

Universidade Federal de Minas Gerais

Instituto de Ciências Exatas

Departamento de Estatística

*Comparação dos Softwares MINITAB,
SAS, SPSS e EVIEWS na estimação
de modelos ARIMA(p,d,q)*

*Glaura C. Franco, Janaína P. Soares
e Juliana A. Ribeiro*

Relatório Técnico

RTE- 02/2004

Série Ensino

ÍNDICE

Capítulo 1 - Introdução	04
Capítulo 2 - Modelagem Box & Jenkins	05
2.1 Modelos ARMA(p,q)	05
2.2 Estacionariedade dos Modelos Box & Jenkins	06
2.3 Inversibilidade dos Modelos Box & Jenkins	06
2.4 Modelos Não estacionários ARIMA	07
2.5 Modelos sazonais ARIMA(p,d,q)(P,D,Q) _s	07
2.6 Identificação de Modelos ARIMA(p,d,q)(P,D,Q) _s	08
Capítulo 3 - Utilização dos <i>Softwares</i>	09
3.1 <i>Software</i> Econometric Views (EViews)	09
3.1.1 Entrada dos dados no programa	09
3.1.2 Obtenção do gráfico de uma série	18
3.1.3 Obtenção dos gráficos de autocorrelação e autocorrelação parcial	20
3.1.4 Estimação dos parâmetros de modelos ARIMA	23
3.2 <i>Software</i> MINITAB for Windows	28
3.2.1 Entrada dos dados no programa	28
3.2.2 Obtenção do gráfico de uma série	30
3.2.3 Obtenção dos gráficos de autocorrelação e autocorrelação parcial	31
3.2.4 Estimação dos parâmetros de modelos ARIMA	34
3.3 <i>Software</i> SPSS Versão 8.0	37
3.3.1 Entrada dos dados no programa	37
3.3.2 Obtenção do gráfico de uma série	40
3.3.3 Obtenção dos gráficos de autocorrelação e autocorrelação parcial	41
3.3.4 Estimação dos parâmetros de modelos ARIMA	44
3.4 <i>Software</i> SAS - versão 8	46
3.4.1 Entrada dos dados no programa	46
3.4.2 Obtenção do gráfico de uma série, dos correlogramas e estimação dos parâmetros	48
Capítulo 4 – Resultados	50
4.1 Modelo Autorregressivo de ordem 1 – AR(1) com parâmetro $\phi = 0,7$	50
4.2 Modelo Autorregressivo de ordem 1 – AR(1) com parâmetro $\phi = -0,7$	52
4.3 Modelo Autorregressivo de ordem 2 – AR(2) com parâmetros $\phi_1 = 0,2$ e $\phi_2 = 0,7$	53
4.4 Modelo Autorregressivo de ordem 2 – AR(2) com parâmetros $\phi_1 = -0,6$ e $\phi_2 = 0,3$	54
4.5 Modelo de Médias Móveis de ordem 1 – MA(1) com parâmetros $\theta = 0,7$	55
4.6 Modelo de Médias Móveis de ordem 1 – MA(1) com parâmetros $\theta = -0,7$	56
4.7 Modelo de Médias Móveis de ordem 2 – MA(2) com parâmetros $\theta_1 = 0,7$, $\theta_2 = -0,2$ e $\mu = 10$	57
4.8 Modelo de Médias Móveis de ordem 2 – MA(2) com parâmetros $\theta_1 = 0,6$, $\theta_2 = 0,3$ e $\mu = 10$	59
4.9 Modelos Autorregressivos e Médias Móveis com parâmetros $\phi = -0,8$, $\theta = 0,5$ e $\mu = 10$	60
4.10 Vícios Estimados	62

Capítulo 5 - Análise Descritiva dos Dados e Comparação dos <i>Softwares</i>	63
5.1 Análise Geral	63
5.1.1 Análise Descritiva para todos os parâmetros	64
5.1.2 Comparação Geral dos <i>Softwares</i>	65
5.2 Análise dividida por parâmetros (\emptyset e θ) e intercepto (μ)	65
5.2.1 Parâmetros \emptyset e θ	65
5.2.1.1 Análise Descritiva	65
5.2.1.2 Comparação dos <i>Softwares</i> segundo os parâmetros \emptyset e θ estimados ..	66
5.2.2 Parâmetro μ	67
5.2.2.1 Análise Descritiva	67
5.2.2.2 Comparação dos <i>Softwares</i> segundo os parâmetros μ estimados	68
5.3 Análise dividida por Modelos Autoregressivos e de Médias Móveis	68
5.3.1 Modelos Autorregressivos	69
5.3.1.1 Análise Descritiva	69
5.3.1.2 Comparação dos <i>Softwares</i> segundo os parâmetros \emptyset estimados	70
5.3.2 Modelos de Médias Móveis	70
5.3.2.1 Análise Descritiva	70
5.3.2.2 Comparação dos <i>Softwares</i> segundo os parâmetros θ estimados	71
5.4 Conclusões	72
 Capítulo 6 – Conclusão Geral	 73
 Referências Bibliográficas	 74
 Anexo 1 – Macros para gerar os processos	 75
 Anexo 2 – Conjuntos de dados utilizados	 80

Introdução

Uma série temporal é qualquer conjunto de observações ordenadas no tempo, que de um modo bastante geral, pode ser representada matematicamente por um vetor Z_1, Z_2, \dots, Z_n de uma variável Z nos tempos t_1, t_2, \dots, t_n , ou seja, a série Z é uma função de t simbolizada por $Z = F(t)$.

Um tipo de modelagem muito utilizado para séries dispostas ao longo do tempo são os modelos $ARIMA(p, d, q)$, que foram propostos por Box & Jenkins (1976). Neste trabalho utilizaremos os processos $AR(1)$, $AR(2)$, $MA(1)$, $MA(2)$ e $ARMA(1, 1)$, que são casos particulares da modelagem $ARIMA(p, d, q)$.

O objetivo principal do trabalho é comparar as estimativas dos parâmetros destes modelos obtidas através dos *softwares* MINITAB, SAS, SPSS e EViews. Para realizar esta comparação, foram geradas séries dos processos $ARIMA$ mencionados acima com os parâmetros necessários pré-fixados. Posteriormente foram estimados os parâmetros destas mesmas séries em cada um dos pacotes estatísticos e então estes parâmetros estimados foram comparados com os pré-fixados. Para efetuar esta comparação, calculamos o vício em cada parâmetro estimado, ou seja, a diferença entre o valor estimado e o valor real. A partir deste vício, analisamos qual *software* estatístico nos fornece melhores estimativas.

Além das comparações, apresentamos também os procedimentos necessários para ajustar estes modelos em cada um dos *softwares* utilizados.

No capítulo 2, apresentamos a modelagem proposta por Box & Jenkins (1976), isto é, o embasamento teórico utilizado na modelagem das séries. No capítulo 3, apresentamos passo a passo como os *softwares* são utilizados na estimação de modelos $ARIMA$, obtenção do gráfico das séries e gráficos de autocorrelação e autocorrelação parcial. No capítulo 4, apresentamos os resultados obtidos na estimação dos parâmetros das séries em cada um dos *softwares* e os vícios estimados para cada *software*. Apresentamos também, os gráficos das séries e gráficos de autocorrelação e autocorrelação parcial das mesmas. No capítulo 5, apresentamos uma análise descritiva dos vícios estimados e a comparação dos *softwares* no que diz respeito a estimação dos modelos $ARIMA$. No capítulo 6, apresentamos a conclusão, ou seja, qual dos quatro *softwares* estudados se mostrou mais eficaz na estimação dos modelos $ARIMA(p, d, q)$.

Modelagem Box & Jenkins

Um método utilizado para a modelagem de séries de dados dispostos ao longo do tempo é o método de Box & Jenkins (1976). A modelagem proposta por Box & Jenkins é da forma

$$Z_t = \sum_{k=0}^{\infty} \psi_k u_{t-k} \quad (2.1)$$

onde o filtro linear ψ é definido por $\psi(B) = \frac{\theta_q(B)}{\phi_p(B)}$.

2.1 Modelos ARMA(p,q)

O modelo definido na equação (2.1) é conhecido como ARMA(p,q) e é constituído por um componente autorregressivo de ordem p e por um componente de média móvel de ordem q . Uma representação deste modelo é dada por

$$\phi_p(B)\tilde{Z}_t = \theta_q(B)u_t \quad (2.2)$$

sendo:

\tilde{Z}_t : a série em estudo subtraída de sua média, ou seja, $\tilde{Z}_t = Z_t - \mu$;

B : é o operador de retardo, cuja relação $Z_{t-1} = BZ_t$ é válida;

$\phi_p(B)$: componente autorregressivo;

$\theta_q(B)$: componente da média móvel;

u_t : ruído branco com média zero e variância constante.

O modelo que tem $\phi(B) \equiv 1$ é chamado Modelo Médias Móveis e sua notação é MA(q). O nome Médias Móveis vem do fato que Z_t é uma função soma algébrica ponderada dos u_t que se movem no tempo.

O modelo que tem $\theta(B) \equiv 1$ é chamado Modelo Autorregressivo e sua notação é AR(p). O nome Autorregressivo se deve ao fato de que Z_t no instante t é função dos Z 's nos instantes anteriores a t .

O modelo que tem tanto uma parte AR ($\phi(\cdot) \neq 1$) como uma parte MA ($\theta(\cdot) \neq 1$) é conhecido como ARMA(p,q).

2.2. Estacionariedade dos Modelos Box & Jenkins

Proposição 1: Um processo estocástico $Z_t = \psi(B)u_t$ será estacionário se a série

$$\psi(B) = \sum_{k=0}^{\infty} \psi_k B^k$$

converge para $|B| < 1$.

- **Estacionariedade dos modelos MA**

Como $\psi(B) = \theta(B)$ para modelos MA, a convergência de $\psi(B)$ para $|B| < 1$ é trivial, pois $\psi(B)$ é uma soma finita. Portanto, podemos dizer que todo modelo MA é estacionário.

- **Estacionariedade dos modelos AR**

Os modelos AR devem ter as raízes do polinômio $\psi^{-1}(B) = \phi(B) = 0$ fora do círculo unitário como condição de estacionariedade.

- **Estacionariedade dos modelos ARMA**

Um modelo ARMA(p,q) será estacionário se $\phi(B)$ satisfizer as condições de estacionariedade de um modelo AR.

2.3. Inversibilidade dos Modelos Box & Jenkins

Vamos inicialmente expressar o modelo geral ARMA na forma inversa, isto é, expressando o ruído u em função de Z :

$$u_t = \phi(B)\theta^{-1}(B)Z_t = \pi(B)Z_t$$

Proposição 2: Um processo estocástico $u_t = \pi(B)Z_t$ será inversível se a série

$$\pi(B) = \sum_{j=0}^{\infty} \pi_j B^j$$

converge para $|B| < 1$.

- **Inversibilidade dos modelos AR**

Como $\pi(B) = \phi(B)$ para modelos AR, a convergência de $\pi(B)$ para $|B| < 1$ é trivial, pois $\pi(B)$ é uma soma finita. Portanto, podemos dizer que todo modelo AR é inversível.

- **Inversibilidade dos modelos MA**

Os modelos MA devem ter as raízes do polinômio $\pi^{-1}(B) = \theta(B) = 0$ fora do círculo unitário como condição de inversibilidade.

- **Inversibilidade dos modelos ARMA**

Um modelo ARMA(p,q) será inversível se $\theta(B)$ satisfizer as condições de inversibilidade de um modelo MA.

2.4. Modelos Não Estacionários ARIMA

Um processo não estacionário homogêneo é dado por

$$\nabla Z_t = (1 - B)Z_t = w_t$$

onde ∇ é um polinômio do tipo AR, $\nabla = (1 - B)$, em que a condição de estacionariedade foi violada, ou seja,

$$\phi(B) = 0 \Rightarrow B = 1.$$

Se $w_t = \nabla^d Z_t$ é estacionária, podemos representar w_t por um modelo ARMA(p,q), ou seja,

$$\phi(B)w_t = \theta(B)u_t \tag{2.3}$$

Dizemos então que Z_t segue um modelo Autorregressivo - Integrado - Média Móvel, ou ARIMA(p,d,q). No modelo (2.3), todas as raízes de $\phi(B)$ estão fora do círculo unitário. Portanto o modelo ARIMA supõe que a d-ésima diferença da série Z_t pode ser representada por um modelo ARMA, estacionário e inversível. Na maioria dos casos usuais, $d = 1$ ou 2 .

2.5 Modelos Sazonais ARIMA(p,d,q)(P,D,Q)_S

Sazonalidade é a tendência do processo em repetir um certo tipo de comportamento dentro de um período sazonal, S (geralmente 12 meses para séries mensais, quatro meses para séries trimestrais, etc.)

Se um processo apresenta correlação serial “dentro” e “entre” períodos sazonais, dizemos que o processo pode ser ajustado através de um modelo ARIMA multiplicativo, denotado ARIMA(p,d,q)(P,D,Q)_S, com a seguinte equação:

$$\Phi_P(B^S) \phi_p(B) \nabla_S^D \nabla^d \tilde{Z}_t = \Theta_Q(B^S) \theta_q(B) u_t \tag{2.4}$$

onde:

\tilde{Z}_t : a série em estudo subtraída de sua média, ou seja, $\tilde{Z}_t = Z_t - \mu$;

$\Phi_P(B^S)$: componente autorregressivo sazonal de período S ;

$\phi_p(B)$: componente autorregressivo simples;

∇_S^D : Componente de diferenciação sazonal;

∇_d : Componente de diferenciação simples;

$\Theta_Q(B^S)$: componente da média móvel sazonal de período S ;

$\theta_q(B)$: componente da média móvel simples;

u : ruído branco com média zero e variância constante.

2.6 Identificação de Modelos ARIMA(p,d,q)(P,D,Q) $_S$

A forma utilizada para se definir qual processo uma série temporal segue, ou seja, distinguir qual dos casos particulares da modelagem ARIMA(p,d,q) em que haja uma melhor adequação aos dados, é a construção das funções de autocorrelação e autocorrelação parcial, em que cada processo tem uma representação típica.

- **Escolha de d e D**

Se uma série apresenta não-estacionariedade, as autocorrelações estimadas terão valores absolutos altos para todos os "lags". Neste caso, aplicamos sucessivamente o operador diferença à série e calculamos sua autocorrelação, que indicará quando uma série com características de um processo estacionário foi obtida. Assim, se a função de autocorrelação tem um decaimento muito lento, este é um indicativo de não-estacionariedade da série.

- **Escolha de p, q, P e Q**

Uma vez que o grau d tenha sido identificado, o passo seguinte será a escolha dos graus p e q dos polinômios $\phi(B)$ e $\theta(B)$ e P e Q dos polinômios $\Phi(B)$ e $\Theta(B)$ do modelo ARMA aplicado à série $w = \nabla \nabla^d Z$. A identificação dos parâmetros é feita comparando-se o comportamento dos estimadores das autocorrelações (r_k) e das autocorrelações parciais (ϕ_{kk}) com as correspondentes funções teóricas. Maiores detalhes podem ser vistos em Bowerman & O'Connell (1993).

Obs.: A maioria das séries estacionárias, na prática, apresentam $p + q \leq 2$ e $P + Q \leq 2$.

Utilização dos *Softwares*

Neste capítulo iremos apresentar os procedimentos necessários para a utilização dos *softwares* em estudo no que diz respeito a identificação e estimação de modelos ARIMA. Para cada um dos *softwares* será mostrado como se entra com os dados no programa, como fazer os gráficos de autocorrelação, autocorrelação parcial, os gráfico da séries e como ajustar os modelos.

A título de ilustração, utilizaremos o modelo ARIMA(1,0,0), ou seja, um modelo autorregressivo de ordem um, ou seja, AR(1) não sazonal e não diferenciado com parâmetro $\phi = 0.7$, para aplicarmos os procedimentos básicos de cada um dos quatro *softwares* estudados.

3.1 - *Software* Econometric Views (EViews)

O *software* Econometric Views, também chamado de EViews, é um pacote estatístico desenvolvido por economistas e com a maioria de aplicações na Economia, mas pode ser usado em outras áreas. Este é um *software* que produz regressões e previsões, desenvolve relações estatísticas entre os dados e usa estas relações para prever valores futuros dos dados. As áreas onde o EViews pode ser útil são: previsão de vendas, análise de custos, previsões em análises financeiras, simulação e previsão macroeconômica, análise científica e avaliação de dados.

A seguir apresentaremos os quatro procedimentos básicos para utilização do *software* no tratamento de modelos ARIMA. A versão do EViews utilizada neste trabalho é a 3.0.

3.1.1 - Entrada dos dados no programa

Os dados podem ser incorporados no programa através do teclado ou de arquivos de disco, novas séries podem ser criadas a partir de séries já existentes. Cada série inserida recebe um nome e as operações de qualquer complexidade feitas nas observações podem ser repetidas apenas mencionando o nome da série.

Iniciando o *software*, a tela do programa (Figura 1), chamada de Menu Principal, aparecerá. Nesta tela são executadas as operações básicas referentes ao arquivo de trabalho, criação e manipulação de dados, importação e exportação de dados, criação de atalhos, sistema de ajuda on-line, etc.

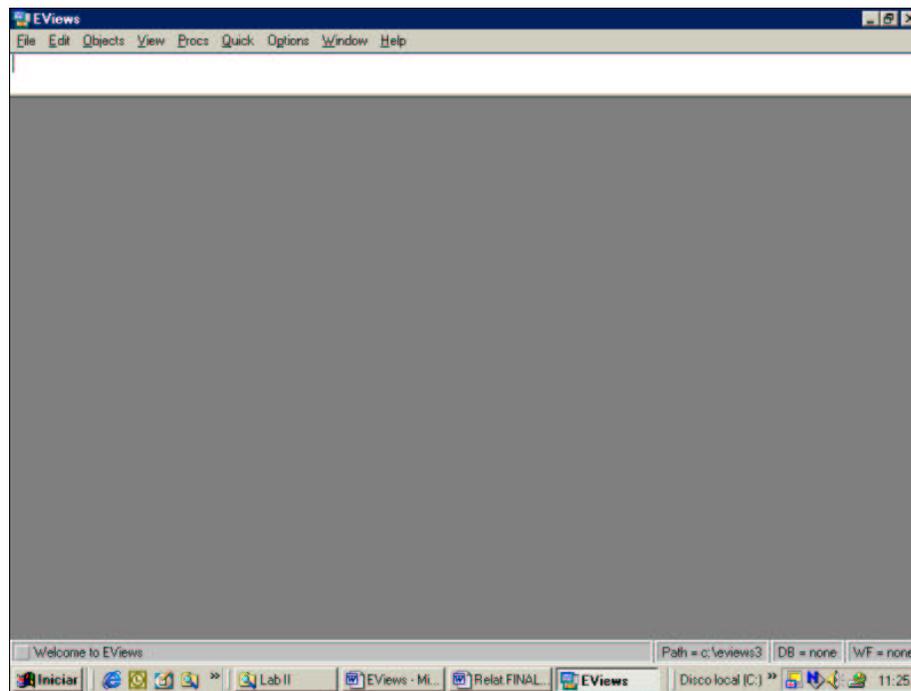


Figura 1: Tela de Menu Principal do *software* EViews.

Em primeiro lugar, precisamos criar ou abrir um arquivo de trabalho. Para criar um arquivo, efetuar o comando *File* do Menu Principal (Figura 1), em seguida *New* e *Workfile*. A seguinte tela aparecerá:

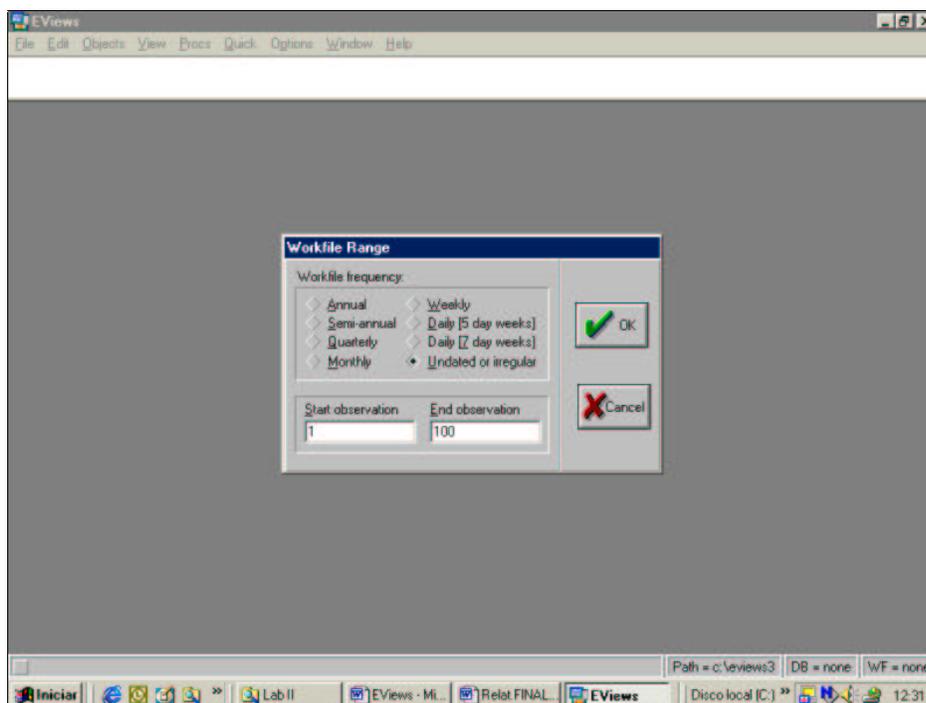


Figura 2: Tela de comando do EViews onde se define a frequência dos dados.

O programa EViews utiliza datas para identificar séries temporais. Nesta tela (Figura 2), define-se como será a frequência dos dados. A composição das datas apresentam algumas regras que devem ser

definidas no local *Workfile frequency*. Em seguida, devemos colocar a data inicial do período da série a ser trabalhada em *Start observation* e em *End observation* a data final do período.

Utilizando o modelo AR(1) não sazonal com $\phi = 0.7$ e 100 observações como exemplo, definiremos a frequência destes dados na Figura 2 selecionando a opção *Undated or irregular*. Em seguida definiremos o valor 1 como sendo a data inicial do período e o valor 100 como a data final. Esta definição de frequência e data da série foi feita deste modo porque não se conhece ou não se tem interesse em especificar a data de início fim para estes dados. As séries que apresentam sazonalidade devem ter seus períodos de oscilação definidos utilizando as outras opções do *Workfile frequency* (Figura 2). Feito isto, a seguinte tela aparecerá sobreposta à anterior:

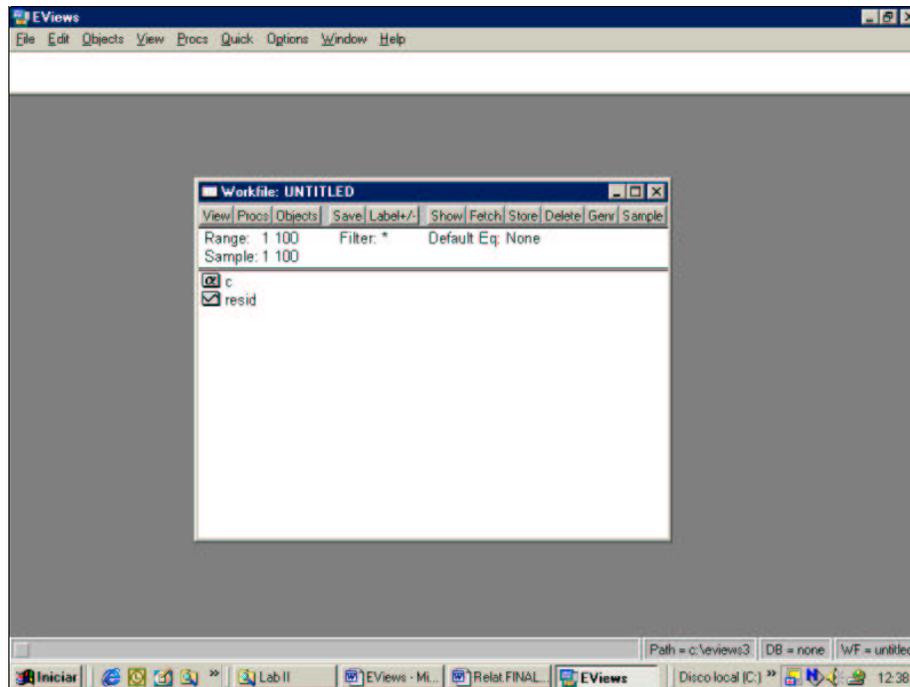


Figura 3: Janela de comandos do *software* EViews.

Esta é uma janela de trabalho (Figura 3), onde todas as tarefas executadas aparecerão como objeto. O próximo passo, é incluir as variáveis que serão trabalhadas. Os métodos de inclusão podem ser digitando diretamente os dados, copiando os dados já digitados de uma planilha qualquer ou importando os dados de algum outro *software*.

Em primeiro lugar, iremos apresentar os procedimentos usados para digitar diretamente os dados nas células correspondentes e para copiar os dados de uma planilha qualquer. Para tal, devemos escolher a opção *Objects* e *New Objects* do Menu Principal e a seguinte tela aparecerá, também sobreposta à anterior:

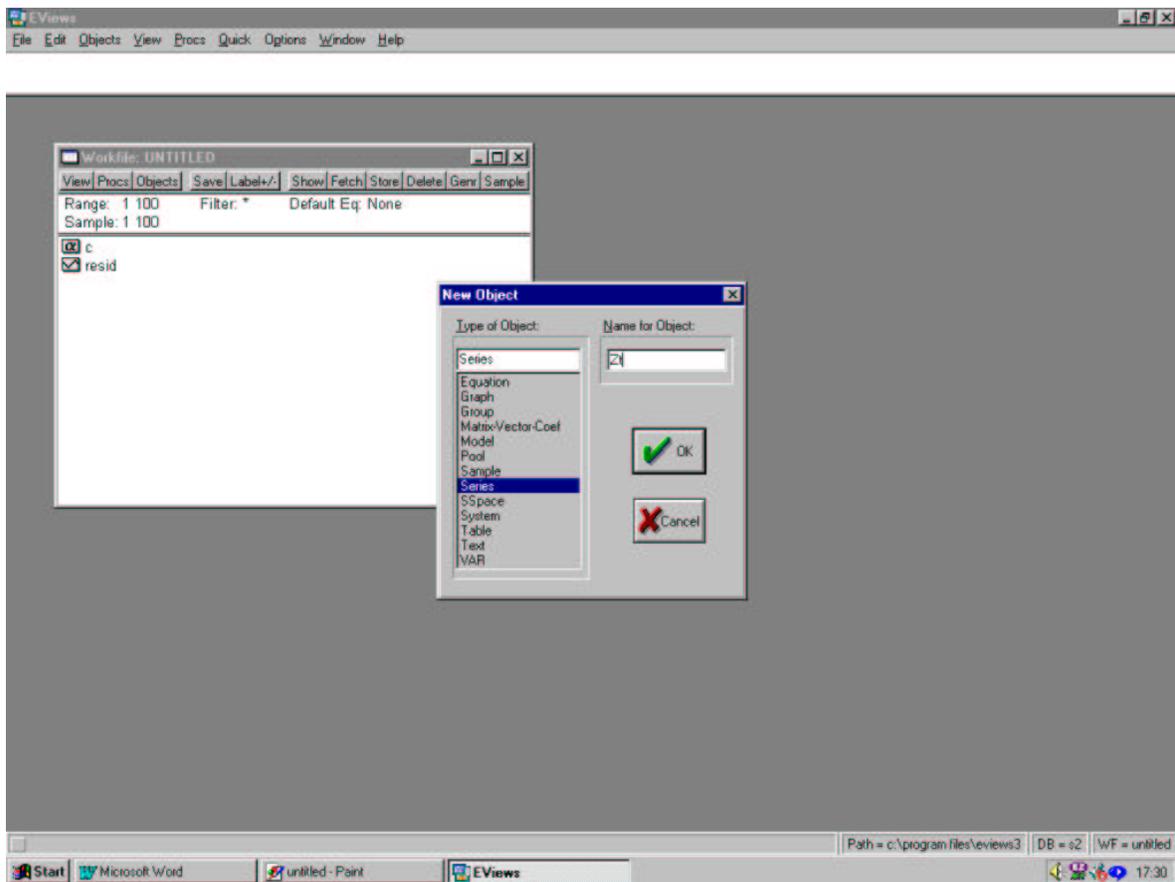


Figura 4:Tela de comandos do EViews onde se define o que será trabalhado.

Esta janela (Figura 4) apresenta os possíveis tipos de objetos que podemos trabalhar (séries, equações, gráficos, etc.) que deverão ser selecionados no local *Type of Objects*. Para a série adotada como exemplo, devemos selecionar a opção *Séries*, pois estamos definindo a entrada dos dados de uma série temporal. Em seguida, devemos nomear a série no local *Name of Object*. Feito isto, aparecerá a tela:

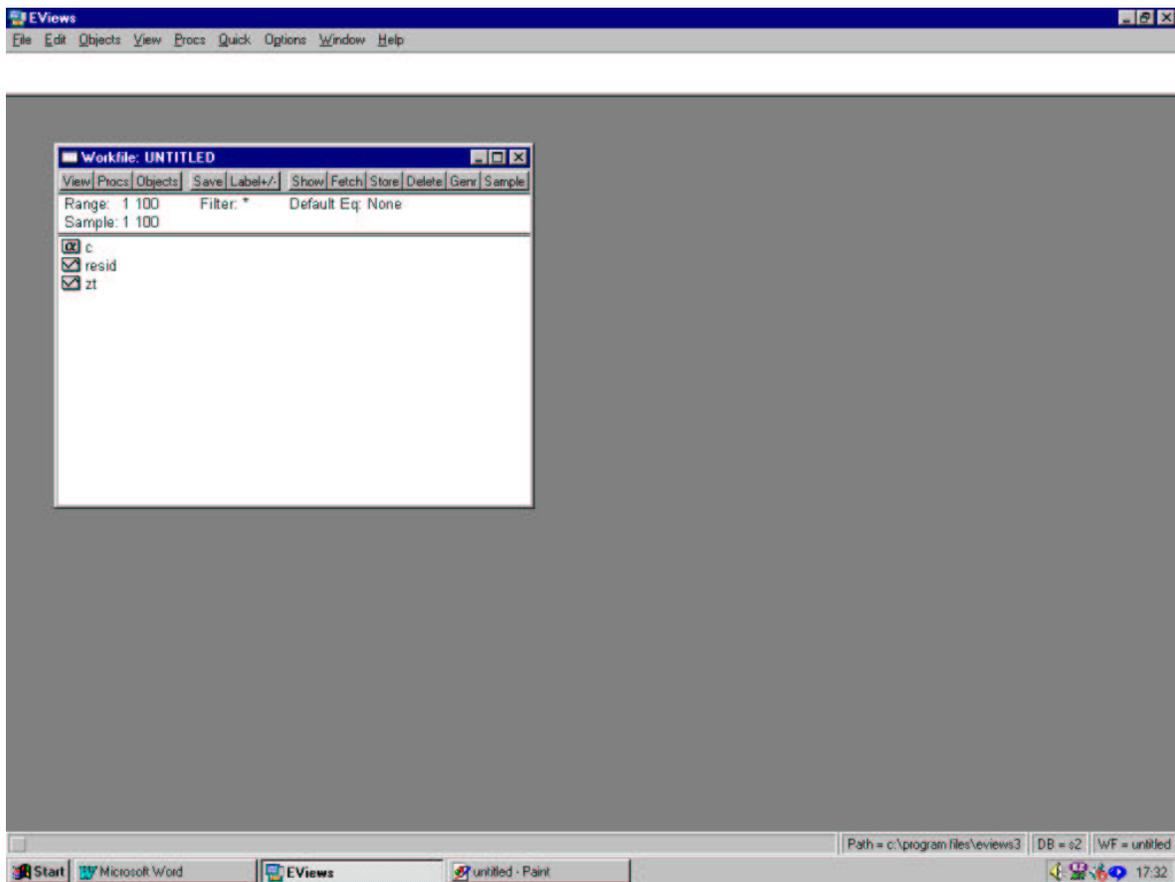


Figura 5: Tela de comandos do EViews onde selecionamos as séries que serão incluídas.

Nesta janela (Figura 5), aparecerá o nome que foi dado a série que será trabalhada. Devemos então selecioná-la. Se quisermos trabalhar com várias séries ao mesmo tempo, devemos inclui-las uma de cada vez, de modo que este procedimento será repetido várias vezes. Depois de selecionada uma ou mais séries, devemos escolher a opção *Show* e uma nova tela aparecerá sobreposta à anterior:

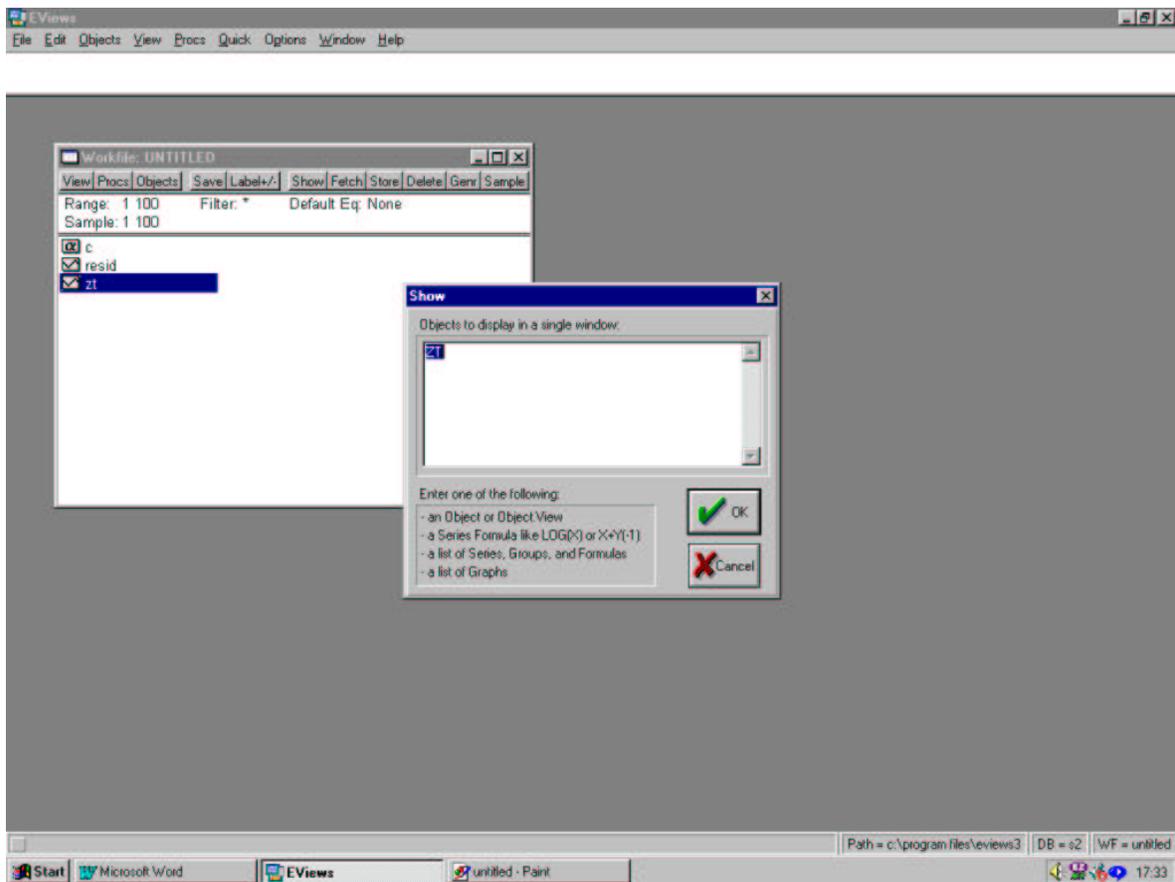


Figura 6: Tela de comandos do EViews onde mostra os nomes das séries a serem incluídas.

Esta tela (figura 6) mostra os nomes das séries que serão incluídas para posteriormente serem trabalhadas. Se o nome de todas as séries que desejamos trabalhar estiver nesta tela, o programa está pronto para receber os dados e a seguinte tela aparecerá:

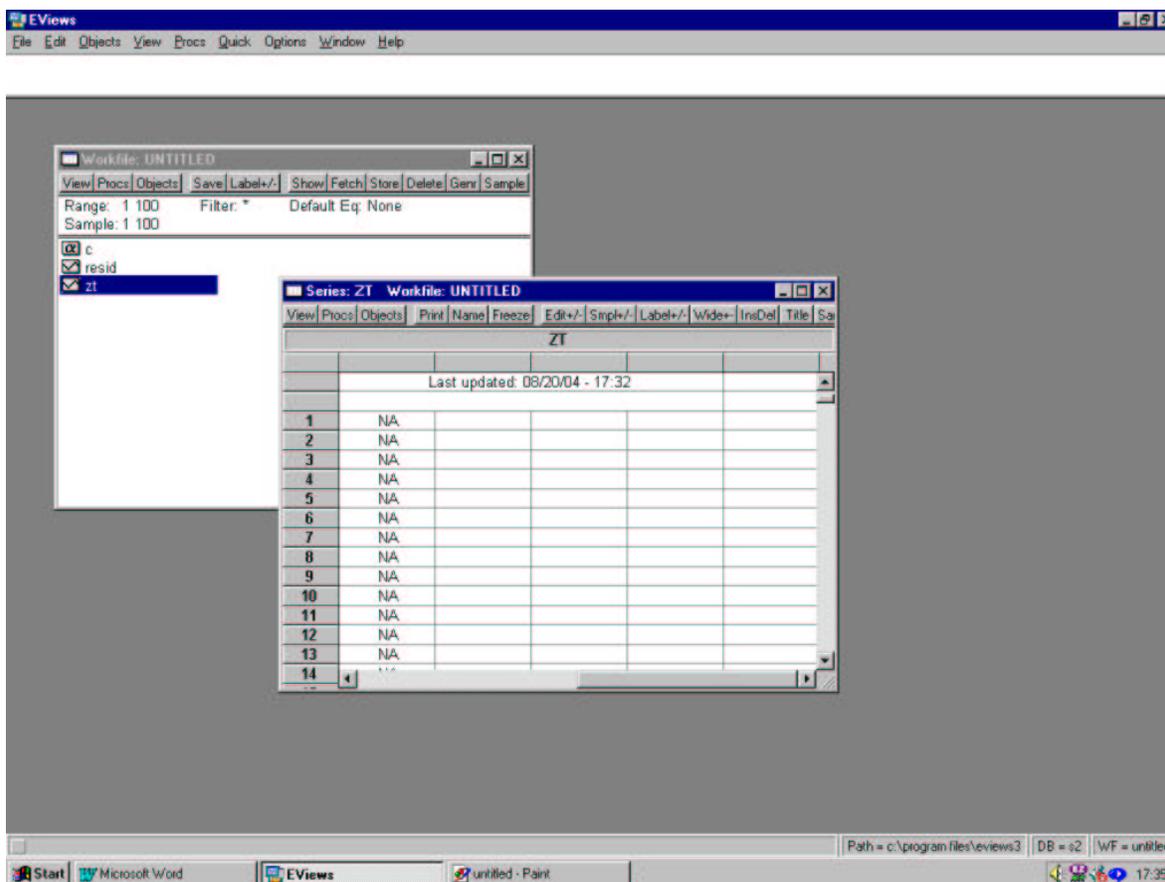


Figura 7: Tela de comandos do EViews onde são inseridos os dados das séries.

Observe que, nas células da planilha da Figura 7 aparece a sigla NA no lugar dos dados que neste momento devem ser inseridos. Para tal, devemos escolher a opção *Edit+/-*. Neste momento deve-se digitar os dados nas células da planilha da Figura 7 ou copiar os dados de uma outra planilha qualquer que deve ter os dados copiados. No nosso exemplo, utilizamos uma planilha do Excel. No próprio Excel, devemos selecionar os dados e utilizar o comando *Editar e Copiar*. O operador decimal utilizado na planilha a ser copiada deverá ser ponto e não vírgula, pois, o EViews reconhece apenas o símbolo ponto. Voltamos ao EViews e escolhemos a opção *Edit* (do Menu Principal), colocando o cursor na primeira célula com a sigla NA e, em seguida, *Paste*. Feito isto, aparecerá uma tela (Figura 8) contendo os dados.

Neste momento os dados estão prontos para serem trabalhados. Pode-se simplesmente fechar a janela que é mostrada na Figura 8 ou dar um nome para este grupo de dados, no caso de várias séries estarem sendo trabalhadas ao mesmo tempo.

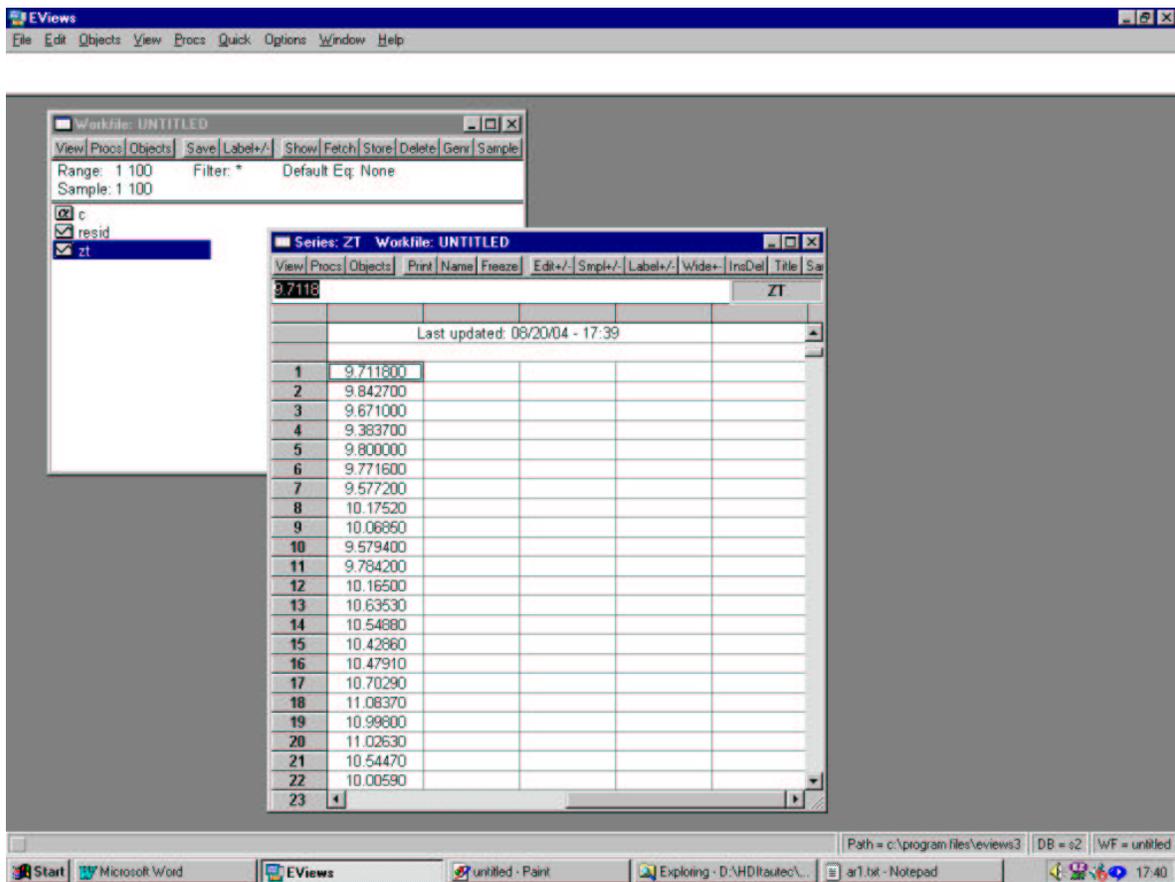


Figura 8: Tela de comandos do EViews onde encontram-se os dados.

Podemos também, importar os dados de uma planilha que já contenha os dados digitados. A planilha que será importada deve conter na primeira linha o nome das variáveis para facilitar o processo de leitura dos dados. Para efetuar a leitura dos dados selecionar a opção *file* do Menu Principal e em seguida as opções *Import* e *Read Text-Lotus-Excel....* e a seguinte tela aparecerá:

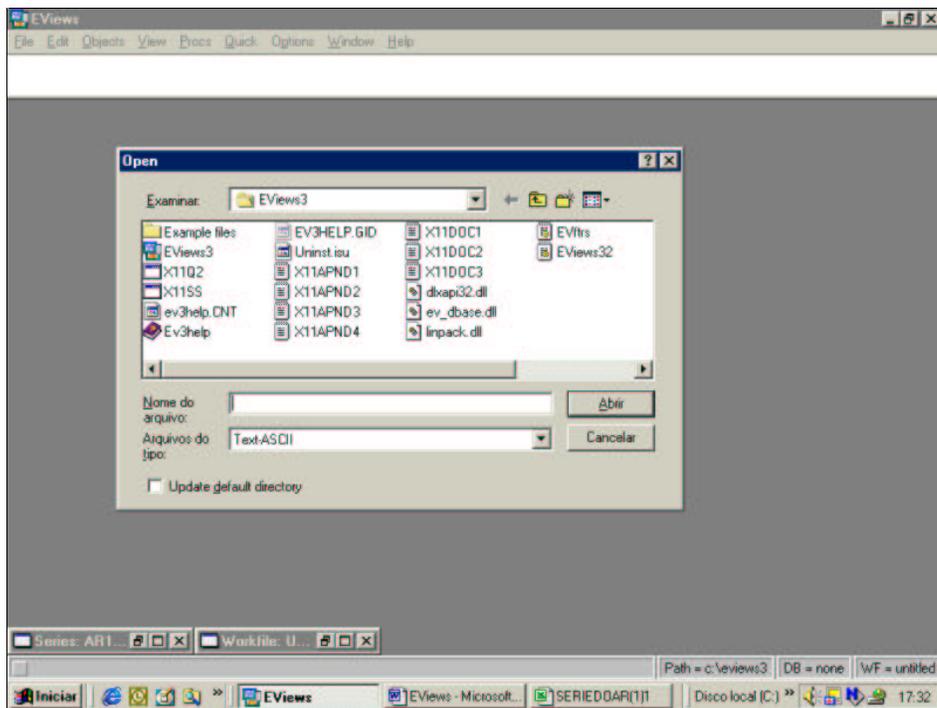


Figura 9: Tela de comandos do EViews onde especificamos o tipo e a origem do arquivo a ser importado.

Nesta tela (Figura 9), devemos especificar o tipo e a origem do arquivo a ser importado. Primeiro especificamos o tipo do arquivo que deverá ser feito no local *Arquivos do tipo*. A origem do arquivo deve ser selecionada no local *Examinar* e no quadro abaixo do local *Examinar*, deve-se clicar duas vezes em cima do arquivo de interesse, ou selecionar este arquivo que deverá ter seu nome exibido no local *Nome do arquivo* e em seguida clicar em *Abrir*. Feito isso, a seguinte tela aparecerá:

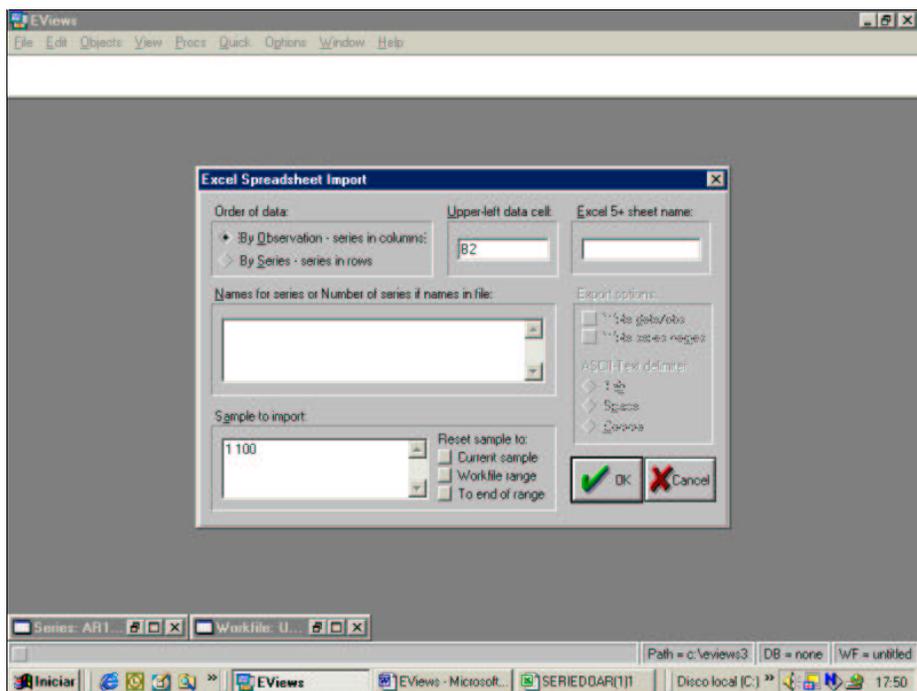


Figura 10: Tela de comandos do EViews que contém informações sobre o arquivo importado.

Nesta janela (Figura 10), aparecem algumas informações sobre os dados do arquivo a ser importado. O local *Order of Data* nos mostra como os dados estão dispostos na planilha. O local *Sample to import* nos mostra a frequência dos dados. No nosso exemplo, os dados estão dispostos em coluna e a frequência é descrita mostrando o número de observações existentes, pois os dados não apresentam sazonalidade, o que já foi mencionado e descrito anteriormente na figura 2. No local *Name for series or number of series if names in file* deve-se colocar o nome das variáveis a serem lidas ou o número de variáveis. Quando a planilha que será importada contiver o nome das variáveis na primeira linha, basta indicar o número de variáveis a serem lidas. Feito isso, o nome do arquivo importado deverá aparecer no local *Workfile*. A entrada de dados realizada desta forma é idêntica ao que já foi descrito anteriormente a partir da Figura 3.

O mais aconselhável é utilizar o procedimento de copiar os dados de uma planilha ao invés de importá-los, pois é mais fácil e seguro.

3.1.2 - Obtenção do gráfico de uma série

Para obtermos os gráficos de uma série, basta selecionar a opção *Quick* do Menu Principal e em seguida a opção *Graph*. Feito isso, a seguinte tela aparecerá:

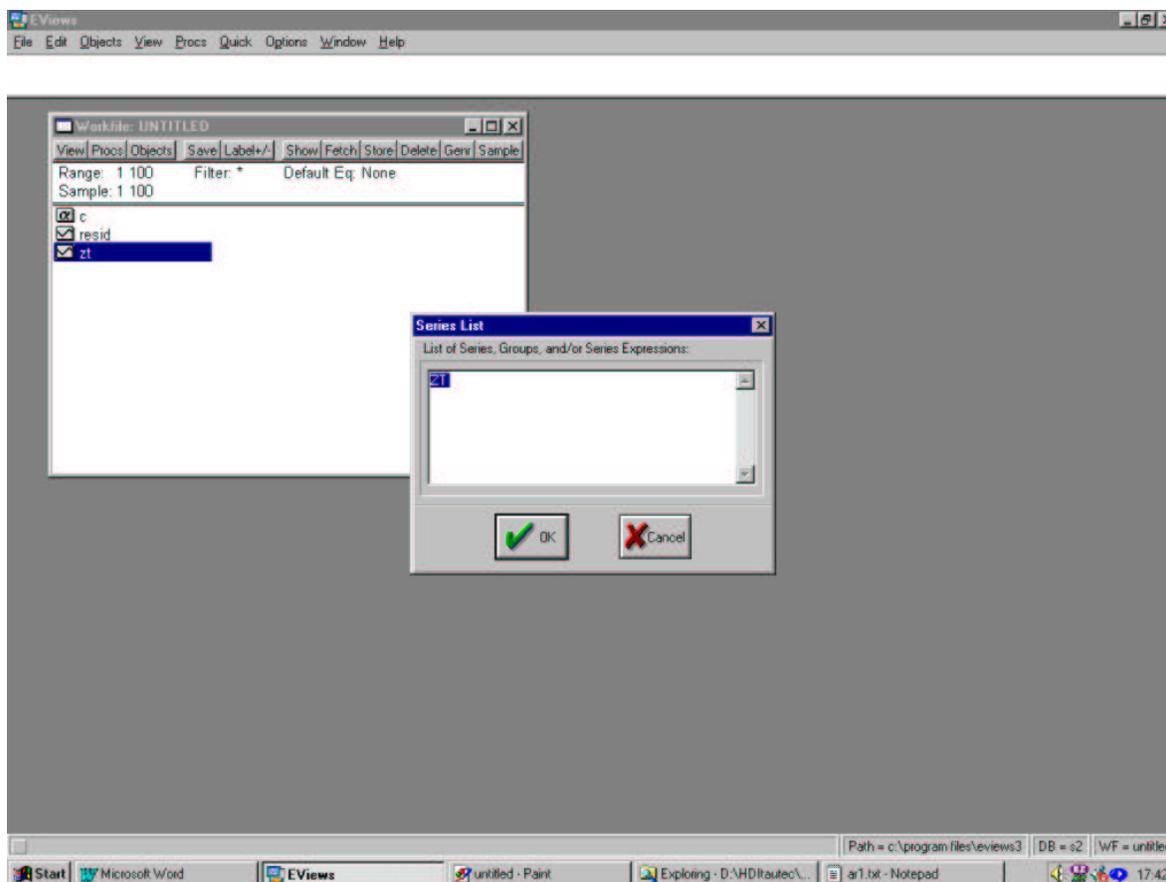


Figura 11: Tela de comandos do EViews onde selecionamos a série.

Nesta tela (Figura 11), selecionaremos a série que será usada para obtermos o gráfico. Feito isso aparecerá uma nova tela (Figura 12) na qual devemos especificar o tipo de gráfico desejado.

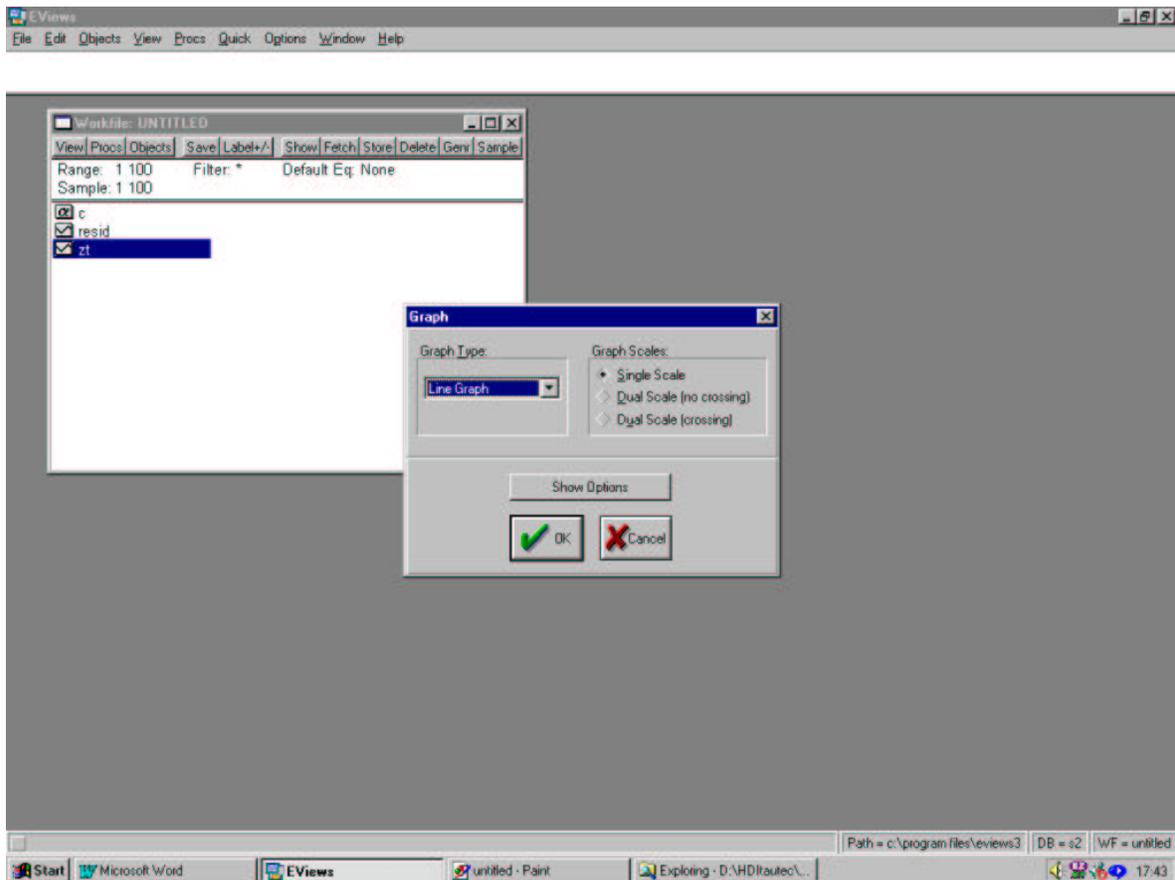


Figura 12: Tela de comandos do EViews onde especificamos o tipo de gráfico desejado

No local *Graph Type*, definiremos o tipo do gráfico, ou seja, gráfico de linha, de barras, etc. No local *Graph Scales* especificaremos a escala que será utilizada na construção do gráfico. Se quisermos que o gráfico apresente mais detalhes, devemos especificá-los no local *Graph Options*. No exemplo adotado, o gráfico da série é linear e com escala simples e é apresentado na figura a seguir (Figura 13), que é uma saída típica do *software* EViews:

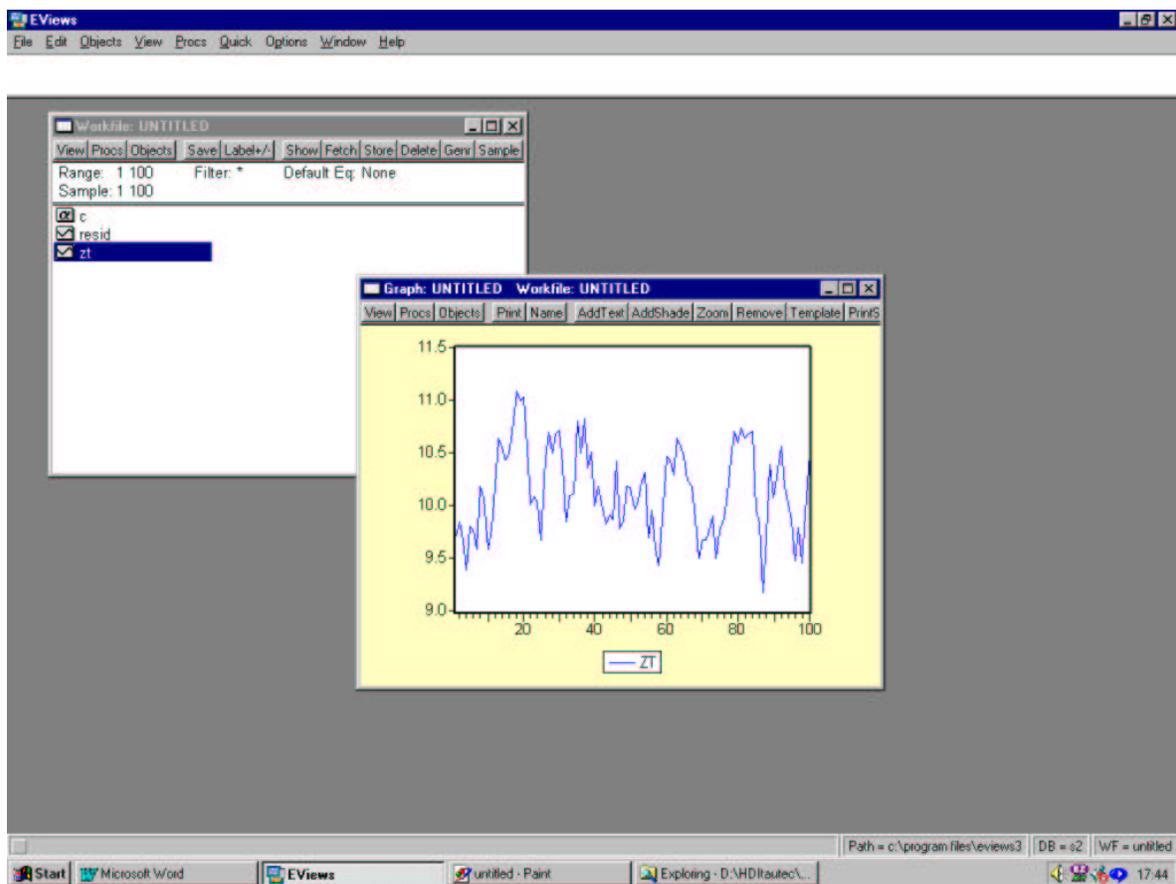


Figura 13: Gráfico da série AR(1) obtido pelo *software* EViews

3.1.3 - Obtenção dos gráficos de autocorrelação e autocorrelação parcial

Para obtermos os gráficos de autocorrelação e autocorrelação parcial de uma série, basta selecionar a opção *Quick* do Menu Principal e em seguida a opção *Series Statistics* e *Correlogram...* Feito isso, a seguinte tela aparecerá:

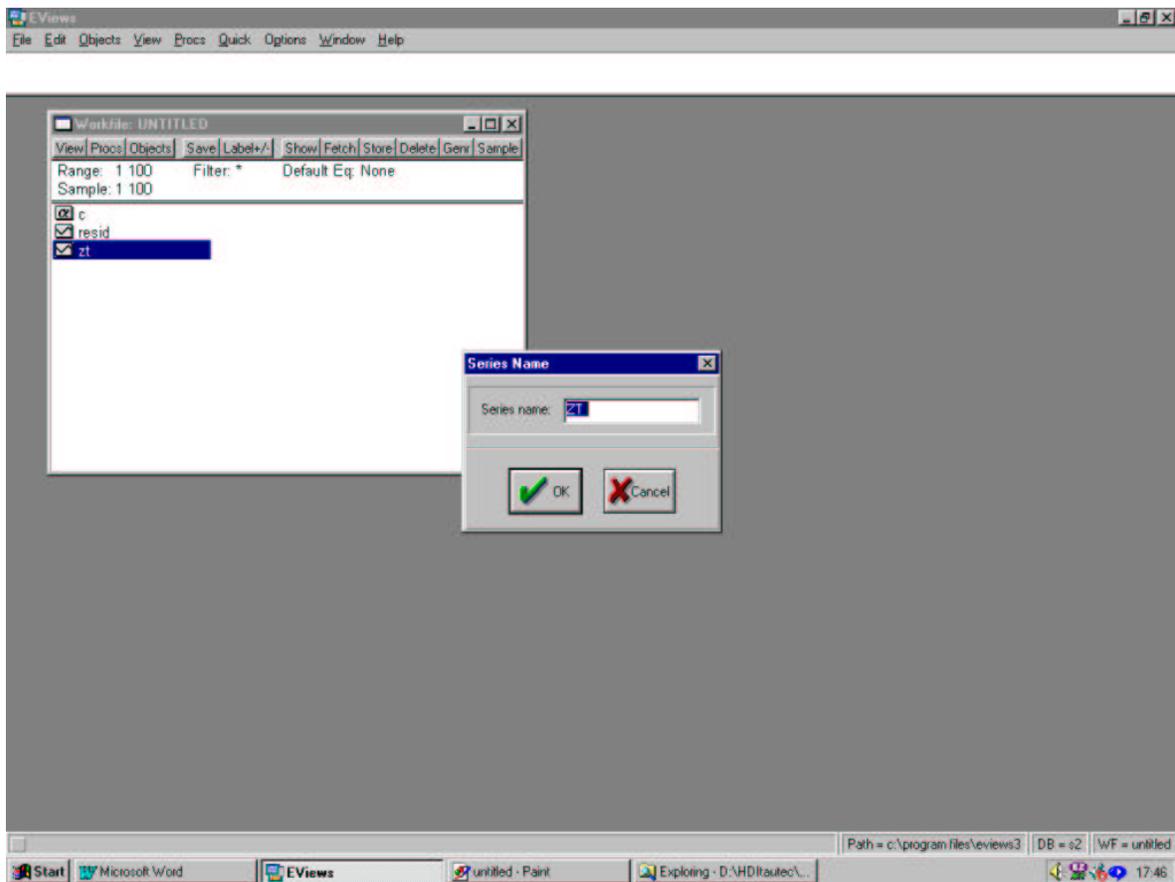


Figura 14: Tela de comandos do EViews onde especificamos o nome da série que utilizaremos para obter os correlogramas.

Nesta tela (Figura 14) aparecerá o nome da série que desejamos obter os gráficos de autocorrelação e autocorrelação parcial. Feito isto a seguinte tela aparecerá:

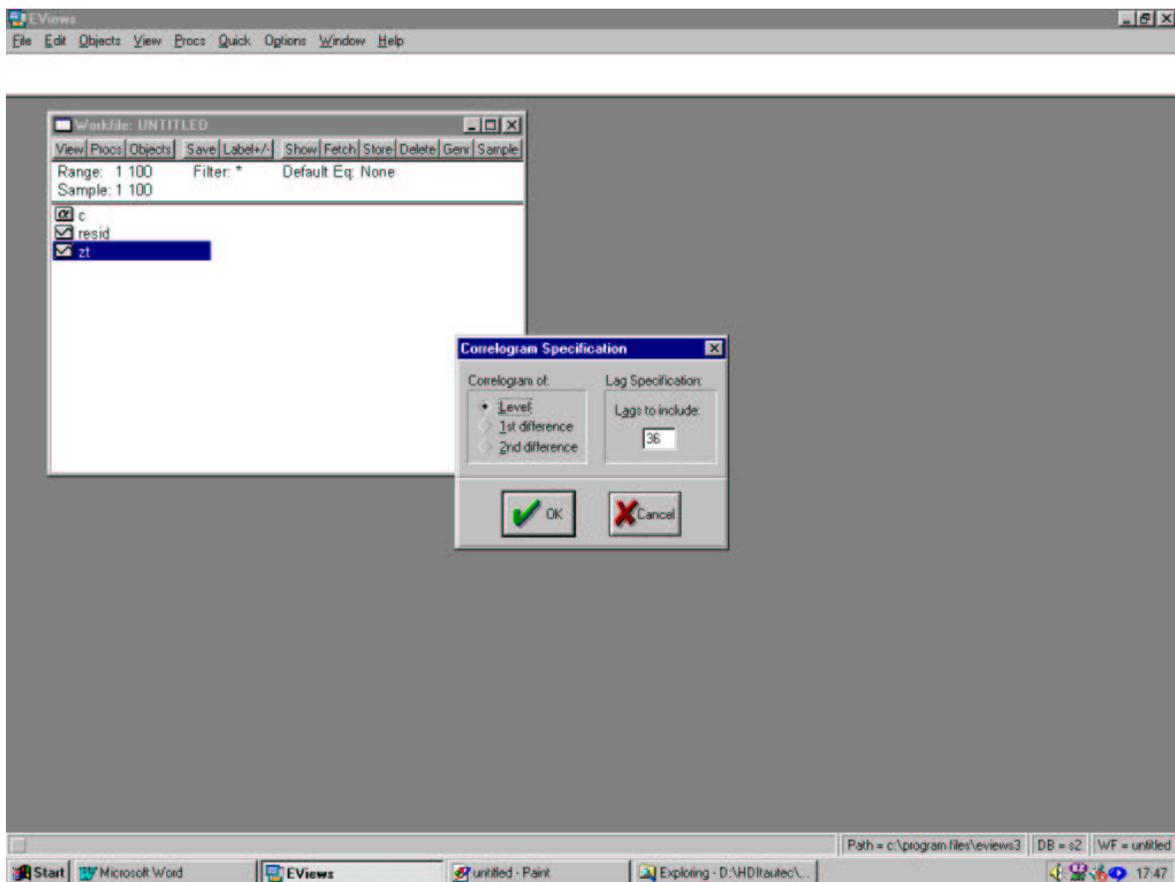


Figura 15: Tela de comandos do EViews onde especificamos o tipo de correlograma desejado.

Nesta tela (Figura 15), devemos especificar o tipo de correlograma desejado. Observamos que esta opção já apresenta os gráficos de autocorrelação e autocorrelação parcial em sua saída, simultaneamente. No local *Correlogram of* especificaremos se os correlogramas serão feitos com ou sem diferenciações na série e no local *Lag Specification*, deve ser indicado o número de *lags* que os correlogramas irão apresentar. Normalmente usamos 36 *lags* o que é suficiente para se observar o comportamento de uma série. Feito isso, obteremos os correlogramas desejados. No exemplo, os gráficos de autocorrelação e autocorrelação parcial são feitos sem diferenciações na série e apresentam apenas 36 *lags*. Estes gráficos são apresentados na figura a seguir (Figura 16) que é uma saída típica do *software* EViews. Além dos gráficos de autocorrelação e autocorrelação parcial, o EViews apresenta também o valor da autocorrelação (AC), o valor da autocorrelação parcial (PAC), a estatística Q de Ljung-Box (Q-Stat) e seu valor-p (Prob).

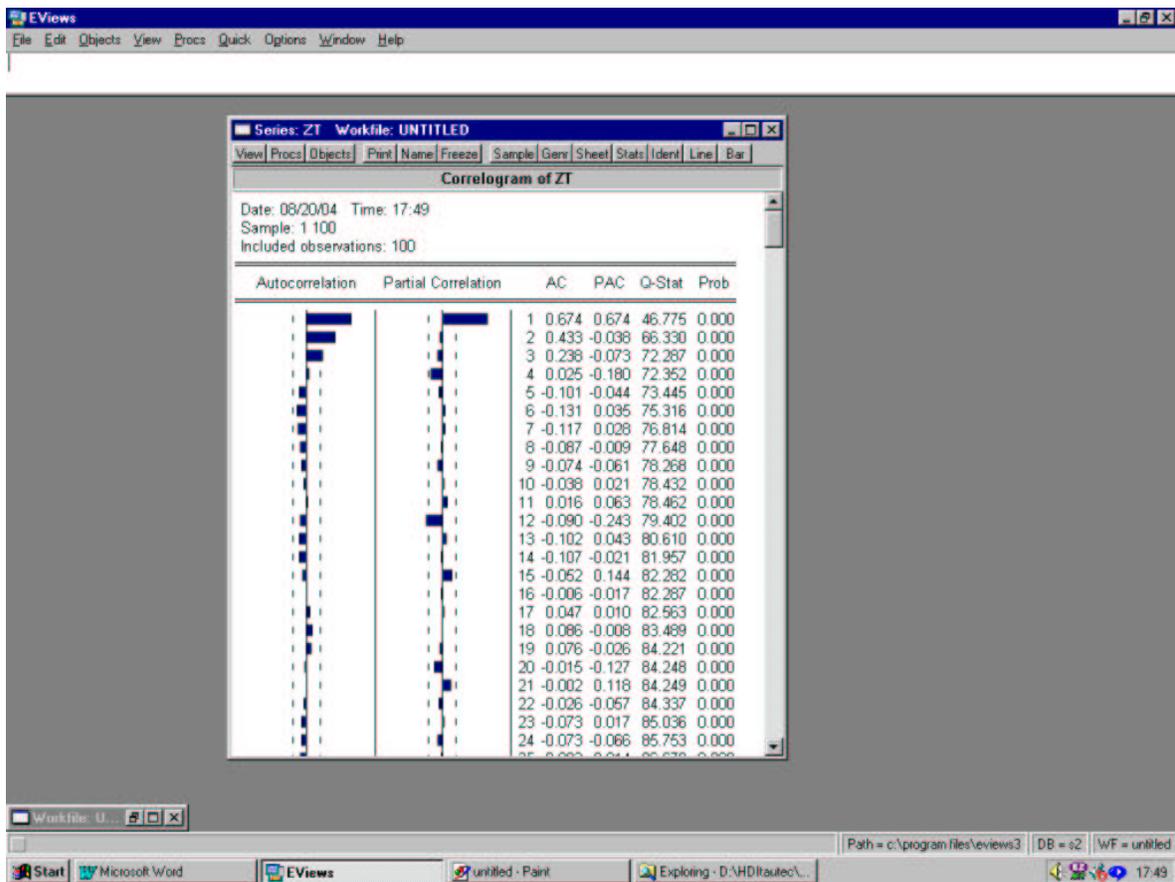


Figura 16: Gráfico de autocorrelação e autocorrelação parcial da série AR(1) obtido pelo *software* EViews.

3.1.4 - Estimação dos parâmetros de modelos ARIMA

Para estimar os parâmetros de modelos ARIMA, selecione a opção *Quick* do Menu Principal e em seguida a opção *Estimate Equation*. A opção *Estimate Equation* é usada para estimar vários tipos de modelos estatísticos, como modelos de regressão linear, semi-log, duplo log, modelos ARIMA, etc. Feito isso, a seguinte tela aparecerá:

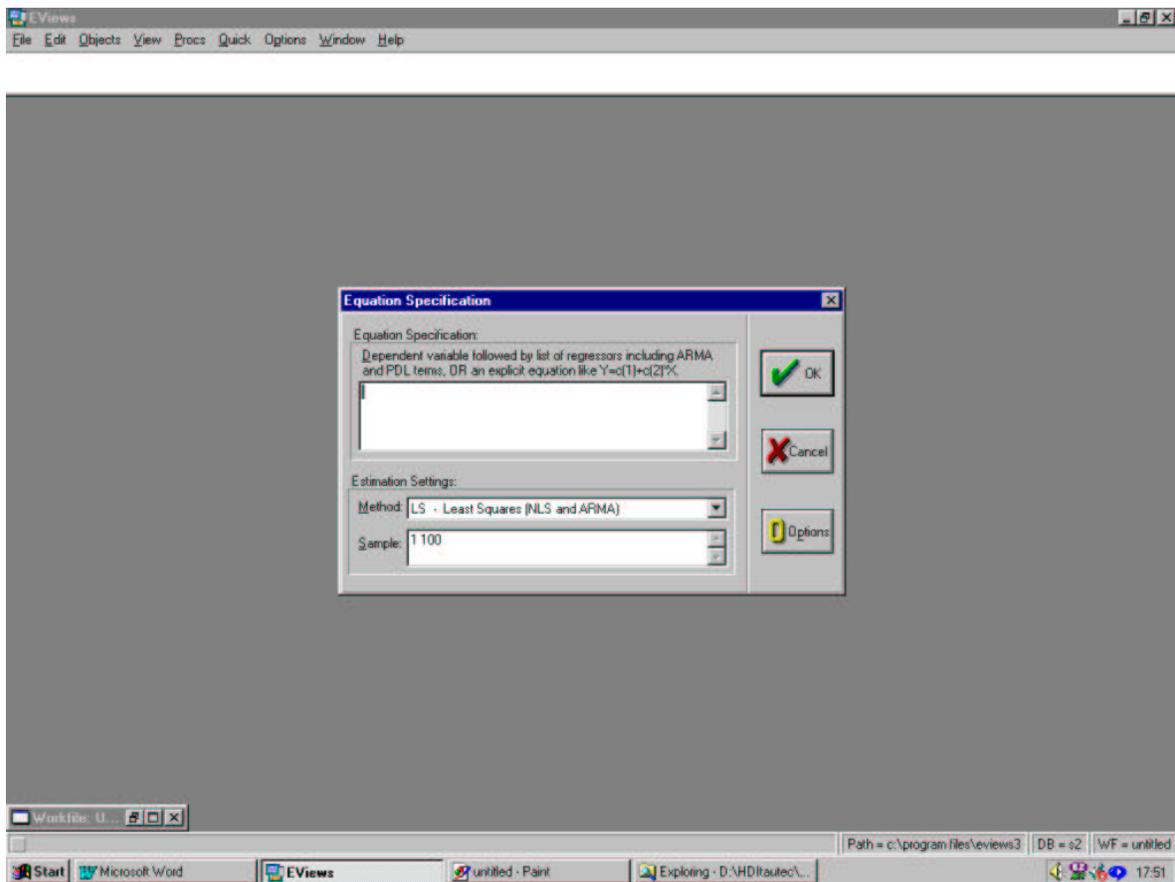


Figura 17: Tela de comandos do EViews onde especificamos o modelo a ser estimado.

Nesta tela (figura 17), devemos especificar o modelo ARIMA que desejamos estimar. No local *Estimation Settings*, devemos selecionar o método de estimação que será usado na opção *Method* e na opção *Sample*, aparecerá a frequência da série que será usada para estimar o modelo ARIMA. No local *Equation Specification*, devemos especificar qual modelo terá seus parâmetros estimados, o que não é muito simples.

Como estamos trabalhando com modelos ARIMA, apresentaremos apenas os procedimentos que devem ser usados para estimar os parâmetros destes modelos, que será descrita a seguir.

Uma norma deve ser sempre respeitada durante a especificação do que iremos estimar: deve-se colocar, nesta ordem, o nome da série que será usada, a letra “c” no caso de incluir a constante no modelo e o modelo que terá seus parâmetros estimados, sempre dando espaço entre os itens descritos. Para modelos autorregressivos não sazonais e não diferenciados, é usados a sigla $AR(p)$, sendo p a ordem do modelo autorregressivo. Para modelos de médias móveis não sazonais e não diferenciados, é usada a sigla $MA(q)$, sendo q a ordem do modelo de médias móveis. Para modelos autorregressivos e de médias móveis, são usadas as duas siglas descritas anteriormente, separadas por espaço. Para ilustrar esta idéia temos:

Regra Básica: “nome da série” c “modelo”

Para modelos AR(p): “nome da série” c AR(1) AR(2) ... AR(p)

Para modelos MA(q): “nome da série” c MA(1) MA(2) ... MA(q)

Para modelos ARMA(p,q): “nome da série” c AR(1) AR(2) ... AR(p) MA(1) MA(2) ... MA(q)

Uma observação importante é que neste *software* é possível ajustar modelos incompletos.

Como um exemplo, no caso de modelos AR(p), seja a seguinte equação:

$$Z_t = \mu + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + u_t$$

No EViews, especificaremos esta equação da seguinte forma:

$$Z \ C \ AR(1) \ AR(2) \ \dots \ AR(p)$$

onde Z é a variável dependente, C é a constante e $AR(1), \dots, AR(p)$ são as regressoras.

Se o modelo a ser estimado apresentar sazonalidade, as siglas usadas serão: $SMA(Q)$ para modelos de médias móveis sazonais, onde Q é o período de sazonalidade e $SAR(P)$ para modelos autorregressivos sazonais, onde P é o período de sazonalidade.

Para modelos que necessitam de diferenciação, a seguinte sigla deve ser usada, $D(\text{nome da série}, d, D)$, onde d é o número de diferenciações simples, D é o número de diferenciações sazonais e “nome da série” deve conter o nome que foi dado à série que será usada. Para ilustrar, supondo a série de interesse ser chamada de “taxa”, temos:

Para modelos $ARIMA(1,0,1)(0,1,1)_{12}$: taxa c AR(1) MA(1) SMA(12) D(taxa,0,1)

Para modelos $ARIMA(0,1,1)(1,1,1)_{12}$: taxa c MA(1) SAR(12) SMA(12) D(taxa,1,1)

Para modelos $ARIMA(1,1,1)(0,0,1)_{12}$: taxa c AR(1) MA(1) SAR(12) D(taxa,1,0)

Para modelos $ARIMA(1,1,1)(1,1,1)_{12}$: taxa c AR(1) MA(1) SAR(12) SMA(12) D(taxa,1,1)

e assim por diante.

Como exemplo, seja um modelo $ARIMA(p,1,0)(0,1,0)_{12}$, que tem a seguinte equação:

$$\Phi(B)(1-B)(1-B^{12})Z = u$$

No EViews, especificaremos esta equação da seguinte forma:

$$D(Z,1,1) \ AR(1) \ AR(2) \ \dots \ AR(P)$$

onde Z é a variável dependente, $d=1, D=1$ e $AR(1), \dots, AR(P)$ são as regressoras.

No exemplo que está sendo usado, temos um modelo AR(1) não sazonal e não diferenciado, portanto devemos usar apenas a constante c e a sigla $AR(1)$, como é mostrado na figura abaixo:

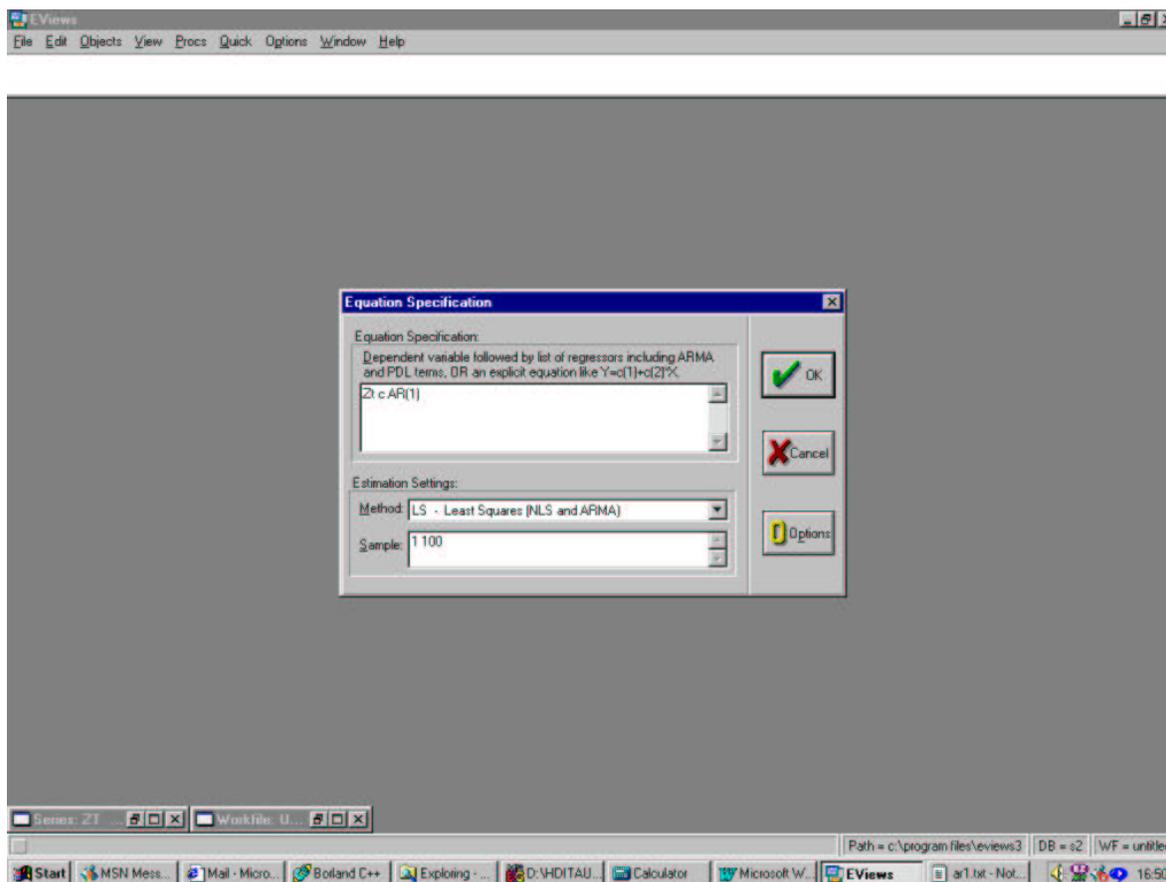


Figura 18: Tela de comandos do EViews onde especificamos o modelo a ser estimado.

Nesta tela (figura 18) especificamos o modelo que terá seus parâmetros estimados e o método utilizado para isto. O modelo é autorregressivo não sazonal e não diferenciado de ordem 1 e o método usado é o de mínimos quadrados ordinários, ou seja, *Least Squares*.

O resultado da estimação da série do exemplo é apresentada na figura a seguir (Figura 19), que é uma saída típica do *software* EViews:

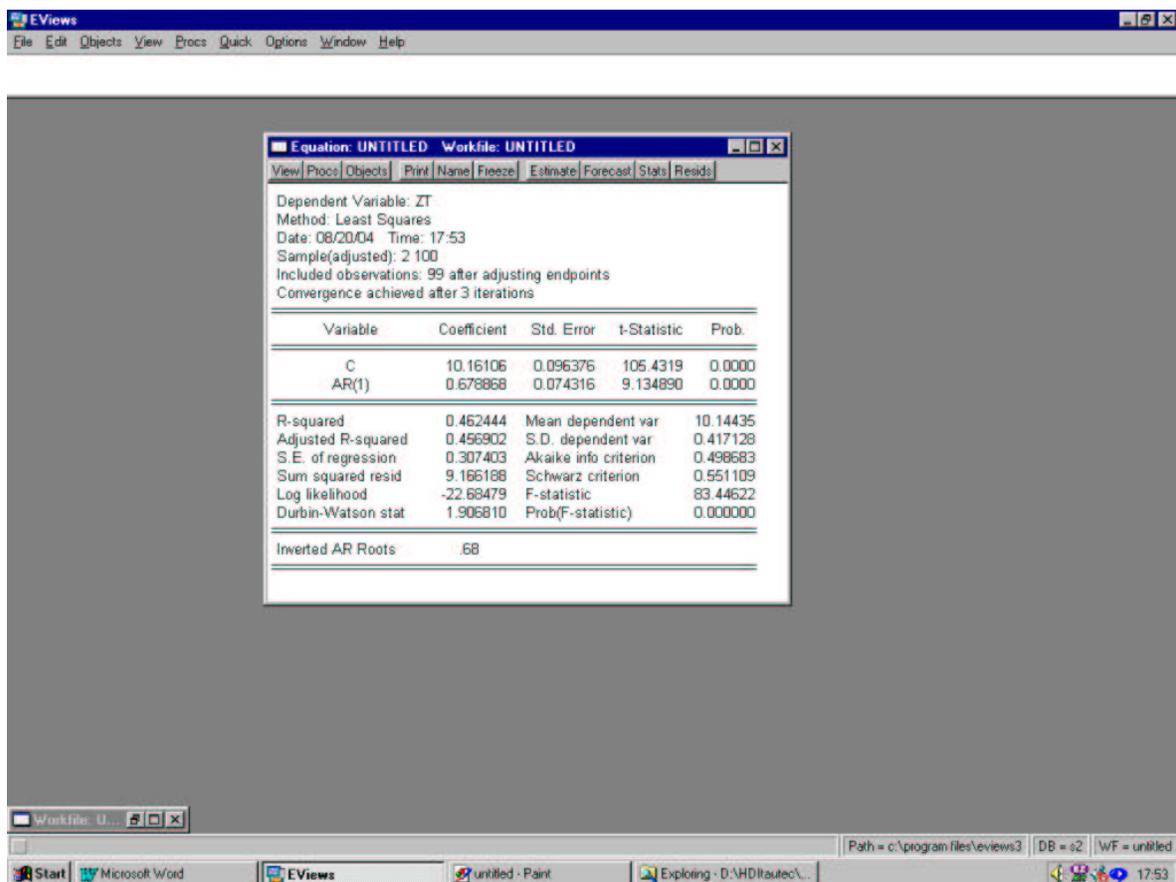


Figura 19: Parâmetros estimados para a série AR(1) pelo EViews.

As estatísticas de ajuste calculadas pelo EViews são:

R-squared: É a fração da variabilidade da variável dependente explicada pelas variáveis independentes.

Adjusted R-squared: O R^2 ajustado penaliza o R^2 pela adição de regressores que não contribuem para o poder explicativo do model. Ele nunca será maior que o R^2 e pode decrescer quando se soma regressores.

Standard Error of the Regression (S.E. of regression): O erro padrão da regressão é uma medida resumo baseada na variância estimada dos resíduos.

Sum of Squared Residuals: A soma de quadrados residual pode ser usada em uma variedade de cálculos estatísticos, e é apresentada separadamente por conveniência.

Log Likelihood: EViews reporta o valor da função de log-verossimilhança (assumindo erros normalmente distribuídos) avaliada nos valores estimados dos coeficientes.

Durbin-Watson Statistic: A estatística de Durbin-Watson (DW) mede a correlação serial nos resíduos. Como regra, se DW é menor que 2, há evidência de correlação serial positiva.

Mean dependent var e S.D. dependent var: A média e o desvio-padrão da variável dependente.

Akaike Information Criterion (AIC): O AIC é frequentemente usado na seleção de modelos. Modelos que apresentam os menores valores de AIC são os preferidos.

Schwarz Criterion (SC): O Critério de Schwarz é uma alternativa ao AIC que impõe uma penalidade alta para coeficientes adicionais.

F-Statistic e Prob(F statistic): A estatística-F testa a hipótese de que todos os coeficientes de inclinação (excluindo a constante, ou o intercepto) são zero. O valor-p denota o nível de significância do teste-F.

3.2 - Software MINITAB for Windows

O MINITAB é um pacote estatístico amplamente utilizado para análise de dados. Este *software* é caracterizado pela simplicidade de uso e por ter excelentes rotinas para cálculos e gráficos, além de poder ser usado em qualquer área como estatística, engenharia, medicina etc.

A seguir apresentaremos os quatro procedimentos básicos para utilização do *software* no tratamento de modelos ARIMA. A versão do MINITAB utilizada neste trabalho é a 13.0.

3.2.1 - Entrada dos dados no programa

Antes de iniciar o uso das ferramentas estatísticas, precisamos entrar com os dados no programa. A janela principal (Figura 20) apresenta o *Menu Principal* que contém todos os comandos necessários para a utilização do *software*, a subjanela *Session* que mostra os resultados não gráficos das análises estatísticas feitas e a subjanela *Data* que é usada para a entrada, edição e visualização dos dados. Existem outras duas subjanelas que podem ser utilizadas para auxiliar os usuários do programa: a subjanela *History* que registra os comandos submetidos pelo usuário e a subjanela *Info* que mostra um resumo da planilha de dados. Estas subjanelas são ativadas na opção *Window* do Menu Principal, que contém o nome das quatro subjanelas que podem ser usadas. Trabalharemos com apenas duas subjanelas *Session* e *Data*.

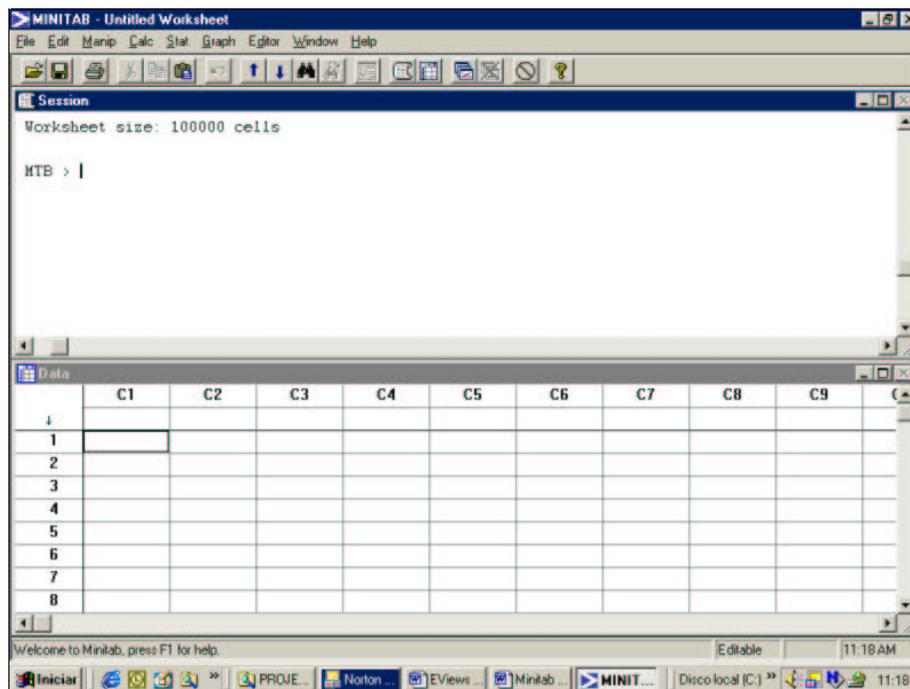


Figura 20: Janela principal do MINITAB

Para entrar com um banco de dados no programa, podemos digita-lo diretamente na planilha apresentada na subjanela *Data* ou ler os dados já digitados em uma outra planilha, como por exemplo o Excel. A planilha a ser lida pelo MINITAB deve conter apenas dados, pois não é possível importar

planilhas que apresentam títulos ou observações de qualquer natureza diferente da dos dados (números). Para isto, devemos selecionar a opção *File*, em seguida a opção *Other Files* e ao final a opção *Import Special Text...*. Na janela que se abre devemos especificar em que coluna os dados serão copiados e o formato dos mesmos. Para exportar dados, devemos proceder da mesma forma, porém escolhendo a opção *Export Special Text...*

Para abrir um arquivo já digitado e que foi armazenado no formato específico do MINITAB, devemos escolher a opção *File* e em seguida a opção *Open Worksheet* (ou *Open Project*) e a seguinte tela aparecerá sobreposta à tela principal do programa:

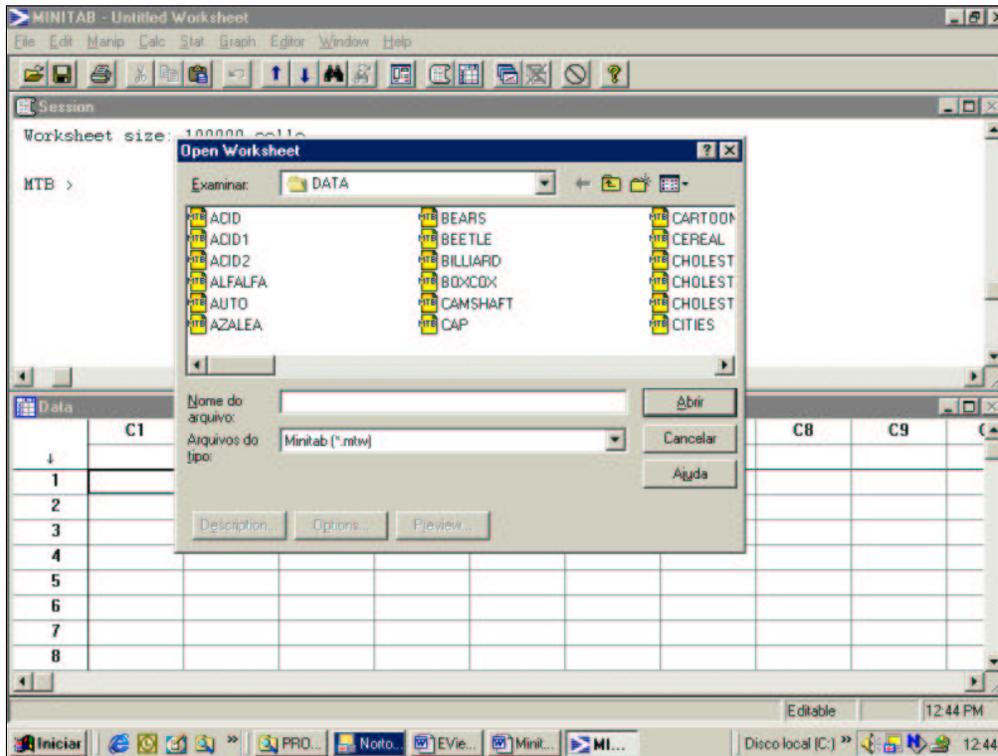


Figura 21: Tela de comandos de MINITAB onde selecionamos o arquivo que será aberto

Nesta tela (Figura 21), selecionaremos o arquivo que queremos abrir na opção *Examinar*. Na opção *Arquivos do tipo*, devemos selecionar o tipo do arquivo que iremos abrir. No nosso caso devemos selecionar arquivos do tipo “mtw” para a opção *Open Worksheet*, ou “MPJ” para a opção *Open Project* e os dados aparecerão na planilha da subjanela *Data*. Neste momento os dados estão prontos para serem trabalhados.

Para aproveitarmos um banco de dados que já foi digitado e transportá-lo para o MINITAB, o caminho mais fácil é abrir o banco de dados no próprio programa em que ele foi digitado, copiá-lo e colá-lo na planilha da subjanela *Data* do MINITAB. Devemos lembrar que este programa reconhece apenas o símbolo ponto e não a vírgula. Neste momento os dados estão prontos para serem trabalhados.

O nome da série pode ser especificado na casela exatamente abaixo do número da coluna (C1, C2, etc.) onde estão os dados.

3.2.2 - Obtenção do gráfico de uma série

O gráfico de uma série pode ser obtido utilizando a opção *Graph* do Menu Principal. Esta opção contém vários tipos de gráficos que podem ser obtidos. No exemplo adotado para ilustrar a utilização dos *softwares*, devemos escolher a opção *Time Series Plot*, pois estamos trabalhando com séries temporais. Um outro caminho para se obter um gráfico de séries temporais é a opção *Stat* do Menu Principal e em seguida as opções *Time Series* e *Time Series Plot*. Feito isso, a seguinte tela parecerá:

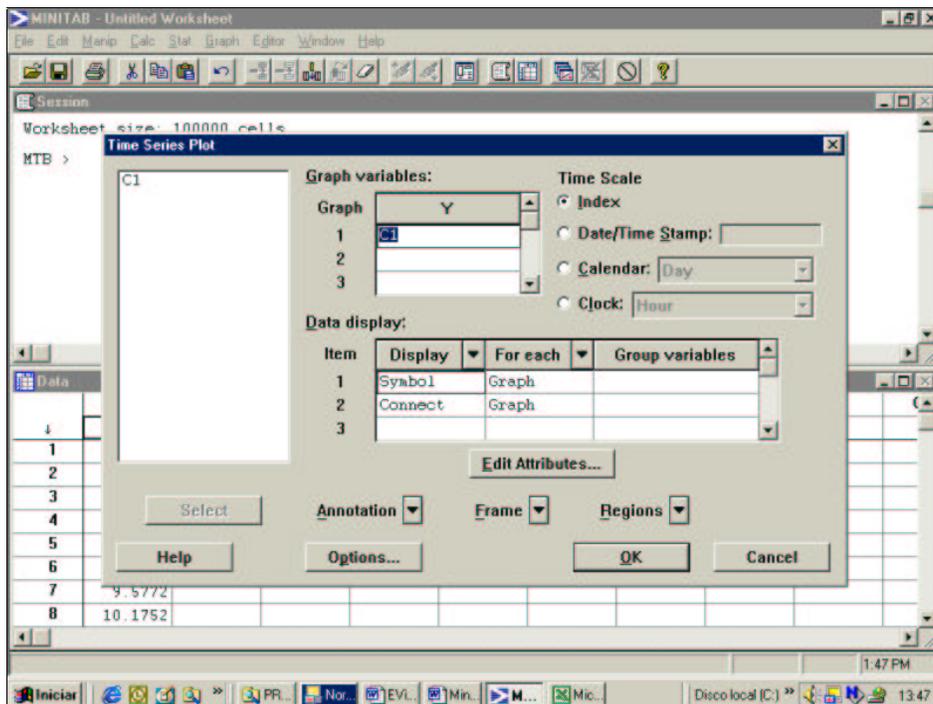


Figura 22: Tela de comandos de MINITAB onde especificamos as características do gráfico a ser obtido.

Nesta tela (Figura 22), iremos definir como será o gráfico. No quadro branco à esquerda da tela selecionaremos a série que será usada para obtermos o gráfico. Uma vez selecionada, o nome que foi dado à série ou o local (célula da planilha onde se encontram os dados que devem estar dispostos verticalmente) onde se encontram os dados devem aparecer no local *Graph variables*. Nos outros locais são definidas apenas as características do gráfico que o usuário desejar. Vários gráficos podem ser feitos ao mesmo tempo, basta repetir o procedimento descrito anteriormente para cada gráfico desejado. Feito isso, o gráfico aparecerá sobreposto à tela do programa MINITAB, como é mostrado a seguir:

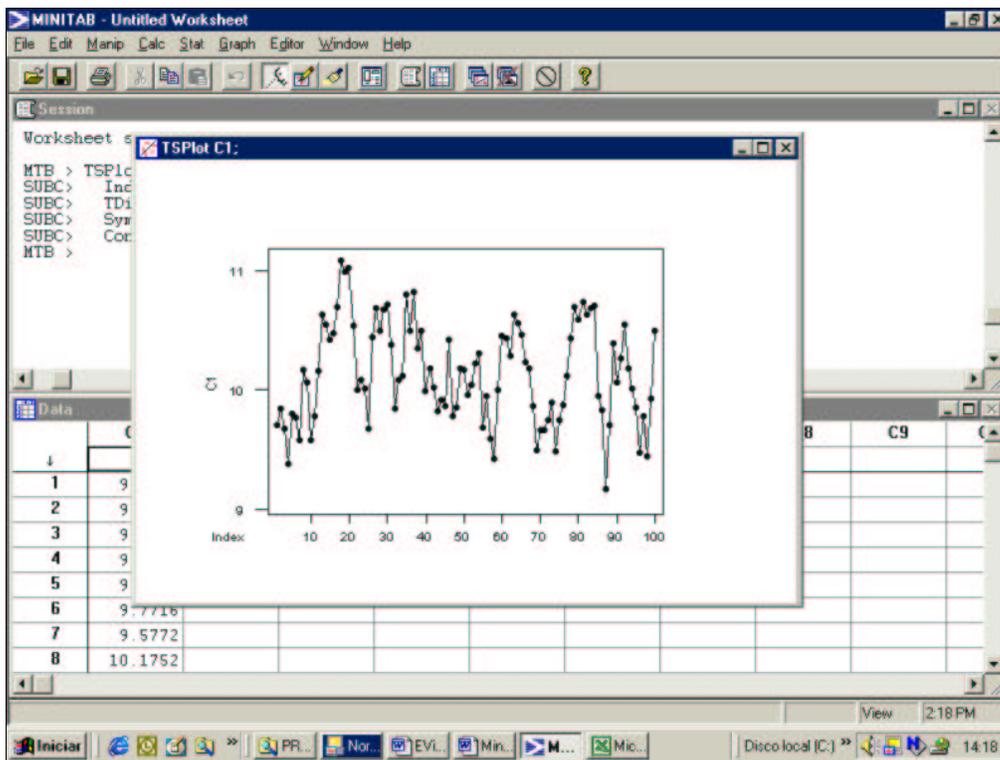


Figura 23: Gráfico feito pelo MINITAB utilizando a série AR(1) como exemplo.

Nesta tela (Figura 23) é apresentado o gráfico da série AR(1) adotada para exemplificar os procedimentos do programa MINITAB.

3.2.3 - Obtenção dos gráficos de autocorrelação e autocorrelação parcial

Para obtermos os gráficos de autocorrelação, basta selecionar a opção *Stat* do Menu principal e em seguida *Time Series* e *Autocorrelation* e a seguinte tela aparecerá:

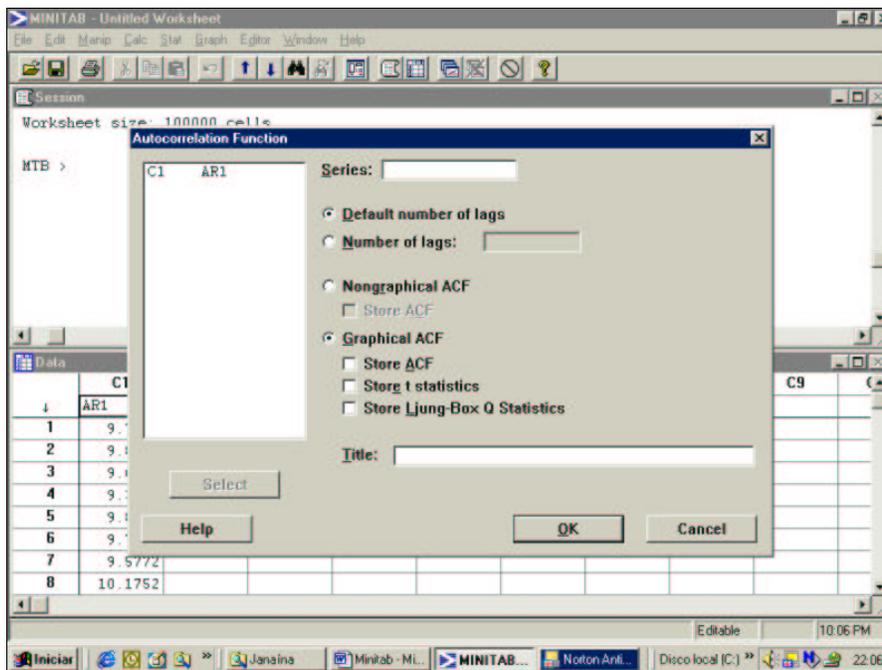


Figura 24: Tela de comandos do MINITAB onde especificamos as características do gráfico de autocorrelação a ser obtido.

Nesta tela (Figura 24), devemos selecionar a série que será usada para obter o gráfico de autocorrelação no quadro branco localizado à esquerda da tela. Feito isso, a série selecionada terá seu nome ou localização (célula da planilha onde se encontram os dados que devem estar dispostos verticalmente) inserido no local *Series*. Normalmente, a opção *Default number of lags* já vem selecionada e indica que o número de *lags* usados na construção do gráfico de autocorrelação é o padrão do programa, ou seja, 25 *lags*. Se desejarmos aumentar ou diminuir o número de *lags*, devemos selecionar a opção *Number of lags* e indicar o número desejado no quadrinho ao lado. A opção *Nongraphical ACF* nos fornece os valores dos *lags* ordenados em um gráfico do tipo ramo-e-folhas e se quisermos armazenar os valores das autocorrelações na planilha de trabalho, basta ativar a opção *Store ACF*. A opção *Graphical ACF* nos fornece os valores dos *lags* ordenados e um gráfico. Se quisermos armazenar os valores destes *lags* na planilha de trabalho, basta ativar a opção *Store ACF* e se desejarmos obter as estatísticas de teste *t* e Ljung-Box Q, ativarmos respectivamente as opções *Store t statistics* e *Store Ljung-Box Q Statistics*. No nosso exemplo, usaremos apenas 25 *lags* e a opção *Graphical ACF* para obtermos o gráfico de autocorrelação da série AR(1) que é uma saída típica do *software* MINITAB, como é mostrado a seguir (Figura 25):

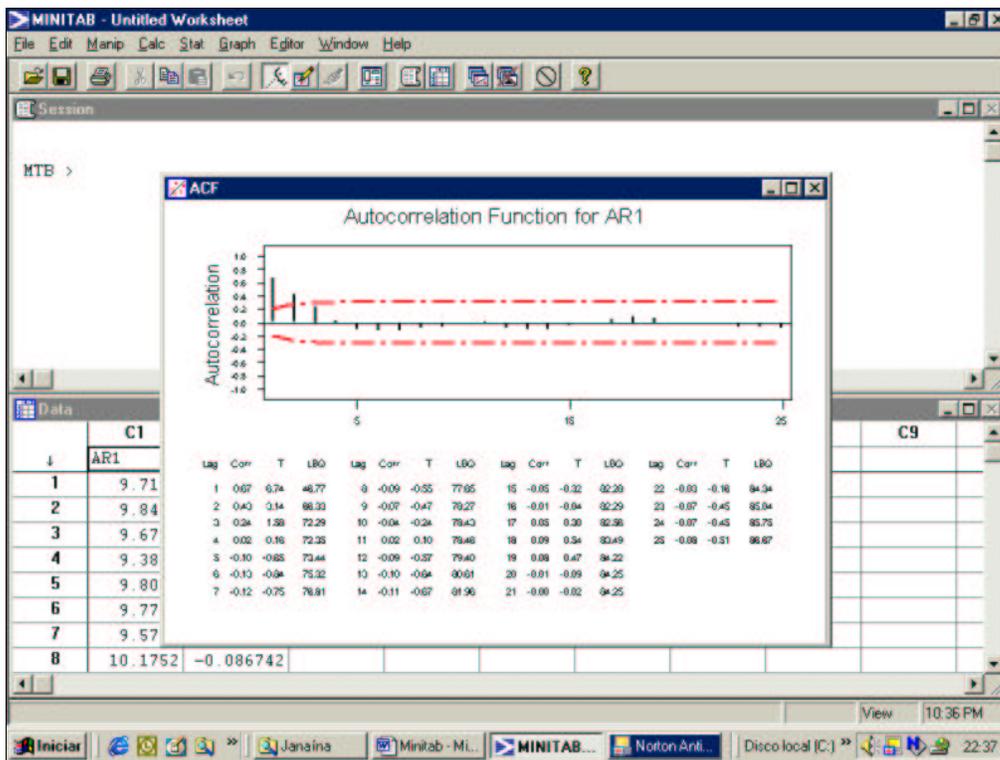


Figura 25: Gráfico de autocorrelação da série AR(1) feito pelo MINITAB.

Para obtermos os gráficos de autocorrelação parcial, o procedimento é semelhante ao descrito acima. Basta seleccionar a opção *Stat* do Menu principal e em seguida *Time Series* e *Partial Autocorrelation* e a seguinte tela aparecerá:

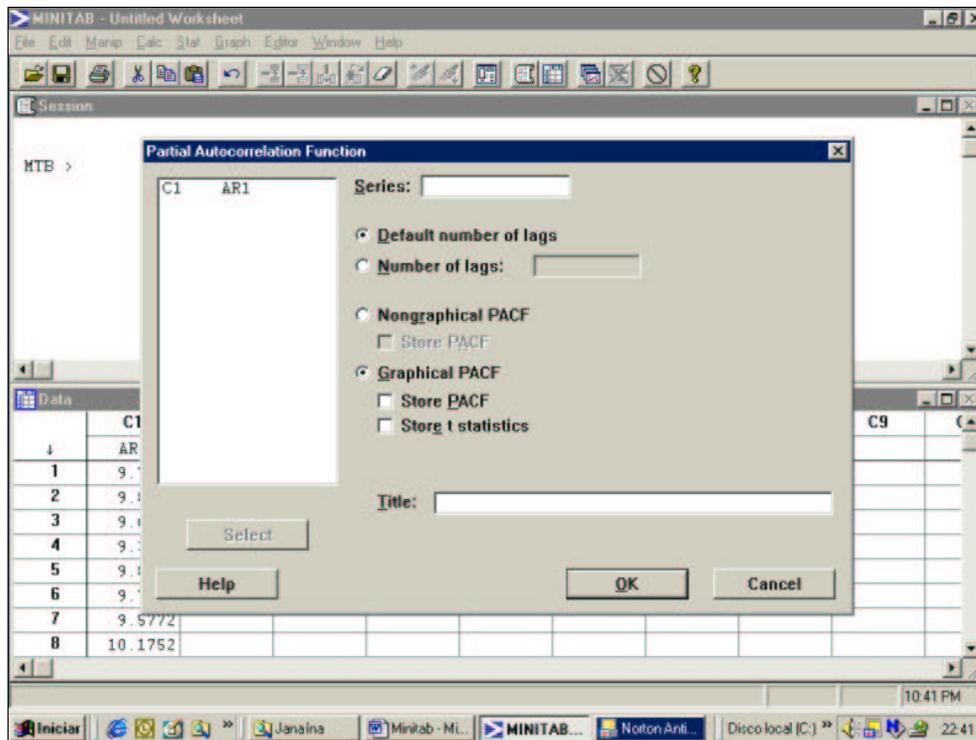


Figura 26: Tela de comandos do MINITAB onde especificamos as características do gráfico de autocorrelação parcial a ser obtido.

Nesta tela (Figura 26), devemos selecionar a série que será usada para obter o gráfico de autocorrelação parcial no quadro branco localizado à esquerda da tela. As mesmas observações feitas para o gráfico de autocorrelação (ACF) são válidas aqui. No nosso exemplo, usaremos apenas 25 lags e a opção *Graphical PACF* para obtermos o gráfico de autocorrelação parcial da série AR(1) que é uma saída típica do *software* MINITAB, como é mostrado a seguir (Figura 27):

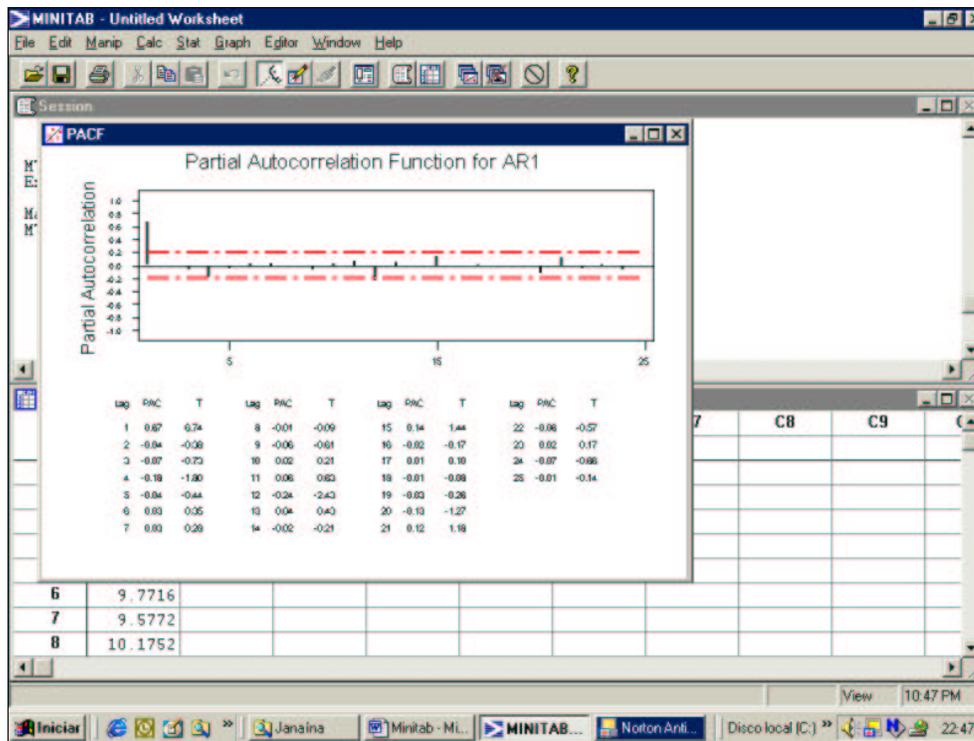


Figura 27: Gráfico de autocorrelação parcial da série AR(1) feito pelo MINITAB

3.2.4- Estimação dos parâmetros de modelos ARIMA

O *software* MINITAB pode ser usado para uma infinidade de tarefas, como já foi dito anteriormente. Apresentaremos apenas os procedimentos utilizados para estimar parâmetros de modelos ARIMA, pois são os modelos que estamos trabalhando neste projeto.

Para estimarmos os parâmetros de modelos ARIMA, basta selecionarmos a opção *Stat* do Menu Principal e em seguida *Time Series* e *ARIMA*. Feto isso, a seguinte tela aparecerá:

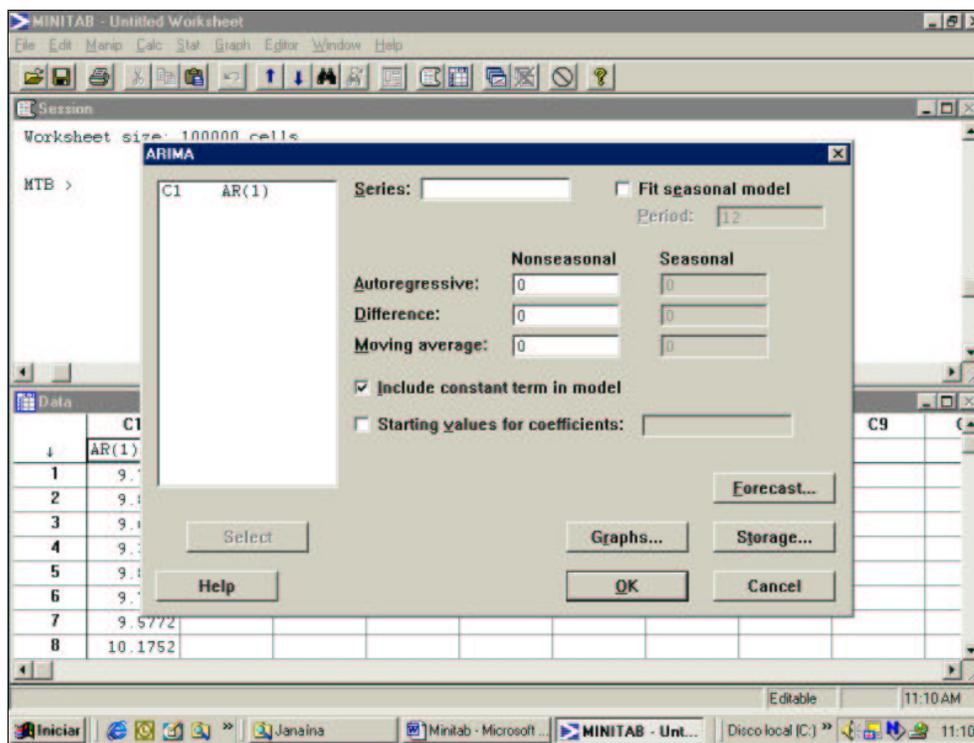


Figura 28: Tela de comandos do MINITAB onde definimos o modelo ARIMA a ser estimado.

Nesta tela (Figura 28), definiremos qual dos modelos ARIMA terá seus parâmetros estimados. Em primeiro lugar, devemos selecionar a série que será utilizada no quadro branco no lado esquerdo da tela. Feito isso, o nome da série selecionada ou localização (célula da planilha onde se encontram os dados que devem estar dispostos verticalmente) aparecerá no local *Series*. Se a série apresentar sazonalidade, a opção *Fit seasonal model* deverá ser ativada e o período de sazonalidade deve ser indicado no local *Period*. Nos locais *Autoregressive Nonseasonal* e *Autoregressive Seasonal* deverá ser indicada a ordem das componentes autorregressivas não sazonais e sazonais respectivamente. Caso não exista variável autorregressiva, colocar o valor zero nos locais indicadores destas variáveis. Nos locais *Difference Nonseasonal* e *Difference Seasonal* deverá ser indicado o número de diferenciações não sazonais e sazonais respectivamente. Caso não seja necessário diferenciar, colocar o valor zero nos locais indicadores das diferenciações. Nos locais *Moving average Nonseasonal* e *Moving average Seasonal* deverá ser indicada a ordem das componentes de médias móveis não sazonais e sazonais respectivamente. Caso não exista variável de médias móveis, colocar o valor zero nos locais indicadores destas variáveis. Para a constante ser inserida no modelo e conseqüentemente estimada, a opção *Include constant term in model* deverá ser ativada. Para indicar os valores iniciais dos parâmetros a serem estimados, a opção *Starting values for coefficients* deve ser ativada e o local (coluna) da planilha de trabalho do MINITAB onde estes valores iniciais foram armazenados, deve ser indicado no quadrinho ao lado. No local *Graphs...* poderão ser selecionados e obtidos alguns gráficos, como ACF e PACF, histogramas, gráfico dos resíduos, etc. No local *Storage...* podemos selecionar tudo aquilo que desejarmos armazenar na planilha de trabalho do MINITAB, como os resíduos, coeficientes, etc. O local *Forecast* é usado para fazer previsões. No exemplo utilizado, definiremos na Figura 28, no local *Autoregressive Nonseasonal* o valor um e nos demais locais o valor zero, pois, a série utilizada é um AR(1) não sazonal e não diferenciado. Feito isso, a

estimação dos parâmetros do modelo aparecerá na subjanela *Session*, que é uma saída típica do *software* MINITAB como é mostrado na Figura 29.

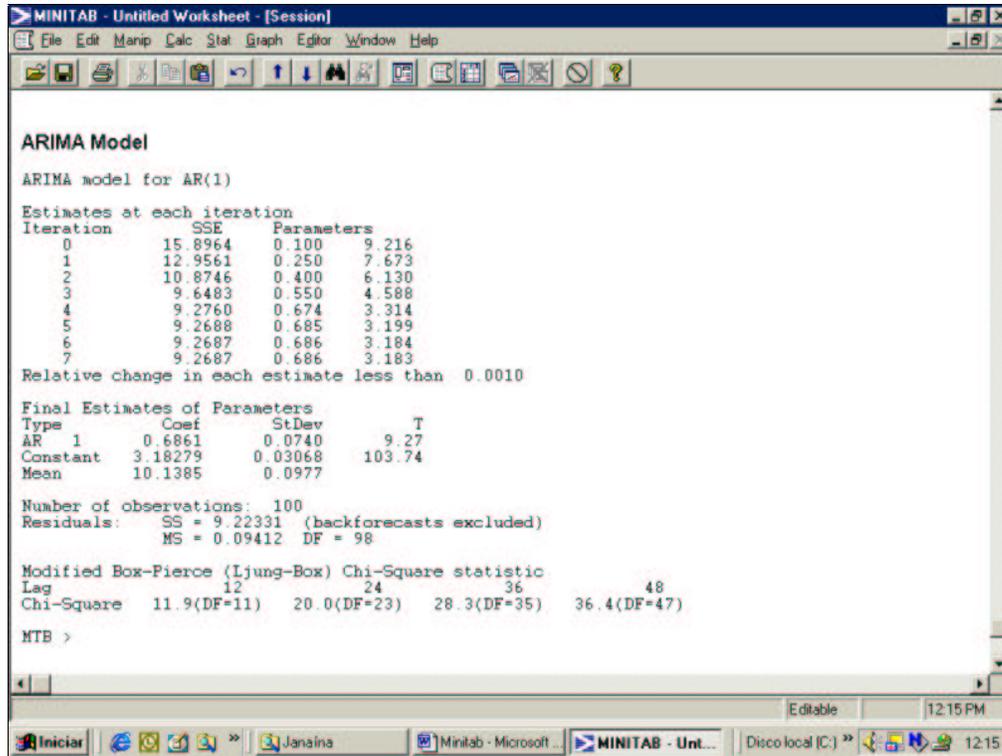


Figura 29: Tela do MINITAB que apresenta os parâmetros estimados para o modelo AR(1).

As estatísticas de ajuste calculadas pelo MINITAB são:

Estatística T: É calculado o valor da estatística-t para cada coeficiente do modelo ARIMA especificado.

Residual SS e MS: Soma de Quadrados e Quadrado médio residual

Modified Box-Pierce (Ljung-Box) Chi-Square statistic: Calcula a estatística de Box-Pierce para os resíduos do modelo especificado.

3.3 - Software SPSS

O *software* SPSS tem aplicações em diversas áreas. Especialmente na área da Estatística, possui ferramentas de trabalho importantes e, por este motivo, é amplamente usado nos cursos de Estatística e pelos profissionais desta área, além de ser um *software* de fácil manipulação.

A seguir apresentaremos os quatro procedimentos básicos para utilização do *software* no tratamento de modelos ARIMA. A versão do SPSS utilizada neste trabalho é a 8.0.

3.3.1 - Entrada dos dados no programa

O programa SPSS trabalha simultaneamente com duas janelas. A primeira delas é a janela principal de trabalho, que é chamada *SPSS Data Editor* e que contém a planilha de trabalho e o Menu Principal. A outra janela é chamada de *Output SPSS Viewer* e contém o histórico das tarefas feitas pelo usuário do programa e os resultados obtidos. No decorrer do texto, apresentaremos estas janelas.

Os dados podem ser incorporados no programa via teclado, ou seja, podem ser digitados diretamente na planilha de trabalho do SPSS (Figura 30). Outra forma é copiar os dados de uma planilha que contenha os dados já digitados. Para tal, devemos copiar os dados e colá-los na planilha de trabalho do SPSS (Figura 30). O operador decimal que deve ser usado é a vírgula, pois é o único que o *software* SPSS na versão em português reconhece. A versão do *software* SPSS em inglês reconhece o operador decimal ponto. Cada um dos conjunto de dados que serão inseridos no programa, deverão estar dispostos em colunas.

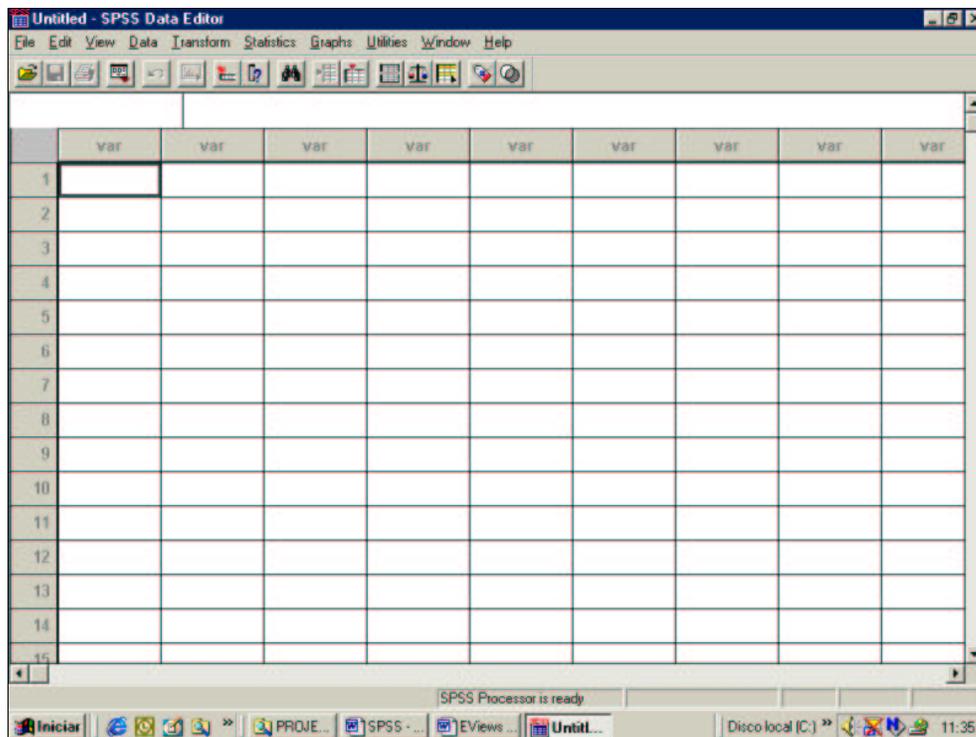


Figura 30: Tela de comandos do SPSS que contém a planilha de trabalho e o Menu Principal.

Na figura 30 é apresentada a tela principal do *software* SPSS que é chamada de *SPSS Data Editor* e que contém a planilha de trabalho, onde deverão ser inseridos os dados e o Menu Principal, que contém as ferramentas de utilização do *software*.

Para abrirmos um arquivo de trabalho já digitado e que foi armazenado no formato do próprio SPSS indicado pela extensão “.sav”, basta selecionar a opção *File* e em seguida a opção *Open*. Feito isso a seguinte tela aparecerá sobreposta à tela principal:

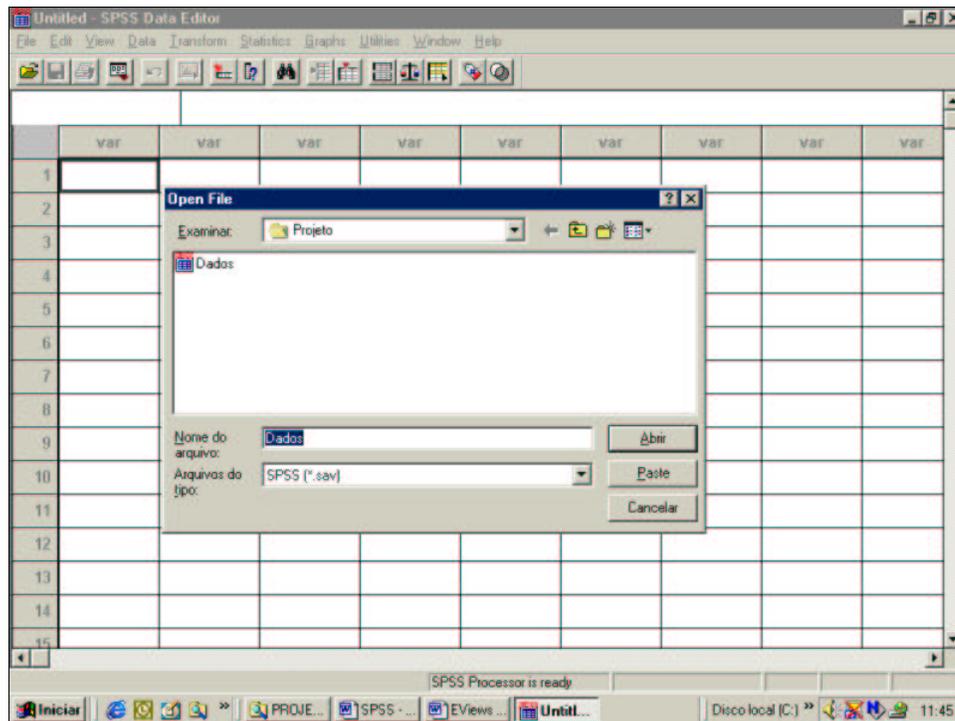


Figura 31: Tela de comandos do SPSS onde selecionamos e abrimos o arquivo de trabalho.

Nesta tela, devemos selecionar o local onde se encontra o arquivo que iremos abrir no local *Examinar*. Feito isso, todos os arquivos do tipo “sav” aparecerão no quadro branco e o arquivo de interesse deve ser selecionado. Depois de selecionado, o nome do arquivo aparecerá no local *Nome do arquivo*. Feito isso, os dados do arquivo selecionado aparecerão na planilha de trabalho do SPSS e estarão prontos para serem trabalhados.

Podemos também abrir um arquivo de trabalho já digitado e que foi armazenado em um formato diferente do SPSS, o procedimento é semelhante ao descrito anteriormente. Podemos também copiar estes dados e colá-los na planilha de trabalho do SPSS, utilizando respectivamente os comandos *Copy* ou *Copiar* do *software* onde os dados se encontram e *Paste* da opção *Edit* do Menu Principal do SPSS. Depois de inseridos os dados na planilha de trabalho do programa, precisamos definir o tipo de dados que foram inseridos e que serão trabalhados, além de nomeá-los. Cada coluna de dados da planilha vem com a indicação numérica desta coluna que é do tipo *var00001*. Cada uma destas colunas deverá ter o tipo de seus dados definidos e deverá receber um nome. Para isto basta clicar duas vezes na indicação numérica

da coluna de dados ou selecionar a opção *Data* do Menu Principal e em seguida a opção *Define Variable*. Feito isso, a seguinte janela aparecerá sobreposta à janela principal:

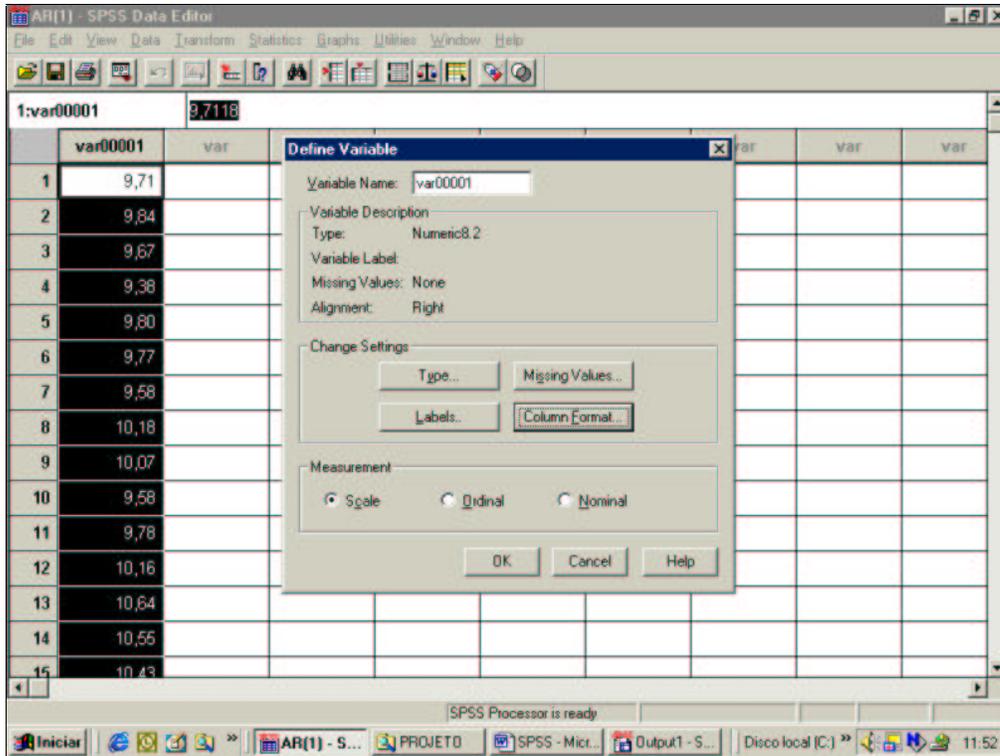


Figura 32: Tela de comandos do SPSS onde definimos o tipo de variável que será trabalhada

Nesta janela (Figura 32) deverá ser definido o tipo da variável inserida em cada uma das colunas da planilha de trabalho. No local *Variable Name* aparecerá a indicação numérica da coluna que terá seus dados definidos. Neste local, devemos apagar a indicação numérica da coluna e em seguida nomeá-la. No local *Variable Description* aparecerá a descrição atual da variável e, após mudá-la, a nova descrição deverá aparecer neste local. No local *Change Settings* iremos definir a variável. Na opção *Type* definimos o número de casa decimais, a amplitude e o tipo dos dados, ou seja, se os dados são constituídos de números, datas, letras, etc. O local *Missing Values* deverá ser utilizado se nos dados existem valores faltantes ou perdidos, onde deverão ser especificados. O local *Labels* deverá ser utilizado se nos dados existem valores qualitativos, ou seja, valores que não são numéricos, onde deverão ser especificados. O local *Column Format* deverá ser usado para definir a disposição dos dados na planilha, ou seja, se os dados ficarão alinhados à direita, à esquerda ou no centro das células da planilha. No local *Measurement* definiremos a escala dos dados, ou seja, se os dados seguem uma escala numérica, ordinal ou se são nominais. Neste momento, os dados estão prontos para serem trabalhados.

3.3.2 - Obtenção do gráfico de uma série

Para obtermos o gráfico de uma série, basta selecionar a opção *Graphs* e em seguida a opção *Sequence* e a seguinte tela aparecerá sobreposta à tela *SPSS Data Editor*:

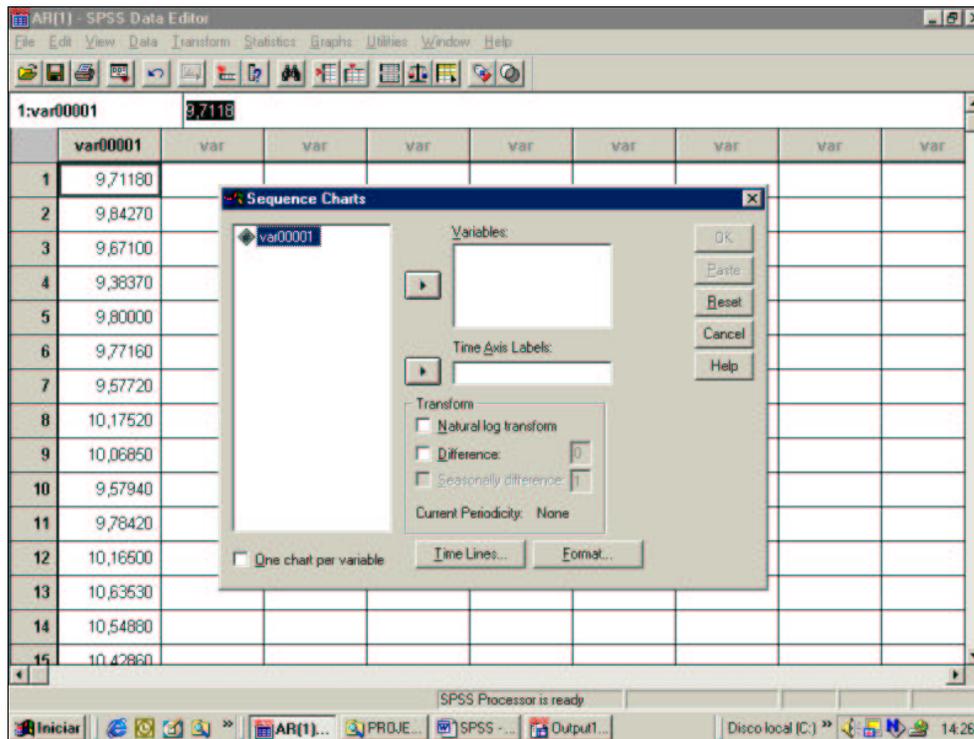


Figura 33: Tela de comandos do SPSS onde definimos o tipo de gráfico desejado

Nesta tela (Figura 33) definiremos as características do gráfico desejado. No quadrinho branco à esquerda da tela, devemos selecionar a variável que será usada para obtermos o gráfico e utilizar a seta ao lado para inseri-la no local *Variables*. Se desejarmos incluir uma variável nominal para colocar os rótulos do período de tempo utilizado, esta deverá ser incluída no local *Time Axis Labels*. O local *Transform* deverá ser utilizado caso transformações e diferenciações sejam necessárias. Os outros locais são utilizados para formatações do gráfico. Utilizando a série AR(1) não sazonal e não diferenciada como exemplo, devemos apenas selecionar a variável utilizada na construção do gráfico. Feito isso, obtemos o gráfico desejado na janela *Output SPSS Viewer*, como é mostrado na Figura 34.

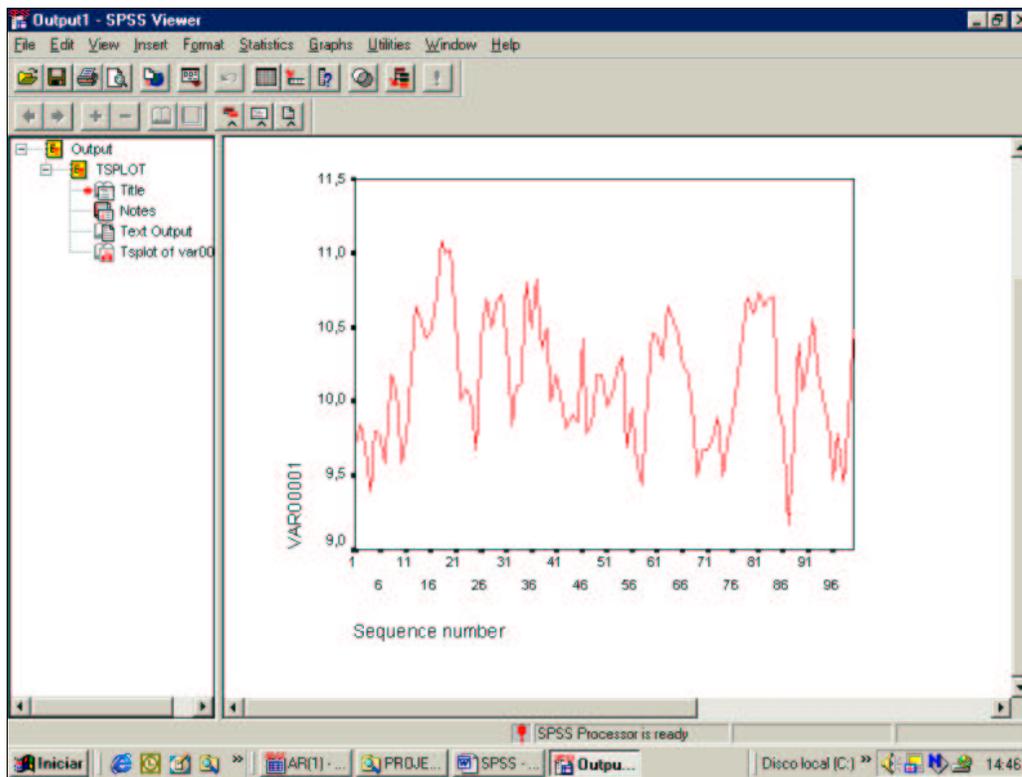


Figura 34: Janela *Output SPSS Viewer* do SPSS onde são apresentados os resultados das tarefas executadas e o histórico das mesmas.

Nesta janela (Figura 34), chamada *Output SPSS Viewer*, são apresentados os resultados das tarefas executadas no quadro à esquerda e o histórico das mesmas no quadro à direita. O gráfico apresentado na Figura 34 é da série AR(1) que foi adotada como exemplo e é uma saída típica do *software* SPSS.

3.3.3 - Obtenção dos gráficos de autocorrelação e autocorrelação parcial

Para obtermos os gráficos de autocorrelação e autocorrelação parcial, devemos selecionar a opção *Graphs* do Menu Principal e em seguida as opções *Time Series* e *Autocorrelations*. Feito isso, a seguinte tela aparecerá:

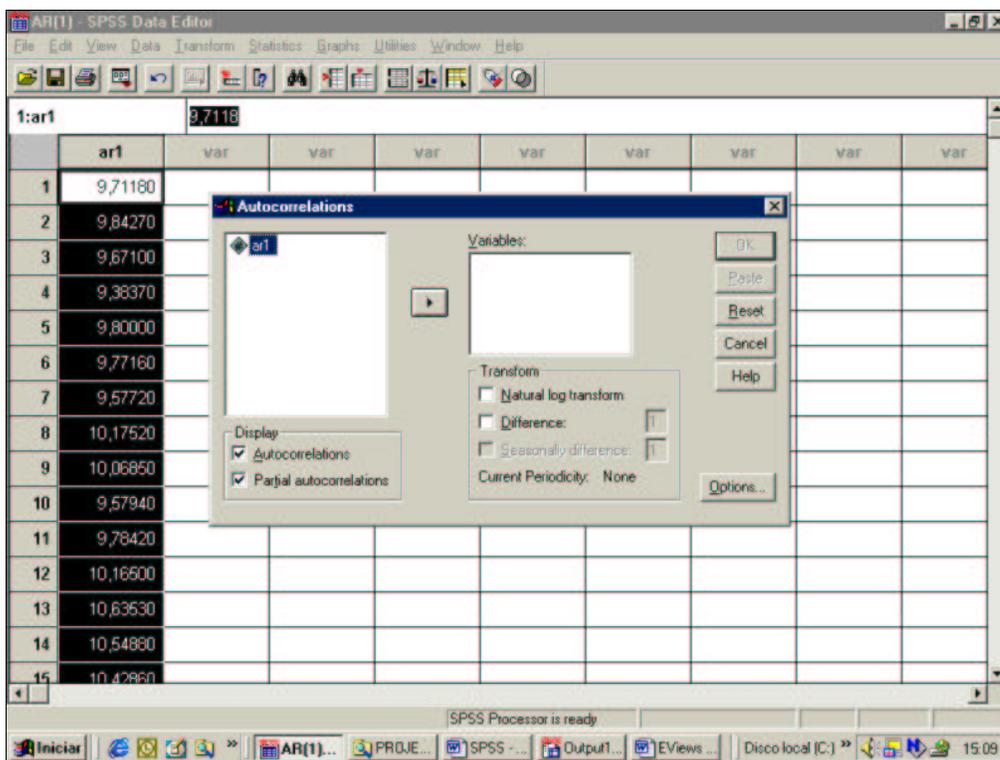


Figura 35: Tela de comandos do SPSS onde definimos o tipo dos correlogramas

Nesta tela (Figura 35), definiremos o tipo do gráfico de autocorrelação e autocorrelação parcial desejados. No quadro branco à esquerda, devemos selecionar a série que será utilizada e usando a seta ao lado devemos inserir a série no local *Variables*. No local *Display* deverá ser selecionado os correlogramas desejados. Como exemplo, faremos os gráficos de autocorrelação e autocorrelação parcial. Se transformações e diferenciações forem necessárias, o local *Transform* deverá ser utilizado. Feito isso, os gráficos de autocorrelação e autocorrelação parcial da série AR(1) não sazonal e não diferenciada são apresentados na janela *Output SPSS Viewer* e são saídas típicas do *software* SPSS apresentados nas Figuras 36 e 37.

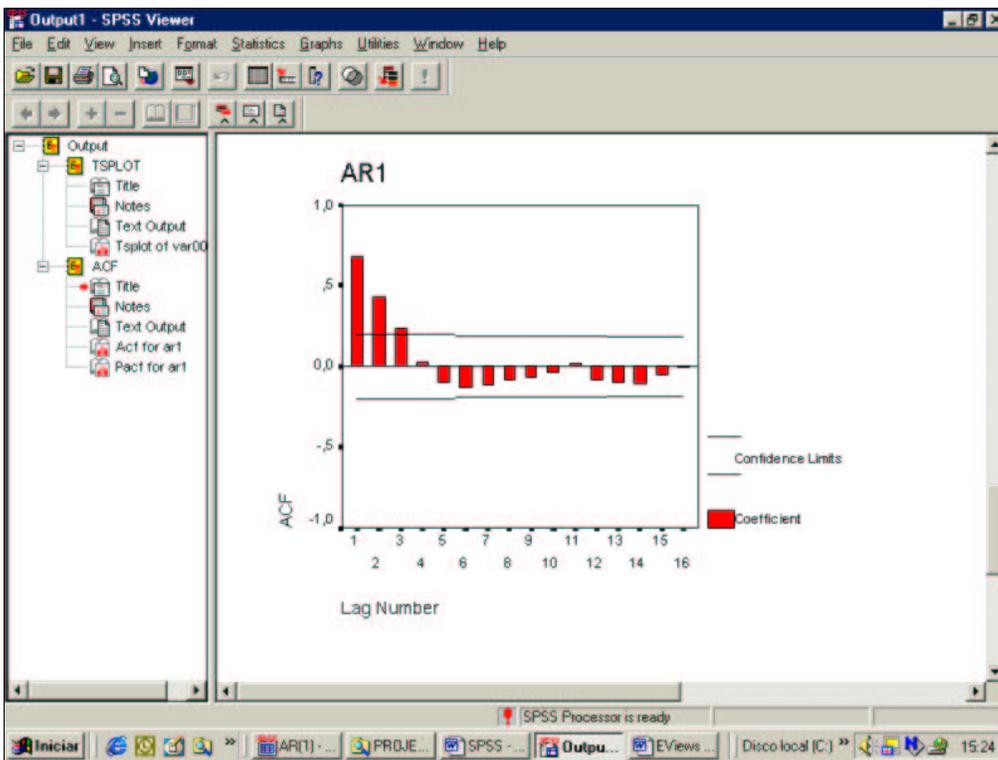


Figura 36: Janela *Output SPSS Viewer* do SPSS onde é apresentado o gráfico de autocorrelação

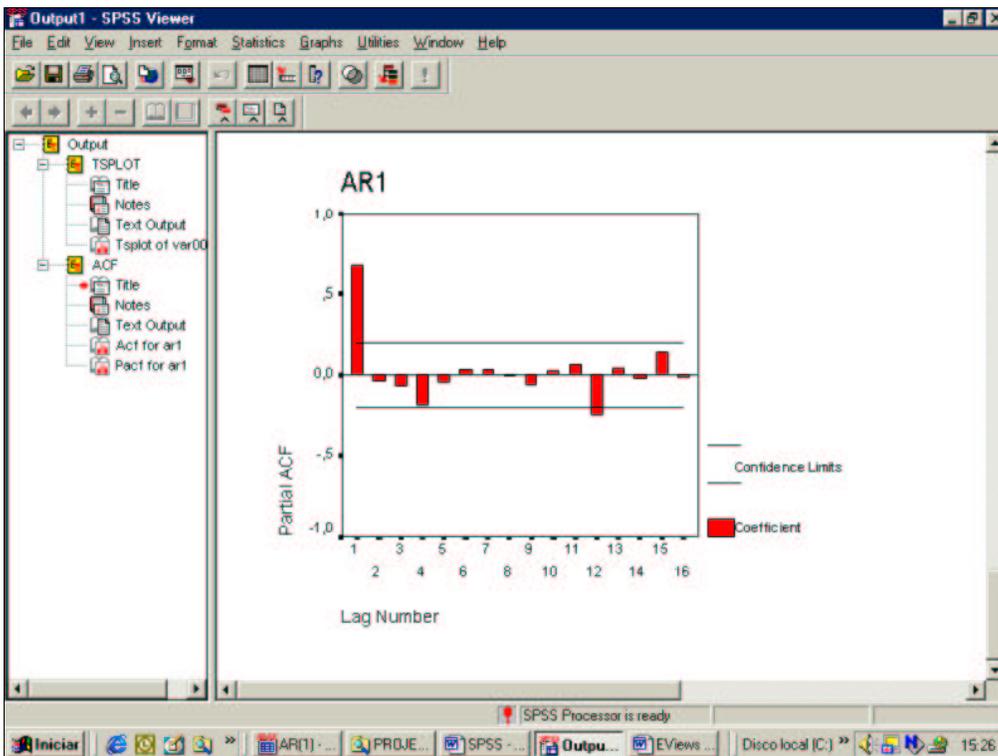


Figura 37: Janela *Output SPSS Viewer* do SPSS onde é apresentado o gráfico de autocorrelação parcial.

3.3.4 - Estimação dos parâmetros de modelos ARIMA

Para estimarmos os parâmetros de um modelo ARIMA, devemos selecionar a opção *Statistics* do Menu Principal e em seguida *Time Series* e *ARIMA*. Feito isso a seguinte tela aparecerá sobreposta à tela principal:

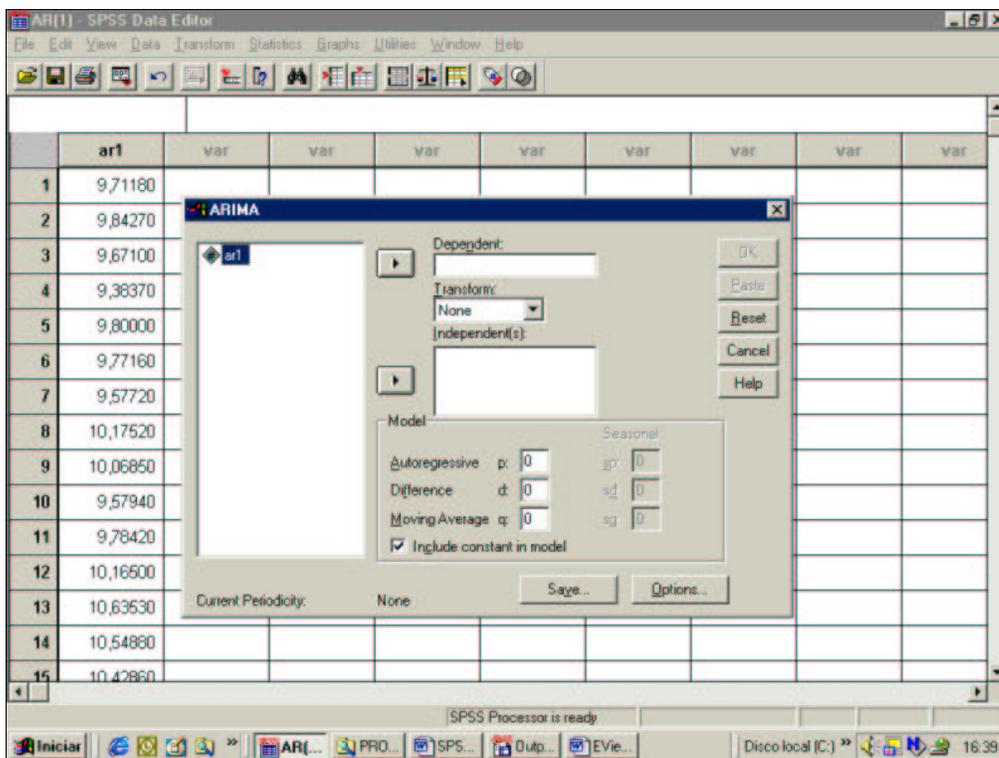


Figura 38: Tela de comandos do SPSS onde especificamos o modelo ARIMA que será ajustado

Nesta tela (Figura 38), devemos especificar o modelo ARIMA que iremos ajustar. Para isto, devemos selecionar, no quadro branco à esquerda, a série que será utilizada para tal e em seguida inserir a série selecionada no local *Dependent* utilizando a seta ao lado. No local *Transform* deverá ser especificado se a série deve ser transformada ou não. No local *Independent(s)* deverão ser inseridas as variáveis explicativas no ajuste do modelo, caso elas existam. No local *Model*, deverá ser especificado o número de parâmetros autorregressivos, autorregressivos sazonais, médias móveis e de médias móveis sazonais a serem estimados e o número de diferenciações sazonais e não sazonais, respectivamente, nas opções *Autorregressive p*, *Autorregressive sp*, *Moving Average q*, *Moving Average sq*, *Difference d* e *Difference sd*. Se algum dos parâmetros citados acima não precisar de ser estimado, devemos colocar o número zero. A opção *Include constant in model* deverá ser ativada, caso a constante deva ser incluída no modelo e conseqüentemente estimada. Se as séries utilizadas possuírem sazonalidade, é necessário inicialmente definir a sazonalidade dos dados em *Data: Define Dates*. Esta opção possibilita definir a data dos dados (por exemplo, se os mesmos são anuais, mensais, trimestrais, etc.).

Utilizando a série AR(1) do nosso exemplo, definiremos na tela da figura 38 a série que será utilizada. Neste caso, não temos nenhuma transformação nem variáveis explicativa e apenas um

parâmetro autorregressivo será estimado, com os demais recebendo valor zero. Feito isso, obteremos o modelo AR(1) estimado através da série utilizada como exemplo e a saída típica do *software* SPSS é apresentado na janela *Output SPSS Viewer*, mostrada na Figura 39.

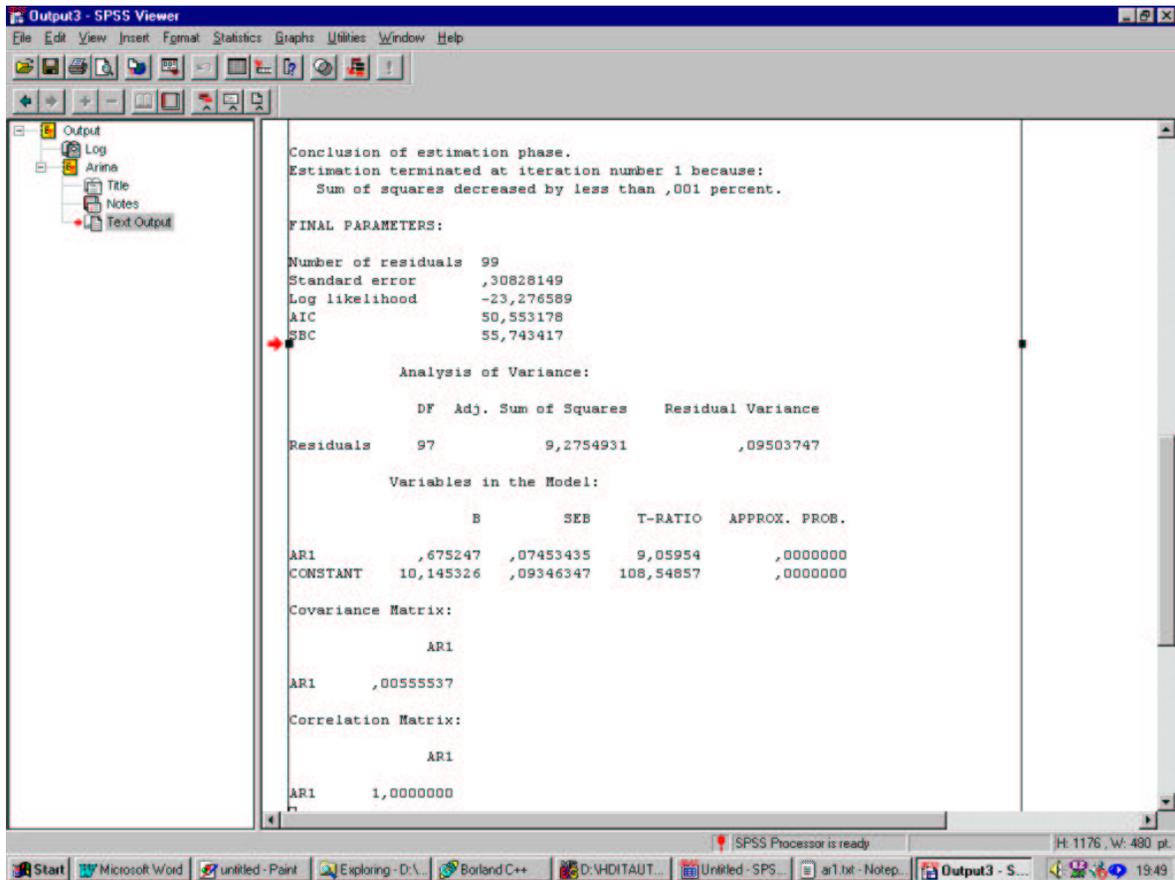


Figura 39: Janela *Output SPSS Viewer* do SPSS onde são apresentados os resultados da estimação do modelo ARIMA.

As estatísticas de ajuste calculadas pelo SPSS são:

- Análise de variância;
- T-Ratio: É calculado o valor da estatística-t para cada coeficiente do modelo ARIMA especificado.
- Matriz de correlação para os coeficientes do modelo.

Outras estatísticas podem ser solicitadas na opção *Options...* da Figura 38.

3.4 - Software SAS

O SAS é um *software* que pode ser utilizado em várias áreas, como engenharia, economia e outros. Dentre todas as áreas, este *software* é utilizado principalmente na estatística, pois, apresenta muitas ferramentas úteis. O manuseio deste *software* não é uma tarefa muito fácil, pois, ele trabalha com linhas de comandos, ou seja, o usuário do SAS precisa ter um certo conhecimento de programação para a implementação de programas no mesmo. A versão do SAS utilizada neste trabalho é a 8.0.

3.4.1 - Entrada dos dados no programa

Para utilizar o *software* SAS, precisamos, em primeiro lugar, construir um programa contendo os comandos utilizados para obtermos as tarefas que desejamos que o programa execute. Para ilustrar, apresentaremos o programa implementado para obtermos o gráfico das séries temporais estudadas, ou seja, modelos $ARIMA(p,d,q)$, a estimação de seus parâmetros e os gráficos de autocorrelação e autocorrelação parcial. O programa é apresentado a seguir:

```
DATA Modelo;
INPUT Y;
Time = _N_;
Cards;
> Coloca-se os dados da série a ser analisada <
Proc Plot Data = Modelo;
Plot Y * Time;
Proc ARIMA Data = Modelo out=resultados;
Identify VAR = Y;
Estimate > coloca-se os parâmetros que deseja-se incluir no ajuste <;
proc print data=resultados;
```

Figura 40: Programa contendo os comandos utilizados na construção do gráfico das séries, das funções de autocorrelação e de autocorrelação parcial e no ajuste de modelos $ARIMA(p,d,q)$.

Na Figura 40, são apresentados os comandos do programa implementado para a execução das tarefas pelo *software*. No comando intitulado por *Cards*, deve-se incluir as observações da série temporal a que se deseja analisar. No comando *Estimate*, têm-se as opções para o ajuste dos modelos constituintes da modelagem proposta por Box & Jenkins (1976). Caso queira se ajustar um modelo autorregressivo de ordem p , deve-se colocar no comando *Estimate* a indicação “ $P = (1,2,...,p)$ ”. Para o ajuste de um modelo de médias móveis de ordem q , deve-se incluir o subcomando “ $Q = (1,2,...,q)$ ”. Analogamente quando se deseja ajustar um modelo autorregressivo e médias móveis de ordem (p,q) , incluímos o subcomando duplo “ $P = (1,2,...,p) Q = (1,2,...,q)$ ”.

Tendo o programa implementado, devemos, então, inicializar o *software* SAS. A tela principal do *software* é apresentada na Figura 41.

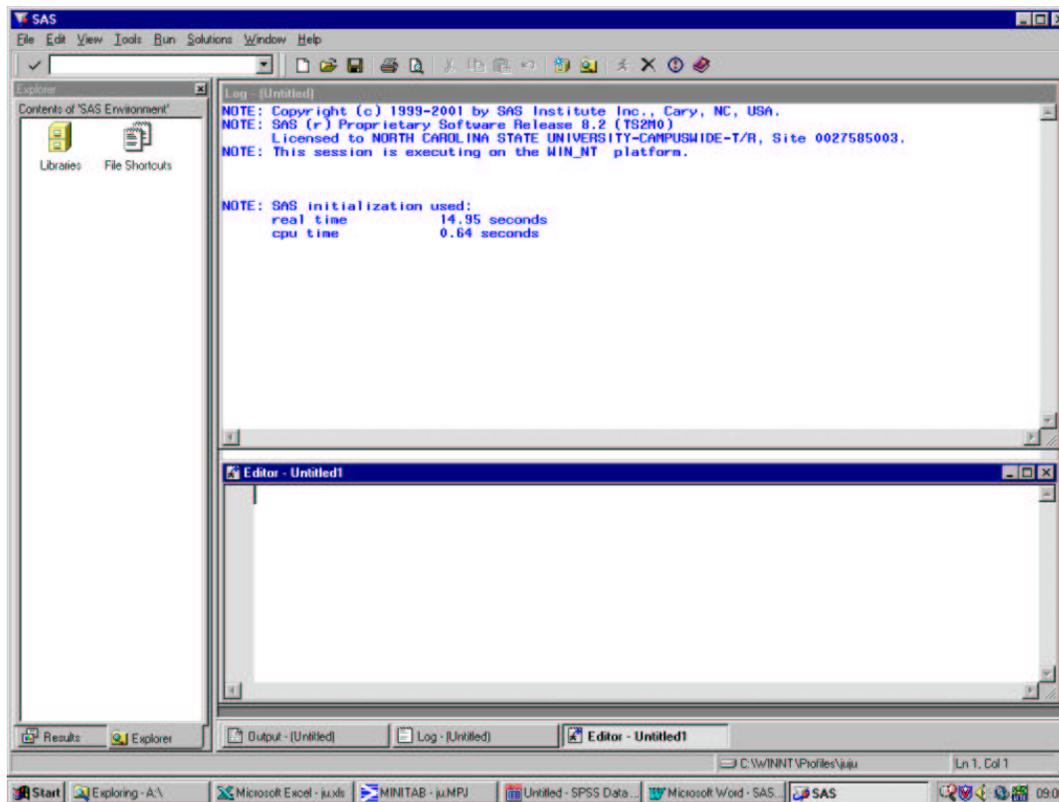


Figura 41: Tela principal de trabalho do *software* SAS.

Na Figura 41 é apresentada a tela principal de trabalho do *software* SAS. Esta tela contém o Menu Principal e é dividida em três subtelas de trabalho. A subtelas à esquerda chamada *Explorer* apresentará o histórico de todas as tarefas executadas pelo programa e todos os arquivos existentes que apresentam extensão *sas*, isto é, todos os arquivos que foram armazenados no formato do *software* em estudo. A subtelas chamada *Log-(untitled)* apresentará os resultados das tarefas executadas e a subtelas denominada *Editor-Untitled1* deverá conter o programa implementado e apresentado na Figura 40.

Antes de entrar com os dados no *software*, devemos inserir o programa implementado na subtelas *Editor-Untitled1*. Para tal, tendo o programa já copiado utilizando o comando *Copiar* do *software* onde o programa for digitado, basta utilizar os comandos *Edit* e *Paste* do Menu Principal do SAS. Em seguida, devemos nomear e salvar o programa inserido no formato do *software* em estudo, ou seja, extensão *sas*, utilizando as opções *File* e *Save as* do Menu Principal. Feito isto, o nome do programa aparecerá ao lado do nome da subtelas *Editor-Untitled1*.

Neste momento, o *software* está pronto para receber os dados, que devem ser inseridos na subtelas *Editor-Untitled1* logo após o comando intitulado *Cards* do programa implementado. Os dados podem ser copiados de uma planilha qualquer e colados no local indicado ou podem ser importados do próprio SAS ou de outros *softwares* utilizando as opções *File* e *Open* do Menu Principal. Depois de entrar com os dados no *software* a seguinte tela aparecerá:

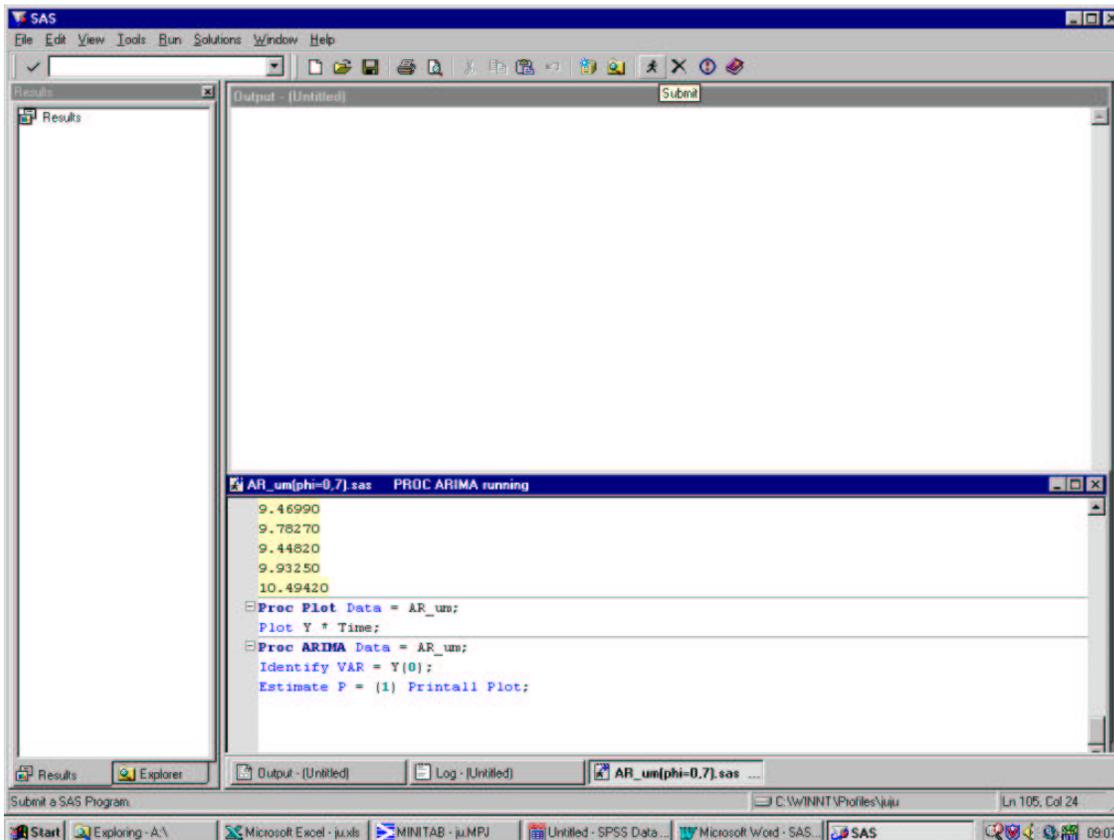


Figura 42: Tela do *software* SAS onde os dados foram armazenados.

Na Figura 42, são apresentados os dados que foram inseridos no *software* e que serão posteriormente trabalhados e é apresentado também o programa implementado que será utilizado pelo *software* para executar as tarefas desejadas.

3.4.2 - Obtenção do gráfico de uma série, dos correlogramas e estimação dos parâmetros

As tarefas a serem executadas não são feitas separadamente como ocorrem nos outros *softwares* estudados. Como já foi dito anteriormente, as tarefas a serem executadas pelo SAS já foram descritas no programa implementado e, quando este for rodado, os resultados serão obtidos todos de uma só vez. Em seguida devemos rodar o programa implementado utilizando o comando *Submit* do Menu Principal, que se encontra destacado em amarelo. Feito isto a seguinte tela aparecerá:

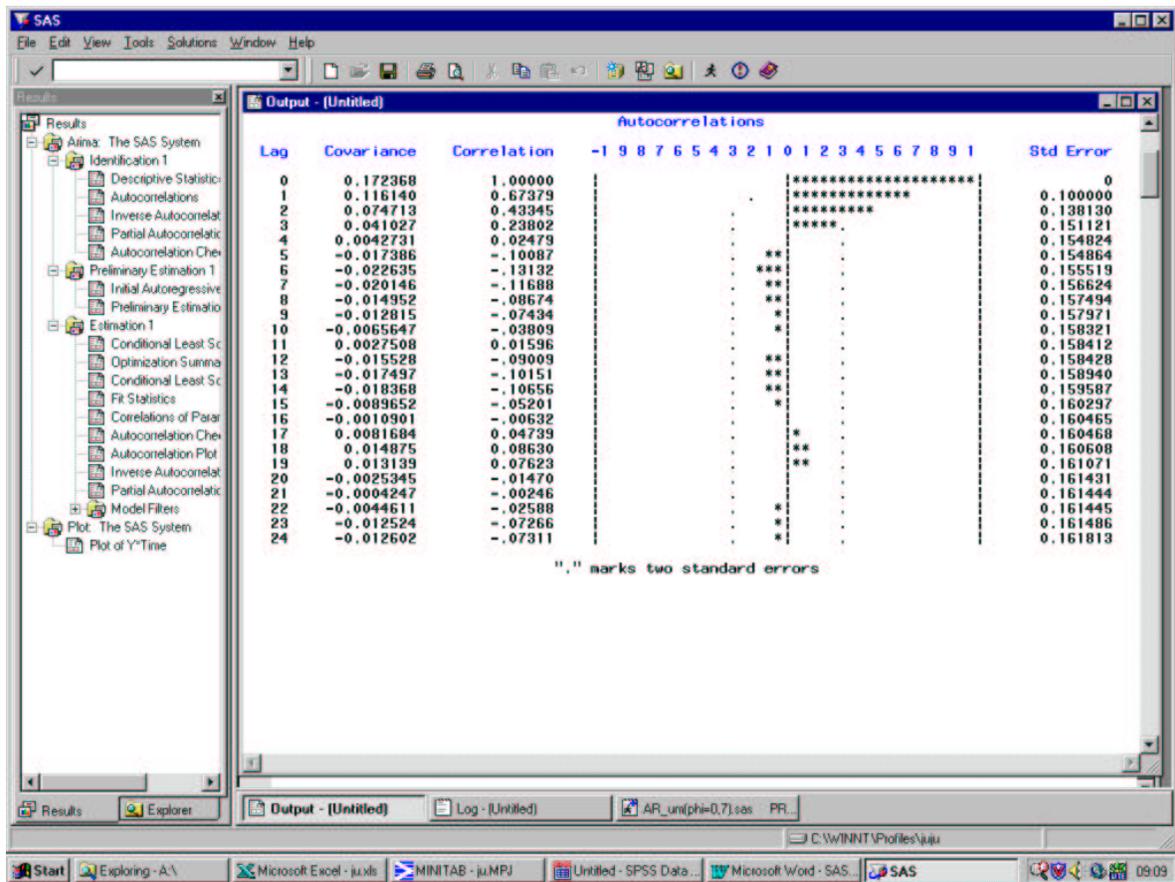


Figura 43: Tela de comandos do *Software* SAS onde são apresentados os resultados das tarefas executadas.

Na Figura 43, são apresentados os resultados das tarefas executadas. Como todas as tarefas desejadas estão contidas no programa implementado, elas aparecem todas de uma só vez quando rodamos o programa. Para visualizar algum dos resultados obtidos, basta dar um clique duplo em cima do que desejar que deverá estar listado na subtela *Results*. A visualização dos resultados que poderá ser selecionada na subtela *Results*, será apresentada na subtela *Output*. Apenas a título de ilustração, a Figura 43 apresenta a saída típica do gráfico de autocorrelação obtido no *software* SAS.

Resultados

Neste capítulo, vamos gerar séries dos modelos AR(1), AR(2), MA(1), MA(2) e ARMA(1,1), de tamanho $n = 100$ e média igual à 10. O *software* utilizado para gerar as séries em estudo será o MINITAB. Cada série terá seus parâmetros pré-fixados estimados nos *softwares* MINITAB, SAS, SPSS e EViews. Posteriormente serão calculados os vícios de cada um dos parâmetros estimados e em cada um dos *softwares* utilizados. A partir dos vícios estimados, faremos uma análise objetivando verificar qual é o melhor *software* para estimarmos modelos ARIMA que será apresentada no capítulo 5. As séries e macros encontram-se no anexo. Para ilustrarmos cada um dos modelos ARIMA estudados, apresentaremos o gráfico da série, gráfico de autocorrelação e autocorrelação parcial obtido apenas pelo *software* SPSS, pois, qualquer que seja o *software* utilizado estes gráficos serão sempre os mesmos.

4.1 - Modelo Autorregressivo de ordem 1 – AR(1) com parâmetro $\phi = 0,7$

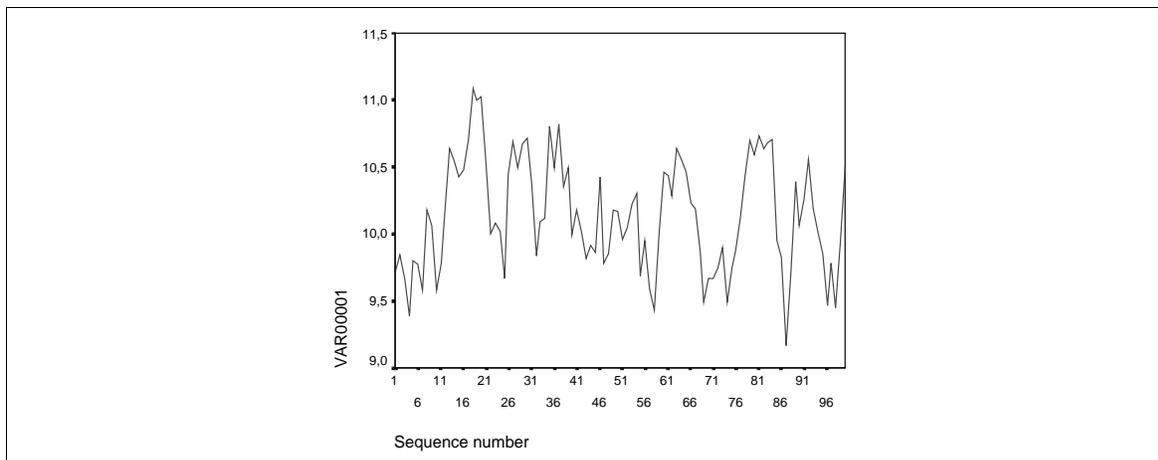


Figura 44: Gráfico da série AR(1) gerada com $\phi = 0,7$.

A Figura 44 nos mostra que a série é estacionária pois não apresenta tendências e seus valores giram em torno da média.

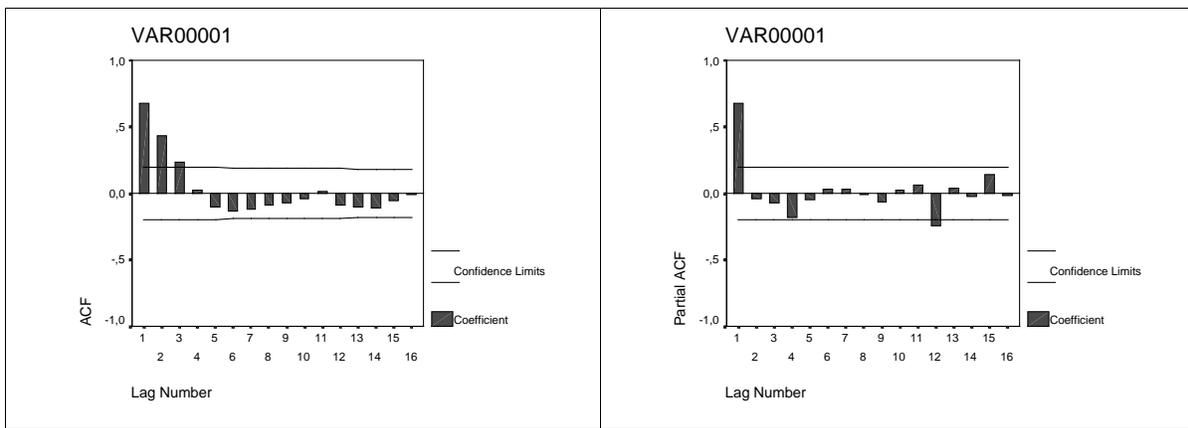


Figura 45: Gráfico de autocorrelação e autocorrelação parcial da série AR(1) com $\phi = 0,7$.

Analisando simultaneamente os gráficos de autocorrelação e autocorrelação parcial (Figura 45), observamos respectivamente um decaimento rápido e apenas um valor fora dos limites, pertencente à parte positiva do gráfico mostrando então que a série é um AR(1) com $\phi > 0$.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\phi = 0,7$	0.67379	0.678868	0.6861	0.68002
$\mu = 10$	10.13856	10.16106	10.13851	10.12081

Figura 46: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados.

Para a série com o parâmetro $\phi = 0,7$, verificamos que o melhor valor estimado para ϕ é 0.68002 obtido pelo *software* SAS e o melhor valor estimado para μ é 10.12081, também obtida pelo SAS, como é mostrado na Figura 46. Os valores estimados para ϕ e μ são próximos dos valores pré-fixados, portanto as estimativas são boas.

4.2 - Modelo Autorregressivo de ordem 1 – AR(1) com parâmetro $\phi = -0,7$

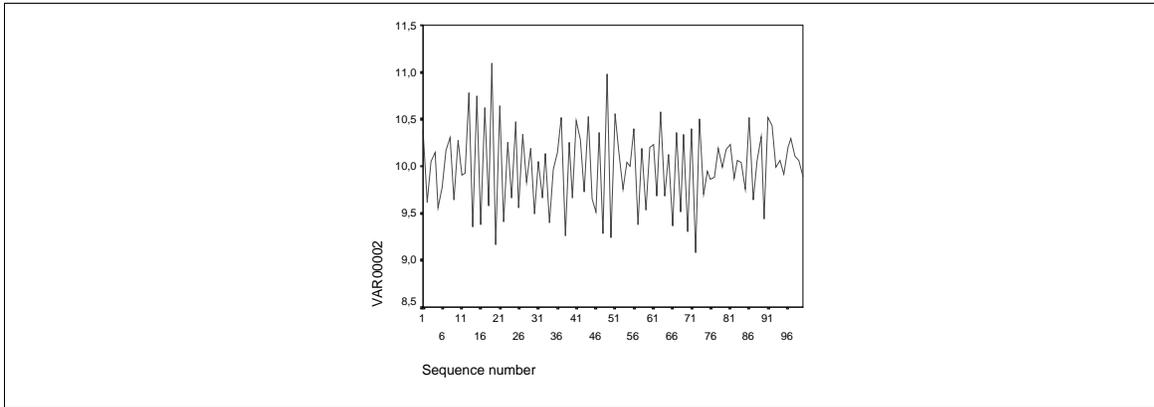


Figura 47: Gráfico da série AR(1) gerada com $\phi = -0,7$.

A Figura 47 nos mostra que a série é estacionária pois não apresenta tendências e seus valores giram em torno da média.

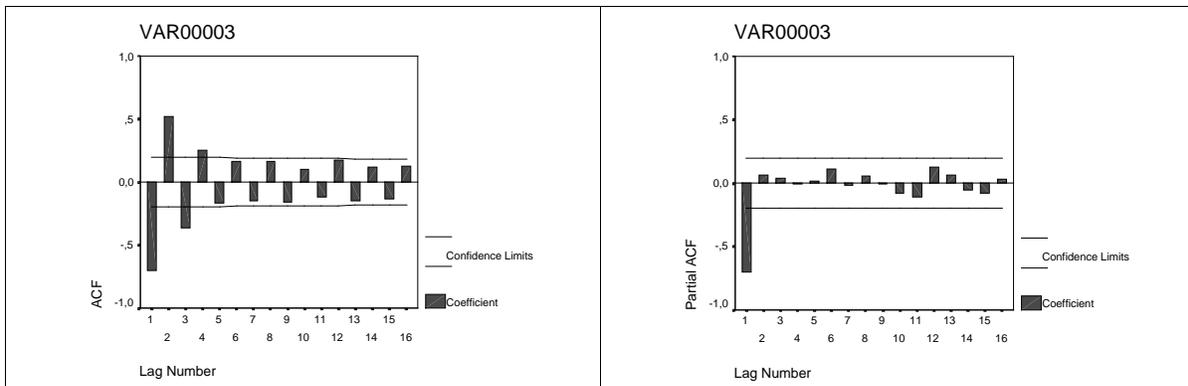


Figura 48: Gráfico de autocorrelação e autocorrelação parcial da série AR(1) com $\phi = -0,7$.

Analisando simultaneamente os gráficos de autocorrelação e autocorrelação parcial, observamos na Figura 48 um decaimento alternado rápido e apenas um valor fora dos limites e pertencente à parte negativa do gráfico mostrando então que a série é um AR(1) com $\phi < 0$.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\phi = -0.7$	0.69760	-0.698045	-0.7038	-0.69806
$\mu = 10$	9.9993557	9.998665	9.9994	10.00001

Figura 49: Tabela comparativa das estimativas obtidas em cada um dos softwares utilizados

Para a série com o parâmetro $\phi = 0,7$, verificamos que o melhor valor estimado para ϕ é **-0.69806** obtido pelo *software* SAS e o melhor valor estimado para μ é **10.00001**, também obtida pelo SAS, como é mostrado na figura 49. Os valores estimados para ϕ e μ são próximos dos valores pré-fixados, portanto as estimativas são boas.

4.3 - Modelo Autorregressivo de ordem 2 – AR(2) com parâmetros $\phi_1 = 0,2$ e $\phi_2 = 0,7$.

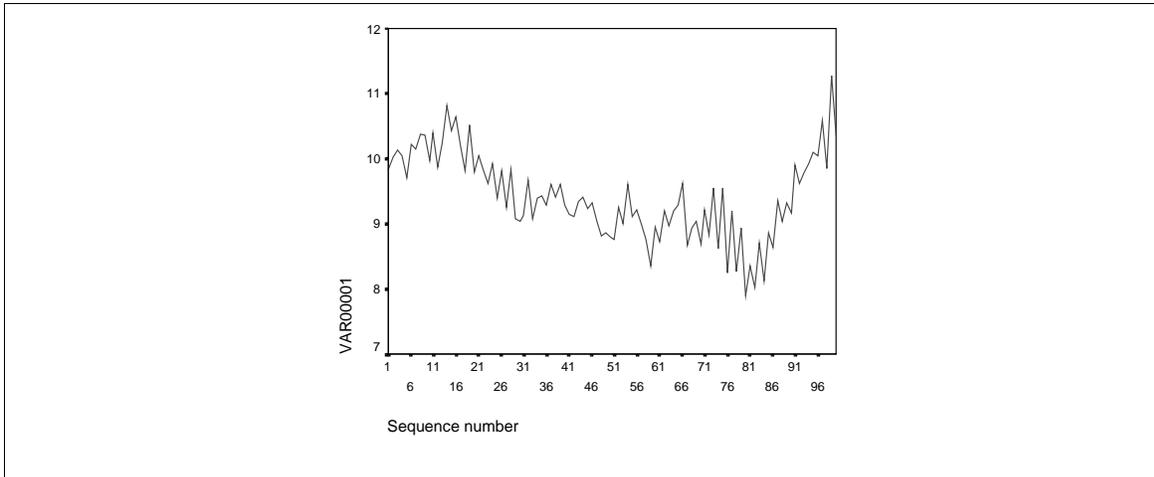


Figura 50: Gráfico da série AR(2) gerada com $\phi_1 = 0,2$, $\phi_2 = 0,7$.

No modelo AR(2) com $\phi_1 = 0,2$, $\phi_2 = 0,7$ e $\mu = 10$ verificamos que ele está no limite da estacionariedade (Figura 50) pois $\phi_1 + \phi_2 = 0,9$, sendo este limite igual a $\phi_1 + \phi_2 < 1$. Mas, esta série é estacionária porque atende aos requisitos pré estabelecidos que são $\phi_1 + \phi_2 = 0,9 < 1$, $\phi_2 - \phi_1 = 0,5 < 1$ e $-1 < \phi_2 = 0,7 < 1$.

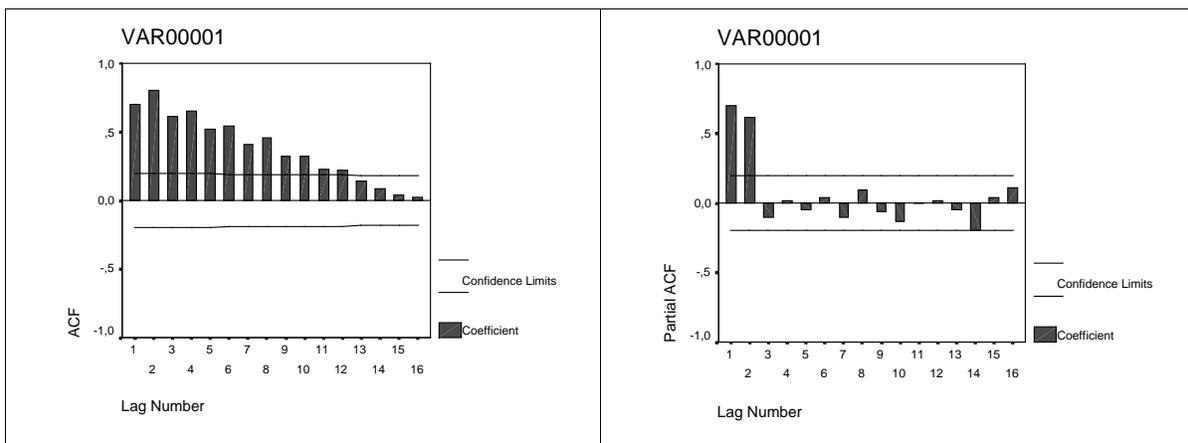


Figura 51: Gráfico de autocorrelação e autocorrelação parcial da série AR(2) com $\phi_1 = 0,2$, $\phi_2 = 0,7$.

Observando a Figura 51, temos respectivamente a função de autocorrelação para este modelo nos mostrando um amortecimento exponencial sendo o primeiro valor menor que o segundo ($\phi_1 < \phi_2$) e a função de autocorrelação parcial nos mostrando que os dois primeiros valores estão fora dos limites. Estas características da FAC e FACP nos mostram que este processo é autorregressivo de ordem 2 com ambos os parâmetros positivos.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\phi_1=0.2$	0.2101374	0.186328	0.2126	0.21448
$\phi_2=0.7$	0.7269050	0.785134	0.7454	0.74650
$\mu = 10$	9.7396107	9.877612	9.8328	9.91450

Figura 52: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados

Para a série com o parâmetro $\phi_1 = 0,2$, $\phi_2 = 0,7$ e $\mu = 10$, verificamos que o melhor valor estimado para ϕ_1 é 0.2101374, para ϕ_2 é 0.7269050, ambos obtidos pelo *software* SPSS e o melhor valor estimado para μ é **9.91450**, obtida pelo SAS, como é mostrado na Figura 52.

4.4 - Modelo Autorregressivo de ordem 2 – AR(2) com parâmetros $\phi_1 = -0,6$ e

$$\phi_2 = 0,3.$$

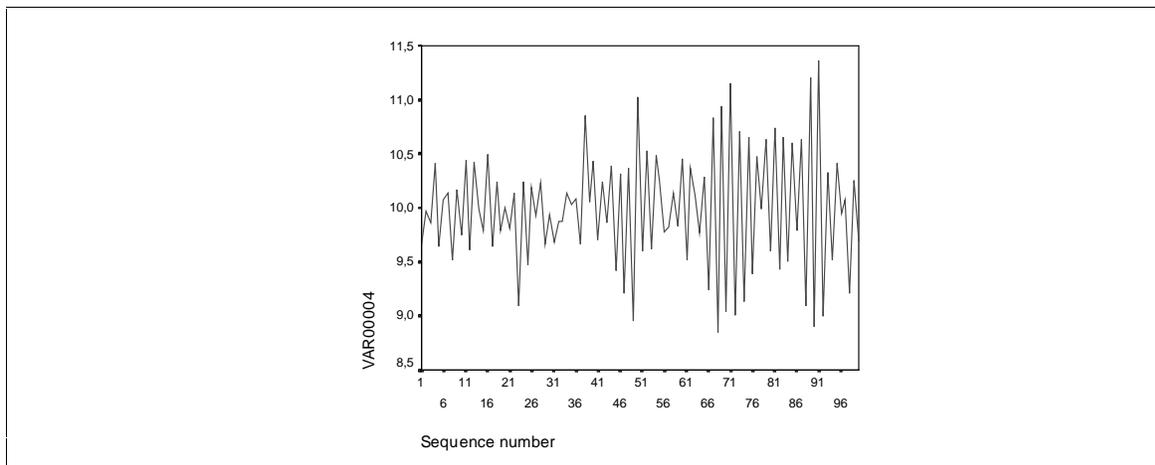


Figura 53: Gráfico da série AR(2) gerada com $\phi_1 = -0,6$, $\phi_2 = 0,3$.

No modelo AR(2) com $\phi_1=-0.6$, $\phi_2=0.3$ e $\mu = 10$ verificamos que a série é estacionária (Figura 53) pois $\phi_2 + \phi_1 = -0.3$, sendo este limite igual a $\phi_1 + \phi_2 < 1$ e atende aos requisitos pré estabelecidos que são $\phi_1 + \phi_2 = -0.3 < 1$, $\phi_2 - \phi_1 = 0.9 < 1$ e $-1 < \phi_2 = 0.3 < 1$.

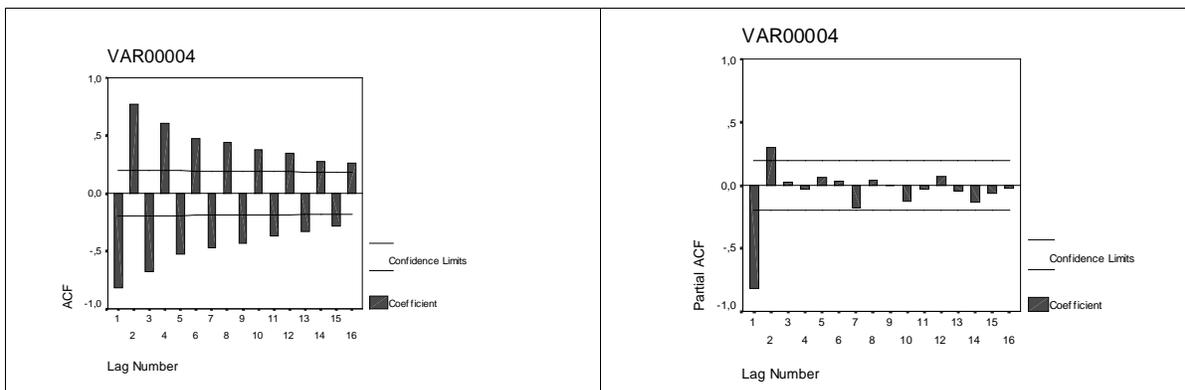


Figura 54: Gráfico de autocorrelação e autocorrelação parcial da série AR(2) com $\theta_1 = -0.6$, $\theta_2 = 0.3$.

A função de autocorrelação para este modelo nos mostra um amortecimento exponencial alternado (Figura 54) e a função de autocorrelação parcial nos mostra que os dois primeiros valores estão fora dos limites (Figura 54). Estas características da FAC e FACP nos mostra que este processo é autorregressivo de ordem 2 com ϕ_1 negativo e ϕ_2 positivo.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\phi_1 = -0.6$	-0.5710069	-0.540361	-0.5764	-0.57256
$\phi_2 = 0.3$	0.2964205	0.350339	0.3021	0.30424
$\mu = 10$	9.9918359	9.995868	9.9918	9.99134

Figura 55: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados

Para a série com o parâmetro $\phi_1 = -0,6$, $\phi_2 = 0,3$ e $\mu = 10$, verificamos que o melhor valor estimado para ϕ_1 é **-0.5764**, para ϕ_2 é **0.3021**, ambos obtidos pelo *software* MINITAB e o melhor valor estimado para μ é 9.995868, obtida pelo EViews, como é mostrado na Figura 55.

4.5 - Modelo de Médias Móveis de ordem 1 – MA(1) com parâmetros $\theta = 0.7$

Os modelos de médias móveis são sempre estacionários (Figura 56).

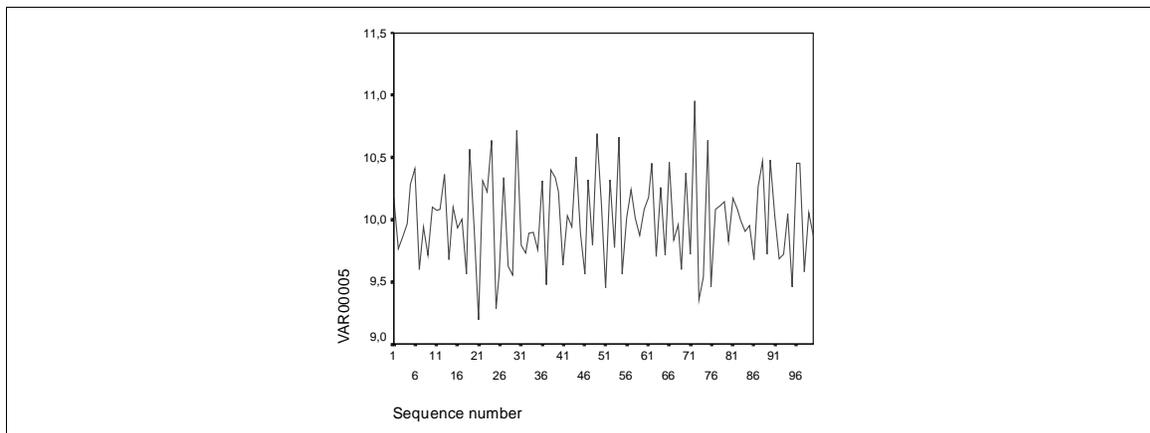


Figura 56 : Gráfico da série MA(1) gerada com $\theta = 0.7$.

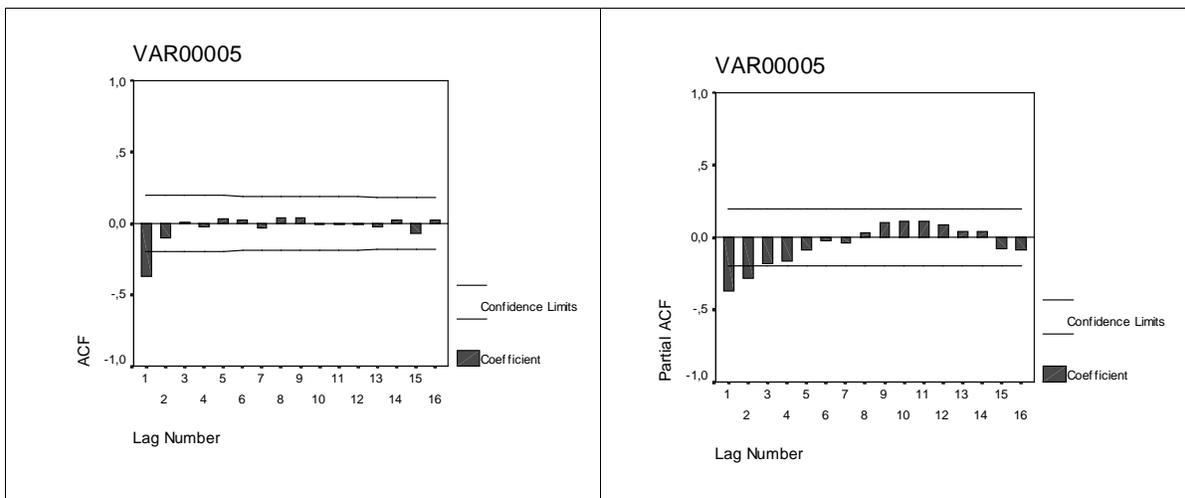


Figura 57: Gráfico de autocorrelação e autocorrelação parcial da série MA(1) com $\theta = 0.7$.

O modelo MA(1) com $\theta = 0.7$ apresenta função de autocorrelação com um valor fora do limite e pertencente à parte negativa do gráfico e a função de autocorrelação parcial (Figura 57) com um amortecimento exponencial pertencente à parte negativa do gráfico. Estas características da FAC e FACP nos mostra que este processo é de médias móveis com $\theta =$ positivo.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\theta = 0.7$	0.616588	0.619987	0.6224	0.62249
$\mu = 10$	10.004214	10.00674	10.0042	10.00424

Figura 58: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados

Para a série com o parâmetro $\theta = 0.7$ e $\mu = 10$, verificamos que o melhor valor estimado para θ é **0.62249** obtidos pelo *software* SAS e o melhor valor estimado para μ é **10.0042** obtido pelo MINITAB, como é mostrado na Figura 58.

4.6 - Modelo de Médias Móveis de ordem 1 – MA(1) com parâmetros $\theta = -0.7$

Os modelos de médias móveis são sempre estacionários (Figura 59).

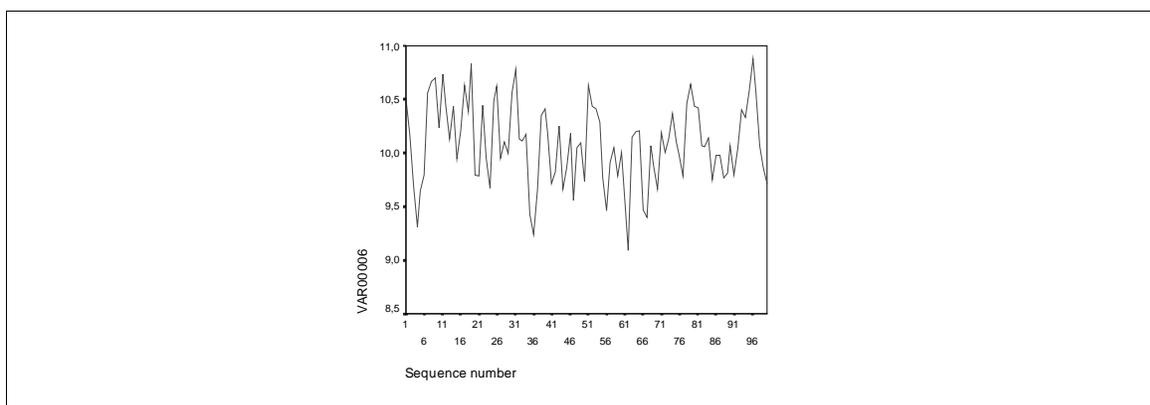


Figura 59: Gráfico da série MA(1) gerada com $\theta = -0.7$.

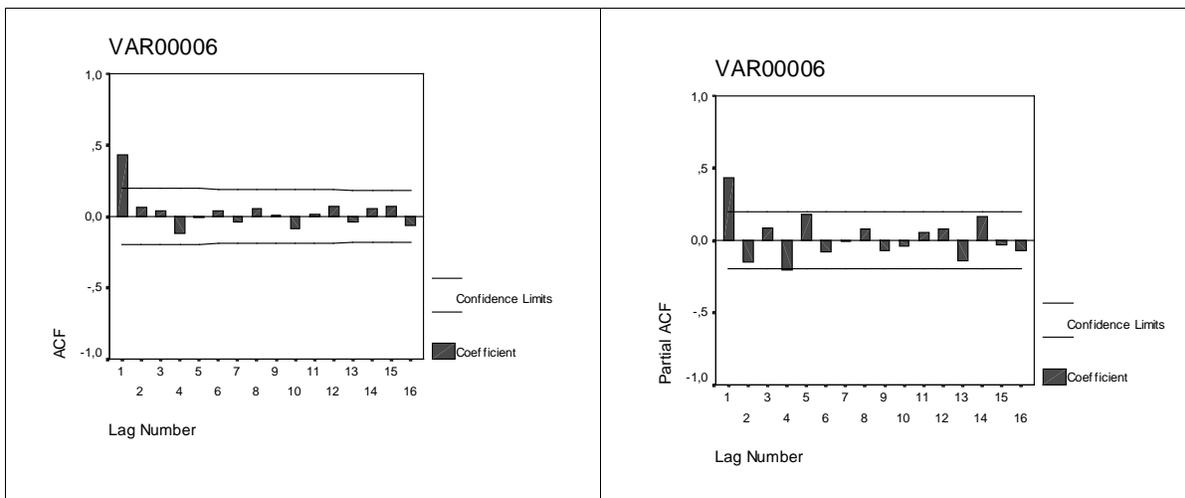


Figura 60: Gráfico de autocorrelação e autocorrelação parcial da série MA(1) com $\theta = -0.7$.

O modelo MA(1) com $\theta = -0.7$ apresenta função de autocorrelação (Figura 60) com um valor fora do limite e pertencente à parte positiva do gráfico e a função de autocorrelação parcial (Figura 60) com um amortecimento exponencial alternado e com o primeiro valor pertencente à parte positiva do gráfico. Estas características da FAC e FACP nos mostra que este processo é de médias móveis com $\theta =$ negativo.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\theta = -0.7$	-0.610793	-0.695663	-0.6192	-0.59837
$\mu = 10$	10.085351	10.004023	10.0854	10.08863

Figura 61: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados

Para a série com o parâmetro $\theta = -0.7$ e $\mu = 10$, verificamos que o melhor valor estimado para θ é -0.695663 obtidos pelo *software* EViews e o melhor valor estimado para μ é 10.004023 também obtido pelo EViews, como é mostrado na Figura 61.

4.7 - Modelo de Médias Móveis de ordem 2 – MA(2) com parâmetros $\theta_1 = 0.7$, $\theta_2 = -0.2$ e $\mu = 10$

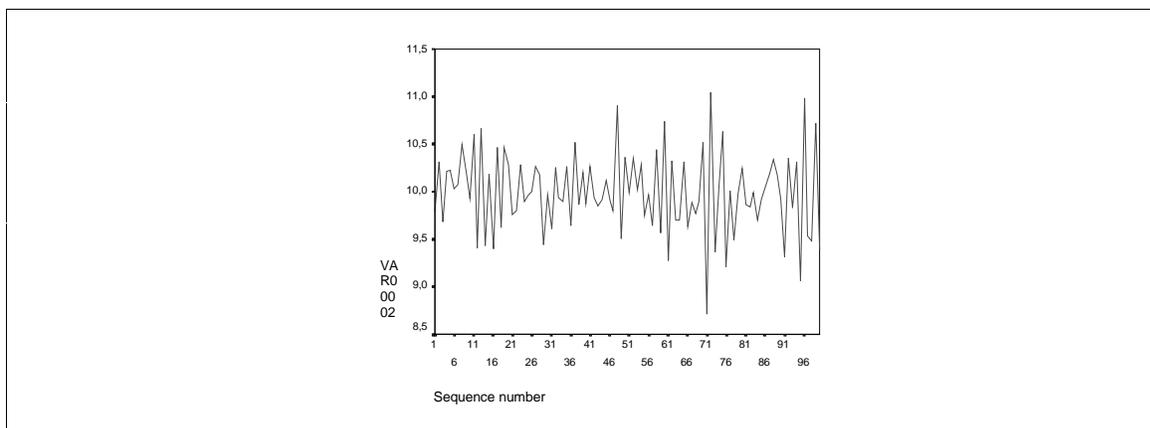


Figura 62: Gráfico da série para o modelo de Médias Móveis com parâmetros $\theta_1 = 0.7$, $\theta_2 = -0.2$ e $\mu = 10$.

Podemos verificar que a série é estacionária como toda série pertencente aos modelos de médias móveis. Os valores giram em torno da média (Figura 62).

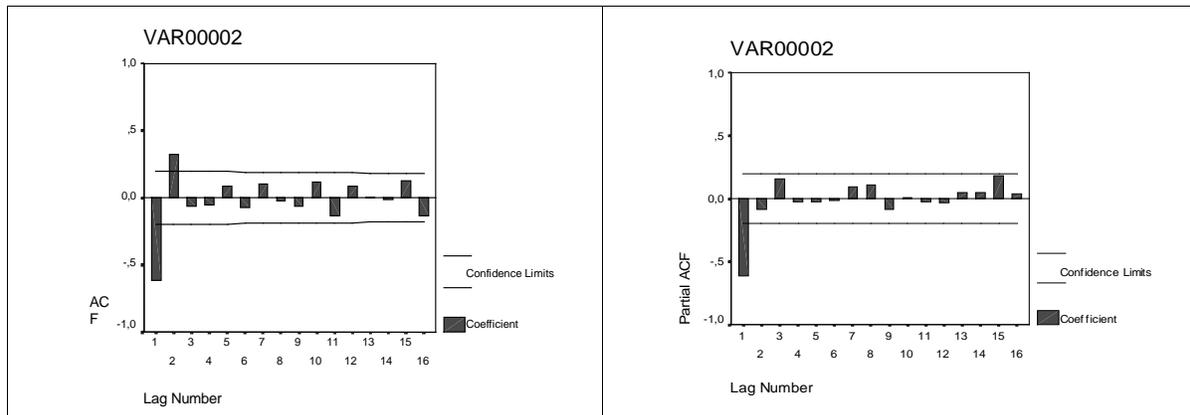


Figura 63: Gráfico de autocorrelação e autocorrelação parcial para o modelo MA(2) com parâmetros $\theta_1 = 0.7$, $\theta_2 = -0.2$ e $\mu = 10$.

Pela Figura 63, podemos verificar respectivamente que o gráfico de autocorrelação para o modelo MA(2) apresenta o primeiro *lag* negativo pois θ_1 é positivo e o segundo *lag* positivo pois θ_2 é negativo e apenas estes dois primeiros *lags* são significativos e que o gráfico de autocorrelação parcial para o modelo MA(2) apresenta um decaimento senoidal. Observando os gráficos de autocorrelação e autocorrelação parcial verificamos que o modelo é de médias móveis de ordem 2 com parâmetros θ_1 positivo e θ_2 negativo.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\theta_1 = 0.7$	0.5926302	0.675041	0.5968	0.59623
$\theta_2 = -0.2$	-0.3265720	-0.275157	-0.3303	-0.33013
$\mu = 10$	9.9940549	9.974935	9.99405	9.99390

Figura 64: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados

Para a série com o parâmetro $\theta_1 = 0.7$, $\theta_2 = -0.2$ e $\mu = 10$, verificamos que o melhor valor estimado para θ_1 é 0.675041 obtido pelo *software* EViews, o melhor valor estimado para θ_2 é -0.275157, também obtido pelo *software* EViews e o melhor valor estimado para μ é 9.9940549 obtido pelo SPSS, como é mostrado na Figura 64.

4.8 - Modelo de Médias Móveis de ordem 2 – MA(2) com parâmetros $\theta_1 = 0.6$, $\theta_2 = 0.3$ e $\mu = 10$

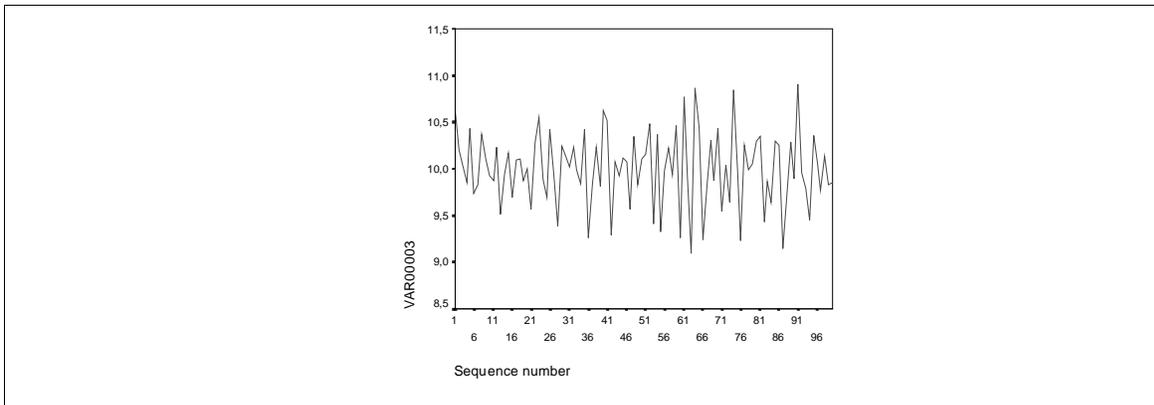


Figura 65: Gráfico da série para o modelo de Médias Móveis com parâmetros $\theta_1 = 0.6$, $\theta_2 = 0.3$ e $\mu = 10$.

Podemos verificar que a série é estacionária como toda série pertencente aos modelos de médias móveis. Os valores giram em torno da média (Figura 65).

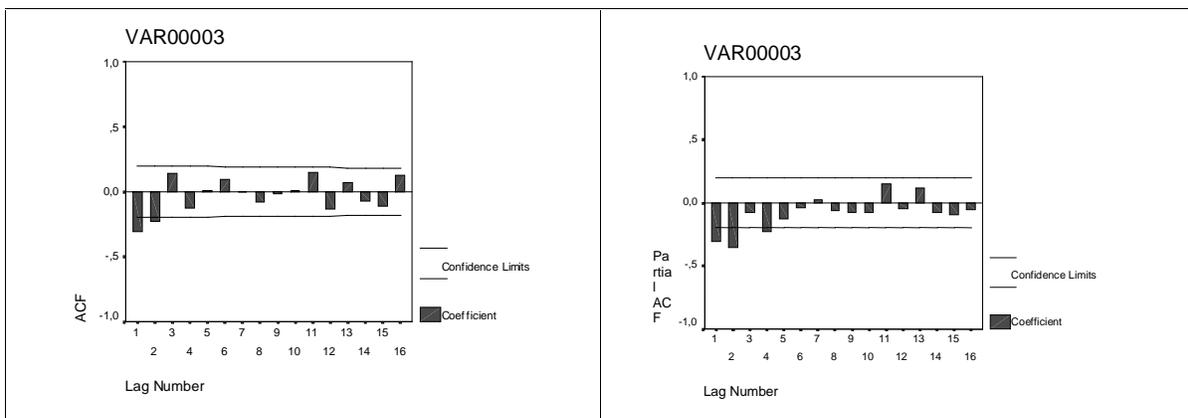


Figura 66: Gráfico de autocorrelação e autocorrelação parcial para o modelo MA(2) com parâmetros $\theta_1 = 0.6$, $\theta_2 = 0.3$ e $\mu = 10$.

Pela Figura 66, podemos ver que o gráfico de autocorrelação para o modelo MA(2) apresenta o primeiro e o segundo *lag* negativo pois θ_1 e θ_2 são positivos. Apenas estes dois primeiros *lags* são significativos. Já o gráfico de autocorrelação parcial para o modelo MA(2) apresenta um decaimento exponencial. Observando os gráficos de autocorrelação e autocorrelação parcial (Figura 66) verificamos que o modelo é de médias móveis de ordem 2 com parâmetros θ_1 e θ_2 positivos.

Parâmetro Pré-fixado	Software SPSS	Software EViews	Software MINITAB	Software SAS
$\theta_1 = 0.6$	0.5927511	0.630327	0.5994	0.48781
$\theta_2 = 0.3$	0.2702331	0.237923	0.2779	0.23501
$\mu = 10$	9.9962339	9.995605	9.99630	9.99931

Figura 67: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados.

Para a série com o parâmetro $\theta_1 = 0.6$, $\theta_2 = 0.3$ e $\mu = 10$, verificamos que o melhor valor estimado para θ_1 é **0.5994** obtido pelo *software* MINITAB, o melhor valor estimado para θ_2 é **0.2779** também obtido pelo *software* MINITAB e o melhor valor estimado para μ é **9.99931** obtido pelo SAS, como é mostrado na Figura 67.

4.9 - Modelos Autorregressivos e Médias Móveis com parâmetros

$$\phi = -0,8, \theta = 0,5 \text{ e } \mu = 10.$$

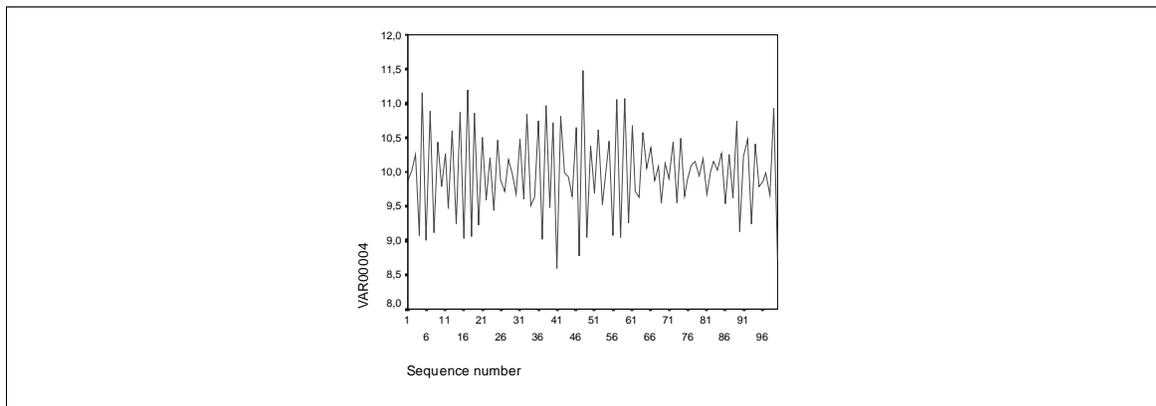


Figura 68: Gráfico da série para o modelo Autorregressivo e Médias Móveis com parâmetros $\phi = -0,8$, $\theta = 0,5$ e $\mu = 10$

Podemos verificar os valores giram em torno da média (Figura 68).

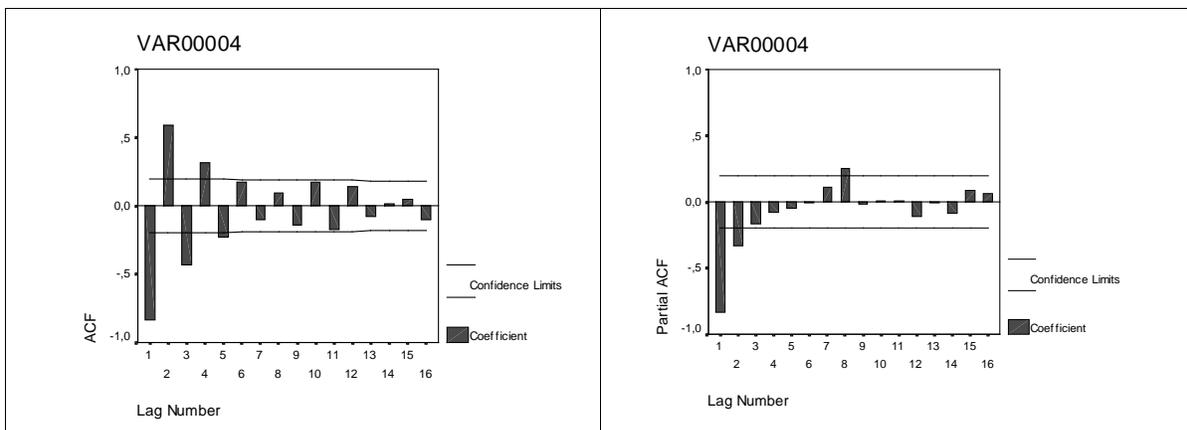


Figura 69: Gráfico de autocorrelação e autocorrelação parcial para o modelo ARMA(1,1) com parâmetros $\phi = -0,8$, $\theta = 0,5$ e $\mu = 10$.

Pela Figura 69, podemos verificar que o gráfico de autocorrelação para o modelo ARMA(1,1) apresenta um decaimento exponencial alternado e podemos verificar que o gráfico de autocorrelação parcial para o modelo ARMA(1,1) apresenta o primeiro *lag* significativo e negativo pois θ é positivo e a partir do segundo *lag* temos um decaimento exponencial alternado pois ϕ é negativo.

Observando os gráficos de autocorrelação e autocorrelação parcial (Figura 69) verificamos que o modelo é Autorregressivo e de Médias Móveis com parâmetros ϕ negativo e θ positivo.

Parâmetro Pré-fixado	<i>Software</i> SPSS	<i>Software</i> EViews	<i>Software</i> MINITAB	<i>Software</i> SAS
$\phi = -0.8$	-0.7422611	-0.674572	-0.7505	-0.75110
$\theta = 0.5$	0.5526098	0.578752	0.5573	0.55029
$\mu = 10$	9.9968720	9.999264	9.9969	9.99642

Figura 70: Tabela comparativa das estimativas obtidas em cada um dos *softwares* utilizados

Para a série com o parâmetro $\phi = -0.8$, $\theta = 0.5$ e $\mu = 10$, verificamos que o melhor valor estimado para ϕ é **-0.75110** obtido pelo *software* SAS, o melhor valor estimado para θ é **0.55029** também obtido pelo *software* SAS e o melhor valor estimado para μ é 9.999264 obtido pelo EViews, como é mostrado na Figura 70.

4.10 - Vícios Estimados

A forma utilizada neste trabalho para comparar os valores pré-fixados dos parâmetros com suas respectivas estimativas fornecidas pelos *softwares*, foi calculando a diferença entre os mesmos, obtendo-se assim o vício da estimativa (vício = valor estimado – valor real) que é apresentado na Figura 71 abaixo.

Modelo	Parâmetro Pré-fixado	Vício MINITAB	Vício SAS	Vício SPSS	Vício EViews
AR(1)	$\phi_1=0.7$	-0.01390	-0.01998	-0.026210	-0.021132
	$\mu = 10$	+0.13850	+0.12081	+0.138560	+0.161060
AR(1)	$\phi_1 = -0.7$	-0.00380	+0.00194	+0.002400	+0.001955
	$\mu = 10$	-0.00060	+0.00001	-0.000644	-0.001335
AR(2)	$\phi_1=0.2$	+0.01260	+0.01448	+0.010137	-0.013672
	$\phi_2=0.7$	+0.04540	+0.04650	+0.026905	+0.085134
	$\mu = 10$	-0.16720	-0.08550	-0.260389	-0.122388
AR(2)	$\phi_1=-0.6$	+0.02360	+0.02744	+0.028993	+0.059639
	$\phi_2=0.3$	+0.00210	+0.00424	-0.003579	+0.050339
	$\mu = 10$	-0.00820	-0.00866	-0.008164	-0.004132
MA(1)	$\theta_1 = 0.7$	-0.07760	-0.07751	-0.083412	-0.080013
	$\mu = 10$	+0.00420	+0.00424	+0.004214	+0.006740
MA(1)	$\theta_1 = -0.7$	+0.08080	+0.10163	+0.089207	+0.004337
	$\mu = 10$	+0.08540	+0.08863	+0.085351	+0.004023
MA(2)	$\theta_1 = 0.7$	-0.10320	-0.10377	-0.107370	-0.024959
	$\theta_2 = -0.2$	-0.13030	-0.13013	-0.126572	-0.075157
	$\mu = 10$	-0.00595	-0.00610	-0.005945	-0.025065
MA(2)	$\theta_1 = 0.6$	-0.00060	-0.11219	-0.007249	+0.030327
	$\theta_2 = 0.3$	-0.02210	-0.06499	-0.029767	-0.062077
	$\mu = 10$	-0.00370	-0.00069	-0.003766	-0.004395
ARMA(1.1)	$\phi_1 = -0.8$	+0.04950	+0.04890	+0.057739	+0.125428
	$\theta_1 = 0.5$	+0.05730	+0.05029	+0.052610	+0.078752
	$\mu = 10$	-0.00310	-0.00358	-0.003128	-0.000736
Vício Médio Estimado (em valor absoluto)		0.045202	0.048792	0.050535	0.045339

Figura 71: Vícios obtidos para cada um dos parâmetros estimados por cada *software*.

Pela Figura 71, podemos verificar que o *software* MINITAB apresenta o menor vício médio estimado e o *software* SPSS apresenta o maior. Os vícios médios encontrados para cada um dos *softwares* estudados são bastante próximos. Outro fato importante a ser destacado é que o intercepto μ apresenta vícios altos em modelos com $\phi_1 > 0$. Nestes casos, o *software* que melhor estima μ é o SAS.

Podemos observar também que, em geral:

- O intercepto μ é subestimado, (exceto no MA(1) e no AR(1) com $\phi_1 > 0$).
- No AR(1), $\phi_1 > 0$ é subestimado e $\phi_1 < 0$ é superestimado.
- No AR(2), os ϕ 's são superestimados.
- No MA(1), $\phi_1 > 0$ é subestimado e $\phi_1 < 0$ é superestimado.
- No MA(2), os ϕ 's são subestimados.
- No ARMA(1,1), os parâmetros são superestimados, exceto ϕ_1 (quando $\phi_1 < 0$).

Análise Descritiva dos Dados e Comparação dos *Softwares*

O objetivo deste capítulo é comparar os *softwares* citados no capítulo 3 quanto ao ajuste de modelos ARMA(p,q). Lembramos que os *softwares* utilizados são MINITAB versão 13.0, SAS versão 8.0, SPSS versão 8.0 e EViews versão 3.0.

A partir dos vícios obtidos para cada um dos parâmetros estimados dos modelos ARMA(p,q), faremos uma análise descritiva destes dados. Como o objetivo é entendermos melhor o que ocorre em cada um dos *softwares* estudados no que diz respeito à estimação de parâmetros em modelos ARMA, apresentaremos a análise descritiva dos vícios em três etapas. A primeira etapa diz respeito aos vícios de todos os parâmetros estimados (\emptyset , θ e μ). Na segunda etapa apresentaremos uma análise dos vícios separados por parâmetros (\emptyset e θ) e intercepto (μ) e na terceira, uma análise dos vícios separados por modelos autorregressivos e modelos de médias móveis.

Em cada uma das etapas descritas anteriormente, apresentaremos uma análise comparativa dos vícios médios obtidos em cada *software* com o objetivo de verificar se a diferença destes vícios médios realmente são significativas, ou seja, verificaremos se os *softwares* estudados são similares ou não quanto a estimação dos modelos ARMA. Para tal utilizaremos Análise de Variância (Triola, 1998) e Comparações Múltiplas de Tukey (Werkema et al., 1996). O nível de significância para as análises é igual à 5%.

A análise de Variância apresenta o teste F de Fisher que será utilizado para verificar se os vícios médios obtidos por cada *software* são iguais ou se existe alguma diferença, mas, este teste não indica qual dos *softwares* apresenta vício médio diferente. Se o valor-p apresentar um valor superior ao do nível de significância, não existirá diferença significativa entre os *softwares* no que diz respeito à estimação dos parâmetros; caso contrário, haverá diferença significativa entre os *softwares*. As Comparações Múltiplas de Tukey serão utilizadas para verificar qual dos *softwares* apresenta vício médio diferente dos demais, caso isto ocorra. Neste procedimento, os *softwares* serão comparados dois a dois e para cada uma das comparações nos serão fornecidos intervalos de confiança. Se estes intervalos contiverem o valor zero, os dois *softwares* que estiverem sendo comparados não apresentam diferenças quanto à estimação dos parâmetros. Caso contrário, os *softwares* comparados apresentarão diferenças.

5.1 - Análise Geral

Neste momento, apresentaremos uma análise descritiva de todos os vícios obtidos a partir das estimativas fornecidas pelos *softwares* MINITAB, SAS, SPSS e EViews, para todos os parâmetros e todos os modelos ajustados conjuntamente. Tivemos um total de 23 parâmetros estimados (incluindo \emptyset , θ e μ) para os nove modelos estimados: dois AR(1), dois MA(1), dois AR(2), dois MA(2) e um ARMA(1,1).

5.1.1 – Análise Descritiva para todos os parâmetros

A tabela abaixo apresenta as estatísticas descritivas para o vício dos parâmetros. Em negrito estão apresentados os menores valores para cada estatística.

Variável	Software	N	Média	Mediana	DP	Min	Max
Vício	MINITAB	23	0.0452	0.0221	0.0509	0.0006	0.1672
	SAS	23	0.0488	0.0465	0.0450	0.0000	0.1301
	SPSS	23	0.0505	0.0269	0.0631	0.0006	0.2604
	EViews	23	0.0453	0.0251	0.0466	0.0007	0.1611

Figura 72: Estatística descritiva dos vícios obtidos a partir das estimativas dos parâmetros (\emptyset e θ) e intercepto (μ)

Pela Figura 72, podemos verificar que o *software* SPSS apresenta a maior média e o MINITAB e EViews, as menores. A maior mediana é apresentada pelo SAS. As medianas dos *softwares* MINITAB, SPSS e EViews apresentam valores semelhantes. O maior desvio padrão é apresentado pelo SPSS, enquanto os *softwares* SAS e EViews apresentam os menores desvios padrões. O valor mínimo para o vício foi encontrado no *software* SAS, e o valor máximo no SPSS.

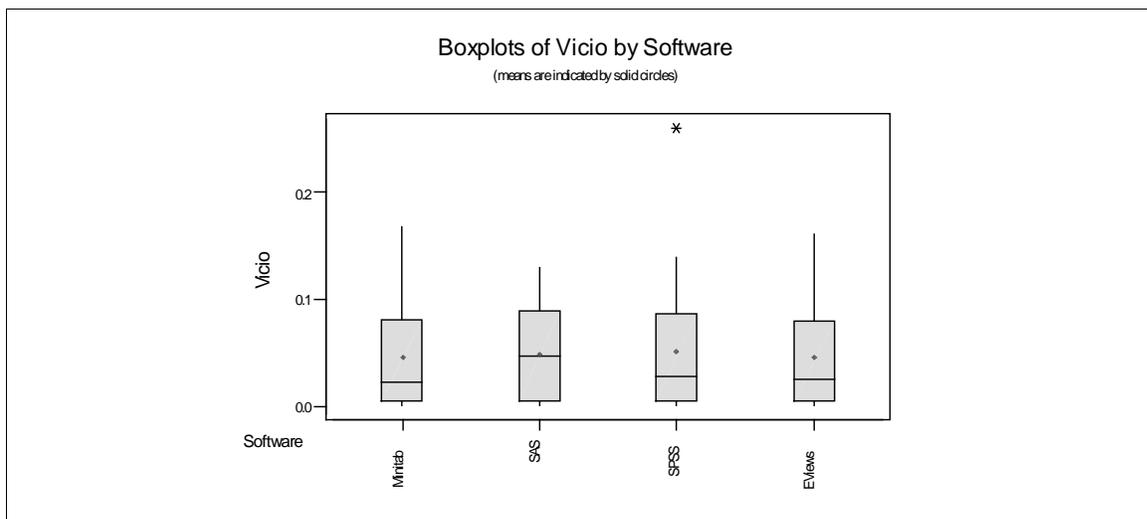


Figura 73: Gráfico dos vícios das estimativas divididos por *software*.

Pela Figura 73, podemos verificar que os *softwares* MINITAB, SPSS e EViews apresentam medianas com valores semelhantes. O *software* SAS apresenta um valor para sua mediana maior que os demais e é o único *software* que apresentou valores para mediana e média próximos. Os demais *softwares* apresentam valores para suas médias superiores aos da suas medianas. A variabilidade dos vícios em cada um dos *softwares* é semelhante. O *software* SPSS apresenta *outlier*, ou seja, um valor para o vício extremamente grande que ocorreu na estimação da constante μ no modelo AR(2) com parâmetros $\emptyset_1 = 0.2$ e $\emptyset_2 = 0.7$.

A princípio, poderíamos identificar o MINITAB como o melhor pacote, pois apresentou os menores valores para média e mediana, e valores bem próximos aos dos outros *softwares* para o desvio-padrão, o mínimo e o máximo. Porém, o fato da mediana ser bem menor que a média (o que pode ser

observado também para os *softwares* SPSS e EViews) indica que algumas das estimativas estão tendo um vício muito grande, o que está puxando a média para cima. Este fato não ocorre com o SAS, que tem valores próximos para a média e a mediana. Nas próximas seções, faremos a análise separada para as estimativas e para os modelos, para tentar identificar em que situações estes *softwares* estão sub ou super estimando os valores dos parâmetros.

5.1.2 - Comparação Geral dos Softwares

Para verificar se os *softwares* são similares ou não na estimação de modelos ARMA, utilizaremos uma análise de variância e comparações múltiplas de Tukey, conforme foi dito anteriormente.

Source	gl	SS	MS	F	P
Software	3	0.00048	0.00016	0.06	0.981
Error	88	0.23675	0.00269		
Total	91	0.23723			

Intervalo com 95% de confiança para média com base no Desvio Padrão (DP) aparado					
Software	N	média	DP		
MINITAB	23	0.04520	0.05089	(-----*-----)	
Sas	23	0.04879	0.04496	(-----*-----)	
SPSS	23	0.05054	0.06309	(-----*-----)	
EViews	23	0.04534	0.04659	(-----*-----)	
DP aparado =		0.05187		0.030	0.045 0.060 0.075

Figura 74: Análise de variância geral para os vícios.

Na Figura 74 é mostrado o teste F de Fisher para os vícios divididos por *software*, adotando o nível de significância igual a 5%. Este teste nos diz que não existe diferença entre os vícios médios obtidos para cada *software*, pois, apresenta valor-p superior aos 5% de significância, ou seja, valor-p = 0.981 > 0.05 indicando que os *softwares* são similares quanto à estimação dos parâmetros. Os intervalos de confiança para cada *software* apresentam valores próximos.

5.2 - Análise dividida por parâmetros (ϕ e θ) e intercepto (μ)

Neste momento, apresentaremos uma análise de todos os vícios obtidos a partir das estimativas dos parâmetros (ϕ e θ) pelos *softwares* MINITAB, SAS, SPSS e EViews e em seguida a análise de todos os vícios obtidos a partir das estimativas do intercepto (μ). Neste caso, temos 14 parâmetros estimados, 7 na parte autorregressiva (dois para os AR(1), quatro para os AR(2) e um para o ARMA(1,1)) e 7 na parte média móvel (dois para os MA(1), dois para os MA(2) e um para o ARMA(1,1)).

5.2.1 - Parâmetros ϕ e θ

5.2.1.1 - Análise Descritiva

A tabela abaixo apresenta as estatísticas descritivas para o vício dos parâmetros ϕ e θ .

Variável	Software	N	Média	Mediana	DP	Min	Max
Vício	MINITAB	14	0.0445	0.0345	0.0408	0.0006	0.1303

SAS	14	0.0574	0.0496	0.0422	0.0019	0.1301
SPSS	14	0.0466	0.0294	0.0407	0.0024	0.1266
EViews	14	0.0509	0.0550	0.0362	0.0019	0.1254

Figura 75: Estatística descritiva dos vícios obtidos a partir das estimativas dos parâmetros (\emptyset e θ)

Pela Figura 75, podemos verificar que o *software* SAS apresenta a maior média, enquanto as menores médias são obtidas nos *softwares* MINITAB e SPSS. A maior mediana é apresentada pelo EViews e a menor, pelo SPSS. O maior desvio padrão é apresentado pelo SAS e o menor, pelo EViews. Os *softwares* MINITAB, SAS e SPSS apresentam desvios padrões próximos. O valor mínimo para os vícios foi encontrado no *software* MINITAB. O SAS, SPSS e EViews apresentam valores mínimos para os vícios semelhantes. O valor máximo para os vícios foi apresentado pelo MINITAB, mas estes valores máximos são semelhantes para os quatro *softwares*.

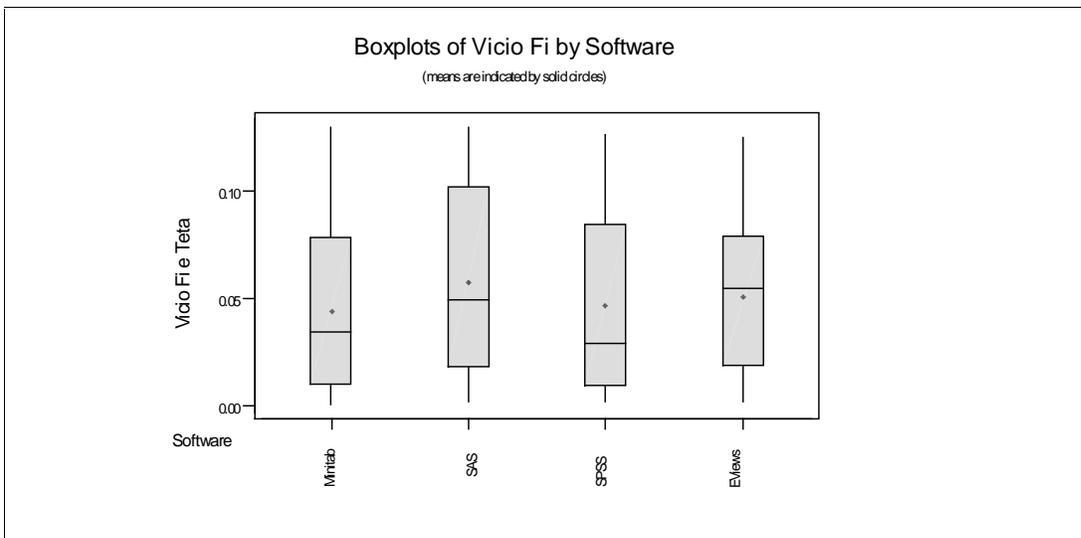


Figura 76: Gráfico dos vícios dos parâmetros (\emptyset e θ) divididos por *software*.

Pela Figura 76, podemos verificar que os *softwares* MINITAB e SPSS apresentam medianas com valores semelhantes e menores que os valores encontrados para o SAS e EViews. Os *softwares* MINITAB, SAS e SPSS apresentam valores para suas médias superiores aos das suas medianas. A variabilidade dos vícios no SAS e SPSS são semelhantes entre si e são maiores que nos demais *softwares*.

5.2.1.2 - Comparação dos *Softwares* segundo os parâmetros \emptyset e θ estimados

Source	gl	SS	MS	F	P
Software	3	0.00137	0.00046	0.29	0.836
Error	52	0.08340	0.00160		
Total	55	0.08477			

Intervalo com 95% de confiança para média com base no Desvio Padrão (DP) aparado					
Software	N	Média	DP		
MINITAB	14	0.04449	0.04084	(-----+-----+-----+-----)	(-----*-----)
Sas	14	0.05743	0.04219	(-----+-----+-----+-----)	(-----*-----)
SPSS	14	0.04658	0.04067	(-----+-----+-----+-----)	(-----*-----)
EViews	14	0.05092	0.03624	(-----+-----+-----+-----)	(-----*-----)
-----+-----+-----+-----					
DP aparado =	0.04005			0.032	0.048
				0.064	0.080

Figura 77: Análise de variância para os vícios obtidos a partir da estimação dos parâmetros \emptyset e θ .

Na Figura 77 é mostrado o teste F de Fisher para os vícios divididos por *software*, adotando o nível de significância igual a 5%. Este teste nos diz que não existe diferença entre os vícios médios

obtidos para cada *software*, pois, apresenta valor-p superior aos 5% de significância, ou seja, valor-p = 0.836 > 0.05 indicando que os *softwares* são similares quanto à estimação dos parâmetros. Os intervalos de confiança para cada *software* apresentam valores próximos.

5.2.2 - Parâmetro μ

5.2.2.1 - Análise Descritiva

Variável	Software	N	Média	Mediana	DP	Min	Max
Vício μ_i	MINITAB	9	0.0463	0.0059	0.0664	0.0006	0.1672
	SAS	9	0.0354	0.0061	0.0483	0.0000	0.1208
	SPSS	9	0.0567	0.0059	0.0905	0.0006	0.2604
	EViews	9	0.0367	0.0044	0.0608	0.0007	0.1611

Figura 78: Estatística descritiva dos vícios obtidos a partir das estimativas do intercepto (μ)

Pela Figura 78, podemos verificar que o *software* SPSS apresenta a maior média e o SAS e EViews, as menores. A maior mediana é apresentada pelo SAS e a menor, pelo EViews. As medianas dos quatro *softwares* são bastante próximas. O maior desvio padrão é apresentado pelo SPSS e o menor, pelo SAS. Os *softwares* MINITAB e EViews apresentam desvios padrões próximos. O valor mínimo para os vícios foi encontrado no *software* SAS. O MINITAB, SPSS e EViews apresentam valores mínimos para os vícios semelhantes. O valor máximo para os vícios foi apresentado pelo SPSS. Os valores máximos são semelhantes para os *softwares* MINITAB, SAS e EViews.

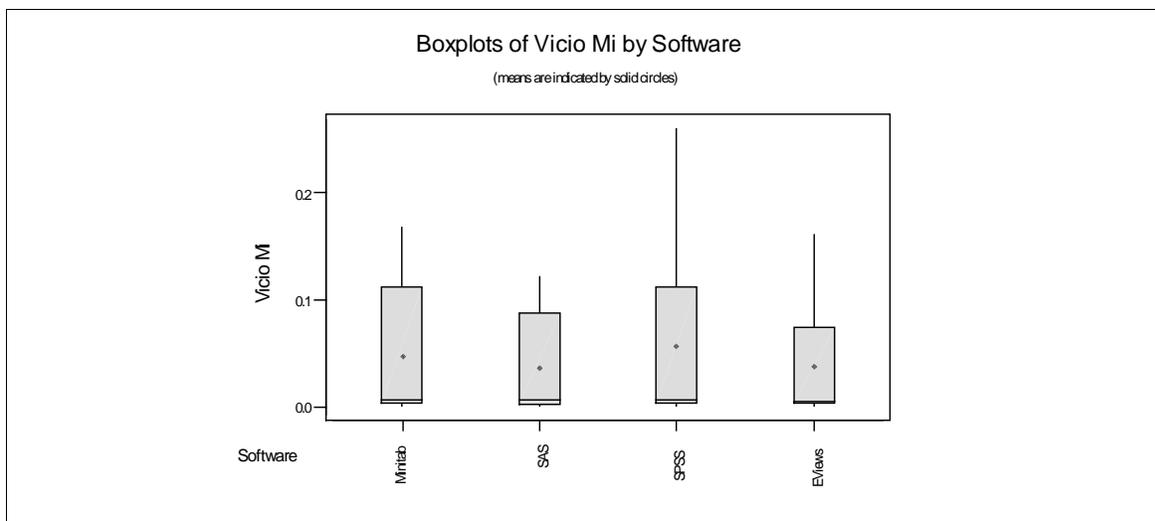


Figura 79: Gráfico dos vícios dos intercepto (μ) divididos por *software*.

Pela Figura 79, podemos verificar que o *software* SAS apresenta a maior mediana. Os demais *softwares* apresentam medianas com valores semelhantes. Todas as medianas estão próximas do valor zero. O *software* SAS e EViews apresentam valores para suas médias semelhantes entre si e menores que as dos demais. Os quatro *softwares* apresentam valores para suas médias superiores aos da suas medianas.

A menor variabilidade e os menores valores dos vícios são encontrados no *software* EViews e as maiores variabilidades são encontradas nos *softwares* MINITAB e SPSS.

Nesta seção podemos perceber que o maior problema ocorre na estimação do intercepto, μ . Para todos os *softwares*, a diferença entre média e mediana é muito grande, sendo o SAS o que apresenta a menor diferença. Assim, vemos que existem algumas situações em que a estimativa do intercepto vem apresentando um vício muito alto. Analisando a Figura (71) do capítulo 4.10, verificamos que o problema ocorre na estimação do intercepto para os modelos AR(1) com \emptyset_1 positivo e AR(2) com \emptyset_1 e \emptyset_2 positivos. No primeiro caso os vícios são semelhantes para os 4 *softwares*, mas no segundo caso, o AR(2), o vício do SAS é bem menor que o dos outros *softwares*. Parece que existe uma dificuldade nos *softwares* para a estimação do intercepto em modelos que possuam o parâmetro \emptyset_1 positivo.

5.2.2.2 - Comparação dos Softwares segundo os parâmetros μ estimados

Source	gl	SS	MS	F	P
Software	3	0.00265	0.00088	0.19	0.903
Error	32	0.14899	0.00466		
Total	35	0.15164			
Intervalo com 95% de confiança para média com base no Desvio Padrão (DP) aparado					
Software	N	Média	DP	-----+-----+-----+-----	
MINITAB	9	0.04632	0.06640	(-----*-----)	
Sas	9	0.03536	0.04829	(-----*-----)	
SPSS	9	0.05668	0.09049	(-----*-----)	
EViews	9	0.03665	0.06078	(-----*-----)	
-----+-----+-----+-----					
DP aparado =	0.06823		0.000	0.035	0.070 0.105

Figura 80: Análise de variância para os vícios obtidos a partir da estimação dos parâmetros μ .

Na Figura 80 é mostrado o teste F de Fisher para os vícios divididos por *software*, adotando o nível de significância igual a 5%. Este teste nos diz que não existe diferença entre os vícios médios obtidos para cada *software*, pois, apresenta valor-p superior aos 5% de significância, ou seja, valor-p = 0.903 > 0.05 indicando que os *softwares* são similares quanto à estimação dos parâmetros. Os intervalos de confiança para cada *software* apresentam valores próximos.

5.3 - Análise dividida por Modelos Autorregressivos e de Médias Móveis

Neste momento, apresentaremos uma análise de todos os vícios obtidos a partir das estimativas dos modelos Autorregressivos (parâmetros \emptyset) e em seguida, uma análise dos vícios obtidos das estimativas dos modelos de Médias Móveis (parâmetros θ). Ambas as análises serão divididas por *softwares* MINITAB, SAS, SPSS e EViews.

5.3.1 - Modelos Autorregressivos

5.3.1.1 – Análise Descritiva

Variável	Software	N	Média	Mediana	DP	Min	Max
Vício Fi	MINITAB	7	0.0216	0.0139	0.0191	0.0021	0.0495
	SAS	7	0.0233	0.0200	0.0188	0.0019	0.0489
	SPSS	7	0.0223	0.0262	0.0193	0.0024	0.0577
	EViews	7	0.0510	0.0503	0.0437	0.0020	0.1254

Figura 81: Estatística descritiva dos vícios obtidos a partir das estimativas do parâmetros \emptyset .

Pela Figura 81, podemos verificar que o *software* EViews apresenta a maior média. As médias para os *softwares* MINITAB, SAS e SPSS apresentam valores bem próximos. A maior mediana é apresentada pelo EViews e a menor, pelo MINITAB. O maior desvio padrão é apresentado pelo EViews. Os *softwares* MINITAB, SAS e SPSS apresentam desvios padrões bem próximos. O valor mínimo para os vícios foi encontrado no *software* SAS, mas os valores mínimos encontrados para todos os *softwares* são semelhantes. Os valores máximos são semelhantes para os *softwares* MINITAB, SAS e SPSS e são todos menores que o do EViews.

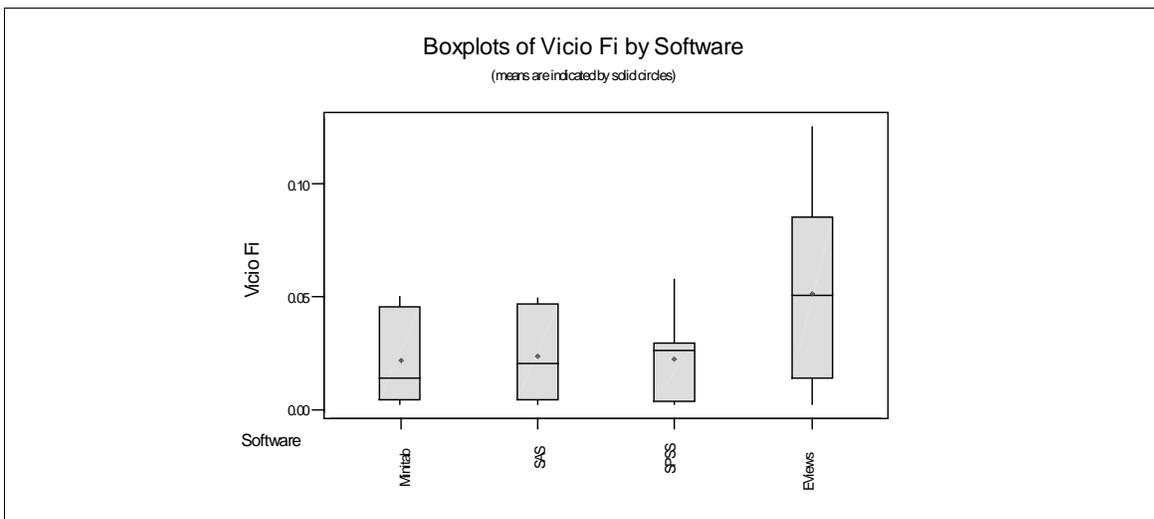


Figura 82: Gráfico dos vícios dos modelos Autorregressivos (parâmetros \emptyset) divididos por *software*.

Pela figura 82, podemos verificar que a mediana encontrada para os *softwares* MINITAB, SAS e SPSS são próximas. A mediana do EViews é bem maior que a dos demais *softwares*. A média encontrada para os *softwares* MINITAB, SAS e SPSS são próximas. A média do EViews é bem maior que a dos demais *softwares*. Para o MINITAB e SAS, temos suas médias com valores maiores que de suas medianas. Para o SPSS temos o valor de sua média superior ao de sua mediana e apresenta também, os menores valores para os vícios. Já o *software* EViews apresenta um mesmo valor para sua média e mediana. A menor variabilidade os vícios é apresentada pelo SPSS e a maior é apresentada pelo EViews. Os *softwares* MINITAB e SAS apresentam variabilidade intermediária e semelhantes entre si.

5.3.1.2 - Comparação dos *Softwares* segundo os parâmetros \emptyset estimados

Source	gl	SS	MS	F	P
Software	3	0.004319	0.001440	1.92	0.153
Error	24	0.018008	0.000750		
Total	27	0.022327			

Intervalo com 95% de confiança para média com base no Desvio Padrão (DP) aparado					
Software	N	Média	DP		
MINITAB	7	0.02156	0.01909	(-----*-----)	
Sas	7	0.02335	0.01879	(-----*-----)	
SPSS	7	0.02228	0.01929	(-----*-----)	
EViews	7	0.05104	0.04372	(-----*-----)	

DP aparado = 0.02739

Figura 83: Análise de variância para os vícios obtidos a partir da estimação dos parâmetros θ dos modelos autorregressivos

Na Figura 83 é mostrado o teste F de Fisher para os vícios divididos por *software*, adotando o nível de significância igual a 5%. Este teste nos diz que não existe diferença entre os vícios médios obtidos para cada *software*, pois, apresenta valor-p superior aos 5% de significância, ou seja, valor-p = 0.153 > 0.05 indicando que os *softwares* são similares quanto à estimação dos parâmetros. Os intervalos de confiança para cada *software* apresentam valores próximos. Somente o EViews apresenta média um pouco superior aos demais, mas não foi significativamente diferente.

5.3.2 - Modelos de Médias Móveis

5.3.2.1 – Análise Descritiva

Variável	Software	N	Média	Mediana	DP	Min	Max
Vício Teta	MINITAB	7	0.0674	0.0776	0.0450	0.0006	0.1303
	SAS	7	0.0915	0.1016	0.0282	0.0503	0.1301
	SPSS	7	0.0709	0.0834	0.0428	0.0072	0.1266
	EViews	7	0.0508	0.0621	0.0306	0.0043	0.0800

Figura 84: Estatística descritiva dos vícios obtidos a partir das estimativas do parâmetros θ .

Pela Figura 84, podemos verificar que o *software* SAS apresenta a maior média e o EViews, a menor. A maior mediana é apresentada pelo SAS e a menor, pelo EViews. O maior desvio padrão é apresentado pelo MINITAB e o menor, pelo SAS. Os *softwares* MINITAB e SPSS apresentam desvios padrões bem próximos. O valor mínimo para os vícios foi encontrado no *software* MINITAB. O valor máximo para os vícios foi apresentado pelo MINITAB. Os valores máximos são semelhantes para os *softwares* MINITAB, SAS e SPSS e são todos maiores que o do EViews.

5.4 - Conclusões

A partir das análises descritivas feitas para os vícios obtidos das estimativas dos parâmetros dos modelos ARMA estudados, podemos tirar as seguintes conclusões:

- Pela análise feita com todos os vícios, análise descritiva geral, verificamos que os desvios padrões são grandes quando comparados com as médias e medianas dos vícios. O *software* MINITAB apresentou a menor média e a menor mediana, portanto, no geral este *software* mostrou ser o melhor na estimação dos modelos ARMA(p,q). Porém, o fato da mediana dos vícios ser bem menor que a média indica que algumas das estimativas estão tendo um vício muito grande. Como este fato não ocorre com o SAS, que tem valores próximos para a média e a mediana, este talvez seja mais robusto para estimar modelos ARMA(p,q).
- Para a estimação dos parâmetros ϕ e θ , verificamos que não existem diferenças substanciais entre os quatro *softwares* pesquisados. Assim, a princípio qualquer um deles poderia ser utilizado para a estimação dos parâmetros ϕ e θ dos modelos ARMA(p,q).
- A análise feita com os vícios obtidos das estimações dos interceptos μ , evidenciou que o problema ocorre na estimação do intercepto em modelos que possuem o parâmetro autorregressivo ϕ_1 positivo. Neste caso, o SAS foi o *software* que apresentou um menor vício na estimação de μ .
- Verificamos que modelos autorregressivos são estimados com maior precisão que os modelos médias móveis. Neste caso, o EViews é o *software* que apresenta melhor performance no caso de modelos médias móveis, porém pior performance para modelos autorregressivos.

A partir das comparações dos *softwares* feitas para os vícios obtidos das estimativas dos parâmetros dos modelos ARMA estudados, utilizando a análise de variância, podemos concluir que, para qualquer um dos parâmetros estimados, os *softwares* estudados não apresentaram diferenças significativas.

Concluimos então que os quatro *softwares* são similares no que diz respeito à estimação de modelos ARIMA (p,d,q). O MINITAB, o SAS e o SPSS são bem regulares em todos os casos. O SAS apresenta a vantagem de estimar melhor o intercepto em modelos que possuem o parâmetro autorregressivo ϕ_1 positivo e o EViews tem uma pior performance para modelos autorregressivos em geral. Porém estas diferenças entre os *softwares* são pequenas e não são estatisticamente significativas. Portanto, as estimativas obtidas pelos quatro *softwares* estudados podem ser considerados equivalentes para um nível de significância de 5%.

Conclusão Geral

As estimações dos modelos ARMA(p,q) feitas pelos *softwares* MINITAB, SAS, SPSS e EViews apresentaram algumas diferenças, mas, no geral, os *softwares* se mostraram bem regulares. O *software* MINITAB foi o que apresentou menor vício médio, portanto, no geral este *software* se mostrou melhor na estimação dos modelos ARMA(p,q). Porém o SAS teve menor variabilidade, fazendo com que ele seja mais robusto para estimar modelos ARMA(p,q). Uma das principais diferenças foi encontrada na estimação dos modelos autorregressivos com parâmetro θ_1 positivo, onde o SAS se mostrou melhor na estimação do intercepto. O EViews tem uma pior performance para modelos autorregressivos em geral e se mostrou adequado na estimação dos modelos de médias móveis.

Apesar se existir diferenças, estas foram bem pequenas e, pelo teste F de Fisher, podemos verificar que as diferenças obtidas entre os *softwares* estudados no que diz respeito à estimação de modelos ARIMA(p,d,q) não são significativas. Concluimos, então, que os *softwares* MINITAB, SAS, SPSS e EViews são similares na estimação de modelos ARIMA (p,d,q) para um nível de significância igual à 5% e podem ser igualmente utilizados na estimação destes modelos.

Referências Bibliográficas

- Box, G.E.P. & Jenkins, G.M. (1976). *Times Series Analysis: forecasting and control*. San Francisco. Holden Day.
- Bowerman, B.L. & O'Connell, R. T. (1993). *Forecasting and Time Series an Applied Approach*. Duxbury Press.
- Drumond, F. B., Werkema, M. C. C. & Aguiar, S. (1996). *Análise de Variância: Comparação de Várias Situações*, vol. 6, Editora QFCO, Belo Horizonte, 1996.
- Triola, M.F. *Introdução à Estatística*. Rio de Janeiro: LTC, 1998.

Anexo 1 – Macros para gerar os processos

- Macro para gerar um processo autorregressivo de ordem 1 - $AR(1)$.

```
Macro
#
#template
AR1 c.1-c.3
#UTILIZAÇÃO
#c:\Temp\AR1.txt c1-c3

#DECLARAÇÕES
mconstant i n phi mi Zo
mcolumn c.1-c.3

#INICIALIZAÇÕES
let phi = 0.7
let mi = 10
let Zo = 0
let n = 150 #tamanho da série

#CORPO DA MACRO
#GERANDO VETOR NORMAL (0; 0,1) PARA O RUIDO E COLOCANDO NA C1
Random n c.1;
Normal 0.0 0.316228.

#GERANDO A SÉRIE DE UM AR(1) COM 150 OBSERVAÇÕES
do i=1:n
    let c.2(i) = (phi * Zo) - (phi * mi) + mi + c.1(i)
    let Zo = c.2(i)
enddo

#RETIRANDO AS 50 PRIMEIRAS OBSERVAÇÕES DA SÉRIE GERADA
do i=1:100
    let c.3(i) = c.2 (i+50)
enddo

NAME c.1 = 'RUÍDO'
NAME c.2 = 'Zt (n=150)'
NAME c.3 = 'Zt (n=100)'
Endmacro
```

- Macro para gerar um processo autorregressivo de ordem 2 – $AR(2)$

```

Macro
#
#template
AR2 c.1-c.3
#UTILIZAÇÃO
#%c:\Temp\AR2.txt c1-c3

#DECLARAÇÕES
mconstant i n phi1 phi2 mi Z_t_2 Z_t_1
mcolumn c.1-c.3

#INICIALIZAÇÕES
let phi1 = -0.6
let phi2 = -0.8
let mi = 10
let Z_t_2 = 0
let Z_t_1 = 0
let n = 150 #tamanho da série

#CORPO DA MACRO
#GERANDO VETOR NORMAL (0; 0,1) PARA O RUIDO E COLOCANDO NA C1
Random n c.1;
Normal 0.0 0.316228.

#GERANDO A SÉRIE DE UM AR(2) COM 150 OBSERVAÇÕES
do i=1:n
    let c.2(i) = (phi1 * Z_t_1) + (phi2 * Z_t_2) + mi * (1 - phi1 - phi2) + c.1(i)
    let Z_t_2 = Z_t_1
    let Z_t_1 = c.2(i)
enddo

#RETIRANDO AS 50 PRIMEIRAS OBSERVAÇÕES DA SÉRIE GERADA
do i=1:100
    let c.3(i) = c.2 (i+50)
enddo
NAME c.1 = 'RUIDO'
NAME c.2 = 'Zt (n=150)'
NAME c.3 = 'Zt (n=100)'
Endmacro

```

- Macro para gerar um processo médias móveis de ordem 1 – $MA(1)$

```

Macro
#
#template
MA1 c.1-c.3

#UTILIZAÇÃO
#%c:\Temp\MA1.txt c1-c3

#DECLARAÇÕES
mconstant i n teta Ao mi
mcolumn c.1-c.3

#INICIALIZAÇÕES
let teta = 0,7
let mi = 10
let Ao = 0
let n = 150 #tamanho da série

#CORPO DA MACRO
#GERANDO VETOR NORMAL (0; 0,1) PARA O RUIDO E COLOCANDO NA C1
Random n c.1;
Normal 0.0 0.316228.

#GERANDO A SÉRIE DO PROCESSO MA(1) COM 150 OBSERVAÇÕES
do i=1:n
    let c.2(i) = c.1(i) - (teta * Ao) + mi
    let Ao = c.1(i)
enddo

#RETIRANDO AS 50 PRIMEIRAS OBSERVAÇÕES DA SÉRIE GERADA
do i=1:100
    let c.3(i) = c.2 (i+50)
enddo

NAME c.1 = 'RUÍDO'
NAME c.2 = 'Zt (n=150)'
NAME c.3 = 'Zt (n=100)'

endmacro

```

- Macro para gerar um processo médias móveis de ordem 2 – $MA(2)$

```

Macro
#
#template
MA2 c.1-c.3

#UTILIZAÇÃO
#%c:\Temp\MA2.txt c1-c3

#DECLARAÇÕES
mconstant i n teta1 teta2 mi A_t_2 A_t_1
mcolumn c.1-c.3

#INICIALIZAÇÕES
let teta1 = 0.2
let teta2 = 0.7
let mi = 10
let A_t_2 = 0
let A_t_1 = 0
let n = 150 #tamanho da série

#CORPO DA MACRO
#GERANDO VETOR NORMAL (0; 0,1) PARA O RUÍDO E COLOCANDO NA C1
Random n c.1;
Normal 0.0 0.316228.

#GERANDO A SÉRIE DE UM MA(2) COM 150 OBSERVAÇÕES
do i=1:n
    let c.2(i) = mi + c.1(i) - (teta1 * A_t_1) - (teta2 * A_t_2)
    let A_t_2 = A_t_1
    let A_t_1 = c.1(i)
enddo

#RETIRANDO AS 50 PRIMEIRAS OBSERVAÇÕES DA SÉRIE GERADA
do i=1:100
    let c.3(i) = c.2 (i+50)
enddo

NAME c.1 = 'RUÍDO'
NAME c.2 = 'Zt (n=150)'
NAME c.3 = 'Zt (n=100)'

endmacro

```

- Macro para gerar um processo autorregressivo e médias móveis de ordem (1,1) – $ARMA(1,1)$

```

Macro
#
#template
ARMA c.1-c.3

#UTILIZAÇÃO
#%c:\Temp\ARMA.txt c1-c3

#DECLARAÇÕES
mconstant i n phi teta mi Yo Ao
mcolumn c.1-c.3

#INICIALIZAÇÕES
let phi = 0.8
let teta = 0.5
let mi = 10
let Yo = 0
let Ao = 0
let n = 150 #tamanho da série

#GERANDO VETOR NORMAL (0; 0,1) PARA O RUÍDO E COLOCANDO NA C1
Random n c.1;
Normal 0.0 0.316228.

#GERANDO A SÉRIE DE UM ARMA(1,1) COM 150 OBSERVAÇÕES
do i=1:n
    let c.2(i) = (1 - phi) * mi + (phi * Yo) + c.1(i) - (teta * Ao)
    let Yo = c.2(i)
    let Ao = c.1(i)
enddo

#RETIRANDO AS 50 PRIMEIRAS OBSERVAÇÕES DA SÉRIE GERADA
do i=1:100
    let c.3(i) = c.2 (i+50)
enddo

NAME c.1 = 'RUÍDO'
NAME c.2 = 'Zt (n=150)'
NAME c.3 = 'Zt (n=100)'

endmacro

```

Anexo 2 – Conjuntos de dados utilizados

- Série de Modelo Autorregressivo de ordem 1 – AR(1) com parâmetros $\phi = 0.7$ e $\mu = 10$

9.7118	10.5447	10.1792	10.4316	10.7362
9.8427	10.0059	10.0213	10.2875	10.6377
9.671	10.0857	9.8178	10.6378	10.6837
9.3837	10.0176	9.9129	10.5561	10.7047
9.800	9.6718	9.8602	10.4639	9.9534
9.7716	10.4422	10.4236	10.2301	9.8287
9.5772	10.6882	9.7817	10.1847	9.1679
10.1752	10.4926	9.8539	9.8672	9.7119
10.0685	10.6763	10.1837	9.4961	10.3908
9.5794	10.7144	10.1738	9.6647	10.0661
9.7842	10.3767	9.9587	9.6666	10.2624
10.165	9.8405	10.0465	9.7503	10.5553
10.6353	10.0881	10.2256	9.8998	10.1841
10.5488	10.1194	10.3044	9.4897	10.0156
10.4286	10.8029	9.6861	9.7511	9.8554
10.4791	10.4969	9.9532	9.8726	9.4699
10.7029	10.8252	9.5924	10.1136	9.7827
11.0837	10.3533	9.4271	10.4319	9.4482
10.998	10.5005	10.0028	10.7008	9.9325
11.0263	9.9967	10.4573	10.5906	10.4942

- Série de Modelo Autorregressivo de ordem 1 – AR(1) com parâmetros $\phi = -0.7$ e $\mu = 10$

10.3833	10.6428	10.487	10.2339	10.2364
9.6184	9.4103	10.2852	9.6783	9.8752
10.0486	10.2587	9.7229	10.5771	10.0686
10.1462	9.6651	10.5312	9.6844	10.04
9.5578	10.4774	9.6517	10.1292	9.754
9.7807	9.5568	9.5089	9.3695	10.5217
10.1682	10.3421	10.357	10.3631	9.6379
10.3046	9.8324	9.2839	9.5098	10.0677
9.6442	10.1885	10.9807	10.3401	10.3148
10.2755	9.4914	9.2386	9.3029	9.4378
9.906	10.053	10.5562	10.3966	10.5196
9.9251	9.6636	10.1483	9.0807	10.4327
10.7865	10.1328	9.7616	10.5108	9.9855
9.3597	9.3998	10.0449	9.7042	10.0616
10.7522	9.9669	9.9974	9.9467	9.9169
9.3774	10.1494	10.3992	9.8651	10.2033
10.6228	10.5187	9.3723	9.8847	10.3005
9.5729	9.2637	10.1928	10.1927	10.103
11.1033	10.2581	9.5337	9.9876	10.059
9.1624	9.6661	10.1979	10.1797	9.8904

- Série de Modelo Autorregressivo de ordem 2 – AR(2) com parâmetros $\phi_1 = 0.2$ $\phi_2 = 0.7$ e $\mu = 10$

9.83530	10.03760	9.14890	8.72960	8.36140
10.02410	9.81270	9.11050	9.19710	8.01430
10.13180	9.61450	9.34720	8.97050	8.71230
10.03720	9.93110	9.41180	9.20620	8.12990
9.71140	9.39580	9.23680	9.29700	8.85940
10.21650	9.81000	9.32880	9.62660	8.63180
10.14840	9.24940	9.04810	8.66930	9.35790
10.37430	9.82610	8.80950	8.92920	9.04780
10.36750	9.08580	8.85950	9.05050	9.33040
9.97920	9.04640	8.80140	8.69000	9.17110
10.40400	9.13730	8.76730	9.21810	9.89640
9.87650	9.66820	9.25080	8.82660	9.62100
10.24020	9.07320	9.00470	9.55540	9.78900
10.82390	9.39570	9.60120	8.62360	9.92160
10.42840	9.43590	9.10610	9.55830	10.09830
10.65070	9.28570	9.22330	8.24950	10.04880
10.18040	9.61370	8.99010	9.19290	10.58780
9.80920	9.41940	8.75910	8.27460	9.84900
10.51360	9.59770	8.35470	8.94180	11.27960
9.80320	9.28240	8.95570	7.89710	10.36480

- Série de Modelo Autorregressivo de ordem 2 – AR(2) com parâmetros $\phi_1 = -0.6$ $\phi_2 = 0.3$ e $\mu = 10$

9.6648	9.8052	9.701	9.5151	10.7442
9.9692	10.1323	10.2414	10.3683	9.4343
9.862	9.0968	9.8577	10.115	10.6571
10.4123	10.2384	10.392	9.7624	9.5038
9.6438	9.4746	9.4202	10.2861	10.6002
10.0736	10.1903	10.3195	9.2361	9.787
10.1386	9.9294	9.2094	10.8359	10.631
9.5097	10.2291	10.3689	8.844	9.089
10.1662	9.6576	8.9539	10.9373	11.2077
9.7504	9.9412	11.0246	9.0405	8.9036
10.4389	9.6875	9.5947	11.1503	11.3591
9.6065	9.8766	10.5275	9.0065	9.0001
10.4256	9.868	9.6174	10.7044	10.3239
9.9886	10.1352	10.4864	9.1313	9.5111
9.7892	10.0299	10.2568	10.6544	10.4148
10.4915	10.0824	9.7819	9.3892	9.9469
9.6453	9.6672	9.8196	10.4789	10.0739
10.2455	10.8529	10.1361	9.988	9.2105
9.7864	10.0482	9.8286	10.6313	10.2538
9.9992	10.4281	10.4583	9.5979	9.6944

- Série de Modelo de Médias Móveis de ordem 1 – MA(1) com parâmetros $\theta = 0.7$ $\mu = 10$

10.17400	9.19110	9.62960	10.17950	10.17200
9.76210	10.30890	10.03290	10.45440	10.08510
9.86010	10.22710	9.94550	9.70680	9.99710
9.97100	10.63420	10.50470	10.25450	9.90490
10.28450	9.28200	9.88570	9.71160	9.94710
10.40960	9.57290	9.56270	10.46380	9.67810
9.59500	10.34020	10.32450	9.83530	10.27080
9.94110	9.62100	9.79040	9.95940	10.46770
9.71680	9.55830	10.69410	9.59470	9.71850
10.10360	10.72030	10.11590	10.37180	10.48160
10.07410	9.78940	9.45280	9.72520	10.03880
10.08180	9.73390	10.31700	10.95390	9.68720
10.36050	9.88790	9.77100	9.35500	9.72100
9.68110	9.89880	10.66010	9.54050	10.04550
10.09680	9.76120	9.56350	10.63770	9.46140
9.93620	10.31450	10.01110	9.45520	10.45640
10.00370	9.47660	10.24550	10.08210	10.44840
9.56710	10.39630	10.01350	10.10720	9.57910
10.56910	10.33410	9.87570	10.14480	10.05620
9.94490	10.22320	10.07900	9.83070	9.8709

- Série de Modelo de Médias Móveis de ordem 1 – MA(1) com parâmetros $\theta = -0.7$ $\mu = 10$

10.5113	9.7841	9.7189	9.4833	10.4225
10.1768	10.4424	9.8202	9.0902	10.0666
9.6845	9.952	10.2481	10.1464	10.0561
9.3075	9.6739	9.6585	10.1954	10.1362
9.6465	10.4859	9.8647	10.2112	9.7503
9.796	10.6198	10.1808	9.4646	9.9782
10.5635	9.9513	9.5598	9.3975	9.9757
10.6648	10.098	10.051	10.0697	9.7704
10.698	9.9986	10.0914	9.8753	9.8151
10.2357	10.5637	9.7364	9.6603	10.0706
10.7396	10.7758	10.6261	10.1882	9.7912
10.4488	10.1292	10.438	10.0054	10.037
10.1268	10.1094	10.4103	10.1278	10.4053
10.4383	10.1727	10.286	10.363	10.3279
9.9455	9.4215	9.7708	10.1	10.5804
10.2099	9.2417	9.4574	9.9757	10.8771
10.6272	9.6546	9.905	9.7866	10.5707
10.3807	10.3528	10.0471	10.4662	10.0657
10.8334	10.4138	9.7878	10.6356	9.8657
9.7899	10.183	10.0059	10.4405	9.7152

- Série de Modelo de Médias Móveis de ordem 2 – MA(2) com parâmetros $\theta_1 = 0.7$ $\theta_2 = -0.2$ $\mu = 10$

9.78650	9.75780	10.26020	9.27000	9.86430
10.31240	9.80410	9.93860	10.32320	9.84390
9.68350	10.28630	9.85610	9.70690	9.98670
10.20680	9.89960	9.91620	9.70890	9.69920
10.21900	9.97220	10.12100	10.31330	9.91360
10.02770	10.00410	9.90030	9.63280	10.04220
10.07920	10.26390	9.79820	9.88870	10.19540
10.50080	10.17760	10.90970	9.77120	10.33450
10.21600	9.43690	9.50410	9.89710	10.17700
9.92850	9.96680	10.36100	10.51940	9.92800
10.59800	9.60600	9.99410	8.70690	9.31700
9.41170	10.25540	10.35100	11.04620	10.34460
10.66320	9.93660	10.01720	9.36900	9.83400
9.43170	9.88960	10.28330	10.04940	10.31860
10.18520	10.26270	9.75060	10.63690	9.05870
9.39800	9.64580	9.97200	9.20740	10.98670
10.46760	10.52020	9.63950	10.01250	9.53840
9.62110	9.85960	10.44610	9.48880	9.48680
10.46950	10.20080	9.57080	9.97750	10.71380
10.28050	9.87290	10.74370	10.23810	9.40080

- Série de Modelo de Médias Móveis de ordem 2 – MA(2) com parâmetros $\theta_1 = 0.6$ $\theta_2 = 0.3$ $\mu = 10$

10.6264	9.5701	10.5148	10.7686	10.3436
10.1996	10.2872	9.2927	9.9237	9.4309
10.0311	10.5474	10.0756	9.0957	9.8665
9.855	9.8857	9.9294	10.8671	9.6386
10.4344	9.6949	10.1187	10.4401	10.2966
9.7332	10.4187	10.0718	9.2399	10.2525
9.8319	9.9306	9.5686	9.8329	9.1456
10.3667	9.3867	10.3482	10.3031	9.7387
10.109	10.2415	9.8278	9.8775	10.2852
9.9226	10.1396	10.1008	10.4311	9.8971
9.8778	10.0262	10.1617	9.5428	10.9127
10.2342	10.2296	10.4898	10.0472	9.9587
9.5189	9.9876	9.4076	9.6424	9.7858
9.9513	9.8457	10.3652	10.8434	9.4516
10.1665	10.4255	9.3197	9.9594	10.3549
9.6891	9.2592	9.9818	9.2319	10.0497
10.0952	9.8442	10.2172	10.2582	9.7697
10.1062	10.2286	9.9315	9.9846	10.1361
9.872	9.8089	10.4629	10.0513	9.8267
9.9974	10.6236	9.2632	10.295	9.851

- Série de Modelo Autorregressivo e de Médias Móveis de ordem 1 – ARMA(1,1)

com parâmetros $\phi = -0.8$ $\theta = 0.5$ $\mu = 10$

9.87050	10.51230	8.59410	10.68190	9.68220
10.00790	9.59400	10.82200	9.71660	10.00980
10.25990	10.21630	9.98140	9.64020	10.15580
9.06560	9.43980	9.93590	10.57810	10.02190
11.14810	10.47030	9.65100	10.05970	10.27210
9.00300	9.89310	10.64100	10.35850	9.53910
10.88770	9.72510	8.77980	9.87320	10.26010
9.11030	10.18040	11.48200	10.08650	9.62490
10.43540	9.96750	9.04100	9.55300	10.75230
9.79360	9.67780	10.37890	10.12570	9.12670
10.26270	10.47310	9.69710	9.89710	10.22660
9.46920	9.60220	10.61940	10.43450	10.47760
10.60260	10.85190	9.52270	9.54770	9.23580
9.23990	9.51290	10.05640	10.48600	10.40780
10.86950	9.63410	10.45120	9.64680	9.79540
9.03000	10.74550	9.07530	9.88930	9.86210
11.19680	9.00770	11.05310	10.09600	9.99200
9.05760	10.97030	9.04920	10.14810	9.66210
10.86500	9.48040	11.06610	9.94090	10.92650
9.22240	10.71980	9.25700	10.19550	8.72820