema de raiz unitária, o que significa estar-se na presença de não-estacionaridade.

Na econometria de séries temporais, uma série que tenha raiz unitária é conhecida como caminho aleatório. Um caminho aleatório é um exemplo típico de uma série não estacionária. Pode se ver que a equação (11) é uma forma alternativa da equação (10), com operador da primeira diferença Δ e $\delta = (\rho - 1)$, a hipótese nula será agora $\delta = 0$.

Se de facto $\delta = 0$, então $\Delta X_t = c + \varepsilon_t$, o que nos diz que as primeiras diferenças de uma série temporal com caminho aleatório, são uma série estacionária, pois por hipótese, ε_t é puramente aleatório. Desta forma, se a série diferenciada uma vez for estacionária, dizemos que a série em nível (com caminho aleatório), é integrada de ordem um se for diferenciada um vez, representada por $I(1)$. Se tiver que ser diferenciada d -vezes ela será integrada de ordem d , representada por $I(d)$.

Segundo o mesmo autor, sob a hipótese nula $\rho = 1$, calcula de modo convencional, é conhecida como estatística tau (τ), e que na literatura especializada o teste tau é também teste de Dickey-Fuller (DF). Se a hipótese nula for rejeitada, a série é estacionária, pode se usar o teste t de Student.

Se o valor absoluto calculado da estatística τ , (isto é, $|\tau|$) exceder os valores críticos absolutos τ de DF ou Mackinnon-DF, então não rejeitamos a hipótese de que dada série temporal seja estacionária. Se por outro lado, este for menor que o valor crítico, a série temporal é não estacionária (Gujarati: 2000,725).

Segundo o mesmo autor, a estatística do teste de Dickey-Fuller Aumentado é assintótica que a estatística Dickey-Fuller, daí que podem ser usados os mesmos valores críticos. O teste DF é chamado ADF quando é aplicado a modelos de tipo:

$$\Delta X_t = \beta_1 + \beta_2 t + \delta X_{t-1} + \alpha_i \sum_{i=1}^m \Delta X_{t-i} + \varepsilon_t \quad (12)$$

Para além do teste de ADF foram desenvolvidos outros testes de raiz unitária pelos autores Phillips e Perron (1988) conhecido como teste PP, e por Kwiatkowski et al (1992) - conhecido por teste KPSS (Kwiatkowski-Phillips-Schmidt-Shin).

Segundo Figueiredo e Marques (2007:10), o teste de PP baseia-se numa abordagem semiparamétrica a partir do princípio da invariância e dos funcionais movimentos brownianos, considerando que os termos de perturbação estocástica são serialmente correlacionados. Assim como a maioria dos testes clássicos para estacionaridade, o procedimento PP possui como hipótese nula a existência de uma raiz unitária, enquanto para o KPSS a hipótese nula é a inexistência de raiz unitária.

De acordo com o mesmo autor com o uso conjugado destes dois testes espera-se que seja possível uma determinação mais precisa da ordem de integração da série. Segundo Baillie *et al* (1996b) citado por Figueiredo e Marques (2007: 10), disse que a utilização destes procedimentos pode gerar quatro possíveis resultados:

- a rejeição da hipótese nula do teste de PP e a não rejeição da hipótese nula do teste de KPSS, indicando uma forte evidência de um processo estacionário;
- a não rejeição da hipótese nula do teste de PP e a rejeição da hipótese nula do teste de KPSS, indicando deste modo que a série possui uma raiz unitária;
- a não rejeição das hipóteses nulas em ambos testes, o que gera uma indeterminação sobre o processo gerador dos dados ;
- e a rejeição da hipótese nula em ambos testes, sugerindo que o processo gerador de dados não é estacionário em nível nem em primeiras diferenças, indicando uma possível integração fracionária.

Sobre estes dois testes no que diz respeito a escolha do número de defasagens, Pinto e Vieira (2003), afirmam que se usa o critério automático de Eviews-Newey-West Bandwith e o método de estimação espectral de Bartlett Kernel.

2.3. Metodologia ARIMA

O objectivo de ARIMA, genericamente conhecido por Box-Jenkins, é identificar e estimar um modelo estatístico que possa ser interpretado como tendo gerado os dados amostrais. Se esse modelo estimado será usado para a previsão, devemos supôr que as características desse modelo são constantes no tempo e particularmente, no período futuro.

Assim, a razão simples de se necessitar de dados estacionários é que qualquer modelo que é inferido a partir desses dados pode ser interpretado como estacionário ou estável, fornecendo assim uma base válida para previsão (Gujarati: 2000,744).

Segundo o mesmo autor esta metodologia compreende quatro etapas, enquanto que, para Murteira *et al.* (1993), diz que para se alcançar um bom modelo Box-Jenkins (1970) propuseram uma metodologia dividida em três etapas: identificação, estimação e avaliação do diagnóstico.

2.3.1.Identificação

Esta é a primeira etapa, a partir da qual se pretende escolher um modelo ARMA (ARIMA ou SARIMA) que, aparentemente descreva a série que por sua vez compreende as seguintes subetapas:

- Estacionarização da série temporal;
- Selecção do modelo ARMA.

Em geral, as séries não se encontram estacionarizadas e os modelos ARMA correspondem a processos estacionários, nesta subetapa deve ser feitas transformações com o fim de torná-la estacionária, transformações essas já discutidas antes neste capítulo.

Estacionarizada a série, passa-se à subetapa seguinte que é realizada através da comparação das funções autocorrelação e autocorrelação parcial, que é respeitante à selecção do modelo, sendo momento crucial neste processo de modelação e condição indispensável para a correcta identificação do seu conhecimento profundo.

Como já foi visto, existem três classes de processos estacionários o AR, MA e ARMA com características diferentes em termos de funções de autocorrelação e autocorrelação parcial, características essas que são ilustradas nas tabelas 1 e 2 com mais pormenores dos cinco processos estacionários mais comuns, os sazonais e não sazonais (Murteira *et al.*, 1993).

Tabela.1-Principais características das FAC e FACP teóricas dos processos estacionários não sazonais

Processo	FAC	FACP
AR	Decaimento para zero sob-forma exponencial ou sinusoidal amortecida	Decaimento brusco para zero a partir de um certo lag k ou desfasagem k
MA	Decaimento brusco para zero A partir de um certo lag k ou desfasagem k	Decaimento para zero sob-forma exponencial ou sinusoidal amortecida
ARMA	Decaimento para zero sob-forma exponencial ou sinusoidal amortecida	Decaimento para zero sob-forma exponencial ou sinusoidal amortecida

Fonte: Murtiira et.al.(1993)

Tabela.2- Algumas particularidades das FAC e FACP teóricas dos processos estacionários não sazonais e sazonais mais comuns

Processo	FAC	FACP
AR(1) ou AR(1) _s	Decaimento exponencial: i) por valores positivos se $\alpha > 0$ ii) por valores alternados, começando Em valores negativos, se $\alpha < 0$	Valor significativo em k=1 (ou k=S) seguido de um corte brusco para zero:i) valor significativo se $\alpha > 0$; ii) negativo se $\alpha < 0$
MA(1) ou MA(1) _s	Valor significativo em k=1 (ou k=S) seguido de um corte Brusco para zero:i) valor significativo se $\beta < 0$; ii) negativo se $\beta > 0$	Decaimento exponencial em k=1 (ou k=S) : i) por valores alternados, Começando por um valor positivo, se $\beta < 0$ ii) por valores negativo se $\beta > 0$
AR(2) ou AR(2) _s	Mistura de decaimento exponen- cial ou sinusoidal amortecido. O comportamento exacto depen- de dos sinais e dimensões dos parâmetros.	Valor significativo em k=1,2 (ou k=S, 2S) seguido de um corte brusco para zero
MA(2) ou MA(2) _s	Valor significativo em k=1,2 (ou k=S, 2S) seguido de um corte brusco para zero	Mistura de decaimento exponen- cial ou sinusoidal amortecido. O comportamento exacto depen- de dos sinais e dimensões dos parâmetros.
ARMA(1,1) ou ARMA(1,1) _s	Decaimento exponencial: i) sinal de $\rho_1 = \text{sinal de } (\alpha - \beta)$ ii) valores sempre positivos ou negativos se $\alpha > 0$;iii) por va- lores alternados se $\alpha < 0$	Decaimento exponencial: i) $\beta_{11} = \rho_1$ (ou $\beta_{ss} = \rho_s$); ii) valores sempre positivos ou negativos se $\beta > 0$;iii) por va- lores alternados se $\beta < 0$

Fonte: Murteteira et al (1993)

Morettin (2004), disse que a partir de 1970 foram propostos vários procedimentos para a identificação de modelos ARMA, que consistem na ideia de escolher k e l que minimizam a quantidade:

$$P(k,l) = \ln \hat{\sigma}_{k,l}^2 + (k+l) \frac{C(T)}{T} \quad (13)$$

Onde $\hat{\sigma}_{k,l}^2$ é uma estimativa residual obtida ajustando um modelo ARMA (k,l) , T observações da série e C (T) é uma função do tamanho da série.

A quantidade $(k+l)\frac{C(T)}{T}$, é termo penalizador, que tem uma relação de proporcionalidade directa com o número de parâmetros, isto é, aumenta com o número de parâmetros, enquanto que $\hat{\sigma}_{k,l}^2$ diminui. Sendo assim, para minimizar, a equação (13) corresponde a identificação de parâmetros k e l que equilibrem esse comportamento.

Os critérios de informação, de um modo geral, se diferenciam no que respeita ao termo de captura a penalização do processo, sendo os mais populares os seguintes:

Critério de informação de AIC

Akaike (1973, 1974), citado pelo mesmo autor, sugere escolher um modelo cujas ordens k e l minimizam o critério.

$$AIC(k,l) = \ln \hat{\sigma}_{k,l}^2 + \frac{2(k+l)}{T} \quad (14)$$

Onde $\hat{\sigma}_{k,l}^2$ é estimador de máxima verosimilhança de σ^2 para um modelo ARMA (k,l), podendo a expressão (14) estar reduzida a um AR(p)

$$AIC(k,l) = \ln \hat{\sigma}_{k,l}^2 + \frac{2k}{T}, \quad k \leq K \quad (15)$$

na condição de estipular valores limite superiores K e L para k e l e calcular a expressão (15) para todas as combinações de (k,l) com $0 \leq k \leq K$ e $0 \leq l \leq L$.

Critério de informação Bayesiano BIC

Akaike (1977), Rissanem (1978) e Schwarz (1978), citados por Morettim (2004: 85) sugerem minimizar o critério de informação Bayesiano dado por:

$$BIC = -2 \ln(FV) + (\text{numero_de_parametros}) \ln T$$

Onde FV é função de verosimilhança, e ela passa a tomar a seguinte forma para os modelos ARMA.

$$BIC(k,l) = \ln \hat{\sigma}_{k,l}^2 + (k+l) \frac{\ln T}{T} \quad (16)$$

2.3.2. Estimação

Segundo Morettim (2004), esta etapa é a da estimação dos parâmetros desconhecidos das componentes autoregressivas e médias móveis. Para a estimação dos parâmetros nos modelos autoregressivos, atendendo a normalidade de resíduos, isto é, admitindo que os erros formam uma sucessão de variáveis aleatórias $i.i.d \sim N(0, \sigma_\epsilon^2)$, o processo AR(p), X_t , é Gaussiano. Supondo, sem perda de generalidade, que $\mu = 0$, pode se provar que o logaritmo da verossimilhança é dado, a menos de uma constante aditiva, pela expressão:

$$L(\alpha_1, \dots, \alpha_p) = -\frac{N}{2} \ln \sigma_\epsilon^2 + \frac{1}{2} \ln |V_p| - \frac{S^*(\alpha_1, \dots, \alpha_p)}{2\sigma_\epsilon^2} \quad (13)$$

Onde: $\sigma_\epsilon^2 V_p^{-1}$ é a matriz de autocovariâncias de (X_1, \dots, X_p) ,

$$S^*(\alpha_1, \dots, \alpha_p) = \sum_{i=1}^p \sum_{j=1}^p v_{ij} X_i X_j + \sum_{t=p+1}^N (X_t - \alpha_1 X_{t-1} - \dots - \alpha_p X_{t-p})^2 \quad (13.1)$$

Com v_{ij} elemento genérico de V_p .

Podendo as equações (13) e (13.1), ser obtidas através do cálculo com distribuições normais multivariadas,

$$\begin{aligned} & f(X_1, \dots, X_p, X_{p+1}, \dots, X_N), \\ & f(X_1, \dots, X_p) f(X_{p+1}, \dots, X_N \setminus X_1, \dots, X_p), \\ & f(X_1, \dots, X_p) f(\varepsilon_{p+1}, \dots, \varepsilon_N \setminus X_1, \dots, X_p), \end{aligned} \quad (13.2)$$

Fazendo a mudança de variável temos,

$$\varepsilon_t = X_t - \alpha_1 X_{t-1} - \dots - \alpha_p X_{t-p}, \quad t = p+1, \dots, N$$

Que tem um jacobiano igual à unidade.

A matriz V_p depende dos parâmetros $(\alpha_1, \dots, \alpha_p)$, as derivadas de $\ln |V_p|$ são difíceis de obter, resultando que os estimadores da máxima verossimilhança são solução de um sistema de equações não lineares.

Na estimação dos parâmetros nos modelos de médias móveis, este processo permite, através das correspondentes equações de Yule-Walker, determinar os estimadores e os respectivos parâmetros.

Tal como para o processo anterior também para este processo desenvolve-se a metodologia de máxima verossimilhança condicional para os processos MA(q), assim como para processos mistos.

2.3.3. Avaliação do diagnóstico

Após a verificação das etapas anteriores e a consequente identificação do modelo e estimação dos parâmetros, passamos para a avaliação do modelo. Esta fase compreende à avaliação da qualidade estatística do modelo assim como a qualidade do ajustamento. Esta metodologia é considerada iterativa, isto porque, se o modelo seleccionado for rejeitado volta-se à primeira etapa, até que o modelo seja adequado.

Murteira *et al.* (1993), defende que a avaliação da qualidade estatística tem as sub etapas:

- Significância estatística dos parâmetros estimados

Tendo em conta o princípio de parcimónia, devem-se analisar as estimativas dos parâmetros obtidos com objectivo de eliminar aqueles que sejam desnecessários, ou seja, os parâmetros que não se possam considerar significativamente diferentes de zero. A aplicação deste princípio tem surtido grandes efeitos. Pois, a prática tem demonstrado que, em geral, os modelos parcimoniosos produzem melhores previsões.

E algumas das subetapas foram referenciadas por Morettin (2004), nomeadamente:

-Teste de autocorrelação residual

Estimados os parâmetros α e β , as quantidades $\hat{\varepsilon}_t = \hat{\beta}^{-1}(B)\hat{\alpha}(B)W_t$, que são chamadas resíduos estimados. Se o modelo for adequado os resíduos estimados $\hat{\varepsilon}_t$, deverão estar próximos dos resíduos ε_t e, deverão ser aproximadamente não-correlacionados. Se representarmos por \hat{r}_k as autocorrelações, os resíduos estimados, então deve-se ter em conta $\hat{r}_k = 0$.

As autocorrelações \hat{r}_k são calculadas por:

$$\hat{r}_k = \frac{\sum_{t=k+1}^m \hat{\varepsilon}_t \hat{\varepsilon}_{t-k}}{\sum_{t=1}^m \hat{\varepsilon}_t^2} \quad (14)$$

O desvio padrão de \hat{r}_k pode ser consideravelmente menor que $1/\sqrt{n}$ especialmente para pequenos valores de k , segundo Durbin (1970). Este autor pôs que para um modelo puramente aleatório, $\sigma^2(\hat{r}_k) \approx \frac{\alpha^2}{n}$, pode ser bem menor que $1/n$. Box, Jenking e Reinsel (1994) citados por Morettin (2004), provaram que para um modelo AR (1) tem se:

$$\sigma^2(\hat{r}_k) \approx \frac{1}{n} [1 - \alpha^{2(k-1)}(1 - \alpha^2)] \quad (15)$$

$$\text{cov}(\hat{r}_i \hat{r}_j) \approx \frac{1}{n} \{ \delta_{ij} - \alpha^{i+j-2}(1 - \alpha^2) \} \quad (15.1)$$

e os valores das autocorrelações devem estar contidos dentro do intervalo de confiança de 95% com limites de $\pm 2/\sqrt{n}$, forma a que não se quebre o comportamento do ruído branco.

Teste de Box-Pierce (1970) ou teste de 'Portmanteau'

Este teste é um teste global para os m defasagens considerando $\rho_k(\hat{\epsilon})$; $k=1,\dots,n$ com a seguinte hipótese de nulidade; $H_0: \rho_1(\hat{\epsilon}) = \rho_2(\hat{\epsilon}) = \dots = \rho_n(\hat{\epsilon}) = 0$, onde em geral se tomar $m \approx N/4$ a sua rejeição sugere que o modelo estimado não é apropriado para descrever a série em causa (Murteira et al, 1993) e para Morettin (2004), caso seja adequado, é apresentada a estatística deste teste modificado proposto por Ljung e Box (1978) citado pelo mesmo autor.

$$Q(m) = n(n+2) \sum_{k=1}^m \frac{\hat{r}_k^2}{n-k} \quad (16)$$

Que terá distribuição χ^2 com $n-p-q$ graus de liberdade. A hipótese de ruído branco para os resíduos é rejeitada para valores grandes $Q(\cdot)$, que ele sugere as 15 ou 20 primeiras \hat{r}_k .

Para Murteira et al. (1993), deve-se ensaiar o H_0 e concluir pela má qualidade do ajustamento se o valor observado de Q exceder o limite de significância estabelecida, e as hipóteses do teste são formuladas de acordo com Granger et al. (1986), são as seguintes:

H_0 : O modelo é adequado; os resíduos do modelo estimado são puramente aleatórios,

H_1 : O modelo não é adequado; os resíduos do modelo estimado não são puramente aleatórios,

E a rejeição será feita para valores de Q maiores que os valores críticos da tabela χ^2 .

2.3.3.1. Comparação dos modelos.

Wheelwright e Makridakis (1985), consideram que para a identificação e escolha do melhor modelo de previsão após a estimativa de vários, é necessário fazer compará-los por forma a identificar o modelo óptimo e, para o efeito, recorre-se as seguintes estatística sendo o melhor o que apresentar o mínimo valor. As mesmas medidas foram sugeridas por McClain e Humphres (1996).

$$\text{Raiz do Erro Quadrático Médio } REQM = \sqrt{\frac{1}{h+1} \sum_{t=s}^{s+h} (\hat{X}_t - X_t)^2} \quad (17)$$

$$\text{Erro Absoluto Médio } MAE = \frac{\sum_{t=s}^{s+h} |\hat{X}_t - X_t|}{h+1} \quad (18)$$

$$\text{Erro Absoluto Médio Percentual } EAMP = 100 \times \sum_{t=s}^{s+h} \left| \frac{(\hat{X}_t - X_t)}{X_t} \right| \frac{1}{h+1} \quad (19)$$

$$\text{Coeficiente de Desigualdade de Theil } CDT = \frac{REQM}{\sqrt{\frac{1}{h+1} \sum_{t=s}^{s+h} \hat{X}_t + \sqrt{\frac{1}{h+1} \sum_{t=s}^{s+h} X_t}}} \quad (20)$$

Onde h é o número de períodos de previsão, s- tamanho da amostra, \hat{X}_t - valor previsto ou estimado e X_t - valor observado.

3. MATERIAL E MÉTODO

3.1. Material

3.1.1. Fonte de Dados

Para a materialização do presente trabalho foi aplicada uma das técnicas ligadas a séries temporais, que é o processo autoregressivo integrado de médias móveis, genericamente conhecido por método de Box-Jenkins, com o objectivo de fazer previsão da ocupação de terras nos períodos futuros, com base nos seus dados históricos.

Os dados observados são mensais referentes ao período de Janeiro de 1996 à Abril de 2008, correspondendo a um total de 148 observações, e a série foi designada por AEMM2- que significa Área em metros quadrados de terra concedida para habitação, na província de Inhambane, para requerentes até 5.000 m², da Direcção Nacional de Terras .

Na análise e processamento de dados foram usados pacotes Excel da Microsoft para a organização dos dados e os softwares estatísticos eviews v.4.1 e SPSS V.13 para a sua análise.

3.2. Métodos

De acordo com o número de observações que uma dada série comporta pode se decidir o método de modelagem a aplicar, segundo os autores Newbold & Granger (1974), para séries com:

- Até 30 observações, o método de Holt-Winters deve ser utilizado;
- Mais de 30 e menos de 50 observações não há muita certeza, e pode-se escolher entre Holt-Winters e modelos ARIMA;
- Mais de 50 observações, se o custo de previsão não for importante, deve-se utilizar modelos ARIMA. Caso o custo de previsão seja importante, deve-se utilizar Holt-Winters ou modelos AR.

Esta modelagem comprehende quatro etapas nomeadamente: identificação, estimação, diagnóstico e previsão, estando estas abordadas no capítulo anterior. Esta fase consistiu na identificação de indícios de estacionaridade e sazonalidade a partir da análise gráfica. Uma vez visto que a série é não estacionária em nível, a modelagem adequada a esta série será um modelo autoregressivo integrado de médias móveis-ARIMA.

4. RESULTADOS E DISCUSSÃO

A série apresenta 148 observações mensais referentes à concessão de terras para habitação da província de Inhambane no período de Janeiro de 1996 à Abril de 2008.

Na representação gráfica a seguir mostra-se uma tendência crescente como se pode visualizar na figura.1. Este comportamento é de uma série não estacionária. Pode-se ver que o nível de concessão de terras foi evoluindo de 1996 até 2000, tendo atingido em Janeiro de 2000 cerca de $30,800\text{ m}^2$ correspondente ao nível máximo de concessão, e seguido de uma queda acentuada até aos meados de 2001, em $1,200 \text{ m}^2$, voltando novamente a uma tendência crescente até 2004. Deste período em diante houve uma tendência para estabilização da série.

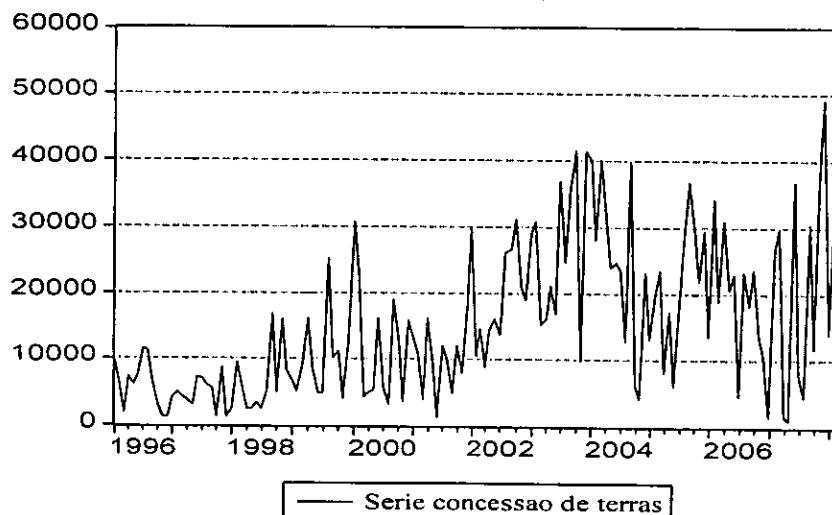


Figura.1: Representação gráfica da Série em nível de Concessão de terras em metros quadrados no período em análise

A natureza da série em análise não é de carácter sazonal pois a figura 1 acima representada mostra que não há ciclos repetitivos em períodos inferiores a um ano.

4.1. Testes de Estacionaridade

A figura 1 apresenta uma série com indícios de não estacionaridade, passando deste modo a aplicação de alguns testes com vista à confirmação da sua estacionaridade ou não estacionaridade.

4.1.1. Correlograma.

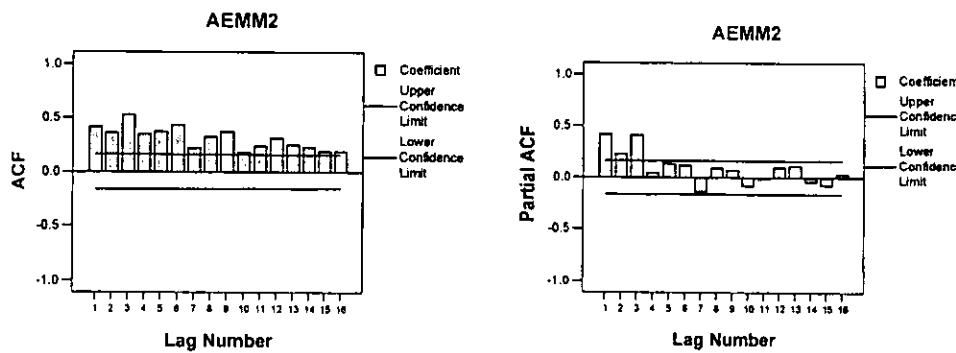


Figura 2: Correlogramas da Função de autocorrelação e autocorrelação parcial em nível da série de concessão de terras.

A figura 2 sugere que a série em análise não apresenta indício de ser estacionária pois, pode-se notar que nem todas as autocorrelações estão dentro do intervalo de confiança apresentando deste modo picos significativos.

A significância estatística de qualquer autocorrelação estimada pode ser julgada pelo seu erro padrão. Os coeficientes de autocorrelação amostral são aproximadamente distribuídos com média zero e variância $1/n$, onde teríamos a variância de $1/148 = 0.000676$, e o respectivo erro padrão de $1/\sqrt{148} = 0.0822$.

Deste modo, num intervalo de confiança de 95%, se um $\hat{\rho}_k$ situar-se dentro do intervalo de confiança, não se rejeita a hipótese de que $\rho_k = 0$, ou seja é estacionária, caso contrário, é não estacionária como é o caso da figura 2. É de salientar que este teste apenas sugere quanto a estacionaridade, pois, não se pode tirar nenhuma conclusão a partir do mesmo, sendo um teste de natureza qualitativa. Para concluirmos é necessário que se recorra ao teste quantitativo a seguir indicado.

4.1.2.Raiz Unitária

O teste Dickey-Fuller Aumentado não só considera a estatística t, mas também as probabilidades sugeridas por Mackinnon (1996). A partir das estatísticas da tabela 3, notamos que o valor do $|t|$ de ADF é menor que os $|t|$ críticos a 1%, e 5% , e a prob* é superior a 5%, o que leva à não rejeição da hipótese nula ($H_0: \delta = 0$). Logo, pelo teste de ADF conclui-se que a série é não estacionária em nível, e a sua regressão está estimada na tabela 4. Para além deste teste, a estacionaridade foi também verificada com base nos testes de KPSS (tabela 5).

Tabela 3: Teste de Raiz unitária para a série AEMM2 em nível usando o teste de ADF.

Hipótese Nula: AEMM2 tem Raiz Unitária

	Estatística-t	Prob.*
Estatística do teste de Dickey-Fuller Aumentado	-2.809	0.059
Valores críticos do teste		
1% level	-3.476	
5% level	-2.881	
10% level	-2.577	

*Mackinnon (1996) one-sided p-values

Tabela 4: Equação do teste de Dickey-Fuller Aumentado da série AEMM2 em nível

Variável Dependente: D (AEMM2)

Variáveis	Coeficientes	Erro Padrão	Estatística-t	Prob.
AEMM2(-1)	-0.247	0.088	-2.809	0.006
D(AEMM2(-1))	-0.553	0.094	-5.876	0.000
D(AEMM2(-2))	-0.459	0.080	-5.762	0.000
C	4117.072	1552.174	2.652	0.009

Pelo teste de KPSS a formulação das hipóteses, é o inverso dos testes de ADF e PP pois, este define como sendo estacionária a hipótese nula, ou seja, a série não possui uma raiz unitária. Sendo assim, considerando o valor crítico de 5% que é igual a 0.463, o valor da estatística LM-Stat (1.084) é maior. Nestas condições não se aceita a hipótese nula, tornando desta maneira consistente a avaliação da estacionaridade com o cruzamento dos dois testes.

Tabela 5: Teste de Raiz unitária para a série AEMM2 em nível usando o teste de KPSS.

Hipótese Nula: AEMM2 é Estacionária

	LM-Stat.
Kwiatkowski-Phillips-Schmidt-Shin test statistic	1.084
Asymptotic critical values*:	
1% level	0.739
5% level	0.463
10% level	0.347

*Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1)

Tabela 6: Equação do teste de KPSS da série AEMM2 em nível.

Variável Dependente: D(AEMM2)

Variáveis	Coefficientes	Erro Padrão	Estatística-t	Prob.
C	15364.816	963.211	15.952	0.000

A figura 3 mostra uma tendência de estabilização da série em torno de zero e uma vez transformada, ela perde uma observação, passando deste modo para 147 observações.

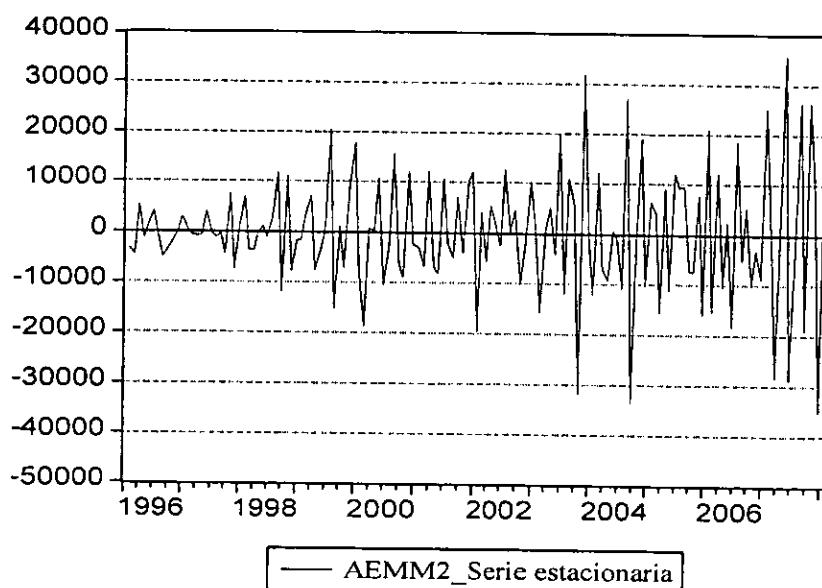


Figura.3: Representação gráfica da Série em primeiras diferenças de concessão de terras em metros quadrados no período em análise

Do mesmo modo que se procedeu à verificação da estacionaridade para a série original, passamos à análise das primeiras diferenças, apresentadas nas tabelas 7 e 9 e as respectivas estatísticas de regressão nas tabelas 8 e 10. Concluimos que a série é estacionária em primeiras diferenças, uma vez que a probabilidade de Mackinnon (2006) é menor que o nível de significância de 5%, ou

também pelo valor de $|t|$ de ADF que é maior que os valores críticos de 1%, 5% e 10%. Pelo teste de KPSS também se pode visualizar que o valor de LM-Stat é 0.357 menor que o valor crítico de 5%. Logo, não rejeitamos o H_0 pelo KPSS mas rejeitamos pelo ADF, significando deste modo que a série em análise não possui raiz unitária em primeiras diferenças.

Tabela 7: Teste de Raiz unitária para a série AEMM2 em primeiras diferenças pelo teste de ADF.

Hipótese Nula: D (AEMM2) tem Raiz Unitária

	Estatística-t	Prob.*
Estatística do teste de Dickey-Fuller Aumentado	-18.064	0.000
Valores críticos do teste		
1% level	-3.476	
5% level	-2.881	
10% level	-2.577	

*MacKinnon (1996) one-sided p-values

Tabela 8: Equação do teste de Dickey-Fuller Aumentado da série AEMM2 em primeiras diferenças

Variável Dependente: D (AEMM2,2)

Variáveis	Coeficientes	Erro Padrão	Estatística-t	Prob.
D (AEMM2 (-1))	-2.274	0.126	-18.064	0.000
D (AEMM2(-1),2)	0.550	0.075	7.365	0.000
C	359.250	806.349	0.446	0.657

Tabela 9: Teste de Raiz unitária para a série AEMM2 em primeiras diferença usando o teste de KPSS.

Hipótese Nula: D (AEMM2) é Estacionária

	LM-Stat.
Kwiatkowski-Phillips-Schmidt-Shin test statistic	0.357
Asymptotic critical values*:	
1% level	0.739
5% level	0.463
10% level	0.347

*Kwiatkowski-Phillips-Schmidt-Shin (1992, Table 1)

Tabela 10: Equação do teste de KPSS da série AEMM2 em primeiras diferenças.

Variável Dependente: D (AEMM2,2)

Variáveis	Coefficientes	Ero Padrão	Estatística-t	Prob.
C	-6.939	1047.920	-0.007	0.995

4.2. Identificação

Esta fase precede a estacionarização da série com vista a estabilizar a variância e, uma vez verificada a estacionaridade, torna-se deste modo necessário identificar os parâmetros, ou seja os valores de p , d e q com vista a estimação dos modelos. Logo a *priori* o valor de $d=1$ visto que a série só se estabilizou em primeiras diferenças.

Na análise das F.A.C e P.F.A.C da figura 4, pode-se constatar que a série apresenta picos significativos nas defasagens 1, 2, 3, 6, 7, 9 e 10 para a F.A.C., sugerindo os possíveis valores do parâmetro p , e nas defasagens 1 e 2 para a P.F.A.C que serão os possíveis valores de q . É de salientar que a identificação do modelo estimado é feito empiricamente, a partir da leitura dos correlogramas, sem se basear em nenhuma estatística.

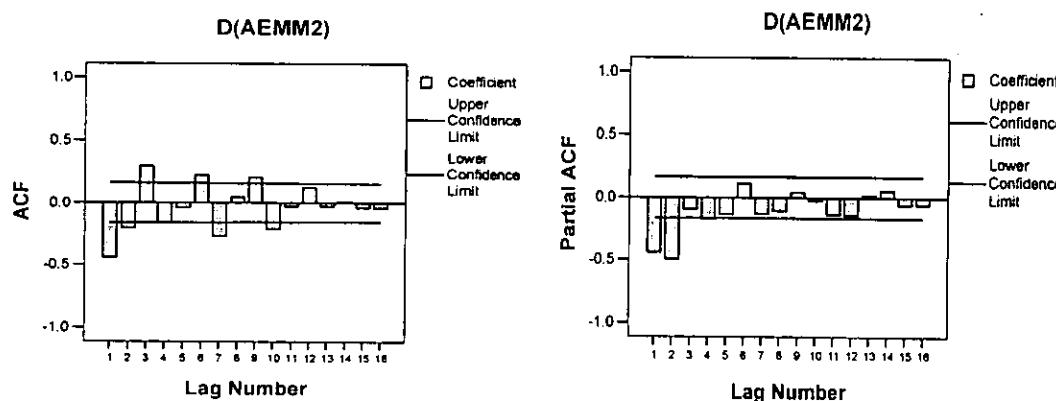


Figura 4: Correlogramas da Função autocorrelação e autocorrelação parcial em primeiras diferenças da série de concessão de terras.

4.3. Estimação dos Modelos

A estimação dos modelos consistiu na identificação dos parâmetros p e q , a respectiva estimação, onde se diagnosticaram os modelos abaixo indicados. Dentre os vários modelos sugeridos pelo comportamento da F.A.C. e P.F.A.C. estimados, apenas estes é que são estatisticamente significativos:

4.3.1. Estimação do modelo ARIMA (3,1,1)

Tabela 11: Estatísticas da estimação do modelo ARIMA (3,1,1)

Variável Dependente:DAEMM2

Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
C	153.018	42.19914	3.626094	0.0004
AR(3)	0.380176	0.084567	4.495564	0.000
MA(1)	-0.980202	0.013799	-71.03242	0.000
R-quadrado	0.479066	Variância media dependente		9.583333
R-quadrado ajustado	0.471677	S.D. dependent var		12821.97
E.p. da regressão	9319.759	Critério de informação de Akaike		21.13827
S.Q.Resíduos	1.22E+10	Critério Schwarz		21.20015
Log likelihood	-1518.956	Estatística-F		64.83379
Durbin-Watson stat	1.767532	Prob(Estatística-F)		0.000

4.3.2. Estimação do modelo ARIMA (1,1,2)

Tabela 12: Estatísticas da estimação do modelo ARIMA (1,1,2)

Variável Dependente:DAEMM2

Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
AR(1)	-0.768857	0.067550	-11.38197	0.0000
MA(2)	-0.717823	0.073391	-9.780815	0.0000
R-quadrado	0.433247	Variância media dependente		14.93151
R-quadrado ajustado	0.429311	S.D. dependent var		12746.32
E.p. da regressão	9629.070	Critério de informação de Akaike		21.19656
S.Q.Resíduos	1.34E+10	Critério Schwarz		21.23744
Log likelihood	-1545.349	Durbin-Watson stat		2.129973

4.3.3. Estimação do modelo ARIMA (0,1,1)

Tabela 13: Estatísticas da estimação do modelo ARIMA (0,1,1)

Variável Dependente:DAEMM2

Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
MA(1)	-0.830985	0.046927	-17.70793	0.0000
R-quadrado	0.425904	Variância media dependente		-6.938776
R-quadrado ajustado	0.425904	S.D. dependent var		12705.36
E.p. da regressão	9626.737	Critério de informação de Akaike		21.18926
S.Q.Resíduos	1.35E+10	Critério Schwarz		21.20960
Log likelihood	-1556.410	Durbin-Watson stat -F		2.055631

4.3.4. Estimação do modelo ARIMA (9,1,0)

Tabela 14: Estatísticas da estimação do modelo ARIMA (9,1,0)

Variável Dependente: DAEMM2

Variável	Coeficiente	Erro Padrão	Estatística-t	Prob.
AR(6)	0.256907	0.092079	2.790061	0.006
AR(8)	0.254222	0.103839	2.448231	0.0156
AR(9)	0.335024	0.104824	3.196066	0.0017
R-quadrado	0.138527	Variância media dependente		40.14493
R-quadrado ajustado	0.125764	S.D. dependent var		13084.05
E.p. da regressão	12233.66	Critério de informação de Akaike		21.68327
S.Q.Resíduos	2.02E+10	Critério Schwarz		21.74691
Log likelihood	-1493.146	Durbin-Watson stat		2.82941

4.4. Avaliação do Diagnóstico

Todos os modelos acima estimados são válidos para produzirem previsões, uma vez que os seus parâmetros são estatisticamente significativos. Para o efeito é necessário que se faça a selecção do melhor modelo para previsão.

Esta fase também passa pela verificação de alguns pressupostos da série de resíduos, nomeadamente o da normalidade e o da variância constante (homoscedasticidade). A figura 5 mostra a série de resíduos com um comportamento similar a de um ruído branco, isto é, apresenta uma estabilidade da variância em torno de zero.

Este pressuposto pode ser verificado na figura 6, que apresenta um histograma normalmente distribuído, a figura 7 também apresenta todos os coeficientes dentro do intervalo de confiança, não existe autocorrelação e autocorrelação parcial, podendo deste modo suspeitar-se que a série de resíduos está normalmente distribuída.

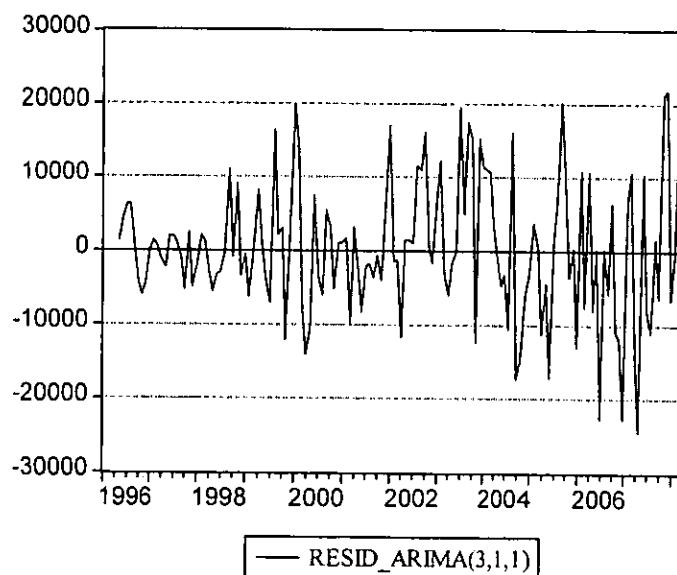


Figura 5: Série de resíduos do modelo ARIMA (3,1,1) ajustado

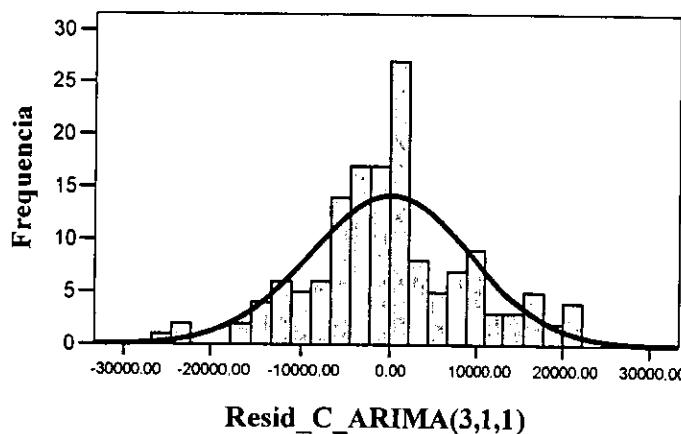


Figura 6: Histograma dos resíduos do modelo ARIMA (3,1,1)

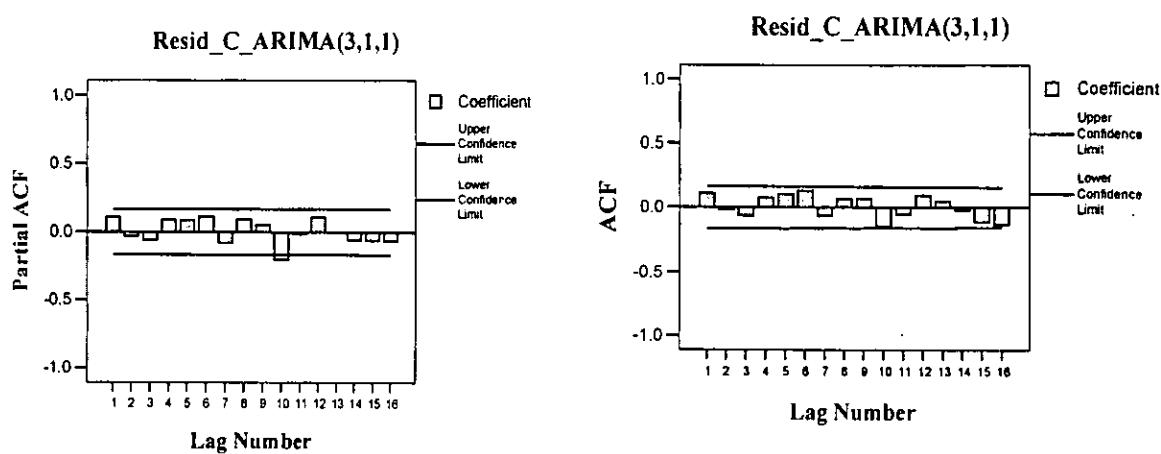


Figura 7: Correlogramas da função autocorrelação e autocorrelação parcial da série de resíduos do modelo ARIMA (3,1,1) ajustado

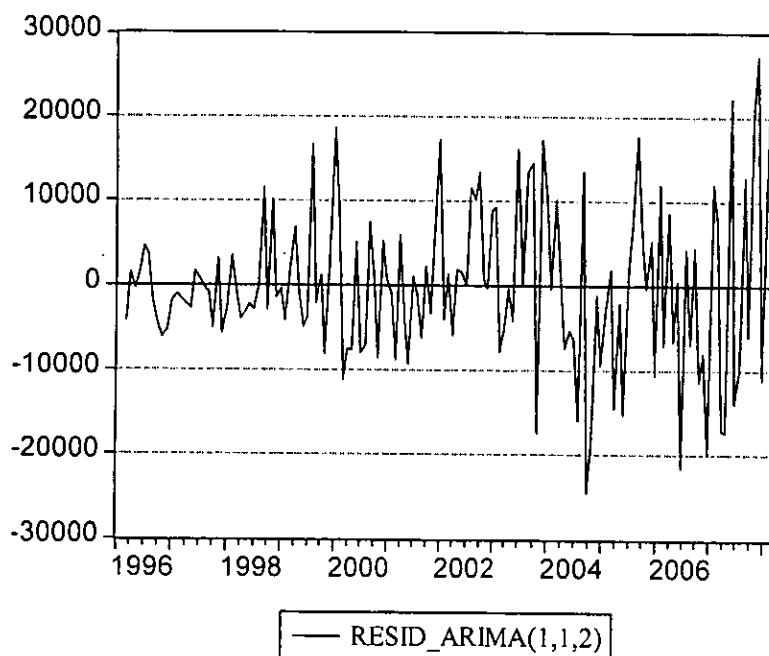


Figura 8: Série de resíduos do modelo ARIMA (1,1,2) ajustado

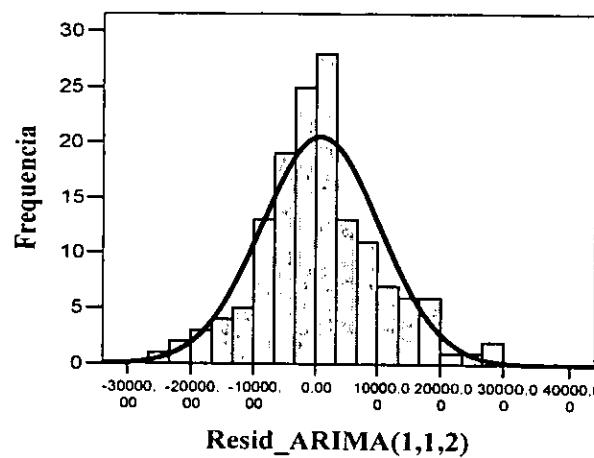


Figura 9: Histograma dos resíduos do modelo ARIMA (1,1,2)

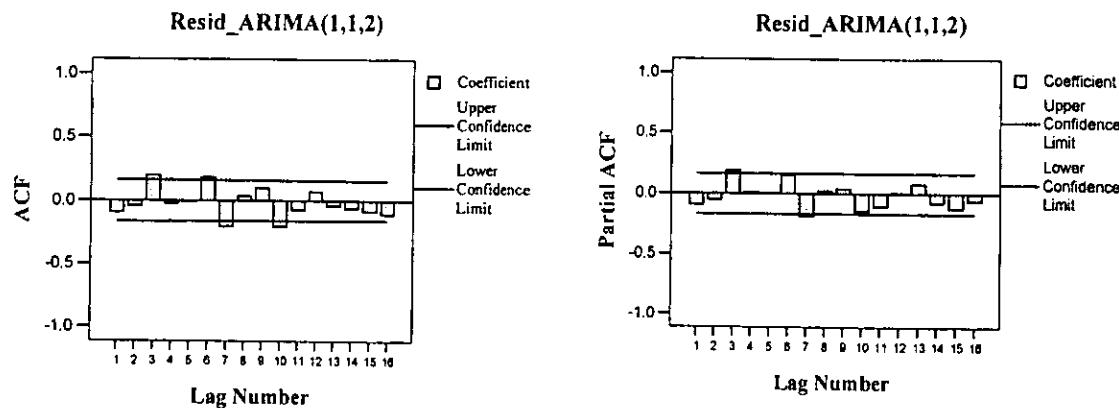


Figura 10: Correlograma da função autocorrelação parcial da série de resíduos do modelo ARIMA (1,1,2) ajustado

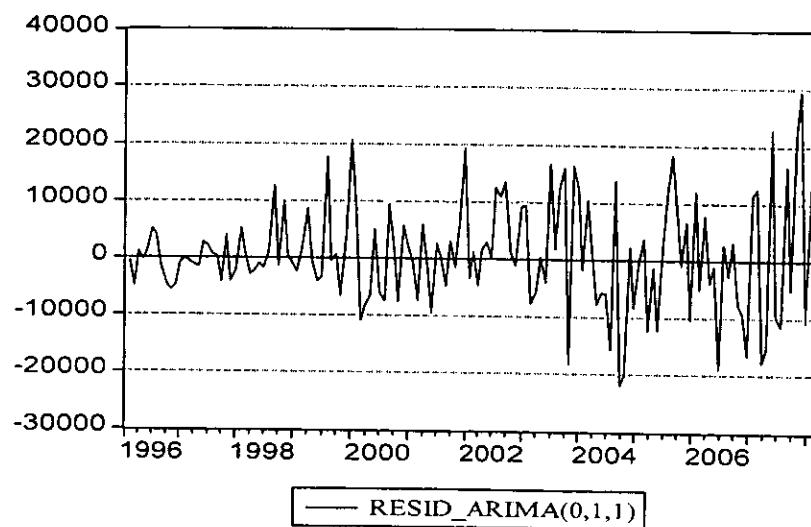


Figura 11: Série de resíduos do modelo ARIMA (0,1,1) ajustado

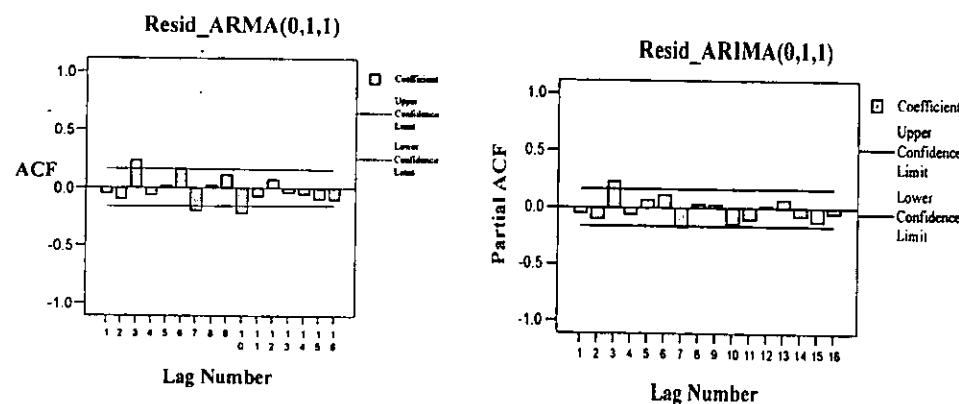


Figura 12: Correlograma da função autocorrelação parcial da série de resíduos do modelo ARIMA (0,1,1) ajustado

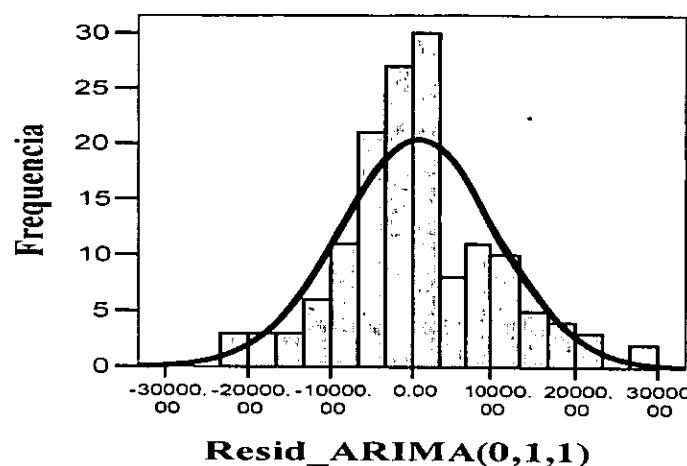


Figura 13: Histograma dos resíduos do modelo ARIMA (0,1,1)

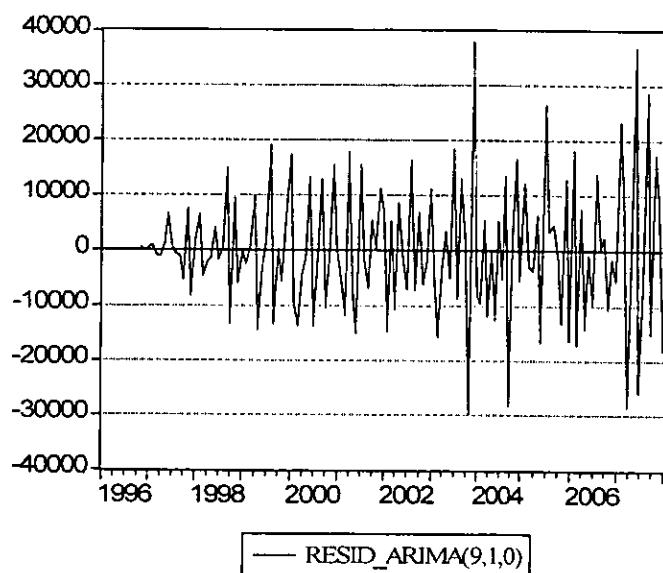


Figura 14: Série de resíduos do modelo ARIMA (9,1,0) ajustado

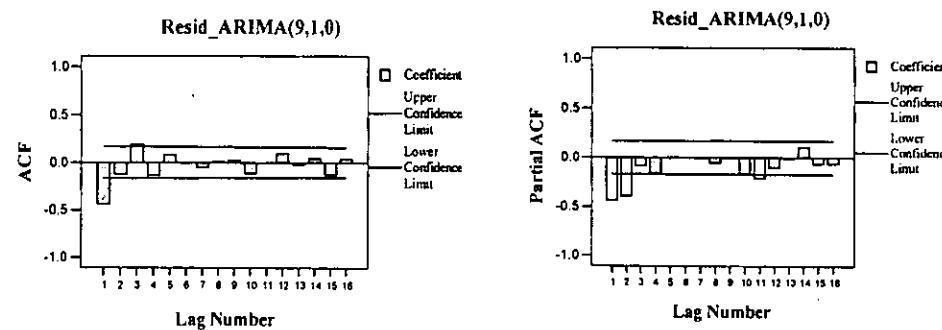


Figura 15: Correlograma da função autocorrelação parcial da série de resíduos do modelo ARIMA (9,1,0) ajustado

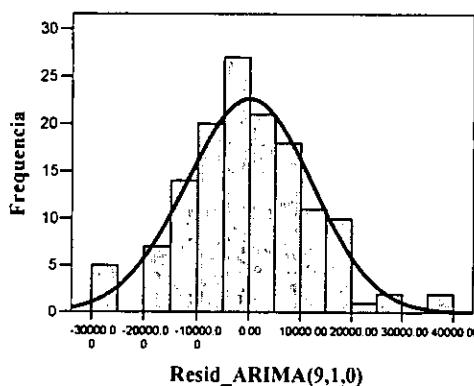


Figura 16: Histograma dos resíduos do modelo ARIMA (9,1,0)

A tabela 15 mostra o teste da normalidade de resíduos, teste de Kolmogorov-Smirnov (K-S) para os modelos diagnosticados, cuja hipótese de nulidade a 5% não é rejeitada, o que significa que a série de resíduos tem uma distribuição normal pois, os valores do sig. para os modelos são maiores que 5%.

Tabela 15: Estatísticas de normalidade de resíduos de K-S

	Resid_ARIMA(1,1,2)	Resid_ARIMA(0,1,1)	Resid_ARIMA(9,1,0)	Resid_C_ARIMA(3,1,1)
Kolmogorov-S	1.048272527	1.236795525	1.055602941	1.260630333
Asymp. Sig. (2-tailed)	0.221801177	0.093828892	0.215090319	0.08330033

4.5. Seleção e comparação de modelos

Avaliado o diagnóstico dos vários modelos estimados, constatou-se que apenas quatro deles são que apresentaram parâmetros estatisticamente significativos. Destes, apenas um modelo será seleccionado segundo os critérios anteriormente mencionados, que estão apresentados na tabela 16.

O modelo ARIMA (3,1,1) é que apresenta valores mais baixos de todas as estatísticas, sugerindo deste modo o modelo com melhor desempenho para previsão dentro e fora da amostra.

. Tabela 16: Estatísticas de desempenho dos modelos na previsão

Modelos	MAE	REQM	CDT	AIC	BIC
ARIMA(3,1,1)	6,989.95	9,222.17	0.40	21.14	21.20
ARIMA(1,1,2)	7,140.06	9,562.89	0.47	21.20	21.24
ARIMA(0,1,1)	7,092.26	9,593.94	0.47	21.19	21.21
ARIMA(9,1,0)	9,092.39	12,099.90	0.67	21.68	21.75

4.6. Previsão

Seleccionado o modelo ARIMA (3,1,1) segue-se a fase da previsão do uso e aproveitamento de terra, ou seja da área de terra que o Governo irá conceder para habitação de Maio de 2008 até Dezembro de 2008, e os respectivos intervalos de confiança a um nível de significância de 5%.

A tabela 17 mostra as previsões com uma tendência crescente no período de Maio a Junho de 2008 onde atingiu o ponto mais alto de concessão de terra em cerca de 36,732.12 metros quadrados, seguido valor mais baixo no mês seguinte em 21,381.19 metros quadrados.

Tabela 17: Previsão de concessão de terra para habitação para o período de Maio-08 a Dezembro-08 e os respectivos intervalos de confiança.

Período de Previsão	Limite Inferior	Valor Previsto	Limite superior
Maio-08	8,126.69	26,491.21	44,855.74
Junho-08	18,165.62	36,732.12	55,298.62
Julho-08	2,771.94	21,381.19	39,990.43
Agosto-08	6,481.87	26,609.47	46,737.07
Setembro-08	10,533.49	30,813.14	51,092.79
Outubro-08	5,388.71	25,718.74	46,048.77
Novembro-08	6,599.10	27,250.62	47,902.13
Dezembro-08	8,235.90	28,973.17	49,710.44

5. CONCLUSÕES E RECOMENDAÇÕES

5.1 Conclusões

O trabalho debruça-se sobre a previsão de concessão de terra para habitação de requerentes que solicitam áreas até 5,000.00 metros quadrados na província de Inhambane, tendo como ferramenta a aplicação de metodologia ARIMA, genericamente conhecida por Box & Jenkins, tendo-se chegado às seguintes conclusões:

- A série em análise não é de carácter sazonal, pois, as solicitações são feitas independentemente de qualquer época do ano, como se pode visualizar no gráfico da figura 1, a evolução da série em nível, não apresenta ciclos repetitivos em períodos inferiores a um ano, tem uma tendência crescente, tendo-se verificado em Março de 2008 a maior concessão de terra em cerca de 53,816.00 metros quadrados e a menor em Maio de 2007 com 900,00 metros quadrados;
- A série não é estacionária em nível, pois, houve necessidade de diferenciá-la para que variância seja constante;
- Com base nos resultados obtidos foram estimados vários modelos, tendo-se identificado o ARIMA (3,1,1) ou seja o modelo autoregressivo integrado de médias móveis como sendo o melhor para a previsão dentro e fora da amostra, segundo os critérios apresentados;
- Os pedidos de terras para habitação tenderam a estabilizar-se durante o período previsto, conforme a figura 1 do anexo A ilustra.

5.2. Recomendações

Para estudos futuros recomenda-se à Direcção Nacional de Terras, a criar mecanismos de uniformização de bases de dados a nível nacional, de forma a facilitar um estudo que abranja todas as províncias do País, para diversos fins de utilização de terra, tais como: concessão de terras para actividade Agro-pecuária, turismo, serviços sociais, industria, etc.

5.3. Limitações

Uma das grandes dificuldades atravessadas na realização do presente trabalho foi o acesso à informação sobre o estudo em causa e às respectivas bases de dados, pois em qualquer instituição estas são consideradas de carácter confidencial para a boa imagem da mesma.

6. BIBLIOGRAFIA

1. Akaike, H.(1977). On entropy maximization principle in applications of statistics, P. R. Krishnaiah ed, pp 27-41, Amsterdan: North –Holland.
2. Da Silva, W. V., J. M. Del Corso e L. C. Duclós (2005), Process transmission evaluation of soya beans prices beetween brazilian and u.s.a market, Curitiba-PR, Brasil.
3. Ehlers, R. S. (2003). Análise de Séries Temporais, Brasil.
4. Figueiredo, E. A. e Marques, A. M. (2007), Inflação Inercial como um processo de Longa Memória : Análise a partir de um modelo ARFIMA-FIGARCH, Universidade Federal do Rio Grande do Sul, Departamento de Economia da UFRN, Brasil.
5. Granger, C. W. J and Newbold, P. (1986), Forecasting Economic Time Series. New York, Academic Press.
6. Gujarati, D. N (2000). Econometria Básica, 3^a. Edição, Makron books editora, Brasil (tradução).
7. Ministério da Agricultura e Desenvolvimento Rural (1997). Lei de terras 19/97 e seus regulamentos, Maputo.
8. McClain, K. T. e Humphreys, H. B. (1996), Atahunpa . Measuring risk in the mining sector with arch models with important observations on sample size. Journal of empirical finance, pp.369-391.
9. Morettin, P. A. e Toloi, C. M. C. (1987). Previsão de séries temporais (2^a edição), editora Atual, São Paulo.
10. Morettin, Pedro A. (2004). Econometria Financeira, Universidade de São Paulo, Instituto de Matematica e Estatística, Departamento de Estatística, Brasil.
11. Muller, Alesandro(1996), Uma aplicação de Redes Neurais Artificiais na previsão do mercado Acionário, Universidade Federal de Santa Carolina, Centro Tecnológico, Departamento de Pós- Graduação em Engenharia de produção, Florianópolis, Brasil.
12. Murteira, B. J. F., D. A. Muller e K. F. Turkman (1993). ANALISE DE SUCESSOES CRONOLÓGICAS, Editora McGraw-Hill, Portugal.
13. Newbold, P. & Granger, C.W.J. (1974). Experience with forecasting univariate time series and the combination of forecasts, Journal of the Royal Statistical Society A, 137, pp 131-146.
14. Pandit, S. M. e S. M. Wu (1983). Time Series and System Analysis with Applications, Canada, by John Wiley & Sons, Inc.

-
15. Pinto, A. C. B. e Vieira F. V. (2003), Câmbio Flexível de Inflação em Selecionados da América: Análise de Vectores Auto-Regressivos, Brazil.
 16. Wheelwright, S. C. & Makridakis, S. (1985). Forecasting Methods for Management, 4th edition, New York, John Wiley & Sons Inc.

ANEXOS

Anexo. A

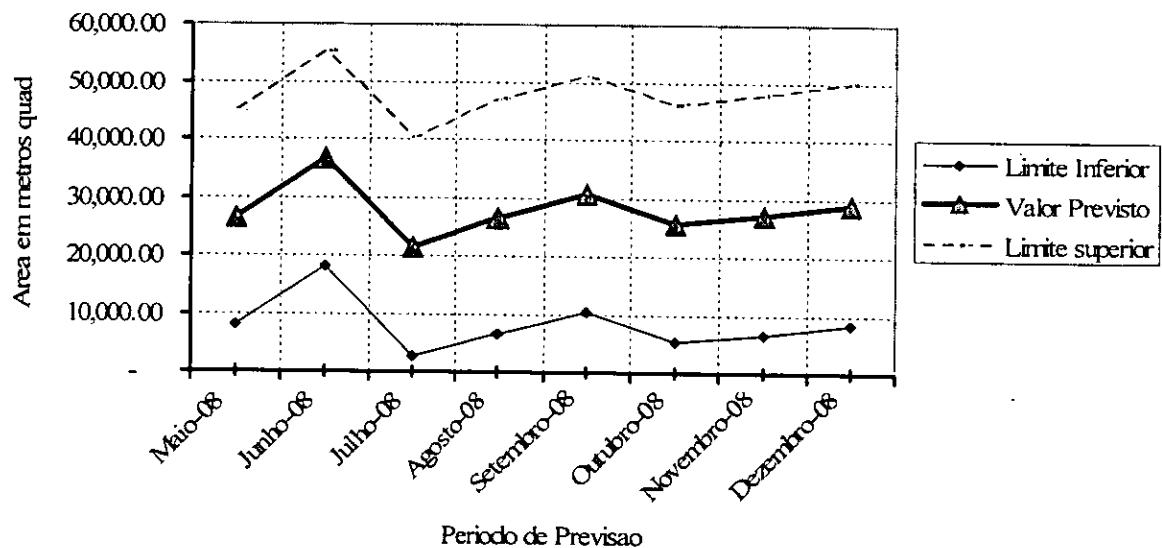


Figura1: Evolução da previsão da concessão de terra para habitação no período de Maio-08 a Dezembro-08 fora da amostra.

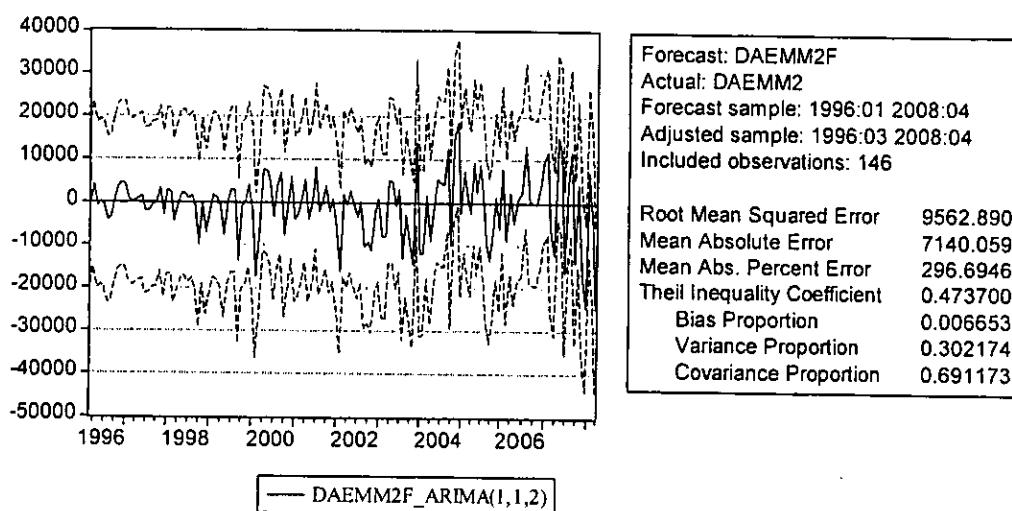


Figura2: Previsão da concessão de terra para habitação dentro da amostra, limites de confiança e estatísticas do desempenho do modelo ARIMA (1,1,2), sem termo intercepto.

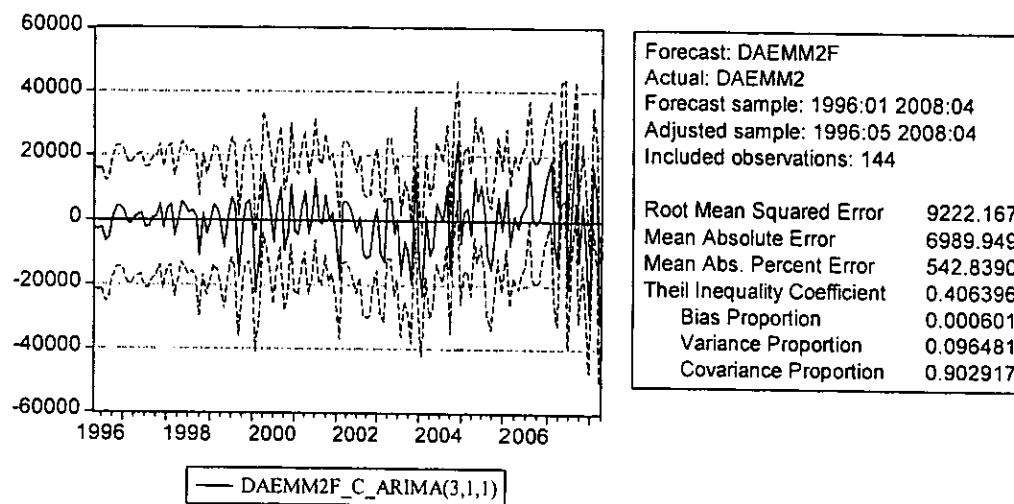


Figura 3: Previsão da concessão de terra para habitação dentro da amostra, limites de confiança e estatísticas do desempenho do modelo ARIMA (3,1,1) incluindo termo intercepto.

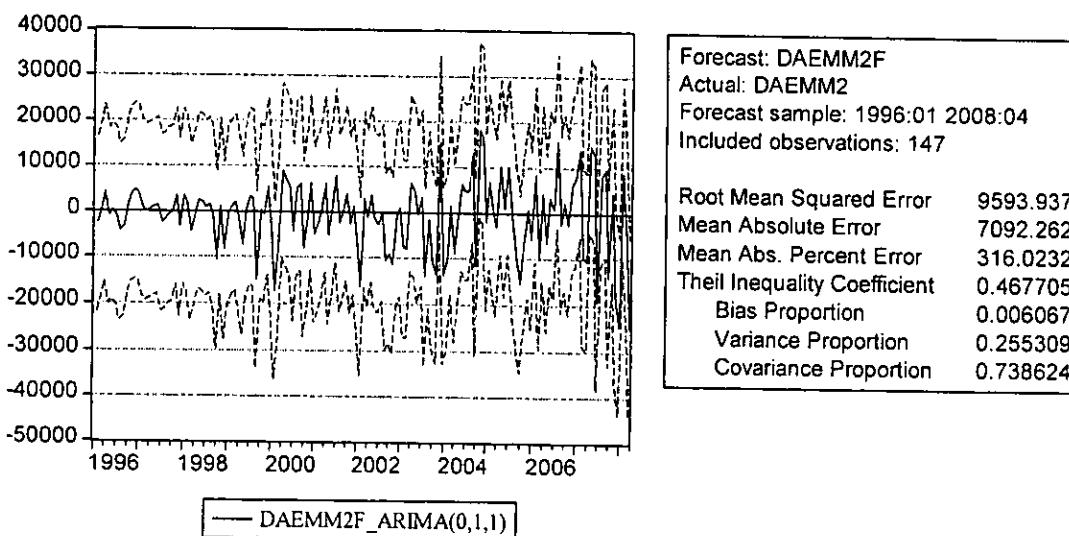


Figura 4: Previsão da concessão de terra para habitação dentro da amostra, limites de confiança e estatísticas do desempenho do modelo ARIMA (0,1,1) incluindo termo intercepto.

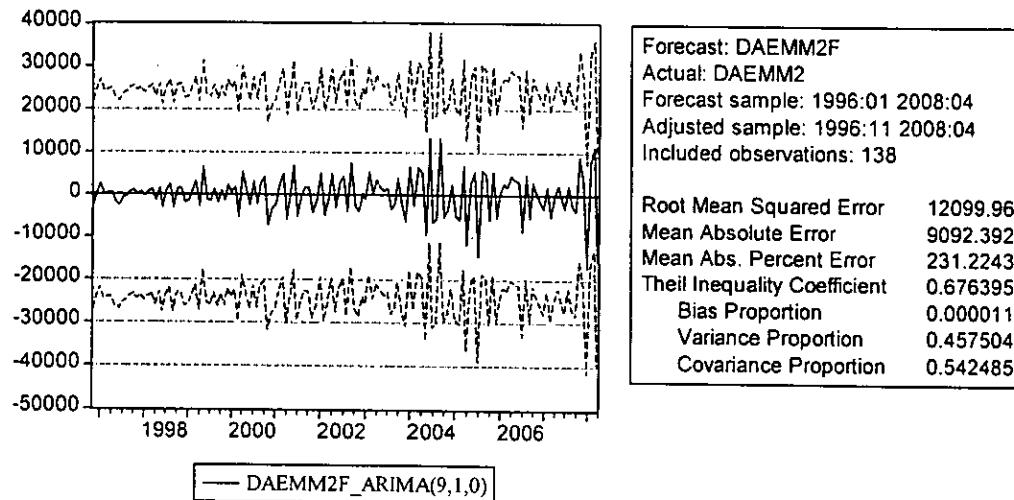


Figura 5: Previsão da concessão de terra para habitação dentro da amostra, limites de confiança e estatísticas do desempenho do modelo ARIMA (9,1,0) incluindo termo intercepto.

Anexo.B

Tabela 1: Estatísticas do modelo ARIMA (1,1,1)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 00:57

Sample(adjusted): 1996:03 2008:04

Included observations: 146 after adjusting endpoints

Convergence achieved after 12 iterations

Backcast: 1996:02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	149.1767	143.3186	1.040874	0.2997
AR(1)	-0.071000	0.104495	-0.679453	0.4979
MA(1)	-0.815030	0.060414	-13.49076	0.0000
R-squared	0.431945	Mean dependent var		14.93151
Adjusted R-squared	0.424000	S.D. dependent var		12746.32
S.E. of regression	9673.775	Akaike info criterion		21.21256
Sum squared resid	1.34E+10	Schwarz criterion		21.27387
Log likelihood	-1545.517	F-statistic		54.36802
Durbin-Watson stat	1.984940	Prob(F-statistic)		0.000000

Tabela 2: Estatísticas do modelo ARIMA (1,1,3)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 00:58

Sample(adjusted): 1996:03 2008:04

Included observations: 146 after adjusting endpoints

Convergence achieved after 9 iterations

Backcast: 1995:12 1996:02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	96.80219	758.9814	0.127542	0.8987
AR(1)	-0.459454	0.078213	-5.874414	0.0000
MA(3)	0.210297	0.085178	2.468916	0.0147
R-squared	0.253182	Mean dependent var		14.93151
Adjusted R-squared	0.242737	S.D. dependent var		12746.32
S.E. of regression	11091.95	Akaike info criterion		21.48616
Sum squared resid	1.76E+10	Schwarz criterion		21.54747
Log likelihood	-1565.490	F-statistic		24.23954
Durbin-Watson stat	2.299509	Prob(F-statistic)		0.000000
Inverted AR Roots	.46			
Inverted MA Roots	.30 -.52i	.30+.52i	-.59	

Tabela 3: Estatísticas do modelo ARIMA (1,1,3)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 00:59

Sample(adjusted): 1996:03 2008:04

Included observations: 146 after adjusting endpoints

Convergence achieved after 11 iterations

Backcast: 1996:01 1996:02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	138.5814	115.5329	1.199497	0.2323
AR(1)	-0.789790	0.065208	-12.11180	0.0000
MA(2)	-0.752786	0.069170	-10.88313	0.0000
R-squared	0.438165	Mean dependent var		14.93151
Adjusted R-squared	0.430307	S.D. dependent var		12746.32
S.E. of regression	9620.664	Akaike info criterion		21.20155
Sum squared resid	1.32E+10	Schwarz criterion		21.26286
Log likelihood	-1544.713	F-statistic		55.76157
Durbin-Watson stat	2.105302	Prob(F-statistic)		0.000000
Inverted AR Roots	.79			
Inverted MA Roots	.87	-.87		

Tabela 4: Estatísticas do modelo ARIMA (1,1,6)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 00:59

Sample(adjusted): 1996:03 2008:04

Included observations: 146 after adjusting endpoints

Convergence achieved after 16 iterations

Backcast: 1995:09 1996:02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	115.0906	736.6158	0.156242	0.8761
AR(1)	-0.469563	0.078623	-5.972304	0.0000
MA(6)	0.175259	0.091242	1.920828	0.0567
R-squared	0.240068	Mean dependent var		14.93151
Adjusted R-squared	0.229440	S.D. dependent var		12746.32
S.E. of regression	11188.92	Akaike info criterion		21.50357
Sum squared resid	1.79E+10	Schwarz criterion		21.56488
Log likelihood	-1566.761	F-statistic		22.58737
Durbin-Watson stat	2.386787	Prob(F-statistic)		0.000000
Inverted AR Roots	.47			
Inverted MA Roots	.65 -.37i	.65+.37i	.00+.75i	-.00 -.75i
	-.65 -.37i	-.65+.37i		

Tabela 5: Estatísticas do modelo ARIMA (3,1,1)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 01:03

Sample(adjusted): 1996:05 2008:04

Included observations: 144 after adjusting endpoints

Convergence achieved after 25 iterations

Backcast: 1996:04

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	153.0180	42.19914	3.626094	0.0004
AR(3)	0.380176	0.084567	4.495564	0.0000
MA(1)	-0.980202	0.013799	-71.03242	0.0000
R-squared	0.479066	Mean dependent var		9.583333
Adjusted R-squared	0.471677	S.D. dependent var		12821.97
S.E. of regression	9319.759	Akaike info criterion		21.13827
Sum squared resid	1.22E+10	Schwarz criterion		21.20015
Log likelihood	-1518.956	F-statistic		64.83379
Durbin-Watson stat	1.767532	Prob(F-statistic)		0.000000
Inverted AR Roots	.72	-.36+.63i	-.36 -.63i	
Inverted MA Roots	.98			

Tabela 6: Estatísticas do modelo ARIMA (9,1,1)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 01:23

Sample(adjusted): 1996:11 2008:04

Included observations: 138 after adjusting endpoints

Convergence achieved after 3 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(6)	0.256907	0.092079	2.790061	0.0060
AR(8)	0.254222	0.103839	2.448231	0.0156
AR(9)	0.335024	0.104824	3.196066	0.0017
R-squared	0.138527	Mean dependent var		40.14493
Adjusted R-squared	0.125764	S.D. dependent var		13084.05
S.E. of regression	12233.66	Akaike info criterion		21.68327
Sum squared resid	2.02E+10	Schwarz criterion		21.74691
Log likelihood	-1493.146	Durbin-Watson stat		2.829410
Inverted AR Roots	.98 .13 -.87i .77 -.16i	.66 -.65i .50 -.77i	.66+.65i .50+.77i	.13+.87i .77+.16i

Tabela 7: Estatísticas do modelo ARIMA (0,1,1)

Dependent Variable: DAEMM2

Method: Least Squares

Date: 10/23/08 Time: 01:15

Sample(adjusted): 1996:02 2008:04

Included observations: 147 after adjusting endpoints

Convergence achieved after 9 iterations

Backcast: 1996:01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.830985	0.046927	-17.70793	0.0000
R-squared	0.425904	Mean dependent var		-6.938776
Adjusted R-squared	0.425904	S.D. dependent var		12705.36
S.E. of regression	9626.737	Akaike info criterion		21.18926
Sum squared resid	1.35E+10	Schwarz criterion		21.20960
Log likelihood	-1556.410	Durbin-Watson stat		2.055631
Inverted MA Roots	.83			

Tabela 8: Teste de Kolmogorov-Smirnov de Normalidade de resíduos. Dos modelos diagnosticados

One-Sample Kolmogorov-Smirnov Test

			Resid ARIMA(1,1,2)	Resid ARIMA(0,1,1)	Resid ARIMA(9,1,0)	Resid C_ARIMA(3,1,1)
N			147	147	138	147
Normal Parameters(a,b)	Mean		770.4067	747.2585	39.9586	194.0584
	Std. Deviation		9531.73705	9597.49145	12143.97352	9165.32557
Most Differences	Extreme	Absolute	.086	.102	.090	.104
		Positive	.086	.102	.090	.104
		Negative	-.056	-.050	-.044	-.051
Kolmogorov-Smirnov Z			1.048	1.237	1.056	1.261
Asymp. Sig. (2-tailed)			.222	.094	.215	.083

a Test distribution is Normal.

b Calculated from data.