



SÉRIE DE NOTAS TÉCNICAS EM ECONOMIA DA UFG

NT N. 08

NOTA TÉCNICA EM ECONOMIA **n. 08**

Publicação cujo objetivo é auxiliar na elaboração de aulas e de pesquisas do Curso de Ciências Econômicas da UFG, divulgando demonstrações técnicas e metodológicas ou rotinas computacionais voltadas para a economia.

As opiniões contidas nesta publicação não representam o ponto de vista do NEPEC ou da FACE/UFG, sendo de inteira responsabilidade de seu(s) autor(es).

Reprodução permitida, desde que citada a fonte.

FACE – Faculdade de Administração, Ciências Contábeis e Ciências Econômicas
Curso de Ciências Econômicas
Direção FACE
Prof. Moisés Ferreira da Cunha
Vice-Direção FACE
Prof. Sérgio Barroca
Coordenação do Curso de Ciências Econômicas
Profª. Andrea Freire de Lucena

NEPEC – Núcleo de Estudos e Pesquisas Econômicas
Coordenação
Sérgio Fornazier Meyrelles Filho

Endereço

Campus Samambaia, Prédio da FACE – Rodovia
Goiânia/Nova Veneza, km. 0, CEP 74690-900,
Goiânia – GO. Tel. (62) 3521 – 1390

URL

<http://www.face.ufg.br/economia>

Introdução à Séries Temporais e Modelagem ARIMA no Stata

Jaqueline Moraes Assis Gouveia
Sandro Eduardo Monsueto
FACE/UFG

NEPEC/FACE/UFG
Goiânia – Maio de 2016
Versão 1.0



Dados Internacionais de Catalogação na Publicação (CIP)
GPT/BC/UFG

Monsueto, Sandro Eduardo

Introdução à Séries Temporais e Modelagem ARIMA no Stata

[manuscrito] / Jaqueline Moraes Assis Gouveia. - 2016.

21 f.: il.

Universidade Federal de Goiás, Goiânia, 2016. Bibliografia. Anexos. 1. Séries Temporais. 2. ARIMA. 3. Stata. I. Título.

Introdução à Séries Temporais e Modelagem ARIMA no Stata

Jaqueline Moraes Assis Gouveia¹

Sandro Eduardo Monsueto²

Universidade Federal de Goiás

Resumo: Esta Nota Técnica tem por objetivo introduzir o uso de séries temporais por meio do pacote estatístico Stata. É explicado como configurar o programa para reconhecer corretamente dados em séries temporais. Adicionalmente, são mostrados os principais comandos para a identificação e estimação de um modelo da classe ARIMA.

Palavras chave: Séries Temporais, ARIMA, Stata.

Abstract: *This technical note aims to introduce the use of time series in the statistical program Stata. It is explored the configuration required for the program correctly recognize the data as time series type. Moreover, it is presented the main commands to identify and estimate an ARIMA model.*

Key words: *Time Series, ARIMA, Stata.*

1. Introdução

Esta breve Nota Técnica tem por objetivo introduzir o uso de dados de séries temporais no software Stata, o que pode auxiliar principalmente pesquisadores iniciantes. Também apresentamos neste texto os principais comandos para se estimar um modelo ARIMA, desde sua identificação até o diagnóstico dos resíduos. As explicações e comandos seguem o básico da literatura de econometria de séries temporais. Para aprofundar nos conceitos teóricos, recomendamos a leitura de livros como Bueno (2008), Enders (2008) e Greene (2003). Não são apresentadas todas as opções dos comandos do Stata, mas a sintaxe completa de cada um deles pode ser conferida nos respectivos arquivos de *help* e no manual do programa.

Os exemplos e comandos são apresentados usando a versão Stata 11, mas devem funcionar corretamente em outras versões do programa, com algumas pequenas modificações. Para guiar as explicações, utilizamos uma base de dados mensal sobre a taxa de câmbio do Brasil (ANEXO 1), adquirida diretamente do site www.ipeadata.gov.br, cobrindo o período de

¹ jaquelinemagouveia@gmail.com

² monsueto@face.ufg.br.

janeiro de 2008 a setembro de 2014. Foi aplicado logaritmo sobre esta base e a mesma está disponível no anexo deste trabalho.

2. Passos iniciais

O primeiro passo é criar uma nova variável que guardará o tempo e informará ao Stata que a base se trata de uma série temporal. Note que para cada tipo de periodicidade (anual, mensal, trimestral, etc.) é necessária uma configuração específica. Nesta Nota Técnica usaremos uma base de dados mensal, mas no quadro abaixo são exibidos os comandos para os tipos mais comuns usados em economia:

a) Séries anuais:

Gerar a variável de tempo: `gen timevar = y(ano_inicial) +_n-1`

Formatar a variável de tempo: `format timevar %ty`

Estabelecer a variável: `tsset timevar`

b) Séries trimestrais:

Gerar a variável de tempo: `gen timevar = q(ano_inicial q trimestre_inicial) +_n-1`

Formatar a variável de tempo: `format timevar %tq`

Estabelecer a variável: `tsset timevar`

c) Séries mensais:

Gerar a variável de tempo: `gen timevar = m(ano_inicial m mês_inicial) +_n-1`

Formatar a variável de tempo: `format timevar %tm`

Estabelecer a variável: `tsset timevar`

d) Séries semanais:

Gerar a variável de tempo: `gen timevar = w(ano_inicial w semana_inicial) +_n-1`

Formatar a variável de tempo: `format timevar %tw`

Estabelecer a variável: `tsset timevar`

e) Séries diárias:

Gerar a variável de tempo: `gen timevar = d(dia_inicial mês_inicial ano_inicial) +_n-1`

Formatar a variável de tempo: `format timevar %td`

Estabelecer a variável: `tsset timevar`

Usando como exemplo o logaritmo da taxa de câmbio no Brasil, que é uma série mensal, que se inicia em janeiro (mês 1) de 2008 e se encerra em setembro (mês 9) de 2014, teremos:

```
gen timevar = m(2008m1)+_n-1
format timevar %tm
tsset timevar
```

Assim, declaramos para o Stata que a série é mensal, iniciada em 2008m1 e finalizada em 2014m9. Para visualizar a base de dados, abra o Data Editor (Browse), como mostra a Figura 1:




Figura 1 – Stata Browse.

Se quiser alterar o formato da variável “timevar” para mês e ano, basta selecionar a variável de tempo e depois selecionar “variable properties”, como no exemplo abaixo:




Figura 2 – Stata Browse e menu.

A partir dessa opção, pode-se alterar o formato da variável de *%tm* para *%tmMonth_CCYY*:




Figura 3 – Modificação de formato da variável.

Aplicando as alterações, teremos a seguinte formatação da variável “timevar”:




Figura 4 – Stata Browse com variável de tempo alterada.

3. Gráficos de série temporal

Há duas maneiras de se pedir um gráfico de uma variável contra a variável de tempo (“timevar”):

```
twoway (tsline variável)
tsline variável
```

Em ambas as maneiras, há a possibilidade de editar a área de gráfico, títulos, rótulos:

a) Crie o gráfico:

No exemplo do logaritmo da taxa de câmbio do Brasil, teremos o seguinte gráfico:

```
tsline l_brasil
```



Figura 5 – Gráfico de série temporal

b) Para editar as preferências, clique em File → Start Graph Editor:



Figura 6 – Menu de configuração do gráfico

Isso faz surgir uma barra lateral que oferece opções para alterar: (1) área de plotagem, (2) o eixo vertical, (3) o eixo horizontal, (4) inserir legendas e (5) a posição dos títulos, como mostra a numeração na Figura 7:



Figura 7 – Opções de configuração do gráfico.

Para o nosso exemplo, usamos as opções numeradas pelas setas:


- Alterando os títulos dos eixos:

(2) +yaxis1 → title → text “Logaritmo da Taxa de Câmbio do Brasil” → OK

(3) +xaxis1 → title → text “Mês e Ano” → OK

- Alterando o nome das etiquetas dos meses:

(3) xaxis1 → Edit or add individual ticks and labels



Seleciona a etiqueta a ser editada e clica em “Edit”




Figura 8 – Configurações de etiquetas de tempo.

Faça isso com todas as variáveis, salve as alterações realizadas, de modo que o gráfico final seja tal que:




Figura 9 – Gráfico configurado.

4. Teste de raiz unitária (ADF)

Um dos primeiros passos para a identificação e estimação de modelos de séries temporais como o ARIMA é identificação de tendência nas séries utilizadas. O teste mais difundido é o Dickey-Fuller Aumentado, ou ADF. Para realizar o teste, entre com o comando:

```
dfuller variável
```

No nosso exemplo, temos:

```
dfuller l_brasil
```

```
. dfuller l_brasil
```

Dickey-Fuller test for unit root				
				Number of obs = 80
Test Statistic	1% Critical Value	Interpolated Dickey-Fuller 5% Critical Value	10% Critical Value	
Z(t)	-0.984	-3.538	-2.906	-2.588

Mackinnon approximate p-value for Z(t) = 0.7592

O teste trabalha com a hipótese nula (H_0) de presença de raiz unitária.

Figura 10 – Teste ADF

Com o p-valor de 0,7592, caímos na área de não rejeição de H_0 . Logo, a série em nível possui raiz unitária. Diferencia-se a série uma vez, para testarmos se ainda assim possui raiz unitária. Para diferenciar uma série:

```
gen nome_novo = d1.variável
```

No nosso exemplo:

```
gen difl_brasil = d1.l_brasil
```

Pedimos, agora, o teste ADF para essa variável diferenciada de ordem 1:

```
dfuller difl_brasil
```

```
. dfuller difl_brasil
```

Dickey-Fuller test for unit root				
				Number of obs = 79
Test Statistic	1% Critical Value	Interpolated Dickey-Fuller 5% Critical Value	10% Critical Value	
Z(t)	-5.335	-3.539	-2.907	-2.588

Mackinnon approximate p-value for Z(t) = 0.0000

O teste trabalha com a hipótese nula (H_0) de presença de raiz unitária.

Figura 11 – Teste ADF da primeira diferença

Com o p-valor de 0,0000, podemos rejeitar a H_0 . Logo, essa série em primeira diferença de l_brasil não possui raiz unitária.

5. Correlograma – buscando a ordem AR(p) e MA(q)

Para buscar a ordem p de um processo auto-regressivo (AR), pede-se o gráfico da autocorrelação parcial (FACP):

```
pac variável
```

No nosso exemplo:

```
pac difl_brasil
```

Isso vai resultar no gráfico:




Figura 12 – FACP

É possível supor que trata-se de um AR(1), pela truncagem na primeira defasagem. Para buscar a ordem m do processo de média móvel (MA), pede-se agora o gráfico da função de autocorrelação simples (FAC):

ac variável

No nosso exemplo:

ac difl_brasil




Figura 13 – FAC

É possível supor que trata-se de um MA(1), pela truncagem na primeira defasagem. Combinando os resultados da FACP, FAC e do teste ADF, é possível dizer que se trata de um processo ARIMA(1,1,1). Ou seja, a parcela auto-regressiva é de ordem 1, a série precisa ser diferenciada uma vez e o componente de média móvel tem uma ordem. Este modelo será estimado a seguir.

6. Estimando um modelo ARIMA

O comando no Stata para modelar um ARIMA é:

arima variável_em_nível, **arima** (p,d,q)

É importante destacar que neste caso se usa a variável original e não sua primeira diferença no comando. A primeira diferença seria usada em um modelo ARMA(p,q). No nosso exemplo, o modelo é tal que $p = 1$, $d = 1$ e $q = 1$. Logo:

```
arima l_brasil, arima (1,1,1)
```

```
. arima l_brasil, arima (1,1,1)
(setting optimization to BHHH)
Iteration 0: log likelihood = 151.73161
Iteration 1: log likelihood = 153.84408
Iteration 2: log likelihood = 154.93118
Iteration 3: log likelihood = 155.95659
Iteration 4: log likelihood = 156.38424
(switching optimization to BFGS)
Iteration 5: log likelihood = 156.76414
Iteration 6: log likelihood = 157.24194
Iteration 7: log likelihood = 157.29012
Iteration 8: log likelihood = 157.29237
Iteration 9: log likelihood = 157.29239
Iteration 10: log likelihood = 157.29239

ARIMA regression
Sample: February 2008 - September 2014      Number of obs   =      80
Log likelihood = 157.2924                     Wald chi2(2)    =     32.65
                                           Prob > chi2     =     0.0000
```

D.l_brasil	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
l_brasil _cons	.0033699	.0080127	0.42	0.674	-.0123346 .0190745
ARMA ar L1.	.3632303	.2207081	1.65	0.100	-.0693495 .7958102
ma L1.	.1233488	.2557484	0.48	0.630	-.3779089 .6246065
/sigma	.0338227	.002472	13.68	0.000	.0289776 .0386678

Figura 14 – ARIMA

Para saber se o processo estimado é estável, ou seja, o componente AR é estacionário e a parte MA é invertível, é preciso verificar se o módulo do inverso das raízes reais estão dentro do círculo unitário. Para tanto, logo após rodar o ARIMA, peça:

```
armaroots
```

Se esse comando ainda não tiver instalado no Stata, digite:

```
ssc install armaroots
```

No exemplo utilizado, após rodar um ARIMA (1,1,1), pedimos “armaroots” e temos que:

Characteristic roots of AR-polynomial		
Characteristic roots	Modulus	Period
.3632303	.36323	

Characteristic roots of MA-polynomial		
Characteristic roots	Modulus	Period
-.1233488	.123349	

Ambos os módulos das raízes invertidas estão dentro do círculo unitário, o que garante que o ARIMA estimado é invertível e estacionário.

Figura 15 – Raízes

Este comando também fornece automaticamente em seu output o gráfico do círculo unitário e de onde se encontram as raízes invertidas. No exemplo:




Figura 16 – Gráfico das raízes

No caso de não querer o gráfico do círculo unitário:

armaroots, nograph

Para sabermos qual os valores dos critérios de informação AIC (*Akaike's Information Criterion*) e BIC (*Bayesian Information Criterion*), logo após rodar o modelo, pedimos:

estimates stats

Akaike's information criterion and Bayesian information criterion						
Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	80	.	157.2924	4	-306.5848	-297.0567
Note: N=Obs used in calculating BIC; see [R] BIC note						

Figura 17 – Critérios de informação

No caso de querer realizar essa operação não imediatamente após rodar o modelo, tem-se a opção de salvar o modelo logo após sua estimação. Esta opção também funciona com os outros comandos discutidos:

arima l_brasil, arima (1,1,1)
estimates store nome_do_modelo

E quando quiser pedir os valores de AIC e BIC do modelo:

estimates restore nome_do_modelo
estimates stats nome_do_modelo

7. Diagnóstico de resíduos

Para finalizar o modelo ARIMA, existe a necessidade de verificar se os resíduos seguem um formato de ruído branco: sem memória, homocedásticos e normalmente distribuídos.

a) Verificando se o processo possui memória – Correlograma dos resíduos

Para pedir o correlograma dos resíduos, primeiramente precisamos criar os resíduos (logo após a estimação do modelo ou, se usarmos o comando store/restore, quando o modelo for restaurado). Para criar os resíduos:

```
predict nome_da_variável, residuals  
ac variável  
pac variável
```

No nosso exemplo, criamos uma nova variável chamada ruído, que armazena os resíduos do modelo estimado:

```
predict ruído, residuals  
ac ruído  
pac ruído
```




Figura 18 – FAC e FACP dos resíduos

Apesar de algumas significâncias na autocorrelação parcial (FACP), podemos considerar nosso resíduo livre de memória. Adicionalmente, podemos também exibir o resultado do teste de Ljung-Box, através do comando

```
corrgram variável
```

No nosso exemplo:

```
corrgram ruído
```

. corrgram ruido					-1	0	1	-1	0	1
LAG	AC	PAC	Q	Prob>Q	[Autocorrelation]		[Partial]	Autocor		
1	0.0054	0.0055	.00242	0.9608						
2	0.0219	0.0222	.04262	0.9789						
3	-0.0267	-0.0269	.10319	0.9915						
4	-0.1212	-0.1224	1.3717	0.8491						
5	-0.0713	-0.0713	1.8159	0.8740						
6	0.0387	0.0444	1.9488	0.9243						
7	-0.0719	-0.0792	2.4138	0.9334						
8	-0.2016	-0.2363	6.1158	0.6343						
9	0.0413	-0.0147	6.2735	0.7123						
10	-0.0848	-0.0632	6.9474	0.7304						
11	-0.0649	-0.1224	7.3478	0.7703						
12	0.0003	-0.0595	7.3478	0.8338						
13	-0.0234	-0.0559	7.4013	0.8803						
14	0.0981	0.1050	8.358	0.8699						
15	0.1283	0.1196	10.02	0.8185						
16	0.0495	0.0563	10.271	0.8521						
17	-0.1011	-0.0940	11.336	0.8386						
18	-0.0326	-0.0807	11.449	0.8743						
19	0.0626	0.1172	11.871	0.8911						
20	0.1102	0.1861	13.199	0.8687						
21	-0.0365	-0.0564	13.347	0.8960						
22	0.0111	-0.0737	13.361	0.9226						
23	-0.0321	0.0509	13.479	0.9408						
24	-0.0996	0.0011	14.642	0.9308						
25	-0.0323	-0.1098	14.766	0.9467						
26	0.0059	-0.0679	14.771	0.9614						
27	0.0613	0.1855	15.236	0.9660						
28	-0.0985	-0.1642	16.461	0.9585						
29	0.0235	-0.1882	16.532	0.9690						
30	-0.0327	-0.0323	16.672	0.9763						
31	-0.1028	-0.1281	18.087	0.9685						
32	-0.0578	-0.1156	18.544	0.9722						
33	0.0373	-0.0660	18.738	0.9781						
34	-0.0378	-0.2168	18.942	0.9827						
35	0.0836	0.0665	19.962	0.9806						
36	0.0871	0.0957	21.093	0.9773						
37	-0.0154	-0.3985	21.129	0.9831						
38	-0.0157	0.2107	21.168	0.9876						

Figura 19 – Ljung-Box e Correlograma dos resíduos

b) Testando a normalidade dos resíduos – histograma e teste de Jarque-Bera

Para pedir um histograma dos resíduos comparado a uma distribuição normal:

histogram variável, normal

No caso do exemplo:

histogram ruido, normal




Figura 20 – Histograma dos resíduos

Para realizar o teste de Jarque-Bera,

```
jb variável
```

Se esse comando não estiver instalado no Stata, digite:

```
ssc install jb
```

Esse teste considera que a hipótese nula é de que a distribuição dos resíduos é normal.

No exemplo:

```
jb ruído
```

```
. jb ruido  
Jarque-Bera normality test: 38.62 Chi(2) 4.1e-09  
Jarque-Bera test for Ho: normality:
```

Rejeitamos H_0 ,
os erros não
seguem uma
distribuição

Figura 21 – Teste de normalidade

c) Heterocedasticidade – Teste ARCH LM

O teste ARCH LM somente pode ser executado após uma regressão, de modo que não podemos pedi-lo logo após a execução do ARIMA. Precisamos primeiramente predizer os resíduos (o que já foi ensinado acima) e rodar uma regressão do resíduo contra nenhuma variável e, logo após, pedir o teste “archlm”:

```
reg variável  
estat archlm, lags (x/y)
```

onde x significa a ordem de defasagem inicial e y a ordem final de defasagem para o teste ARCH LM. Se este comando não estiver instalado no Stata, digite:

```
ssc install archlm
```

No exemplo:

```
reg ruído  
estat archlm, lags (1/12)
```

. estat archlm, lags (1/12) LM test for autoregressive conditional heteroskedasticity (ARCH)			
lags (p)	chi2	df	Prob > chi2
1	9.536	1	0.0020
2	10.272	2	0.0059
3	11.165	3	0.0109
4	11.170	4	0.0247
5	11.130	5	0.0489
6	10.937	6	0.0904
7	10.726	7	0.1510
8	13.586	8	0.0932
9	8.459	9	0.4887
10	9.117	10	0.5210
11	8.659	11	0.6534
12	4.153	12	0.9805
H0: no ARCH effects vs. H1: ARCH(p) disturbance			

Figura 22 – Teste ARCH LM

Com 12 lags atribuídos ao teste, o p-valor é de 0,9805, que nos leva a não rejeitar H_0 , ou seja, considerando que a H_0 é ausência de efeito ARCH, podemos considerar esse modelo como sendo homocedástico.

8. Previsão

Para utilizar o modelo ARIMA para previsões de valores dentro da amostra, o comando principal a ser utilizado logo após a estimação do modelo é:

predict variável, y

Os valores previstos serão em relação à variável em nível utilizada no modelo ARIMA e serão calculados para o período da amostra. No nosso exemplo, temos:

```
arima l_brasil, arima (1,1,1)
predict yt, y
tsline yt l_brasil
```




Figura 23 – Gráfico com os valores observados e previstos.

Se quisermos calcular previsões para períodos fora da amostra (*out-of-sample forecasting*), temos que, em primeiro lugar, criar observações na variável de tempo. Assim:

```
tsappend, last (observação_final) tsfmt (formato_do_tempo)
```

Logo após, rodamos novamente o modelo ARIMA e pedimos a previsão dinâmica:

```
predict variável, y dynamic formato_do_tempo(observação_inicial))
```

No nosso exemplo, temos observações da taxa de câmbio do Brasil até Abril de 2016. Porém, nessa base de dados que estamos utilizando, as observações se encerram em Setembro de 2014. Queremos, portanto, prever com o nosso modelo ARIMA até Abril de 2016. Assim:

```
tsappend, last (2016m4) tsfmt (tm)
```

Logo após, rodamos o modelo ARIMA e pedimos a previsão dinâmica até 2016m4:

```
arima l_brasil, arima (1,1,1)
tsappend, last (2016m4) tsfmt (tm)
predict yd, y dynamic(tm(2014m10))
```

```
tsline yd l_brasil
```




Figura 24 – Gráfico com os valores observados até 2014m9 e previstos até 2016m4.

Obviamente, o visto nesta Nota Técnica não encerra o assunto sobre a dinâmica de séries temporais, mas pode servir de guia rápido para os interessados em usar o Stata dentro da metodologia Box-Jenkins ou mesmo para análises descritivas mais simples. Para melhor compreender a parte teórica e estatística, voltamos a recomendar a leitura dos principais livros textos da área de econometria de séries temporais.

Referências bibliográficas

BUENO, R. De L. da S. **Econometria de séries temporais**. Cengage Learning, 2008.

ENDERS, Walter. **Applied econometric time series**. John Wiley & Sons, 2008.

GREENE, William H. **Econometric analysis**. Pearson Education India, 2003.

STATACORP, L. P. **Stata base reference manual**. Volume 2, 2005.

ANEXO

ANEXO 1 – Taxa de câmbio - R\$ / US\$ - comercial - venda - média - R\$.

Data	Taxa de câmbio - R\$ / US\$	Data	Taxa de câmbio - R\$ / US\$	Data	Taxa de câmbio - R\$ / US\$
2008.01	1.7743	2010.04	1.7576	2012.07	2.0287
2008.02	1.7277	2010.05	1.8132	2012.08	2.0294
2008.03	1.7076	2010.06	1.8059	2012.09	2.0281
2008.04	1.6889	2010.07	1.7696	2012.10	2.0298
2008.05	1.6605	2010.08	1.7596	2012.11	2.0678
2008.06	1.6189	2010.09	1.7187	2012.12	2.0778
2008.07	1.5914	2010.10	1.6860	2013.01	2.0311
2008.08	1.6123	2010.11	1.7133	2013.02	1.9733
2008.09	1.7996	2010.12	1.6934	2013.03	1.9828
2008.10	2.1729	2011.01	1.6748	2013.04	2.0022
2008.11	2.2663	2011.02	1.6680	2013.05	2.0348
2008.12	2.3944	2011.03	1.6591	2013.06	2.1730
2009.01	2.3074	2011.04	1.5864	2013.07	2.2522
2009.02	2.3127	2011.05	1.6135	2013.08	2.3422
2009.03	2.3138	2011.06	1.5870	2013.09	2.2705
2009.04	2.2059	2011.07	1.5639	2013.10	2.1886
2009.05	2.0609	2011.08	1.5970	2013.11	2.2954
2009.06	1.9576	2011.09	1.7498	2013.12	2.3455
2009.07	1.9328	2011.10	1.7726	2014.01	2.3822
2009.08	1.8452	2011.11	1.7905	2014.02	2.3837
2009.09	1.8198	2011.12	1.8369	2014.03	2.3261
2009.10	1.7384	2012.01	1.7897	2014.04	2.2328
2009.11	1.7260	2012.02	1.7184	2014.05	2.2209
2009.12	1.7507	2012.03	1.7953	2014.06	2.2355
2010.01	1.7798	2012.04	1.8548	2014.07	2.2246
2010.02	1.8402	2012.05	1.9860	2014.08	2.2656
2010.03	1.7858	2012.06	2.0492	2014.09	2.3329

Fonte: IPEA DATA/Banco Central do Brasil, Boletim, Seção Balanço de Pagamentos (Bacen / Boletim / BP) - BM12_ERV12.