

ACADEMIA DE STUDII ECONOMICE

CATEDRA DE MONEDĂ

Programul de Master Specializat

Managementul Sistemelor Bancare

**MODULUL: Econometrie aplicată
utilizând EViews 5.1**

– NOTE DE CURS –

Dr. Adrian Codirlaşu, CFA

Dr. Nicolaie Alexandru Chidesciuc

Octombrie 2008

Obiective

Cursul de econometrie bancară are ca obiective însușirea de către studenți a tehnicilor econometrice de bază utilizate în domeniul bancar. Principalele teme abordate în cadrul acestui curs se referă la modelarea seriilor de timp, estimarea volatilității activelor financiare, modelarea riscului.

De asemenea, cursul are ca obiectiv și însușirea de către studenți a cunoștințelor necesare modelării econometrice a datelor cu ajutorul programului Eviews 5.1.

Tematică

- Serii de timp: momentele seriilor de timp, staționaritate/nestaționaritate, sezonalitate, distribuții, componente pe termen lung;
- Teste statistice;
- Regresia liniară: estimare, teste, interpretare;
- Modele cu date calitative;
- Modele *ARMA*;
- Modele cu date panel;
- Modele *ARCH/GARCH*;
- Modele cu vectori autoregresivi (*VAR*);
- Modele de evaluare a riscului de piață (*Value at Risk*).

Bibliografie

- Alexander, Carol și Elizabeth Sheedy editori (2004) „The Professional Risk Managers’s Handbook. Volume II: Mathematical Foundations of Risk Measurement”, PRMIA
- Alexander, Carol și Elizabeth Sheedy editori (2004) „The Professional Risk Managers’s Handbook. Volume III: Risk Measurement Practices”, PRMIA
- DeFusco, Richard A., Dennis W. McLeavey, Jerald E. Pinto și David E. Runkle (2001) „Quantitative Methods for Investment Analysis”, AIMR
- Enders, Walter (2004) „Applied Econometric Time Series Second Edition”, Wiley
- Greene, William H. (2000) „Econometric Analysis, Fourth Edition”, Prentice Hall International
- Hamilton, James D. (1994) „Time Series Analysis”, Princeton University Press
- J. P. Morgan (1996) „RiskMetrics – Technical Document”, J. P. Morgan
- Lutkepohl, Helmut și Mekus Kratzig (2004) „Applied Time Series Econometrics”, Cambridge University Press
- Pindyck, Robert S. și Daniel L. Rubinfeld (1991) „Econometric Models and Economic Forecasts” McGraw-Hill
- Quantitative Micro Software (2005) „EViews 5.1 User’s Guide”, Quantitative Micro Software

Cuprins

CAPITOLUL I. SERII DE TIMP	5
CAPITOLUL II. TESTE STATISTICE	8
II.1. DISTRIBUȚII	8
II.2. TESTAREA IPOTEZELOR	13
II.3. TESTAREA MEDIEI	16
II.4. TESTAREA VARIANȚEI	17
CAPITOLUL III. ANALIZA SERIILOR DE TIMP ÎN EViews	20
III.1. INTRODUCEREA SERIILOR ÎN EViews	20
III.2. PRELUCAREA SERIILOR	22
III.3. STAȚIONARITATEA SERIILOR DE TIMP	23
III.4. DISTRIBUȚIA SERIILOR	30
III.5. FUNCȚIA DE AUTOCORELAȚIE A SERIILOR DE TIMP	33
III.6. TRENDUL SERIILOR DE TIMP	35
III.7. AJUSTAREA SEZONIERĂ A SERIILOR DE TIMP	37
CAPITOLUL IV. REGRESIA LINIARĂ MULTIPLĂ	41
IV.1. FORMA GENERALĂ ȘI IPOTEZE	41
IV.2. TESTE STATISTICE ȘI INDICATORI AI REGRESIEI	42
IV.3. REGRESII CU VARIABILE CALITATIVE	44
IV.4. REGRESII CU SERII DE TIMP ÎN EViews	45
IV.5. REGRESII CU SERII CROSECȚIONALE ȘI VARIABILE CALITATIVE ÎN EViews	57
CAPITOLUL V. MODELE ARMA	60
V. 1. PROCESE AR	60
V. 2. PROCESE MA	61
V. 3. PROCESE ARMA	61
V. 4. ESTIMAREA MODELELOR ARMA ÎN EViews	63
CAPITOLUL VI. MODELE CU DATE PANEL	76
VI. 1. UTILIZAREA MODELELOR CU DATE PANEL	76
VI. 2. ESTIMAREA MODELELOR CU DATE PANEL ÎN EViews	76
CAPITOLUL VII. MODELE GARCH	85
VII.1. TIPURI DE MODELE ARCH	85

VII.2. ESTIMAREA MODELELOR ARCH ÎN EViews	88
<u>CAPITOLUL VIII. MODELE CU VECTORI AUTOREGRESIVI (VAR)</u>	<u>93</u>
VIII.1. DEFINIȚIE ȘI UTILIZARE	93
VIII.2. CONSTRUIREA UNUI MODEL VAR	94
VIII.3. ALEGEREA NUMĂRULUI DE LAG-URI PENTRU UN MODEL VAR	96
VIII.4. STABILITATEA ȘI STAȚIONARITATEA UNUI MODEL VAR	98
VIII.5. STABILITATEA ȘI STAȚIONARITATEA UNUI MODEL VAR	98
VIII.6. FUNCȚII DE IMPULS-RĂSPUNS	102
VIII.7. DESCOMPUNEREA VARIANȚEI	104
<u>CAPITOLUL IX. MODELE VALUE AT RISK (VAR)</u>	<u>105</u>
IX.1. MĂSURA VAR	105
IX.2. VAR ANALITIC	105
IX.3. VAR CALCULAT PE BAZA SIMULĂRII MONTE CARLO	106
IX.4. VAR ISTORIC	107
IX.5. UTILIZAREA MODELELOR DE VOLATILITATE ÎN CALCULUL VAR	109
IX.5.1. CALCULUL VAR UTILIZÂND EWMA	109
IX.5.2. CALCULUL VAR UTILIZÂND MODELE GARCH	110
IX.6. CALCULUL VAR PENTRU UN PORTOFOLIU DE ACȚIUNI	111

Capitolul I. Serii de timp

O serie de timp reprezintă o secvență de valori înregistrate de o variabilă aleatoare specifică într-o anumită perioadă de timp.

Principalele caracteristici ale seriilor de timp, care trebuie avute în vedere în analiza econometrică a datelor sunt:

1. **Frecvența** seriei de timp reprezintă periodicitatea cu care este observată variabila. Funcție de specificul seriei de timp, frecvența poate fi zilnică (cum este cazul prețurilor activelor financiare – cursurile acțiunilor, ratele de dobândă, cursul de schimb), lunară (de exemplu, rata inflației, salariul mediu pe economie, rata șomajului), trimestrială (cum este produsul intern brut) sau anuală.

2. **Populație** versus **eșantion**. Populația reprezintă totalitatea observațiilor unei variabile. Eșantionul reprezintă un subset de observații al variabilei aleatoare.

3. **Momentele** seriei de timp:

Primele patru momente ale unei serii de timp sunt:

- Media (calculată ca suma observațiilor împărțită la numărul de observații).
- Deviația standard a seriei, care reprezintă o măsură a dispersiei observațiilor.

Formula de calcul a dispersiei (s) pentru un eșantion de observații este:

$$s = \sqrt{\frac{\sum_{i=1}^N (y_i - \bar{y})^2}{N - 1}},$$

unde:

N reprezintă numărul de observații din eșantion,

y_i – observațiile incluse în eșantion, $i = 1, N$

\bar{y} – valoarea medie a eșantionului.

- Coeficientul de asimetrie – care reprezintă o măsură a asimetriei distribuției față de media sa.

Formula de calcul a coeficientului de asimetrie (S) pentru o serie de timp este:

$$S = \frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \bar{y}}{\sigma} \right)^3,$$

unde:

N reprezintă numărul de observații din eșantion,

y_i – observațiile incluse în eșantion, $i = 1, N$

\bar{y} – valoarea medie a eșantionului,

$\hat{\sigma}$ – un estimator al deviației standard a seriei: $\hat{\sigma} = s \sqrt{\frac{N-1}{N}}$.

s – dispersia seriei de timp.

Coeficientul de asimetrie pentru o distribuție normală este zero.

- Kurtotica – care măsoară înălțimea distribuției seriei. Kurtotica (K) este calculată după cum urmează (notațiile de mai sus se mențin):

$$K = \frac{1}{N} \sum_{i=1}^N \left(\frac{y_i - \bar{y}}{\hat{\sigma}} \right)^4.$$

Pentru o distribuție normală, kurtotica are valoarea 3. Dacă distribuția are kurtotica mai mare decât 3, aceasta se numește leptokurtotică (și are o înălțime mai mare decât o distribuție normală), iar în cazul în care kurtotica are o valoare mai mică decât 3, distribuția se numește platykurtotică (și are o înălțime mai mică comparativ cu o distribuție normală).

În general seriile de date financiare au o distribuție leptokurtotică. O caracteristică a acestei distribuții este faptul că probabilitatea apariției de evenimente extreme este mai mare în cazul distribuției leptokurtotice decât în cazul distribuției normale.

4. Staționaritatea seriei de timp.

Condițiile ce trebuie îndeplinite pentru ca o serie de timp să fie staționară sunt:

- media seriei de timp să fie constantă sau cu alte cuvinte, observațiile trebuie să fluctueze în jurul mediei.
- varianța seriei să fie constantă.

Din punct de vedere economic, o serie este staționară dacă un șoc asupra seriei este temporar (se absoarbe în timp) și nu permanent.

Exemple de serii staționare: rata de creștere a PIB real, rata inflației (cu excepția perioadelor de hiperinflație). Exemple de serii nestaționare: cursul de schimb nominal, indicii prețurilor de consum, nivelul PIB real.

În cazul în care seria nu este staționară, prin diferențiere, se obține o serie staționară. Astfel, ordinul de integrare a seriei reprezintă numărul de diferențieri succesive necesare pentru obținerea unei serii staționare (sau numărul de rădăcini unitare al seriei). În economie, cele mai întâlnite serii nestaționare sunt integrate de ordinul I (necesită o singură diferențiere, au o rădăcină unitară).

De asemenea, există serii de timp trend-staționare: serii de timp care pot fi făcute staționare prin eliminarea (scăderea) trendului (deterministic) al seriei.

5. **Sezonalitatea** seriei de timp. Seriile de timp cu frecvență lunară sau trimestrială prezintă adesea evoluții care au o anumită ciclicitate. De exemplu activitatea economică se încetinește în lunile de iarnă, prețurile cresc mai mult în lunile reci decât în perioada de vară etc.

În analiza econometrică, pentru a elimina aceste evoluții sezoniere și a evidenția doar impactul pe care îl are o anumită variabilă asupra alteia, seriile de timp sunt ajustate sezonier.

Capitolul II. Teste statistice

Inferența statistică are două subdiviziuni: estimarea parametrilor modelelor (abordată în următoarele capitole) și testarea ipotezelor.

Estimarea parametrilor răspunde întrebării: care este valoarea parametrului (de exemplu care este media populației). Răspunsul la această întrebare este prezentat sub forma unui interval de încredere construit în jurul valorii estimate.

În schimb, testarea ipotezelor trebuie să răspundă întrebării: este x valoarea parametrului?

Pentru a putea răspunde ambelor întrebări este esențială cunoașterea distribuției seriei de date ai cărei parametri se analizează.

II.1. Distribuții

Distribuția de probabilitate/funcția de densitate a unei variabile (aleatoare). Aceasta este reprezentarea tuturor valorilor pe care le poate lua o variabilă aleatoare și a probabilității de apariție a acestor valori.

În cazul unei variabile aleatoare discrete (variabilă care poate lua numai anumite valori), distribuția de probabilitate este reprezentată printr-o funcție care returnează probabilitățile de apariție pentru valorile variabilei aleatoare.

În cazul unei variabile aleatoare continue (variabilă care poate lua orice valori în cadrul unui anumit interval) este utilizată funcția de densitate. Deoarece, pentru o variabilă aleatoare continuă, probabilitatea de a avea o anumită valoare este 0, se calculează probabilitatea ca valoarea înregistrată de variabila aleatoare să aparțină unui anumit interval.

Astfel, probabilitatea ca valoarea înregistrată de variabila aleatoare x să aparțină intervalului $[a, b]$ este $\Pr(a \leq x \leq b) = \int_a^b f(x)dx$, iar probabilitatea ca valoarea înregistrată

de variabila aleatoare să fie mai mică decât o valoare c este $\Pr(x \leq c) = \int_{-\infty}^c f(x)dx$.

Cele mai utilizate distribuții de probabilitate în econometrie sunt:

- Distribuția normală (sau Gaussiană).

Ecuția acestei distribuții este: $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$,

unde:

μ reprezintă media distribuției,

σ – abaterea medie pătratică a acesteia,

x – variabila aleatoare,


$\pi \approx 3.14159$

$e \approx 2.71828$.

După cum se poate observa din ecuație, această distribuție poate fi construită numai pe baza primelor două momente ale seriei (media și abaterea medie pătratică).

Dacă variabila x este distribuită normal, notația utilizată este: $x \sim N(\mu, \sigma^2)$.

În graficul de mai jos sunt prezentate exemple de distribuții normale în funcție de medie și deviație standard:



▪ Distribuția lognormală.

O variabilă este lognormal distribuită dacă logaritmul natural al variabilei este normal distribuit.

Funcția densității de probabilitate a unei variabile lognormal distribuite este:

$$f(x) = \frac{1}{\sigma \cdot x \cdot \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{\ln(x) - \mu}{\sigma} \right)^2},$$


unde:

μ reprezintă media distribuției,

σ – abaterea medie pătratică a acesteia,

x – variabila aleatoare.

Funcție de diverse valori ale abaterii medii pătratice, în tabelul de mai jos sunt prezentate exemple de distribuții lognormale.



- Distribuția t .

Această distribuție este folosită pentru modelarea mediei unui eșantion mic de date (sub 30 de observații) extras dintr-o populație cu o distribuție normală, în cazul în care abaterea medie pătratică a eșantionului nu este cunoscută. Pentru eșantioane mari de observații, distribuția t converge către distribuția normală.

Pentru eșantioane mici de date, această distribuție are o kurtotică mai mare decât o distribuție normală; datorită acestei caracteristici este folosită în modelarea randamentelor activelor financiare.


Spre deosebire de distribuția normală, forma acestei depinde și de numărul de grade de libertate a seriei de date. Distribuția t este de fapt o familie de distribuții, (există o distribuție pentru fiecare valoare posibilă a gradelor de libertate).

Dacă $z \sim N(0,1)$ și $x \sim \chi^2[n]$ și x este independent de z , atunci raportul $t = \frac{z}{\sqrt{\frac{x}{n}}}$

urmează o distribuție t cu n grade de libertate, $t \sim t[n]$.

De asemenea, dacă $t \sim t[n]$, atunci $t^2 \sim F[1, n]$.

În graficul de mai jos sunt prezentate exemple de distribuții t funcție de numărul de grade de libertate, k .



- Distribuția Chi pătrat (χ^2).

Această distribuție este printre cele mai folosite distribuții în testele statistice.

Distribuția χ^2 este asimetrică, și ca și în cazul distribuției t , este o familie de distribuții (există o distribuție pentru fiecare valoare posibilă a gradelor de libertate $n - 1$). Distribuția χ^2 este mărginită de zero (toate valorile sunt pozitive).

Dacă $z \sim N(0,1)$, atunci $x = z^2 \sim \chi^2[1]$, x este distribuită χ^2 cu un grad de libertate.


Dacă x_1, x_2, \dots, x_n sunt n variabile independente având fiecare o distribuție $\chi^2[1]$, atunci

$$\sum_{i=1}^n x_i \sim \chi^2[n].$$

Proprietăți

- Dacă $z_i, i = 1, 2, \dots, n$ sunt variabile independente care urmează distribuției $N(0,1)$, atunci $\sum_{i=1}^n z_i^2 \sim \chi^2[n]$;
- Dacă $z_i, i = 1, 2, \dots, n$ sunt variabile independente care urmează distribuției $N(0, \sigma^2)$, atunci $\sum_{i=1}^n \left(\frac{z_i}{\sigma}\right)^2 \sim \chi^2[n]$;
- Dacă $x_1 \sim \chi^2[n_1]$ și $x_2 \sim \chi^2[n_2]$ sunt variabile independente, atunci $x_1 + x_2 \sim \chi^2[n_1 + n_2]$.

În graficul de mai jos sunt prezentate distribuții χ^2 funcție de numărul de grade de libertate, k .




▪ Distribuția F .

Ca și distribuția χ^2 , distribuția F este o familie de distribuții asimetrice, care sunt mărginite de zero (sunt întotdeauna pozitive). Fiecare distribuție F este definită de către două valori de grade de libertate, denumite grade de libertate ale numărătorului și ale numitorului.

Dacă $x_1 \sim \chi^2[n_1]$ și $x_2 \sim \chi^2[n_2]$ sunt variabile independente, atunci $F = \frac{\frac{x_1}{n_1}}{\frac{x_2}{n_2}} \sim F[n_1, n_2]$.

În graficul de mai jos sunt prezentate distribuții F funcție de numărul de grade de libertate, d_1 și d_2 .



II.2. Testarea ipotezelor

O ipoteză este definită ca o afirmație referitoare la una sau mai multe populații.

Pentru testarea unei ipoteze trebuie parcurși următorii pași:

1. Definirea ipotezei;
2. Identificarea testului statistic ce va fi utilizat și a distribuției de probabilitate a acestuia;
3. Specificarea nivelului de relevanță al testului;
4. Specificarea regulii de decizie;
5. Colectarea datelor și estimarea parametrului;
6. Luarea deciziei statistice;
7. Luarea deciziei economice.

1. Primul pas în testarea ipotezei este specificarea ipotezei nule și a ipotezei alternative. Ipoteza nulă, notată cu H_0 , reprezintă ipoteza ce este testată, iar ipoteza alternativă, notată cu H_a , este ipoteza acceptată în cazul în care ipoteza nulă este respinsă.

Exemple de formulări de ipoteze:

- a) $H_0 : x = x_0$ versus $H_a : x \neq x_0$;
- b) $H_0 : x \leq x_0$ versus $H_a : x > x_0$;
- c) $H_0 : x \geq x_0$ versus $H_a : x < x_0$.

Prima formulare reprezintă un test care se referă la ambele cozi ale distribuției (*two tailed test*), ipoteza nulă fiind respinsă fie dacă x este mai mare, fie dacă x este mai mic decât x_0 . A doua și a treia formulare sunt teste care se referă la o singură coadă a distribuției (*one tailed test*), ipoteza nulă este respinsă numai dacă x este mai mare (punctul b)), respectiv mai mic (punctul c)) decât x_0 .

2. Al doilea pas constă în identificarea testului statistic aplicabil și a distribuției de probabilitate a acestuia.

Testul statistic reprezintă o cantitate calculată pe baza unui eșantion, a cărei valoare stă la baza deciziei de acceptare sau respingere a ipotezei nule.

De exemplu, testul statistic pentru media unei populații este:

$$test_statistic = \frac{parametru_esantion - parametru_populatie_sub_H_0}{eroare_std_parametru}$$

Astfel, dacă media unui eșantion cu n observații extras dintr-o populație este \bar{x} , eroarea standard a mediei poate fi calculată prin două metode:

- fie ca $\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$ în cazul în care abaterea medie pătratică a populației este cunoscută,
- sau ca $s_{\bar{x}} = \frac{s}{\sqrt{n}}$ atunci când abaterea medie pătratică a populației nu este cunoscută, dar este cunoscută abaterea medie pătratică a eșantionului, s .

3. Al treilea pas constă în specificarea nivelului de relevanță al testului. Pe baza valorii testului, două acțiuni sunt posibile:

- Ipoteza nulă este respinsă;
- Ipoteza nulă nu este respinsă.

Acceptarea sau respingerea ipotezei nule se bazează pe compararea valorii calculate a testului statistic cu valorile specifice (tabelate) ale testului statistic. Valorile cu care se compară valorile calculate sunt stabilite funcție de nivelul de relevanță ales. Nivelul de

relevanță reflectă cât de multe „dovezi” (probabilitate) avem nevoie pentru respingerea ipotezei nule.

Atunci când testăm o ipoteză nulă pot apărea patru situații:

- Se respinge o ipoteză nulă falsă. Aceasta este acțiunea corectă.
- Se respinge o ipoteză nulă adevărată. Aceasta este o eroare de tipul I.
- Nu se respinge o ipoteză nulă falsă. Aceasta este o eroare de tipul II.
- Nu se respinge o ipoteză nulă adevărată. Aceasta este acțiunea corectă.

Probabilitatea unei erori de tipul I se notează cu α și se numește nivelul de relevanță al testului statistic. De exemplu, un nivel de relevanță de 0.05 (nivelul de relevanță cel mai utilizat în luarea deciziilor statistice) înseamnă că, cu o probabilitate de 5 la sută există riscul de a respinge o ipoteză nulă adevărată.

Probabilitatea unei erori de tipul II se notează cu β .

În luarea deciziei statistice, trebuie găsit un compromis între cele două tipuri de erori. Astfel, dacă scădem probabilitatea de a face o eroare de tipul I vom crește probabilitatea de a face o eroare de tipul II și invers. Singura metodă de a reduce ambele tipuri de erori este creșterea numărului de observații din eșantion, n .

4. Al patrulea pas în testarea ipotezei este stabilirea regulii de decizie. Astfel, atunci când este testată ipoteza nulă, dacă valoarea absolută calculată a testului statistic este mai mare sau egală cu valoarea tabelată pentru testul respectiv pentru nivelul de relevanță α , ipoteza nulă este respinsă (parametrul estimat este semnificativ din punct de vedere statistic). În caz contrar ipoteza nulă nu este respinsă, adică parametrul estimat nu este semnificativ din punct de vedere statistic. Valorile cu care se compară valorile calculate ale testului statistic se numesc valori critice.

Pentru un test care se referă la o singură coadă a distribuției (*one tailed test*) valoarea critică este indicată cu expresia z_{α} , unde z reprezintă valoarea critică iar α nivelul de relevanță. Pentru un test care se referă la ambele capete ale distribuției (*two tailed test*), valoarea critică este indicată cu $z_{\frac{\alpha}{2}}$.

Astfel, în cazul testului z (care este normal distribuit) pentru testarea mediei unui eșantion și considerând un nivel de relevanță de 0.05 rezultă următoarele posibilități:

- Pentru testul $H_0 : \mu = \mu_0$ versus $H_a : \mu \neq \mu_0$ sunt două puncte de respingere a ipotezei nule, unul pozitiv și unul negativ. Având în vedere că testul se referă la ambele capete ale distribuției, pentru un nivel de relevanță de 0.05, probabilitatea totală pentru apariția unei erori de tipul I nu trebuie să fie mai mare de 0.05. Astfel, o probabilitate de $\frac{0.05}{2} = 0.025$ trebuie luată în considerare pentru fiecare coadă a distribuției pentru testarea ipotezei nule. Ca o consecință,

cele două puncte de respingere sunt $z_{0,025} = 1.96$ și $-z_{0,025} = -1.96$. Dacă considerăm z ca fiind valoarea calculată a testului statistic, atunci respingem ipoteza nulă dacă $z < -1.96$ sau $z > 1.96$.

- Pentru testul $H_0 : \mu \leq \mu_0$ versus $H_a : \mu > \mu_0$, la nivelul de relevanță de 0.05, valoarea critică este $z_{0,05} = 1.645$. Ipoteza nulă se respinge dacă $z > 1.645$.
- Pentru testul $H_0 : \mu \geq \mu_0$ versus $H_a : \mu < \mu_0$, la nivelul de relevanță de 0.05, valoarea critică este $-z_{0,05} = -1.645$. Ipoteza nulă este respinsă dacă $z < -1.645$.

5. Al cincilea pas în testarea ipotezei este colectarea datelor și calculul testului statistic. Astfel, majoritatea testelor solicită cel puțin un număr de 20 – 30 de observații.

6. Al șaselea pas este reprezentat de luarea deciziei statistice: acceptarea sau respingerea ipotezei nule.

7. Ultima etapă constă în luarea deciziei economice. Aceasta trebuie să ia în considerare nu numai decizia statistică ci și toate celelalte informații disponibile.

Programele software econometrice raportează, pe lângă valoarea testului statistic și probabilitatea α asociată acestui test (valoarea p). Aceasta reprezintă cel mai mic nivel de relevanță la care ipoteza nulă poate fi respinsă. Astfel decizia statistică este simplificată, aceasta putând fi luată prin compararea valorii p cu nivelul de relevanță la care se lucrează.

II.3. Testarea mediei

Pentru testarea mediei sunt folosite două tipuri de teste: testul z și testul t . Modul de calcul al celor două teste este identic, ceea ce diferă sunt valorile critice ale testului.

Modalitatea de calcul al testului este:

$$test_statistic = \frac{parametru_esantion - parametru_populatie_sub_H_0}{eroare_std_parametru}$$

Decizia de a utiliza unul dintre cele două teste se ia funcție de distribuția populației și numărul de observații disponibile astfel:

	Eșantion mare ($n > 30$)	Eșantion mic ($n < 30$)
Populația are o distribuție normală	Testul t sau testul z	Testul t
Populația nu are o distribuție normală	Testul t sau testul z	Nu se poate testa

De exemplu, se analizează evoluția randamentelor unui fond de investiții. Astfel eșantionul este format din 24 de observații care reprezintă randamentele lunare ale fondului în ultimii 2 ani. Media acestor randamente este 1.5 la sută iar abaterea lor standard este de 3.60 la sută. Datorită nivelului de risc sistematic al investițiilor acestui fond, acesta ar trebui să obțină un randament lunar de 1.10 la sută. Se cere să se determine, cu un nivel de relevanță de 10 la sută, dacă rezultatele fondului sunt consistente cu cerința de a obține un randament lunar de 1.10 la sută.

În aceste condiții testul statistic are ca ipoteză nulă este $H_0 : \mu = 1.10$ versus ipoteza alternativă $H_a : \mu \neq 1.10$.

Deoarece varianța populației nu este cunoscută se va utiliza un test t cu $21 - 1 = 23$ grade de libertate (prin calculul mediei s-a pierdut un grad de libertate).

Având în vedere că este un test care ține cont de ambele capete ale distribuției, valoarea critică este $t_{\frac{\alpha}{2}, n-1} = t_{0.05, 23}$. Conform tabelelor distribuției t, valoarea critică corespunzătoare nivelului de relevanță de 0.05 și a 23 de grade de libertate este 1.714. Ca urmare, cele două puncte de respingere a ipotezei nule sunt 1.714 și respectiv -1.714. Cu alte cuvinte, ipoteza nulă va fi respinsă dacă $t > 1.714$ sau $t < -1.714$.

Valoarea testului statistic este: $t_{23} = \frac{1.5 - 1.10}{\frac{3.60}{\sqrt{24}}} = \frac{0.4}{0.734847} = 0.544331$.

Deoarece 0.544331 nu satisface nici una din condițiile $t > 1.714$ sau $t < -1.714$, ipoteza nulă nu este respinsă.

Funcție de valorile critice ale testului parametrului, și a erorii standard a acestuia se poate construi intervalul de confidență al parametrului astfel: $\left[\bar{x} - t_{\frac{\alpha}{2}} s_{\bar{x}}; \bar{x} + t_{\frac{\alpha}{2}} s_{\bar{x}} \right]$.

Astfel, pentru exemplul de mai sus, cu un nivel de relevanță de 90 la sută, cele două valori sunt $1.5 - (1.714 \cdot 0.734847) = 0.240472$ și $1.5 + (1.714 \cdot 0.734847) = 2.759528$. Astfel, intervalul de confidență al mediei, la un nivel de relevanță de 90 la sută este $[0.240472; 2.759528]$. Cum valoarea de 1.10 la sută aparține acestui interval, ipoteza nulă nu este respinsă.

II.4. Testarea varianței

Varianța și deviația standard sunt măsuri utilizate frecvent pentru măsurarea riscului în investițiile financiare.

Ca și în cazul testelor de medie, considerând σ_0^2 valoarea cu care se compară varianța eșantionului, σ^2 , ipotezele ce pot fi formulate pentru varianța unei populații sunt:

- a) $H_0 : \sigma^2 = \sigma_0^2$ versus $H_a : \sigma^2 \neq \sigma_0^2$;
- b) $H_0 : \sigma^2 \leq \sigma_0^2$ versus $H_a : \sigma^2 > \sigma_0^2$;
- c) $H_0 : \sigma^2 \geq \sigma_0^2$ versus $H_a : \sigma^2 < \sigma_0^2$.

Pentru testele statistice referitoare la varianța unei populații cu distribuție normală este folosit testul χ^2 .

Dacă dispunem de un eșantion de n observații extrase dintr-o populație normal distribuită, testul statistic pentru testarea varianței este:

$$\chi^2 = \frac{(n-1)s^2}{\sigma_0^2},$$

cu $n - 1$ grade de libertate.

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

reprezintă varianța eșantionului de date utilizat.

Dacă alegem un nivel de relevanță al testului, α , punctele de respingere ale ipotezei nule pentru cele trei tipuri de teste sunt:

- a) $H_0 : \sigma^2 = \sigma_0^2$ versus $H_a : \sigma^2 \neq \sigma_0^2$. Respingem ipoteza nulă dacă valoarea testului statistic este egală cu sau mai mare decât punctul cel mai la dreapta (cel mai mare) $\frac{\alpha}{2}$ a distribuției χ^2 cu $n - 1$ grade de libertate (notat cu $\chi_{\frac{\alpha}{2}}^2$) sau dacă valoarea testului statistic este egală cu sau mai mică decât punctul cel mai la stânga (cel mai mic) $\frac{\alpha}{2}$ a distribuției, (notat cu $\chi_{1-\frac{\alpha}{2}}^2$).
- b) $H_0 : \sigma^2 \leq \sigma_0^2$ versus $H_a : \sigma^2 > \sigma_0^2$. Respingem ipoteza nulă dacă valoarea testului statistic este egală cu sau mai mare decât punctul cel mai la dreapta (cel mai mare) α a distribuției χ^2 cu $n - 1$ grade de libertate.
- c) $H_0 : \sigma^2 \geq \sigma_0^2$ versus $H_a : \sigma^2 < \sigma_0^2$. Respingem ipoteza nulă dacă valoarea testului statistic este egală cu sau mai mică decât punctul cel mai la stânga (cel mai mic) α a distribuției χ^2 cu $n - 1$ grade de libertate.

Revenind la exemplul utilizat în cazul testului privind media unei populații, presupunând că, pe parcursul celor 24 de luni de observație a randamentelor fondului de investiții, deviația standard a randamentelor lunare ale acestuia a fost de 3.60 la sută, se cerea să se analizeze dacă strategia de investiții a fondului a urmărit (și a reușit) o abatere standard a randamentelor lunare de cel mult 4 la sută.

În aceste condiții, ipoteza nulă este $H_0: \sigma^2 \geq 16$ iar ipoteza alternativă este $H_a: \sigma^2 < 16$.

Testul statistic folosit este testul χ^2 cu $24 - 1 = 23$ grade de libertate. La $\alpha = 0.05$, valoarea critică a testului este 13.091.

Valoarea testului statistic este:

$$\chi^2 = \frac{(n-1)s^2}{\sigma_0^2} = \frac{23 \cdot 3.6^2}{4^2} = \frac{298.08}{16} = 18.63$$

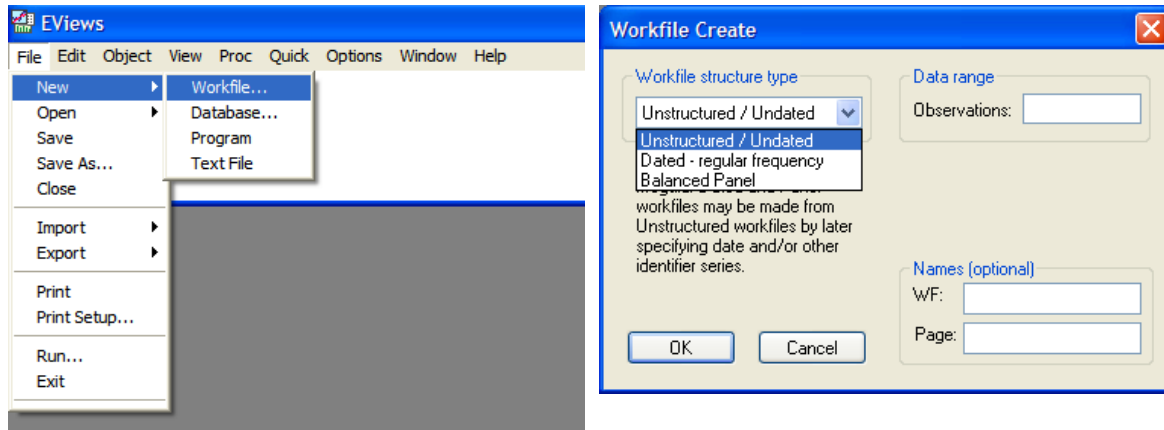
Deoarece valoarea calculată a testului statistic, 18.63, nu este mai mică decât valoarea critică, 13.091, nu respingem ipoteza nulă.

Deci strategia de investiții a fondului a avut ca rezultat o deviație standard a randamentelor lunare înregistrate de fondul de investiții mai mică decât 4 la sută.

Capitolul III. Analiza seriilor de timp în EViews

III.1. Introducerea seriilor în EViews

Crearea unui fișier de lucru (*workfile*) în EViews

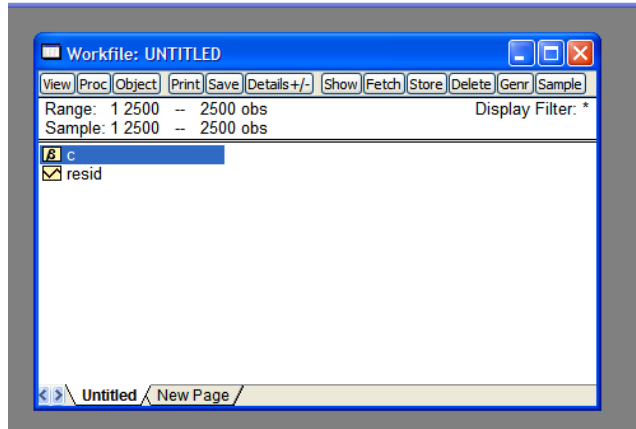
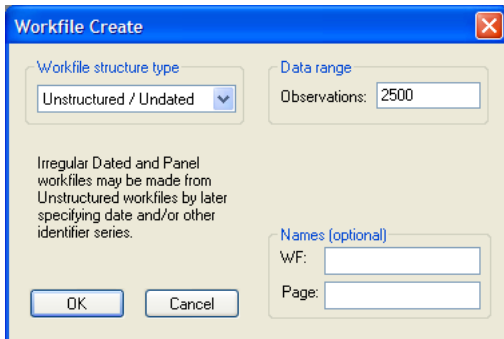



Fișierul de lucru poate să conțină următoarele tipuri de date:

- Serii cros-secționale sau serii de timp nedatate (opțiunea *Unstructured/Undated*);
- Serii de timp cu frecvență constantă (opțiunea *Dated – regular frequency*);
- Serii de tip panel – serii care sunt în același timp cros –secționale cât și serii de timp (opțiunea *Balanced Panel*).

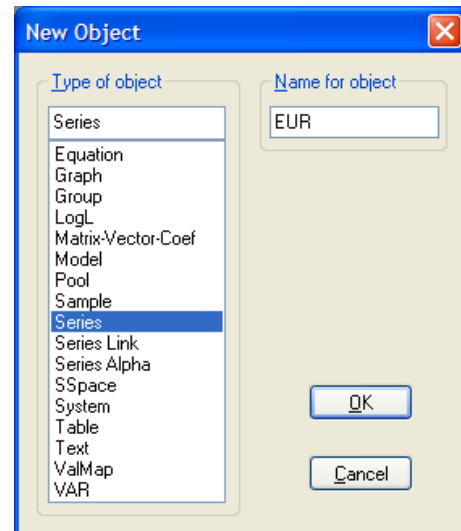
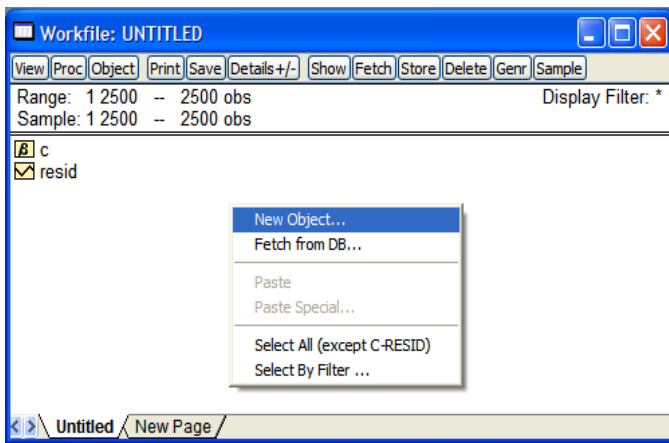
Analizăm seria de timp cu frecvență zilnică a cursului de schimb pentru perioada ianuarie 1999 – mai 2006. Deși seria are frecvență constantă, datorită sărbătorilor legale, care nu pot fi definite în EViews, nu se poate alege opțiunea *Dated*, ci opțiunea *Unstructured/Undated*.

Pentru perioada analizată, sunt disponibile aproximativ 2000 de observații. În cazul realizării de prognoze, trebuie alocate observații și pentru perioada pentru care se face prognoza. De aceea, este recomandat ca intervalul specificat să fie mai mare decât numărul de observații disponibile. De aceea, intervalul specificat în EViews va fi de 2500 observații.

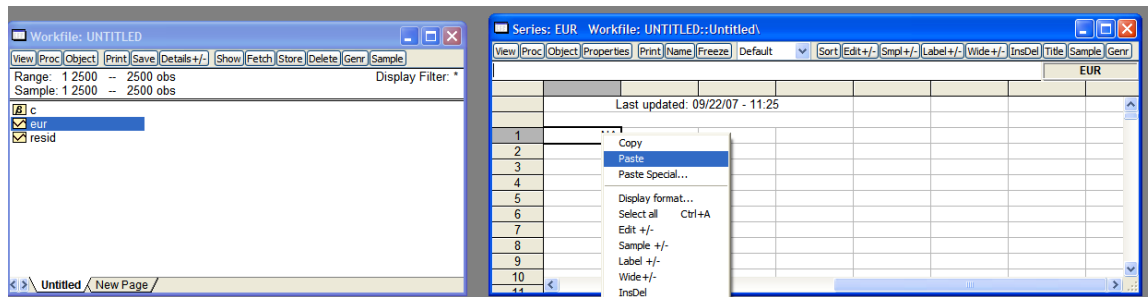


În acest fișier de lucru trebuie definite seriile cu care vor fi folosite în analiza econometrică.

Definirea seriilor: click buton dreapta mouse în interiorul fișierului de lucru, selectarea opțiunii *new object*, alegerea opțiunii *series* și specificarea numelui seriei. Seria creată se numește *eur*.



Introducerea datelor în seria creată: selectarea seriei, click buton stânga mouse, selectare opțiune *edit +/-* în fereastra seriei, introducerea datelor cu *copy* (din fișierul Excel) și *paste* în prima coloană a fișierului seriei.



III.2. Prelucarea seriilor

Asupra seriilor introduce pot fi aplicate operații matematice. Cele mai utilizate sunt logaritmarea și prima diferență.

Cu excepția seriilor care au și valori negative, sau zero, analiza econometrică se realizează cu serii logaritmăte, logaritmarea facilitând interpretarea coeficienților obținuți din regresie (aceștia sunt elasticități).

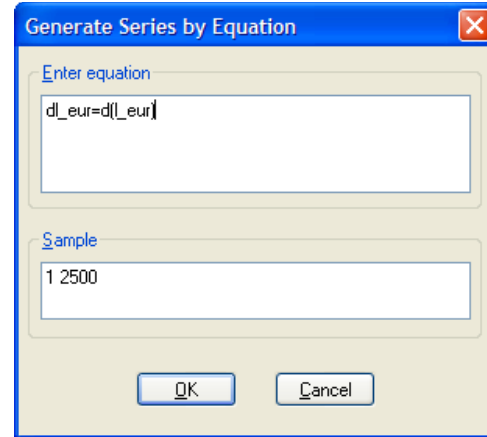
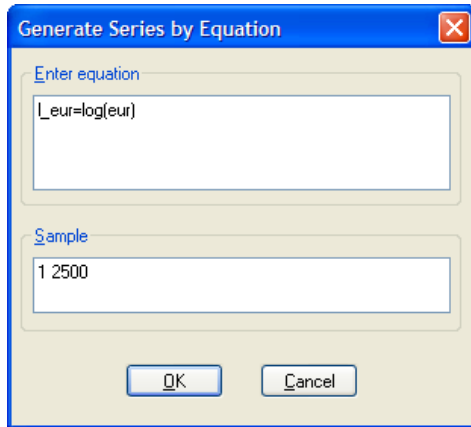
Prima diferență ($x_t - x_{t-1}$) este utilizată pentru staționizarea seriilor.

Prelucrarea se realizează cu opțiunea *generate (genr)* din fereastra fișierului de lucru și introducerea ecuație. De exemplu se logaritmează seria *eur*, seria de logaritmi se numește *l_eur*. Asupra seriei *l_eur* se aplică operatorul primă diferență, seria de prime diferențe fiind denumită *dl_eur*.

Comenzile ce trebuie scrise în fereastra Generate sunt:

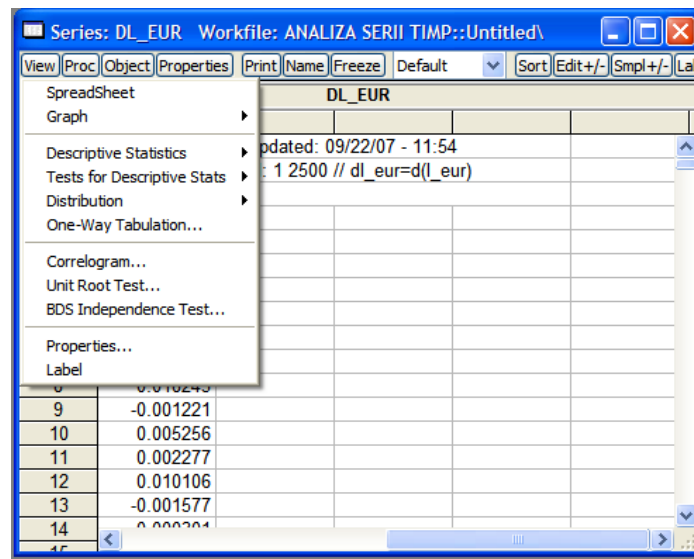
- $l_eur = \log(eur)$
- $dl_eur = d(l_eur)$ sau $dl_eur = l_eur - l_eur(-1)$

$x(-n)$ reprezintă *lag*-ul n al seriei, adică observația x_{t-n} . $x(n)$ reprezintă *lead*-ul n al seriei, adică observația x_{t+n} .



III.3. Staționaritatea seriilor de timp

Opțiunile pentru analiza seriilor de timp sunt disponibile în fereastra seriei, prin opțiunea *view*.




Opțiunile disponibile sunt:

- *Spreadsheet* permite vizualizarea/modificarea datelor seriei;
- *Graph* permite reprezentarea grafică a seriei;
- *Descriptive Statistics* prezintă primele patru momente ale distribuției seriei;
- *Test of Descriptive Statistics* permite efectuarea de teste statistice asupra momentelor seriei;
- *Distribuția* prezintă distribuția seriei;
- *Correlogram* prezintă funcția de autocorelație și autocorelație parțială.

Seriile ce vor fi analizate sunt *l_eur* și *dl_eur*.

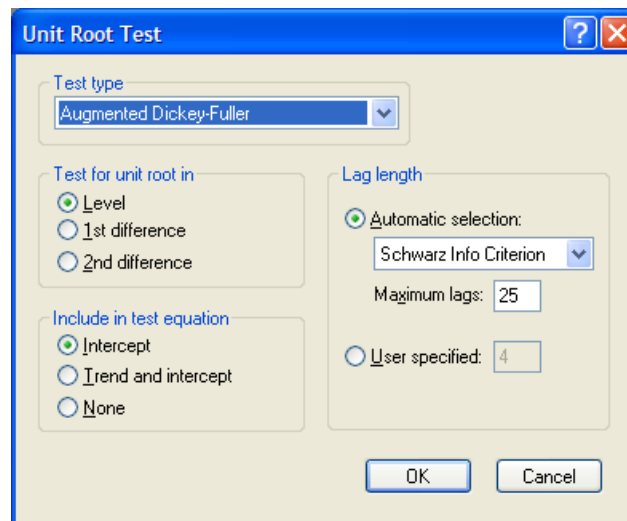
Graficele celor două serii (*View/Graph/Line*) sunt prezentate mai jos:



Din grafice rezultă că *l_eur* (seria cursului de schimb) ar trebui să fie o serie nestaționară iar seria *dl_eur* (variația zilnică a cursului de schimb) o serie staționară. Dar aceste observații trebuie confirmate prin testele de staționaritate.

Testele de staționaritate cele mai folosite sunt *ADF* (*Augmented Dickey-Fuller*) și *PP* (*Phillips-Perron*).

Pentru a testa staționaritatea unei serii de timp: *View/Unit Root Test*



Opțiunile disponibile sunt:

- *Test type*: tipul testului de rădăcină unitară (*Augmented Dickey-Fuller*, *Phillips-Perron*);
- *Test unit root in*:
 - *Level* – seria nivel (seria efectivă);

- *1st difference* – prima diferență a seriei (de obicei în cazul în care testul aplicat asupra seriei nivel a arătat că seria este nestaționară);
- *2nd difference* – a doua diferență a seriei (atunci când și testul aplicat primei diferențe a arătat că seria de prime diferențe este nestaționară).
- *Include in test equation*
 - *Intercept* – dacă testul să includă și un termen constan. Acesată opțiune se alege atunci când din graficul seriei se observă că aceasta fluctuează în jurul unei anumite valori sau pornește dintr-o anumită valoare.
 - *Trend and intercept* – în cazul în care seria prezintă un trend.
 - *None* – în cazul în care seria fluctuează în jurul valorii 0.

Prima parte a testului prezintă informații cu privire la tipul testului (ADF, variabilele exogene introduse – constantă, trend) și cuprinde rezultatul testului, valorile critice pentru fiecare nivel de relevanță (1, 5 și 10 la sută), și probabilitatea, p , asociată rezultatului testului.

În acest exemplu, pentru I_{eur} , ADF are valoarea -0.981155 și valoarea p asociată acestuia este de 0.9448 . Dacă valoarea testului este mai mare decât valoarea critică, nu este respinsă ipoteza nulă – seria are o rădăcină unitară (este nestaționară). În acest caz nu este respinsă ipoteza nulă – seria este nestaționară.

Utilizând valoarea p , este acceptată ipoteza nulă – seria este nestaționară – pentru un anumit nivel de relevanță, ori de câte ori probabilitatea p este mai mare decât acel nivel de relevanță.

Partea a doua a testului prezintă ecuația estimată, pe baza căreia a fost calculat testul ADF .

Testul ADF pentru I_{eur} :

Null Hypothesis: L_EUR has a unit root
 Exogenous: Constant, Linear Trend
 Lag Length: 3 (Automatic based on SIC, MAXLAG=25)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.981155	0.9448
Test critical values:		
1% level	-3.962327	
5% level	-3.411905	
10% level	-3.127850	

*MacKinnon (1996) one-sided p-values.

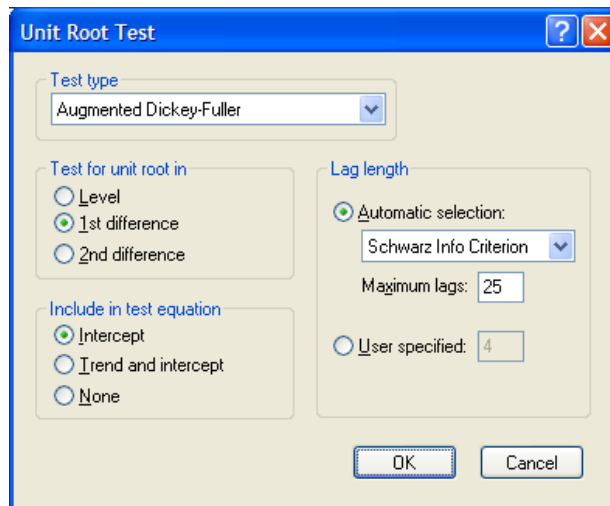
Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(L_EUR)

Method: Least Squares
 Date: 09/22/07 Time: 12:51
 Sample (adjusted): 5 2148
 Included observations: 2144 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
L_EUR(-1)	-0.000783	0.000798	-0.981155	0.3266
D(L_EUR(-1))	0.066581	0.021554	3.089033	0.0020
D(L_EUR(-2))	-0.089595	0.021512	-4.164953	0.0000
D(L_EUR(-3))	-0.074095	0.021552	-3.437954	0.0006
C	0.002038	0.000567	3.593461	0.0003
@TREND(1)	-6.76E-07	3.97E-07	-1.702470	0.0888

R-squared	0.027608	Mean dependent var	0.000428
Adjusted R-squared	0.025334	S.D. dependent var	0.006209
S.E. of regression	0.006129	Akaike info criterion	-7.348637
Sum squared resid	0.080324	Schwarz criterion	-7.332769
Log likelihood	7883.739	F-statistic	12.14042
Durbin-Watson stat	1.995360	Prob(F-statistic)	0.000000

Pentru a determina ordinal de integrare al seriei (de câte diferențieri este nevoie pentru a obține o serie staționară, se va testa staționaritatea seriei de prime diferențe (*dl_eur*).



Testul *ADF* pentru *dl_eur*:

Null Hypothesis: D(L_EUR) has a unit root

Exogenous: Constant

Lag Length: 2 (Automatic based on SIC, MAXLAG=25)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-29.44682	0.0000
Test critical values:		
1% level	-3.433203	
5% level	-2.862686	
10% level	-2.567426	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(L_EUR,2)

Method: Least Squares

Date: 09/22/07 Time: 13:13

Sample (adjusted): 5 2148

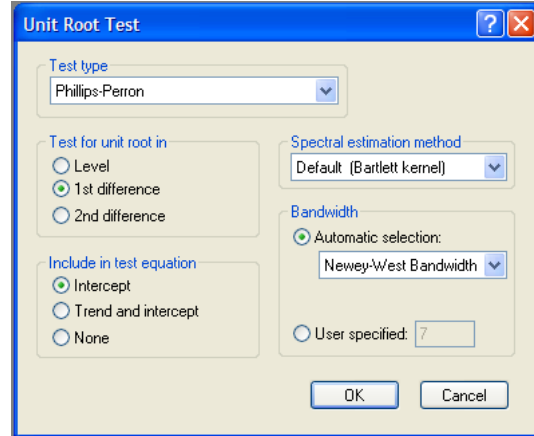
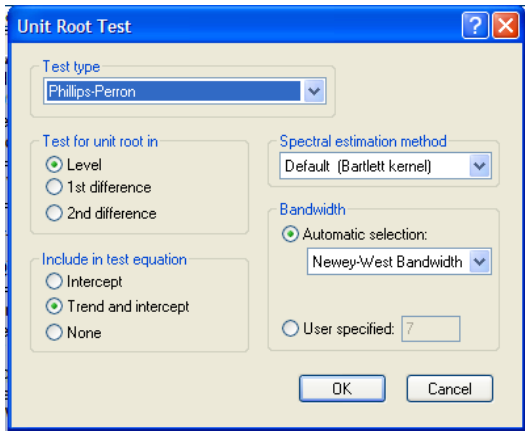
Included observations: 2144 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(L_EUR(-1))	-1.071989	0.036404	-29.44682	0.0000
D(L_EUR(-1),2)	0.147425	0.029223	5.044887	0.0000
D(L_EUR(-2),2)	0.065175	0.021560	3.023036	0.0025
C	0.000459	0.000134	3.425652	0.0006
R-squared	0.469264	Mean dependent var		5.00E-06
Adjusted R-squared	0.468520	S.D. dependent var		0.008448
S.E. of regression	0.006159	Akaike info criterion		-7.340058
Sum squared resid	0.081168	Schwarz criterion		-7.329479
Log likelihood	7872.542	F-statistic		630.7120
Durbin-Watson stat	1.994158	Prob(F-statistic)		0.000000

Cum valoarea testului este mai mică decât valoarea critică pentru oricare dintre nivelele de relevanță, alegând nivelul de relevanță cel mai restrictiv, 1 la sută, se poate spune că la 1 la sută nivel de relevanță, ipoteza nulă (seria este nestaționară) este respinsă. Acest rezultat rezultă și din valoarea probabilității asociate, p . Astfel, aceasta este mai mică decât cel mai restrictiv nivel de relevanță, de 1 la sută și ca urmare, ipoteza nulă – seria este nestaționară – este respinsă. Deci ordinul de integrare al seriei este 1 sau seria este $I(1)$.

Testul *PP* funcționează pe același principiu ca și *ADF*. Rezultatul obținut aplicând testul *PP* este similar.

Cele două teste, pentru nivel și pentru prima diferență sunt:



Testul *PP* pentru L_{eur} :

Null Hypothesis: L_{EUR} has a unit root

Exogenous: Constant, Linear Trend

Bandwidth: 18 (Newey-West using Bartlett kernel)

	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-0.937060	0.9502
Test critical values:		
1% level	-3.962321	
5% level	-3.411902	
10% level	-3.127848	

*MacKinnon (1996) one-sided p-values.

Residual variance (no correction)	3.82E-05
HAC corrected variance (Bartlett kernel)	3.09E-05

Phillips-Perron Test Equation

Dependent Variable: $D(L_{EUR})$

Method: Least Squares

Date: 09/22/07 Time: 13:21

Sample (adjusted): 2 2148

Included observations: 2147 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
$L_{EUR}(-1)$	-0.000808	0.000802	-1.006972	0.3141
C	0.001905	0.000568	3.355915	0.0008

@TREND(1)	-5.70E-07	3.98E-07	-1.430085	0.1528
R-squared	0.008674	Mean dependent var	0.000427	
Adjusted R-squared	0.007749	S.D. dependent var	0.006208	
S.E. of regression	0.006184	Akaike info criterion	-7.332410	
Sum squared resid	0.081982	Schwarz criterion	-7.324485	
Log likelihood	7874.342	F-statistic	9.379616	
Durbin-Watson stat	1.866028	Prob(F-statistic)	0.000088	

Testul *PP* pentru *dl_eur*:

Null Hypothesis: D(L_EUR) has a unit root

Exogenous: Constant

Bandwidth: 14 (Newey-West using Bartlett kernel)

		Adj. t-Stat	Prob.*
Phillips-Perron test statistic		-42.86625	0.0000
Test critical values:	1% level	-3.433200	
	5% level	-2.862685	
	10% level	-2.567426	

*Mackinnon (1996) one-sided p-values.

Residual variance (no correction)	3.83E-05
HAC corrected variance (Bartlett kernel)	3.20E-05

Phillips-Perron Test Equation

Dependent Variable: D(L_EUR,2)

Method: Least Squares

Date: 09/22/07 Time: 13:27

Sample (adjusted): 3 2148


Included observations: 2146 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(L_EUR(-1))	-0.925715	0.021537	-42.98208	0.0000
C	0.000394	0.000134	2.941322	0.0033
R-squared	0.462853	Mean dependent var	1.60E-07	
Adjusted R-squared	0.462603	S.D. dependent var	0.008449	
S.E. of regression	0.006193	Akaike info criterion	-7.329739	
Sum squared resid	0.082240	Schwarz criterion	-7.324453	
Log likelihood	7866.810	F-statistic	1847.459	

III.4. Distribuția seriilor

Momentele seriilor și testul Jarque-Bera pentru testarea distribuției normale sunt disponibile prin opțiunea *View/Descriptive Statistics/Histogram and Stats*.

Pentru seria variațiilor zilnice ale cursului de schimb, *dl_eur*, momentele seriei sunt prezentate mai jos:



Ouput-ul prezintă histograma distribuției, media, mediana, valorile minime și maxime, deviația standard, coeficientul de asimetrie, kurtotica seriei și testul Jarque-Bera.

Pentru o distribuție normală:

- Coeficientul de asimetrie (*skewness*) este zero – distribuția normală este simetrică.
- Kurtotica (*kurtosis*) este 3. Dacă acest indicator are o valoarea mai mare decât 3, atunci distribuția se numește leptokurtotică, iar dacă acesta este mai mic decât 3 atunci distribuția se numește platikurtotică.

În exemplul de mai sus, conform rezultatelor statistice, distribuția evoluțiilor zilnice ale cursului de schimb are media apropiată de zero, prezintă asimetrie pozitivă (ceea ce înseamnă că, în perioada analizată cursul de schimb EUR/RON a avut o tendința de creștere – leul s-a depreciat) iar kurtotica are o valoare de peste 14, ceea ce înseamnă că această distribuție este leptokurtotică.

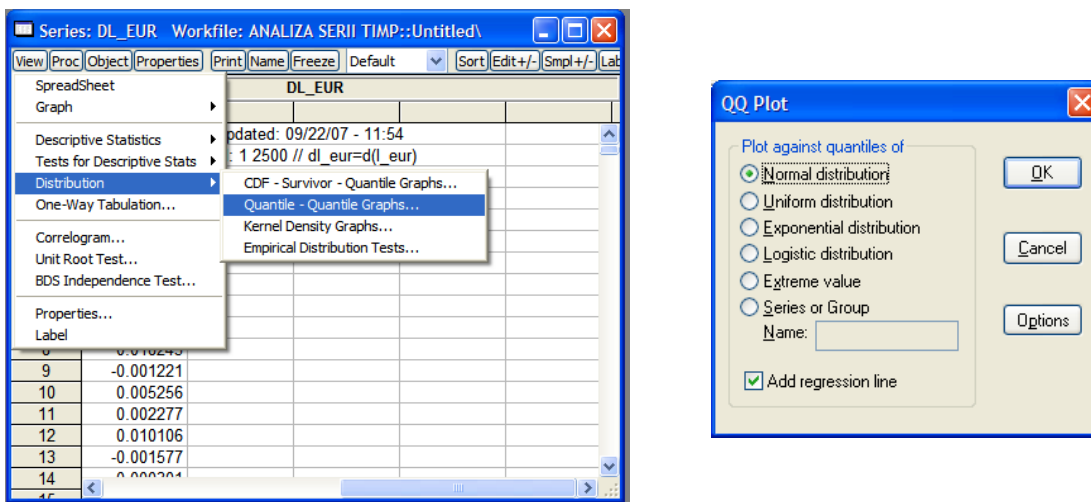
O asemenea distribuție au majoritatea activelor financiare. Într-o distribuție leptokurtotică, probabilitatea de apariție a unui eveniment extrem este superioară probabilității de apariție a aceluși eveniment implicată de o distribuție normală. Ca urmare

modelele de evaluare a prețului și riscului activului respectiv pot genera erori dacă presupun distribuția normală a acestuia.

Jarque-Bera testează dacă o distribuție este normal distribuită. Testul măsoară diferența dintre coeficientul de asimetrie și kurtotica distribuției analizate cu cele ale distribuției normale. Testul are ca ipoteza nulă: seria este normal distribuită. Astfel, dacă probabilitatea asociată testului este superioară nivelului de relevanță ales (1, 5 sau 10 la sută), atunci ipoteza nulă este acceptată.

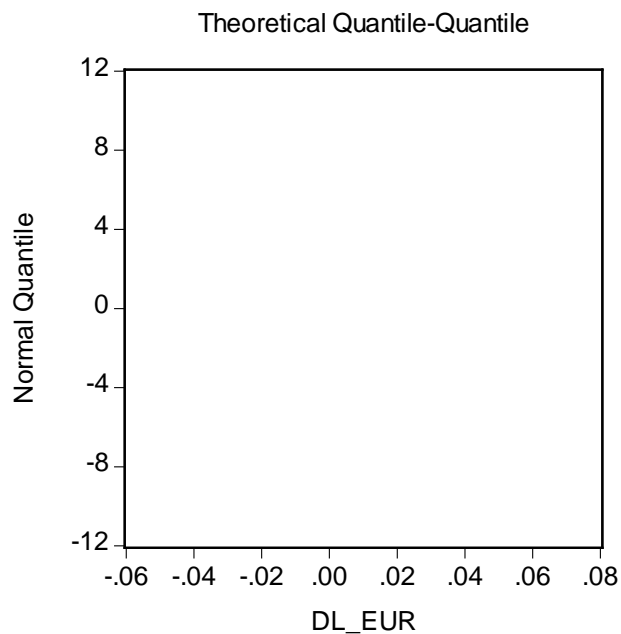
În exemplul de mai sus, cum valoarea probabilității asociate este zero, se respinge ipoteza nulă, cum că seria este normal distribuită.

O altă modalitate de testare a normalității distribuției este utilizând opțiunea *View/Distribution/Quantile-Quantile Graph* și alegând opțiunea *Normal Distribution*:

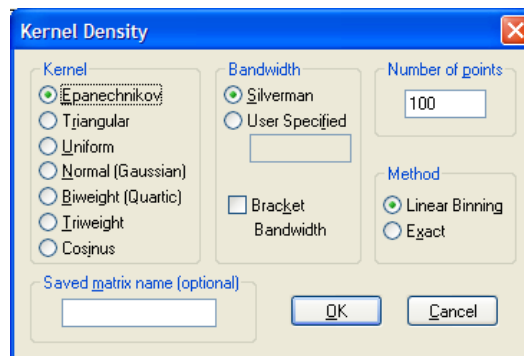
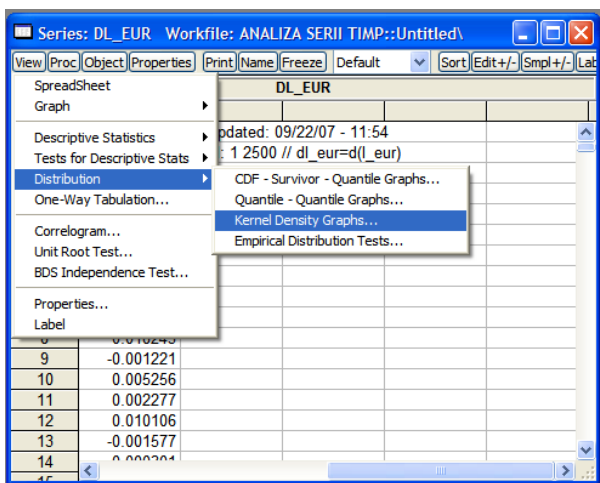


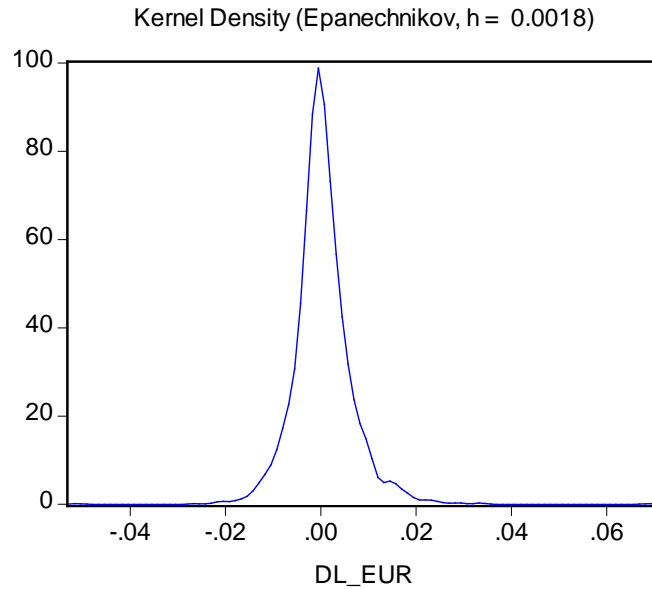
Prin această metodologie sunt reprezentate grafic quantilele distribuției teoretice (normale) versus quantilele distribuției care se analizează. Astfel, cu linie continuă sunt reprezentate quantilele distribuției normale, iar cu puncte cele ale distribuției efective. Cu cât acestea din urmă se abat mai mult față de cele teoretice, distribuția nu este normal distribuită.

În exemplul analizat se observă că distribuția seriei evoluțiilor zilnice ale cursului de schimb EUR/RON nu este normal distribuită.



Reprezentarea grafică a distribuției se realizează cu *View/Distribution/Kernel Density Graphs*:

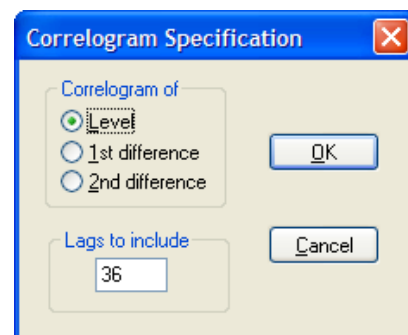
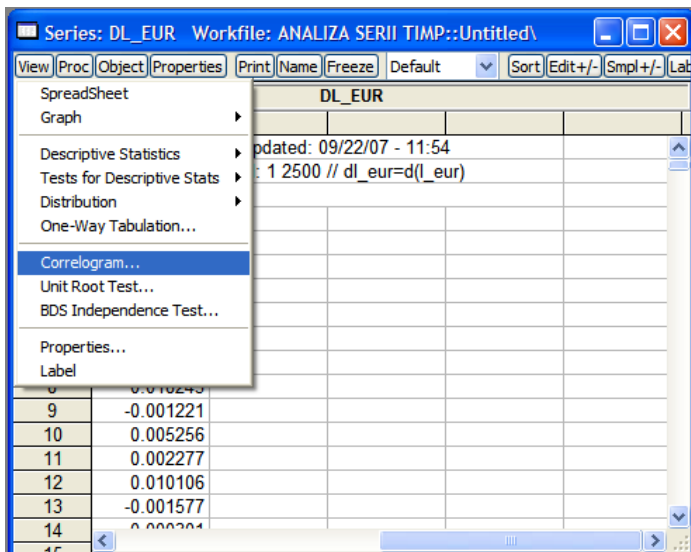




III.5. Funcția de autocorelație a seriilor de timp

Corelograma erorilor este utilizată în analiza erorilor ecuației de regresie și pentru alegerea specificației modelelor ARMA.

Analiza coeficienților de autocorelație și a coeficienților de corelație parțială ai seriilor este disponibilă cu opțiunea *View/Correlogram*.



Specificațiile corelogramei:

- *Correlogram of*
 - *Level* – corelograma serie în nivel;
 - *1st Difference* – corelograma seriei în prime diferențe,
 - *2nd Difference* – corelograma celei de a doua diferențe a seriei.
- *Lags to include* – numărul *lag*-urilor ce sunt incluse.

Coeficientul de corelație de ordinul k , (coeficientul de corelație dintre X_t și X_{t-k} este calculat după cum urmează:

$$\rho_k = \frac{\sum_{t=k+1}^n \frac{((X_t - \bar{X}) \cdot (X_{t-k} - \bar{X}))}{n-k}}{\sum_{t=1}^n \frac{(X_t - \bar{X})^2}{n}}$$

unde:

ρ_k reprezintă coeficientul de corelație de ordinul k ;

n – numărul de observații al seriei;

\bar{X} – media seriei X_t

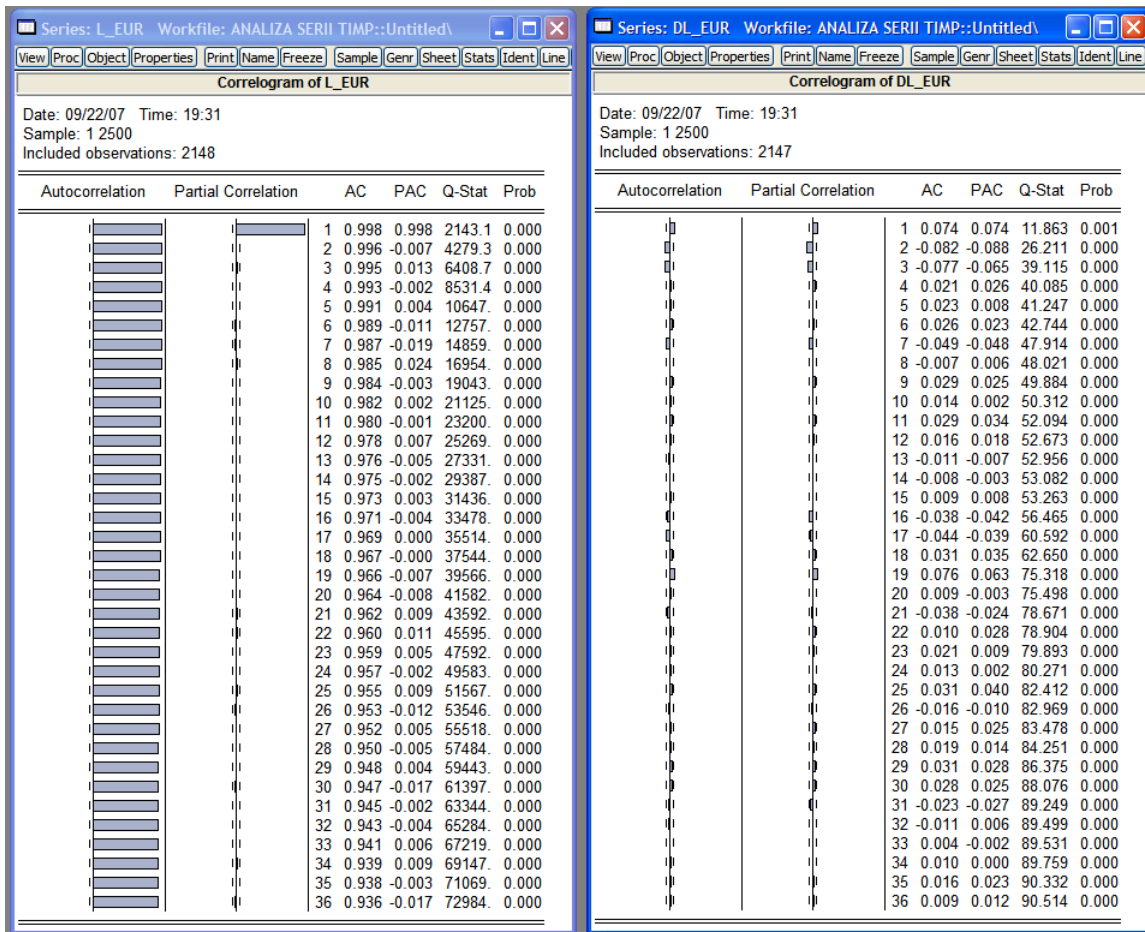
Coeficientul de autocorelație parțială la lag-ul k reprezintă coeficientul de regresie al lui X_{t-k} , atunci când X_t este regresat funcție de X_{t-k} și o constantă.

Pentru o serie nestaționară coeficienții de corelație încep de la o valoare apropiată de -1 sau 1 și scad foarte încet.

Coeficienții parțiali de autocorelație pentru un proces autoregresiv de ordin p , $AR(p)$ se opresc la lag-ul p , iar coeficienții parțiali de autocorelație pentru un proces medie mobilă, MA , converg gradual către zero.

Q-Statistic și probabilitatea asociată acestuia reprezintă un test statistic care are ca ipoteză nulă că nu există autocorelație până la lag-ul k . Dacă probabilitatea asociată testului Q-Statistic este superioară nivelului de relevanță, ipoteza nulă este respinsă și este acceptată ipoteza alternativă – există autocorelație până la lag-ul k .

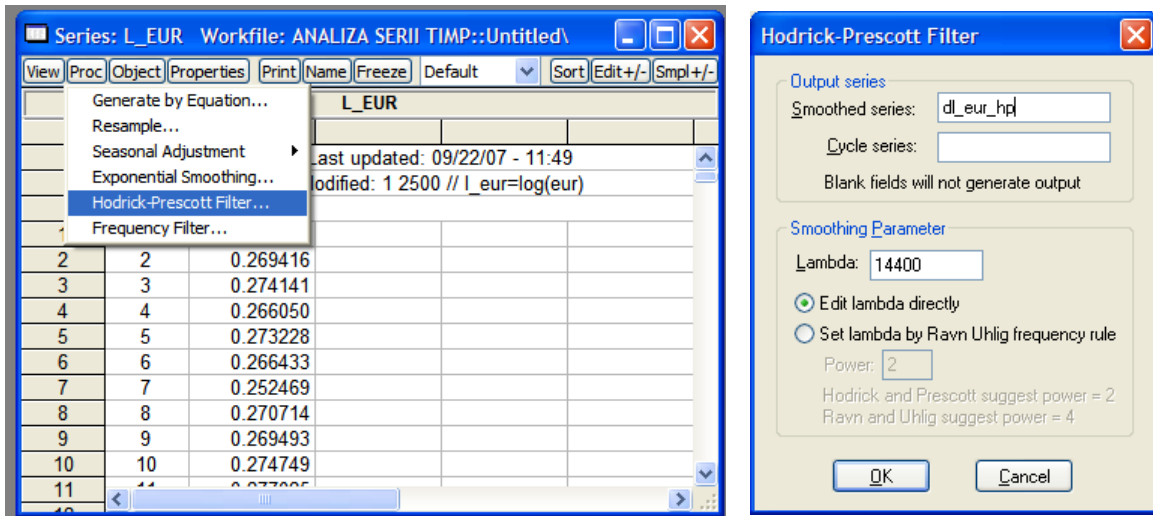
În exemplul ales, conform rezultatelor statistice, seria cursului de schimb EUR/RON, I_{eur} , prezintă autocorelație persistentă, conține o rădăcină unitară și de asemenea, și seria evoluției zilnice a cursului de schimb (seria în primă diferență a serie nivel a cursului de schimb), dl_{eur} prezintă autocorelație serială pentru primele 3 lag-uri.



III.6. Trendul seriilor de timp

Pentru estimarea unei componente pe termen lung a seriei de timp (trend), cea mai simplă metodă ce poate fi utilizată în programul EViews este filtrul Hodrick-Prescot.

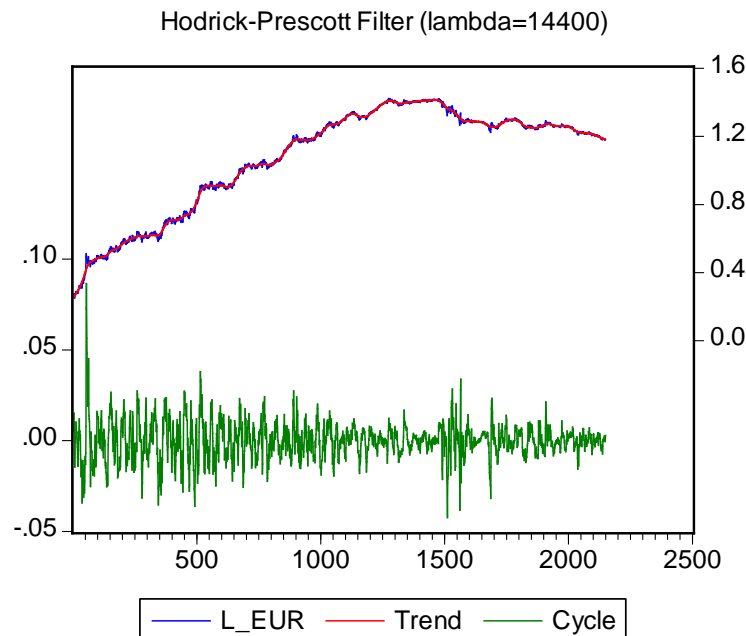
Determinarea componentei pe termen lung a seriei prin filtrul Hodrick-Prescot se realizează în EViews prin opțiunea Proc/Hodrick-Prescot Filter apelată din fereastra seriei de timp.



Opțiuni:

- *Smoothed series* reprezintă numele seriei trend ce va fi generată;
- *Cycle series* – numele seriei abaterii de la trend (calculată ca diferență între seria efectivă și seria trend).

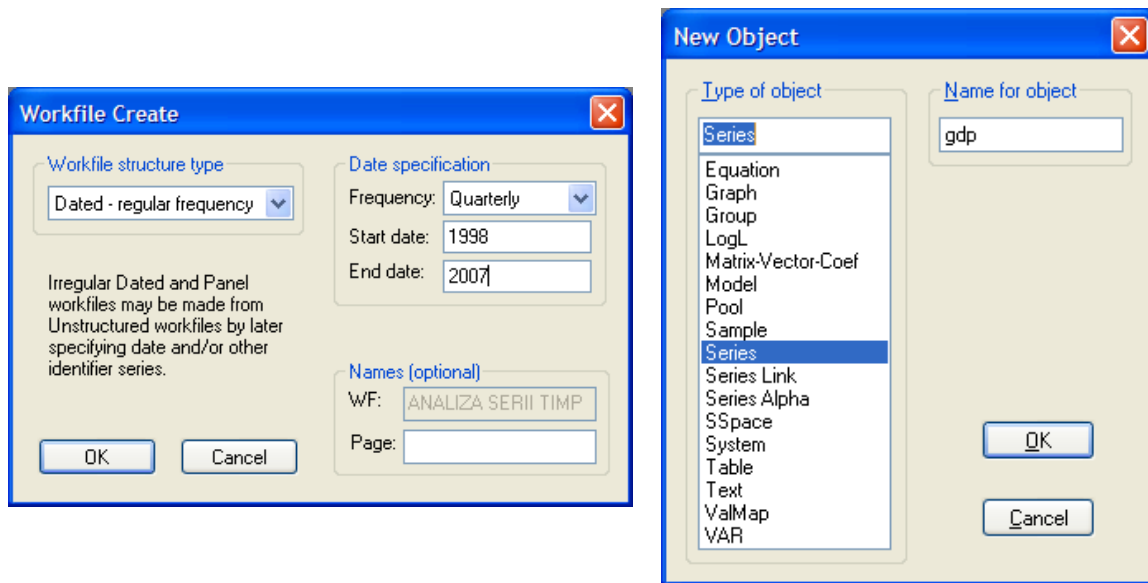
Pentru seria cursului de schimb EUR/RON, trendul și abaterea de la trend sunt prezentate în graficul de mai jos.




III.7. Ajustarea sezonieră a seriilor de timp

Pentru analiza sezonaliității unei serii s-a folosit seria de PIB trimestrial al României, pentru perioada trimestrul I 1998 – trimestrul IV 2006.


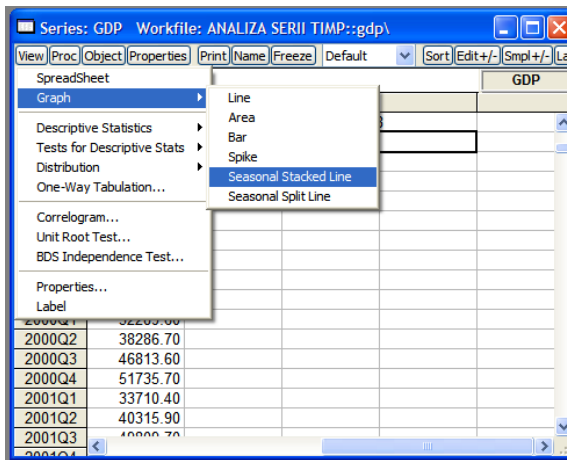
Pentru introducerea seriei de date în EViews a fost creat un fișier de lucru cu date trimestriale pentru perioada 1998 – 2007 și a fost creată seria *gdp*.



Se observă sezonaliitatea seriei din reprezentarea ei grafică:

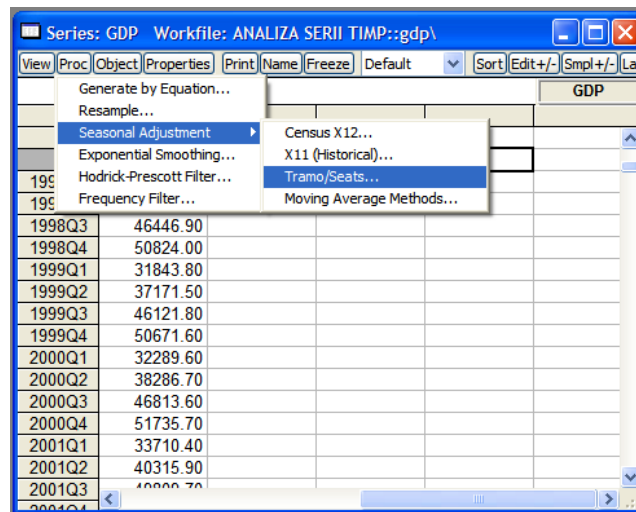


De asemenea, sezonaltatea poate fi pusă în evidență prin opțiunea *View/Graph/Seasonal Stacked Line* apelată din fereastra seriei de timp analizate:



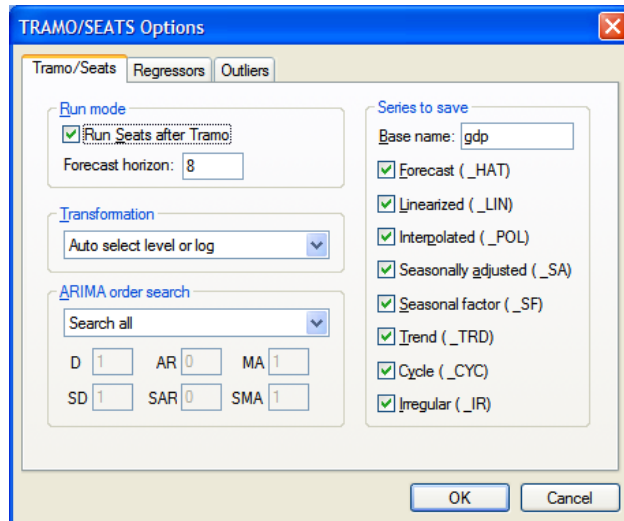
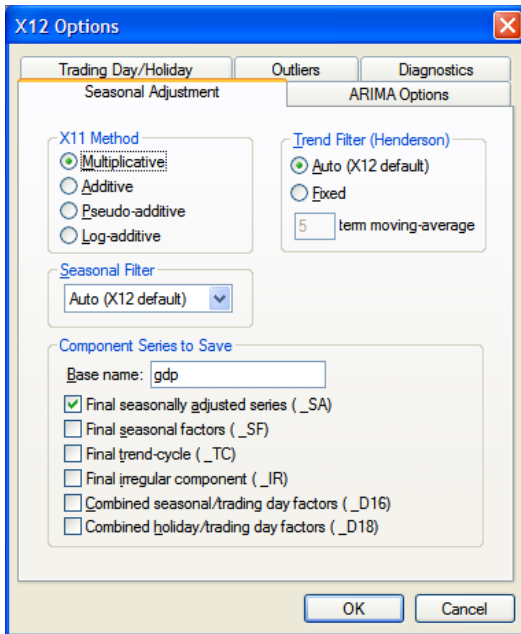
Graficul prezintă evoluția PIB-ului pe fiecare trimestru și media observațiilor pentru fiecare trimestru (linia orizontală). În cazul în care sunt diferențe semnificative între mediile trimestriale, cum este cazul exemplului de mai sus, seria de timp prezintă sezonaltate.

Desezonalizarea seriei de timp se realizează cu opțiunea *Proc/Seasonal Adjustment* apelată din fereastra seriei de timp.



Cele mai utilizate metodologii de ajustare sezonieră sunt:

- *Census X12* – dezvoltată de Biroul de Statistică al Statelor Unite;
- *Tramo/Seats* – utilizată în special de Eurostat (Biroul de Statistică al Comisiei Europene).



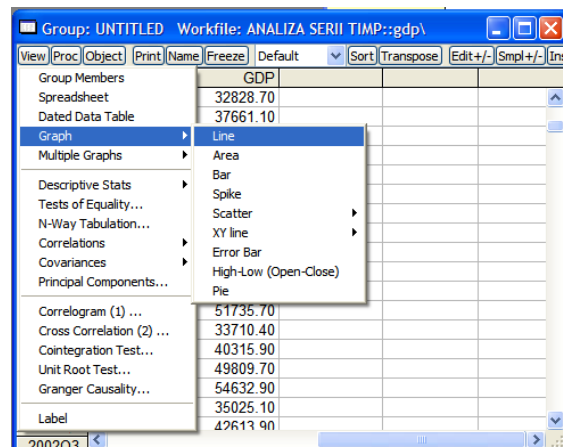
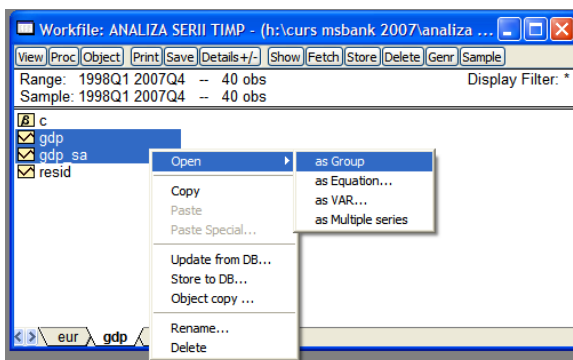
Opțiunile pentru cele două metodologii sunt:

Component Series to Save/Series to Save - Generarea de serii.


- Generarea seriei ajustată sezonier – bifarea opțiunii *_SA*. Va fi generată o serie *numele seriei initiale_SA* care reprezintă seria ajustată sezonier;
- Cele două proceduri pot genera, similar cu filtrul Hodrick-Prescot și trendul/ciclul seriei – opțiunea *_TC* pentru X12 și respectiv, opțiunile *_TRD* și *_CYC* pentru Tramo-Seats.

De exemplu, în cazul aplicării metodologiei X12, a fost generată seri *gdp_sa*.

Pentru a reprezenta pe același grafic cele două serii, se selectează seriile cu *CTRL + click* buton stânga mouse, apoi click buton dreapta mouse/*Open as group* și apoi, în fereastra grupului *View/Graph/Line*.



Cele două serii, cea nedesezonalizată, *gdp*, și cea ajustată sezonier, *gdp_sa* sunt prezentate în graficul de mai jos.



Capitolul IV. Regresia liniară multiplă

IV.1. Forma generală și ipoteze

Cu ajutorul regresiei liniare, se poate determina impactul pe care îl au mai multe variabile independente asupra anumite variabile (numită variabilă dependentă).

Forma generală a ecuației de regresie multiplă este:

$$Y_t = b_0 + b_1 X_{1t} + b_2 X_{2t} + \dots + b_k X_{kt} + \varepsilon_t$$

unde:

$t = 1, 2, \dots, n$ sunt observațiile din eșantion,

Y_t – observația t a variabilei dependente,

X_j – variabilele independente, $j = 1, 2, \dots, k$,

X_{jt} – observația t a variabilei independente X_j ,

b_0 – constanta (termenul liber al ecuației),

b_1, \dots, b_k – coeficienții variabilelor independente,

ε_t – termenul de eroare al ecuației.

Coeficientul variabilei independente arată cu cât se modifică variabila dependentă, Y_t , atunci când variabila independentă, X_{jt} , se modifică cu o unitate, în condițiile în care celelalte variabile independente rămân constante.

Dacă variabila dependentă și variabilele independente sunt specificate în logaritmi naturali, atunci coeficienții variabilelor independente pot fi interpretați ca elasticități. Astfel, acești coeficienți vor arăta cu cât la sută se modifică variabila dependentă dacă variabila independentă se modifică cu 1 la sută.

Pentru ca inferența bazată pe rezultatele regresiei liniare multiple să fie validă, trebuie îndeplinite un set de șase ipoteze, regresia bazată pe acest set de ipoteze fiind cunoscută ca modelul clasic normal de regresie multiplă.

Ipoteze:

1. Legătura dintre variabila dependentă și variabilele independente este liniară.
2. Variabilele independente sunt aleatoare. De asemenea între variabilele independente incluse într-o regresie nu există nici o relație liniară. Dacă variabilele independente sunt corelate atunci există multicolinearitate.
3. Valoarea așteptată a termenului de eroare, ε_t , este zero, $E(\varepsilon_t) = 0$.
4. Variația termenului de eroare, ε_t , este aceeași pentru toate observațiile, $E(\varepsilon_t^2) = \sigma_\varepsilon^2$. Aceste erori se numesc homoskedastice. Dacă, în schimb, variația

- termenului de eroare este variabilă, erorile se numesc heteroskedastice, și trebuie utilizate metode diferite de estimare a regresiei.
5. Termenul de eroare, ε_t , este necorelat între observații, $E(\varepsilon_t \times \varepsilon_s) = 0, s \neq t$.
Dacă există corelație serială a erorilor, trebuie folosite metode diferite de estimare a regresiei.
 6. Termenul de eroare este normal distribuit.

Impactul încălcării uneia dintre ipoteze asupra rezultatelor regresiei este prezentat în tabelul de mai jos:

Heteroskedasticitate	Erorile standard ale regresiei sunt incorecte
Corelație serială a erorilor	Erorile standard ale regresiei sunt incorecte
Multicoliniaritate	Valori mari ale lui R^2 și valori mici ale valorilor t - <i>statistic</i> ale coeficienților variabilelor independente

IV.2. Teste statistice și indicatori ai regresiei

Abaterea pătratică totală lui Y_i , numită și variația totală, (*total sum of squares, TSS*) este calculată ca $\sum_{i=1}^n (Y_i - \bar{Y})^2$.

Suma totală a pătratelor erorilor regresiei, numită și variația neexplicată (*residual sum of squares, sum of squared errors, SSE*) se calculează ca $\sum_{i=1}^n (Y_i - \hat{Y}_i)^2$, unde \hat{Y}_i reprezintă valoarea lui Y_i obținută conform rezultatelor regresiei (valoarea estimată a lui Y_i).

Partea din abaterea pătratică totală a lui Y_i obținută din regresie, numită și variația explicată (*regression sum of squares, RSS*) se calculează ca $\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$, unde \bar{Y} reprezintă media lui Y_i .

Între cele trei măsuri există relația:
 $TSS = SSE + RSS$.

Eroarea standard a estimării, (*standard error of estimate, SEE*) reprezintă eroarea standard a reziduuului ecuației.

$$SEE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{b}_0 - \hat{b}_1 X_{1t} - \hat{b}_2 X_{2t} - \dots - \hat{b}_k X_{kt})^2}{n - (k + 1)}} = \sqrt{\frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{n - (k + 1)}}$$

unde \hat{x} reprezintă x obținut din regresie (x estimat).

Media pătratelor regresiei (*mean regression sum of squares, MSR*) se calculează ca $\frac{RSS}{k}$, unde k este numărul variabilelor independente incluse în regresie.

Media erorii pătratice (*mean square error, MSE*) se calculează ca $\frac{SSE}{n-(k+1)}$.

Similar cu testarea mediei unui eșantion, coeficienții ecuației de regresie pot fi testați printr-un test t . Ipoteza nulă a testului este $b_k = b_{k0}$, unde b_k este coeficientul obținut din regresie iar b_{k0} valoarea testată a coeficientului.

Testul t se calculează conform relației:

$$t = \frac{b_k - b_{k0}}{s_{b_k}},$$

unde s_{b_k} este eroarea standard a coeficientului.

Dacă valoarea testului este mai mare decât valoarea critică, atunci ipoteza nulă este respinsă.

Programele software econometrice testează prin testul t , pentru fiecare coeficient, ipoteza nulă că acel coeficient are valoarea zero. Sunt raportate atât valorile testului t , cât și probabilitățile, p , asociate. Dacă probabilitatea asociată este inferioară nivelului de relevanță la care se lucrează (1, 5 sau 10 la sută), atunci se respinge ipoteza nulă și coeficientul este considerat ca fiind semnificativ din punct de vedere statistic. În cazul în care probabilitatea, p , este superioară nivelului de relevanță la care se lucrează, atunci ipoteza nulă este acceptată, iar coeficientul este considerat ca având, din punct de vedere statistic, valoarea zero.

Testul F măsoară cât de bine variabilele independente explică evoluția variabilei dependente. El determină dacă toți coeficienții regresiei, în același timp au valoarea zero din punct de vedere statistic. Acesta are ca ipoteză nulă că toți coeficienții din regresie au valoarea zero.

Testul F se calculează ca:

$$F = \frac{\frac{RSS}{k}}{\frac{SSE}{n-(k+1)}} = \frac{MSR}{MSE}$$

Testul F are o distribuție F cu $(k, n - (k + 1))$ grade de libertate.

Ca și în cazul testului t , programele software econometrice raportează valoarea testului și probabilitatea, p , asociată acestuia.

Dacă valoarea p este inferioară nivelului de relevanță la care se lucrează, atunci ipoteza nulă este respinsă, ceea ce înseamnă că cel puțin unul dintre coeficienții din regresie este semnificativ din punct de vedere statistic. Însă dacă valoarea p este superioară nivelului de relevanță, atunci este acceptată ipoteza nulă, ceea ce înseamnă că toți coeficienții din regresie sunt considerați nesemnificativi din punct de vedere statistic (egali cu zero).

Un alt indicator care arată dacă modelul de regresie este bine specificat este R^2 . Acesta arată cât la sută din varianța totală a variabilei dependente este datorată variabilelor independente.

$$R^2 \text{ se calculează ca } R^2 = \frac{TSS - SEE}{TSS}$$

R^2 ia valori între 0 și 1, cu cât valoarea acestuia este mai apropiată de 1, regresia este bine specificată.

De fiecare dată când este introdusă în regresie o nouă variabilă independentă care este cât de puțin corelată cu variabila dependentă, R^2 crește, dar în același timp se pierde un grad de libertate.

De aceea, o măsură îmbunătățită a lui R^2 este R^2 ajustat (\bar{R}^2), acesta ținând cont de numărul de variabile independente incluse în regresie. Formula de calcul a lui \bar{R}^2 este

$$\bar{R}^2 = 1 - \left(\frac{n-1}{n-k} \right) \cdot (1 - R^2),$$

unde:

n reprezintă numărul de observații,

k – numărul de variabile independente incluse în regresie.

Astfel, atunci când sunt introduse variabile independente suplimentare în regresie, R^2 poate să crească, dar \bar{R}^2 poate să scadă penalizând astfel introducerea de variabile independente care au o relevanță mică asupra variabilei dependente.

IV.3. Regresii cu variabile calitative

De multe ori este nevoie de introducerea unor variabile calitative în regresie. Unul dintre tipurile de variabile calitative cele mai des folosite în regresii sunt variabilele *dummy*. Acestea iau valoarea 1 dacă o anumită condiție este adevărată și valoarea 0 în caz contrar.

De exemplu, dacă se testează dacă randamentele obținute de o acțiune sunt diferite în luna ianuarie față de restul lunilor din an, se va include în regresie o variabilă *dummy*, care ia valoarea 1 în luna ianuarie și valoarea zero în celelalte luni ale anului.

Numărul de variabile *dummy* este cu 1 mai mic decât numărul de condiții, în caz contrar existând multicoliniaritate. În exemplul de mai sus, randamentul obținut de către acțiune în celelalte luni ale anului este captat de termenul liber al regresiei.

Variabilele *dummy* pot fi utilizate și pentru captarea impactului sezonier asupra variabilei independente, introducând cel mult 11 variabile *dummy* pentru datele cu frecvență lunară sau cel mult 3 variabile *dummy* pentru datele cu frecvență trimestrială, asta în cazul în care datele nu au fost ajustate sezonier în prealabil.

IV.4. Regresii cu serii de timp în EViews

În exemplu următor se va estima și o ecuație de regresie pentru randamentul unei acțiuni funcție de randamentul pieței (modelul de piață).

Astfel, se va estima randamentul acțiunii Banca Transilvania (TLV) funcție de randamentul BET, utilizând date zilnice pentru perioada ianuarie 1999 – mai 2005.

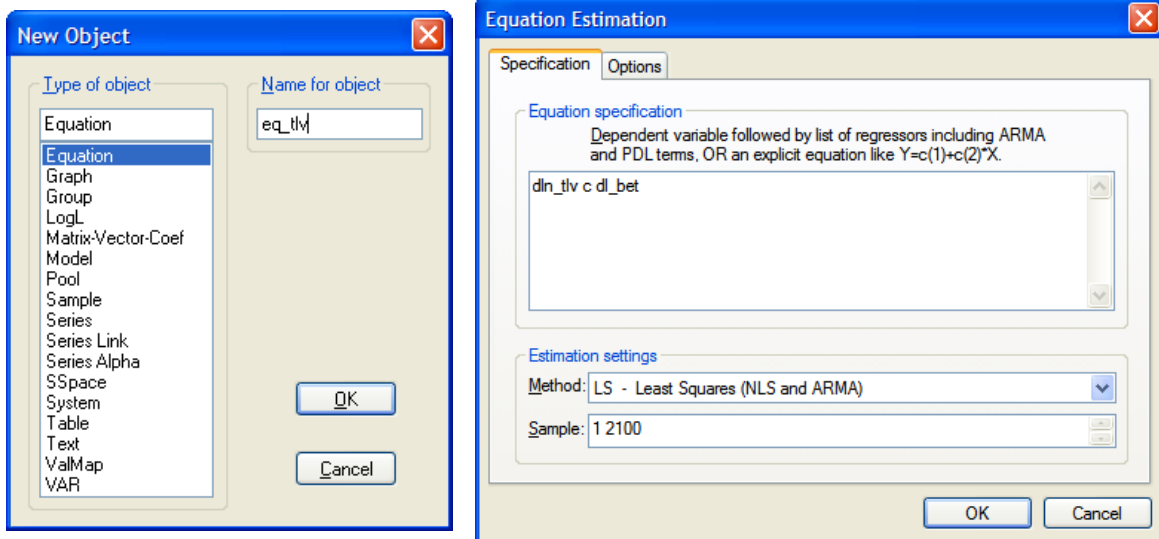
Serii utilizate:

dln_tlv – prima diferență a seriei de logaritmi naturali a prețurilor zilnice ale acțiunii Banca Transilvania (adică randamentul zilnic al acțiunii);

dl_bet – prima diferență a seriei de logaritmi naturali a indicelui BET.

Definirea ecuației: click buton dreapta mouse în interiorul fișierului de lucru, selectarea opțiune *new object*, în fereastra *New Object* selectare opțiune *Equation*.

Apoi în fereastra *Equation Estimation* la categoria *Equation specification* se specifică ecuația de regresie după cum urmează: variabila dependentă (*dln_tlv*), spațiu, constanta (*c*), spațiu, variabila/variabilele independente cu spațiu între ele (*dl_bet*). La categoria *Estimation settings* se selectează *LS – Least Squares*.



Rezultatul ecuației este:

Dependent Variable: DLN_TLV
 Method: Least Squares
 Date: 09/24/07 Time: 21:06
 Sample (adjusted): 2 2091
 Included observations: 2090 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.001601	0.000635	2.520559	0.0118
DL_BET	0.521952	0.040160	12.99691	0.0000
R-squared	0.074845	Mean dependent var		0.002376
Adjusted R-squared	0.074402	S.D. dependent var		0.030051
S.E. of regression	0.028912	Akaike info criterion		-4.248194
Sum squared resid	1.745314	Schwarz criterion		-4.242792
Log likelihood	4441.363	F-statistic		168.9196
Durbin-Watson stat	2.186437	Prob(F-statistic)		0.000000

Pentru fiecare variabilă independentă și constantă EViews raportează eroarea standard a coeficientului, testul *t-Statistic* și probabilitatea asociată acestuia. Presupunând ca se lucrează la nivelul de relevanță de 5 la suta, cum, în exemplul de mai sus probabilitățile atașate testului t-statistic sunt inferioare acestui nivel, coeficienții sunt considerați semnificativi din punct de vedere statistic.

EViews raportează R^2 și \bar{R}^2 , prezentate anterior.

Durbin Watson statistic (DW) este un test statistic care testează corelația serială a erorilor. Dacă erorile nu sunt corelate, atunci valoarea lui *DW* va fi în jur de 2. În exemplul de mai sus acest indicator are valoarea 2.18, și ca urmare, există corelație serială a erorilor.


EViews raportează și două criterii informaționale: *Akaike info criterion* și *Schwarz criterion*. Acești indicatori sunt folositori atunci când trebuie aleasă o ecuație din mai multe variante. Conform criteriului informațional, se alegea specificația pentru care criteriile informaționale au valorile cele mai mici.

În alegerea unei ecuații din mai multe ecuații posibile, de asemenea importante sunt și R^2 și \bar{R}^2 (care trebuie să fie cât mai mari) și testele de corelație serială și heteroskedasticitate. În majoritatea cazurilor fiecare dintre teste va indica o ecuație diferită, de aceea va trebui să se găsească un compromis în alegerea unei ecuații.

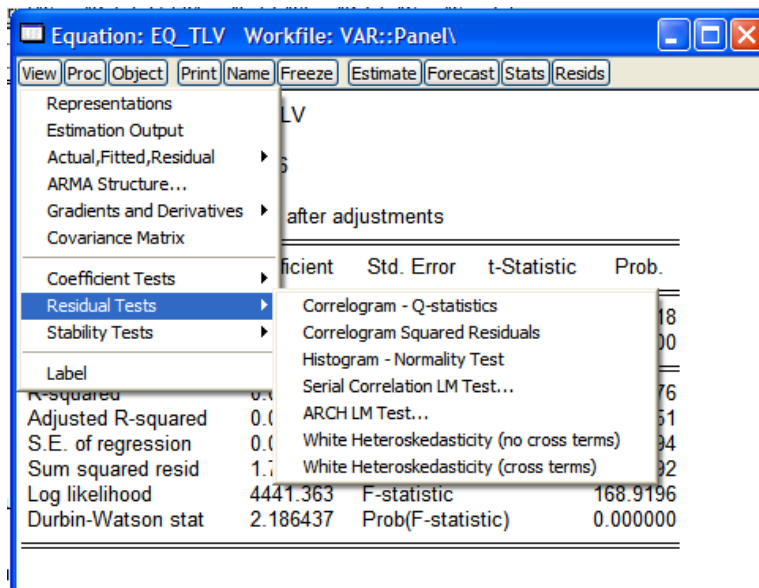
De asemenea este raportat și *F-statistic* și probabilitatea asociată acestuia. Cum această probabilitate este mai mică decât nivelul de relevanță, conform acestui test rezultă că cel puțin un coeficient din regresie este semnificativ din punct de vedere statistic.

Testele pentru ecuația de regresie sunt disponibile cu meniul *View* din fereastra ecuației de regresie.

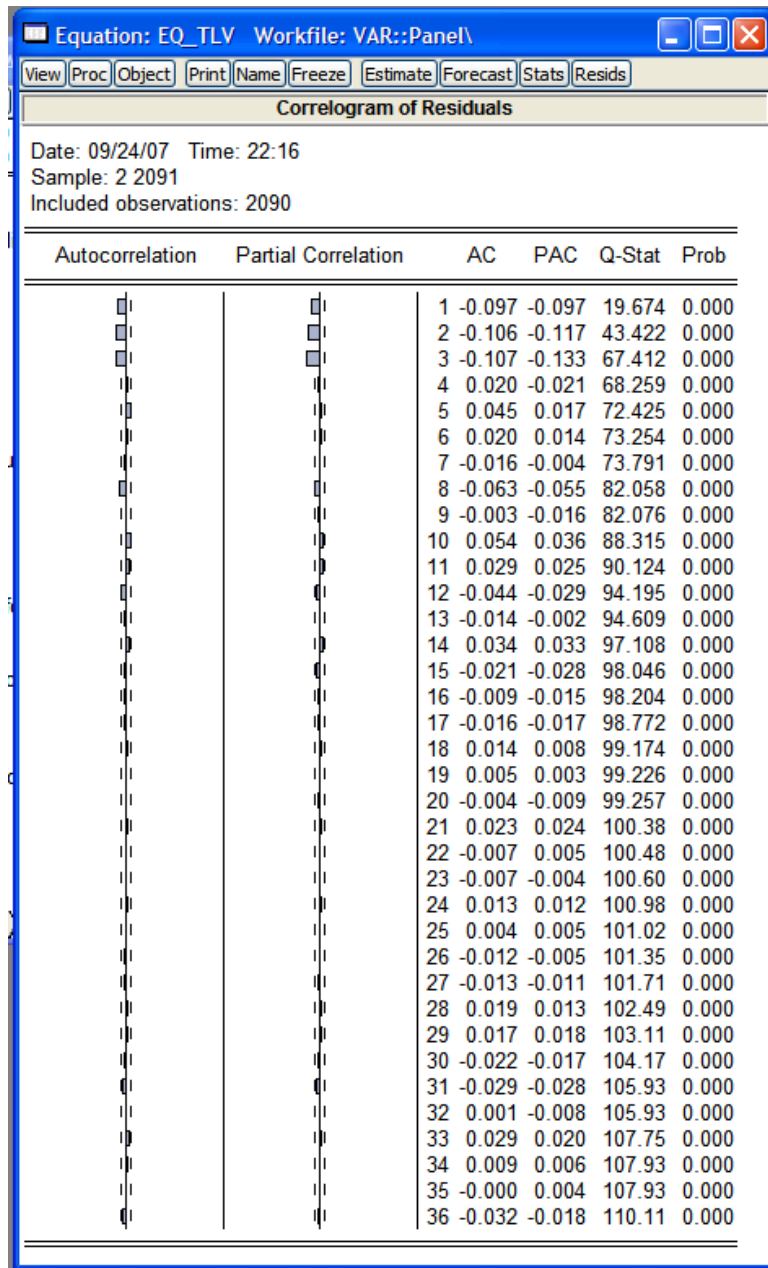
Cu opțiunea *View/Actual, Fitted, Residual/Actual, Fitted, Residual Graph* se reprezintă grafic valoarea efectivă a variabilei dependente, valoarea sa estimată și erorile din regresie.



Cu opțiunea *View/Residual tests* se testează erorile ecuației de regresie.

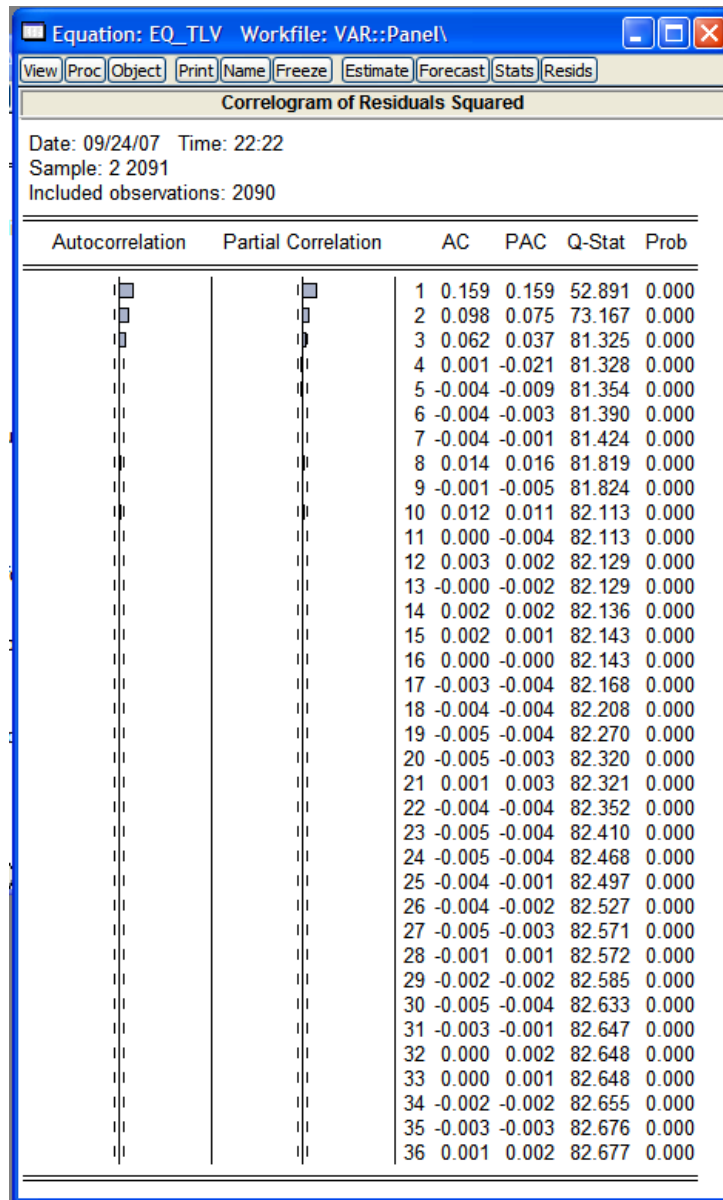


Astfel, cu opțiunea *View/Residual tests/Correlogram - Q-statistics* se testează autocorelația erorilor ecuației de regresie (similar cu testarea autocorelației seriilor de timp).




Conform rezultatelor acestui test, pentru primele 3 lag-uri ale erorilor există corelație serială a erorilor (valoarea coeficientului de autocorelație depășește intervalul punctat în grafic). Existența autocorelației este confirmată și de testul *Q-statistic* și probabilitatea asociată acestuia.

Cu opțiunea *View/Residual tests/Correlogram Squared Residuals* se testează autocorelația erorilor pătratice ale ecuației de regresie după aceleași principii ca și testarea autocorelației erorilor. Dacă există autocorelație ale erorilor pătratic, acest fapt este o indicație a existenței heteroskedasticității (termeni *ARCH*).



Conform rezultatelor econometrice, pentru ecuația estimată anterior, există corelație serială a erorilor pătraticе, deci este posibil să existe termeni ARCH.


Cu opțiunea *View/Residual tests/Histogram – Normality test* se analizează (similar cu analiza distribuției unei serii) distribuția erorilor rezultate din regresie.



Conform rezultatelor testului *Jarque-Bera*, erorile nu sunt distribuite normal. Distribuția normală a erorilor este importată în special când se dorește realizarea de prognoze pe baza ecuației econometrice estimate.

Existența corelației seriale, arătată de corelograma erorilor se confirmă cu ajutorul testului *Serial Correlation LM test*, disponibil cu ajutorul opțiunii *View/Residual tests/Serial Correlation LM Test*.

Alegând 3 lag-uri pentru acest test, rezultatul este prezentat mai jos.



Cea mai importantă parte a output-ului testului este prima parte care prezintă cele două teste statistice *F-Statistic* și *R-squared* și probabilitățile asociate acestor teste.

Ipoteza nulă a celor două teste este că nu există corelație serială a erorilor ecuației de regresie până la *lag*-ul *k* (specificat mai sus). Dacă probabilitatea asociată celor două teste este inferioară nivelului de relevanță la care se lucrează, atunci ipoteza nulă este respinsă, deci se respinge inexistența corelației seriale. În caz contrar ipoteza nulă este acceptată, (nu există corelație serială).

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	29.24197	Prob. F(3,2085)	0.000000
Obs*R-squared	84.38578	Prob. Chi-Square(3)	0.000000

Test Equation:

Dependent Variable: RESID

Method: Least Squares

Date: 09/24/07 Time: 22:31

Sample: 2 2091

Included observations: 2090

Presample missing value lagged residuals set to zero.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-3.51E-05	0.000623	-0.056369	0.9551
DL_BET	0.021783	0.039474	0.551838	0.5811
RESID(-1)	-0.124563	0.021741	-5.729423	0.0000
RESID(-2)	-0.131478	0.021684	-6.063482	0.0000
RESID(-3)	-0.133612	0.021736	-6.146925	0.0000

R-squared	0.040376	Mean dependent var	6.64E-20
Adjusted R-squared	0.038535	S.D. dependent var	0.028905
S.E. of regression	0.028342	Akaike info criterion	-4.286537
Sum squared resid	1.674845	Schwarz criterion	-4.273032
Log likelihood	4484.431	F-statistic	21.93148
Durbin-Watson stat	1.997878	Prob(F-statistic)	0.000000

Conform rezultatelor statistice există corelație serială a erorilor ecuației de regresie până la *lag*-ul 3.

Testul similar (testului *Serial Correlation LM*) pentru testarea corelației seriale a erorilor pătratice este *ARCH LM Test*, disponibil cu ajutorul opțiunii *View/Residual testsARCH LM Test*. Testul funcționează pe aceleași principii ca și testul pentru autocorelația erorilor.

Alegând tot 3 *lag*-uri pentru acest test, conform celor două probabilități asociate, este respinsă ipoteza nulă (inexistența corelației seriale a erorilor pătratice ale ecuației de regresie).

ARCH Test:

F-statistic	22.96701	Prob. F(3,2083)	0.000000
Obs*R-squared	66.82299	Prob. Chi-Square(3)	0.000000

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 09/24/07 Time: 22:44

Sample (adjusted): 5 2091

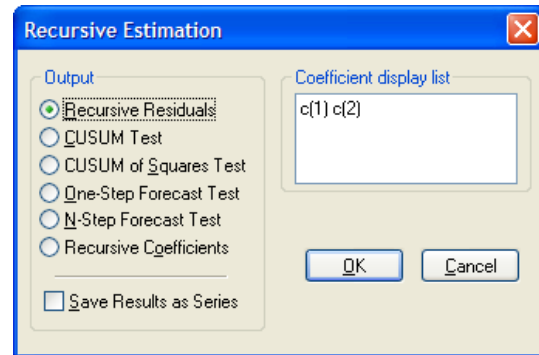
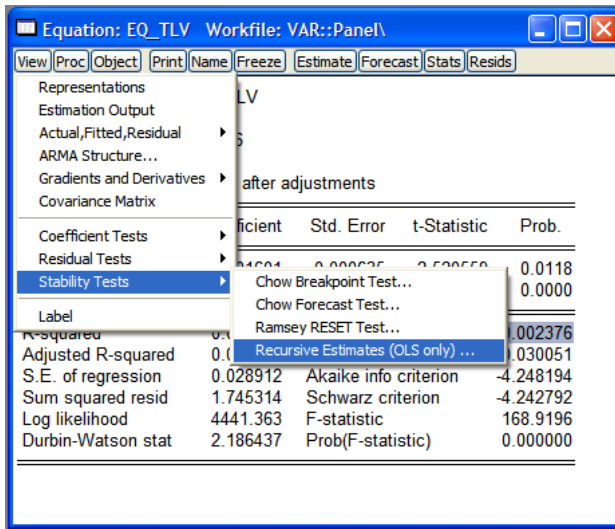
Included observations: 2087 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000618	0.000176	3.522445	0.0004
RESID^2(-1)	0.143865	0.021895	6.570647	0.0000
RESID^2(-2)	0.069810	0.022066	3.163664	0.0016
RESID^2(-3)	0.037151	0.021881	1.697844	0.0897
R-squared	0.032019	Mean dependent var		0.000826
Adjusted R-squared	0.030625	S.D. dependent var		0.008043
S.E. of regression	0.007919	Akaike info criterion		-6.837130
Sum squared resid	0.130634	Schwarz criterion		-6.826314
Log likelihood	7138.545	F-statistic		22.96701
Durbin-Watson stat	1.998429	Prob(F-statistic)		0.000000

Testele de stabilitate ale ecuatiei și coeficienților estimați sunt disponibile cu opțiunea *View/Stability Tests/Recursive Estimates (OLS only)*.

Cele mai utilizate teste de stabilitate sunt:

- *CUSUM Tests*;
- *CUSUM of Squares Tests*;
- *Recursive Coefficients*.



Testul *CUSUM* se bazează pe suma cumulativă a erorilor recursive ale ecuației de regresie.

EViews reprezintă grafic suma cumulativă a erorilor recursive împreună cu liniile critice de 5 la sută. Parametrii ecuației nu sunt considerați stabili dacă suma cumulativă a erorilor recursive iese în afara celor două linii critice.

Erorile recursive sunt calculate după cum urmează: folosind primele $k + 1$ observații, unde k reprezintă numărul de coeficienți ai ecuației de regresie, se estimează coeficienții ecuației, se prognozează variabila dependentă pentru a $k + 2$ -a observație și se calculează eroarea de prognoză (prin compararea valorii variabilei dependente prognozate cu valoarea efectivă a acesteia). Apoi se mai introduce o observație în eșantion (acesta având $k + 2$ observații) și se repetă procedura descrisă anterior.

Suma cumulativă a erorilor recursive este:

$$W_T = \sum_{t=k+1}^T \frac{w_t}{s}, t = k + 1, k + 2, \dots, T,$$

unde:


W_T reprezintă suma cumulativă a erorilor recursive pentru primele T observații;

w_t – eroarea recursivă calculată pe baza primelor t observații din eșantion;

k – numărul de coeficienți ai regresiei;

s – eroarea standard a regresiei.


Pentru ecuația analizată, testul *CUSUM* este prezentat în graficul de mai jos.



Conform rezultatelor statistice, coeficienții ecuației sunt stabili.

Testul *CUSUM of Squares* se calculează și interpretează similar cu testul *CUSUM*, cu deosebirea că în locul erorilor recursive sunt folosite erorile recursive ridicate la pătrat.

Pentru ecuația analizată, conform acestui test, coeficienții ecuației nu sunt stabili.





Recursive Coefficients prezintă coeficienții ecuației de regresie calculați recursiv.

Coeficienții sunt stabili dacă, odată cu mărirea eșantionului, valoarea acestora nu se modifică.

Pentru calculul coeficienților recursivi se pornește cu primele $k + 1$ observații, unde k reprezintă numărul de coeficienți ai ecuației de regresie, se estimează coeficienții ecuației de regresie. Apoi se mărește eșantionul cu următoarea observație și se reestimează coeficienții de regresie. Se procedează similar până se estimează coeficienții pe baza întregului eșantion de date disponibile. Apoi coeficienții recursivi se reprezintă grafic.

Pentru ecuația analizată, coeficienții recursivi sunt reprezentați în graficele de mai jos.



IV.5. Regresii cu serii crossecționale și variabile calitative în EViews

Pentru a analiza impactul variabilelor macroeconomice asupra evoluției spread-ului pentru obligațiunile externe cu scadența de 10 ani¹ emise de țările în curs de dezvoltare, au fost estimate două ecuații de regresie pe un eșantion de 38² de țări în curs de dezvoltare.

Variabila dependentă este evoluția spread-ului obligațiunilor acestor țări în primele 6 luni ale anului 2006 (perioadă care a consemnat două crize valutare – în Islanda și Turcia) și respectiv în primele trei trimestre ale aceluiași an.

Variabilele independente sunt:

- media soldului contului curent, calculat ca pondere în PIB, pentru anii 2004 și 2005 pentru aceste țări, $(CA05+CA04)/2$;
- media soldului bugetului de stat, calculat ca pondere în PIB, pentru anii 2004 și 2005, $(BGBAL05+BGBAL04)/2$;
- variabilă dummy, care ia valoarea 1 în cazul în care datoria externă totală a țării (calculată ca procent în PIB) s-a situat atât în anul 2004 cât și în anul 2005 peste media datoriei externe totale a eșantionului de țări în curs de dezvoltare (DUMMY_DEBT);
- variabilă dummy care ia valoarea 1 dacă țara inclusă în eșantion este din America Latină (DUMMY_LATAM).

Conform rezultatelor statistice, în prima jumătate a anului 2006 (perioadă care a cuprins cele două episoade de criză valutară):

- atât soldul contului curent cât și soldul bugetului de stat și-au pus amprenta asupra evoluției spread-ului obligațiunilor externe în anul 2006 în sensul că un deficit mai mare a condus la o majorare a spread-ului;
- soldul bugetului de stat a avut o importanță mai mare asupra evoluției spread-ului decât soldul contului curent;
- asupra spread-ului și-a pus amprenta și datoria externă totală a țării, în sensul că o valoare a acestei datorii superioară valorii medii a eșantionului în anii 2004 și 2005 a condus la o majorare a spread-ului în perioada analizată;
- țările în curs de dezvoltare din America Latină au înregistrat o majorare a spread-ului în anul 2006 inferioară celorlalte țări în curs de dezvoltare.

Rezultatele econometrice sunt prezentate în tabelul de mai jos.

¹ În cazul în care țara respectivă nu are obligațiuni externe emise cu scadența de 10 ani, în analiză a fost inclus spread-ul pentru obligațiunile externe cu scadența cea mai apropiată de acest termen.

² Africa de Sud, Argentina, Brazilia, Bulgaria, Cehia, Chile, China, Columbia, Coreea de Sud, Croația, Ecuador, Egipt, Estonia, India, Indonezia, Israel, Letonia, Lituania, Malaezia, Maroc, Mexic, Noua Zeelandă, Peru, Philipine, Polonia, România, Rusia, Singapore, Slovacia, Slovenia, Tailanda, Taiwan, Tunisia, Turcia, Ucraina, Ungaria, Uruguay, Venezuela

Dependent Variable: S_30DEC30JUN
 Method: Least Squares
 Sample (adjusted): 1 38
 Included observations: 38 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
(CA05+CA04)/2	-2.055125	0.882112	-2.329777	0.0261
(BGBAL05+BGBAL04)/2	-4.171597	2.120765	-1.967025	0.0576
C	-20.53730	10.84948	-1.892930	0.0672
DUMMY_DEBT	31.00363	13.34970	2.322420	0.0265
DUMMY_LATAM	-51.07850	14.70051	-3.474608	0.0015
R-squared	0.496125	Mean dependent var	-9.815789	
Adjusted R-squared	0.435049	S.D. dependent var	48.65091	
S.E. of regression	36.56759	Akaike info criterion	10.15828	
Sum squared resid	44127.21	Schwarz criterion	10.37375	
Log likelihood	-188.0073	F-statistic	8.123107	
Durbin-Watson stat	2.209404	Prob(F-statistic)	0.000113	

În cazul extinderii perioadei de calcul a evoluției spread-ului la primele trei trimestre ale anului 2006, coeficienții celor două variabile macroeconomice devin ne semnificativi din punct de vedere statistic ceea ce sugerează reducerea aversiunii față de risc a investitorilor, în trimestrul III al anului 2006, către nivelurile anterioare celor două episoade de criză.

Rezultatele econometrice sunt prezentate în tabelul de mai jos.

Conform atât testelor individuale t cât și testului F , coeficienții din ecuația de regresie sunt ne semnificativi din punct de vedere statistic.

Dependent Variable: S_30DEC30SEP
 Method: Least Squares
 Sample (adjusted): 1 38
 Included observations: 38 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
(CA05+CA04)/2	0.158311	1.689682	0.093693	0.9259
(BGBAL05+BGBAL04)/2	-1.485595	4.062315	-0.365702	0.7169
C	-1.132544	20.78213	-0.054496	0.9569
DUMMY_DEBT	7.083560	25.57130	0.277012	0.7835
DUMMY_LATAM	-63.35821	28.15876	-2.250036	0.0312
R-squared	0.161209	Mean dependent var		-10.10526
Adjusted R-squared	0.059537	S.D. dependent var		72.22816
S.E. of regression	70.04505	Akaike info criterion		11.45823
Sum squared resid	161908.2	Schwarz criterion		11.67371
Log likelihood	-212.7064	F-statistic		1.585581
Durbin-Watson stat	1.891845	Prob(F-statistic)		0.201263

Capitolul V. Modele ARMA

Modelele *ARMA* (*autoregressive moving average*) sunt modele univariate – modele prin care variabila dependentă este modelată funcție de propriile observații.

Această clasă de modele cuprinde:

- Modele autoregresive (*AR*);
- Modele cu medii mobile (*MA*);
- Modele *ARMA* – care combină cele două tipuri de procese.

V. 1. Procese AR

O serie staționară, Y_t , urmează un proces $AR(p)$ dacă este îndeplinită condiția:

$$Y_t = \phi_0 + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t,$$

unde $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ serie staționară, $E(\varepsilon_t) = 0$, $E(\varepsilon_t^2) = \sigma^2$, $E(\varepsilon_t \varepsilon_s) = 0$, *daca*, $t \neq s$

În această ecuație, p valori anterioare ale lui Y sunt folosite pentru a prognoza valoarea curentă.

Polinomul caracteristic atașat procesului $AR(p)$ este:

$$P(\lambda) = \phi_0 \lambda^p - \phi_1 \lambda^{p-1} - \phi_2 \lambda^{p-2} - \dots - \phi_p.$$

Procesul $AR(p)$ este staționar dacă valorile absolute ale rădăcinilor polinomului său caracteristic sunt strict mai mici decât 1.

Media procesului $AR(p)$ se obține rezolvând ecuația $Y_t = \phi_0 + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t$, pentru $\varepsilon = 0$

și $Y_t = Y_{t-1} = \dots = Y_{t-p} = Y$. Pentru un proces autoregresiv staționar, media procesului este finită și independentă de timp; procesul se întoarce la medie (este *mean reverting*). În cazul în care procesul este nestaționar, media nu este o valoare finită.

Condițiile suplimentare pentru ca procesul să fie staționar (în covarianță) sunt:

- Variația procesului nu depinde de timp,
- Covarianța nu depinde de timp.

Unul dintre modelele de tip *AR* cele mai folosite în finanțe este modelul *Random Walk*, model pentru care $p = 1$, $\phi_0 = 0$ și $\phi_1 = 1$.

Reprezentarea modelului este: $Y_t = Y_{t-1} + \varepsilon_t$,

unde $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ serie staționară, $E(\varepsilon_t) = 0$, $E(\varepsilon_t^2) = \sigma^2$, $E(\varepsilon_t \varepsilon_s) = 0$, *daca*, $t \neq s$.

Ca urmare, valoarea unei serii într-o anumită perioadă depinde de valoarea seriei în perioada anterioară și de un termen de eroare aleator a cărui valoare așteptată este 0. Astfel, cea mai bună prognoză a valorii seriei este valoarea sa anterioară.

Acest model este foarte utilizat în analiza piețelor financiare și în special a cursului de schimb.

Acest proces este nestaționar (exploziv), și, ca urmare nu are medie.

Cea mai simplă metodă de testare a procesului este testarea termenului $\varepsilon_t = Y_t - Y_{t-1}$ (care reprezintă prima diferență a seriei):

- testarea mediei seriei ε_t : care trebuie să fie zero;
- testarea staționarității seriei ε_t : seria trebuie să fie staționară.

Procesul *random walk* poate să aibă și un trend (*random walk with drift*), în exemplul de mai sus, pentru $\phi_0 \neq 0$. Reprezentarea acestui model este:

$$Y_t = \phi_0 + Y_{t-1} + \varepsilon_t,$$

unde $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$, $E(\varepsilon_t) = 0$, $E(\varepsilon_t^2) = \sigma^2$, $E(\varepsilon_t \varepsilon_s) = 0, \text{daca, } t \neq s$.

V. 2. Procese MA

Deoarece majoritatea seriilor de timp financiare au caracteristicile unor procese autoregresive, modelele AR sunt cele mai utilizate modele de prognoză. Dar, anumite serii urmează alte tipuri de procese, numite procese de medii mobile (MA). De exemplu, conform testelor statistice prezentate în literatura de specialitate, indicele bursier S&P 500 urmează mai degrabă un proces MA decât AR.

Procesul Y_t este urmează un proces medie mobilă de ordinul q , dacă este definit prin egalitatea:

$$Y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q},$$

unde $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ serie staționară, $E(\varepsilon_t) = 0$, $E(\varepsilon_t^2) = \sigma^2$, $E(\varepsilon_t \varepsilon_s) = 0, \text{daca, } t \neq s$.

V. 3. Procese ARMA

Utilizând ambele procese AR și MA, analiza și prognoza seriilor de timp poate fi îmbunătățită. Astfel, prin combinarea celor două procese se obține un model generalizat, autoregresiv medii mobile (ARMA).

Modelul ARMA combină atât lag-urile autoregresive ale variabilei dependente cât și erorile procesului medie mobilă. Ecuația unui asemenea model, cu p termeni autoregresivi și q termeni medie mobilă, notat $ARMA(p, q)$ este:

$$Y_t = \phi_{0+} + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i},$$

unde $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$ serie staționară, $E(\varepsilon_t) = 0$, $E(\varepsilon_t^2) = \sigma^2$, $E(\varepsilon_t \varepsilon_s) = 0$, dacă $t \neq s$.

Estimarea modelelor *ARMA* prezintă limitări severe. În primul rând parametri în modelele *ARMA* pot fi foarte instabili, modificări mici ale eșantionului utilizat putând conduce la parametri foarte diferiți de la o estimare la alta. În al doilea rând, alegerea modelului *ARMA* cel mai potrivit depinde mai mult de experiență decât de indicatori statistici. În plus, un model odată selectat, poate să nu prognozeze foarte bine.


Procedura de estimare a unui model *ARMA* cuprinde următorii pași:

1. Testarea staționarității seriei. Dacă este staționară se trece la pasul trei, dacă nu se parcurg cerințele pasului următor.
2. Se staționarizează seria de date prin diferențiere. Marea majoritate a seriilor nestaționare sunt integrate de ordinul 1, $I(1)$, așa că seria se staționarizează prin prima diferență.
3. Pe baza coeficienților de autocorelație (funcției de autocorelație) și a coeficienților de corelație parțială (funcției de autocorelație parțială) se determină modelele autoregresive de start pentru analiza seriei de date. Astfel, dacă există o valoare a lui h egală cu q începând de la care valoarea funcției de autocorelație scade brusc către zero, atunci pentru prelucrarea seriei se folosește un proces $MA(q)$ sau un proces *ARMA* ce cuprinde o componentă $MA(q)$. În cazul în care valoarea funcției de autocorelație parțială scade instantaneu către zero, începând cu o valoare a decalajului egală cu p , atunci se recomandă ca seria de timp să fie prelucrată prin intermediul unui proces $AR(p)$ pur sau printr-un proces ce cuprinde și această componentă.
4. Se estimează parametrii modelelor *ARMA*.
5. Se testează caracteristicilor modelelor autoregresive ce au fost estimate în etapa anterioară. Astfel se verifică dacă coeficienții modelului sunt semnificativi (diferiți de zero) din punct de vedere statistic, autocorelarea reziduurilor regresiei, proprietatea de homoscedasticitate, stabilitatea parametrilor și caracteristicile distribuției reziduurilor.
6. Se alege cel mai potrivit model folosind diverse criterii de analiză. Astfel, se alege modelul care are valoarea cea mai mare pentru R^2 ajustat sau valoarea cea mai mică pentru varianța sau dispersia reziduurilor. De asemenea se alege modelul care are valorile cele mai mici pentru criteriile informaționale (Akaike, Schwartz).
7. Pe baza modelului selectat se fac diverse analize și prognoze.

V. 4. Estimarea modelelor ARMA în EViews

Utilizând seria de date cu frecvență lunară a BUBOR 1W pentru perioada ianuarie 1997 – august 2007 au fost estimate trei modele AR, MA și ARMA care să descrie evoluția ratei lunare a dobânzii BUBOR 1W.

Graficul seriei utilizate este:



Conform testelor de staționaritate *ADF* și *PP* seria este staționară.

Testul de staționaritate *ADF*

Null Hypothesis: BUBOR has a unit root

Exogenous: Constant, Linear Trend

Lag Length: 0 (Automatic based on SIC, MAXLAG=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.024900	0.0003
Test critical values: 1% level	-4.031899	
5% level	-3.445590	
10% level	-3.147710	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(BUBOR)

Method: Least Squares
Sample (adjusted): 1997M02 2007M08
Included observations: 127 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
BUBOR(-1)	-0.328208	0.065316	-5.024900	0.0000
C	33.57762	7.478112	4.490120	0.0000
@TREND(1997M01)	-0.303782	0.074919	-4.054833	0.0001
R-squared	0.169420	Mean dependent var	-0.383937	
Adjusted R-squared	0.156024	S.D. dependent var	21.04233	
S.E. of regression	19.33121	Akaike info criterion	8.784657	
Sum squared resid	46338.27	Schwarz criterion	8.851843	
Log likelihood	-554.8257	F-statistic	12.64663	
Durbin-Watson stat	1.581948	Prob(F-statistic)	0.000010	

Testul de staționaritate *PP*

Null Hypothesis: BUBOR has a unit root
Exogenous: Constant, Linear Trend
Bandwidth: 3 (Newey-West using Bartlett kernel)

	Adj. t-Stat	Prob.*
Phillips-Perron test statistic	-5.437216	0.0001
Test critical values: 1% level	-4.031899	
5% level	-3.445590	
10% level	-3.147710	

*MacKinnon (1996) one-sided p-values.


Residual variance (no correction)	364.8682
HAC corrected variance (Bartlett kernel)	462.5140

Phillips-Perron Test Equation
Dependent Variable: D(BUBOR)
Method: Least Squares
Sample (adjusted): 1997M02 2007M08
Included observations: 127 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
BUBOR(-1)	-0.328208	0.065316	-5.024900	0.0000

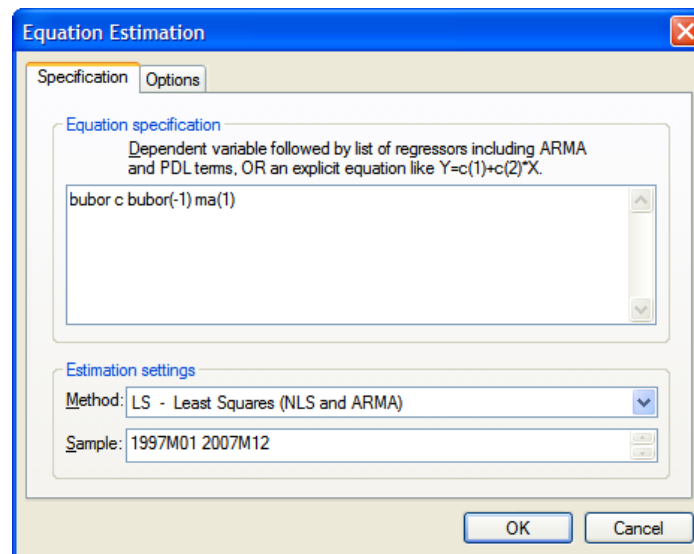
C	33.57762	7.478112	4.490120	0.0000
@TREND(1997M01)	-0.303782	0.074919	-4.054833	0.0001
R-squared	0.169420	Mean dependent var	-0.383937	
Adjusted R-squared	0.156024	S.D. dependent var	21.04233	
S.E. of regression	19.33121	Akaike info criterion	8.784657	
Sum squared resid	46338.27	Schwarz criterion	8.851843	
Log likelihood	-554.8257	F-statistic	12.64663	
Durbin-Watson stat	1.581948	Prob(F-statistic)	0.000010	

Funcția de autocorelație a acestei serii este prezentată în graficul de mai jos.



Atât funcția de autocorelație (care pornește de la o valoare ridicată și scade gradual) cât și funcția de autocorelație parțială (care scade brusc) indică că această serie este preponderent un proces *AR*.

Pentru specificarea ecuației, se procedează similar ca în cazul estimării unei ecuații de regresie liniară: click buton dreapta mouse în interiorul ferestrei fișierului de lucru (*workfile*)/*new object/equation*:



Variabilele *AR* se specifică ca lag-uri ale variabilei dependente (în exemplul de mai sus, *bubor(-1)*), iar variabilele *MA*, se specifică *MA(x)* unde *x* reprezintă ordinul.

În selectarea specificației *ARMA* se ține cont de autocorelația erorilor ecuației de regresie (să nu existe autocorelație), autocorelația erorilor pătratice (să nu existe termeni *ARCH*), R^2 și \bar{R}^2 , criteriile informaționale.

De asemenea, în cazul modelelor care conțin termeni *AR*, valoarea absolută a unui coeficient *AR* trebuie să fie mai mică decât 1 (dacă este egală atunci există o rădăcină unitară, iar dacă este mai mare decât 1 atunci procesul este exploziv). De asemenea suma coeficienților termenilor *AR* trebuie să fie mai mică decât 1 (în caz contrar procesul fiind exploziv).

În plus, pentru ca ecuația să fie stabilă, valoarea absolută a rădăcinilor ecuației trebuie să fie mai mici decât 1.

Estimarea modelului MA

Specificația modelului este MA(4).

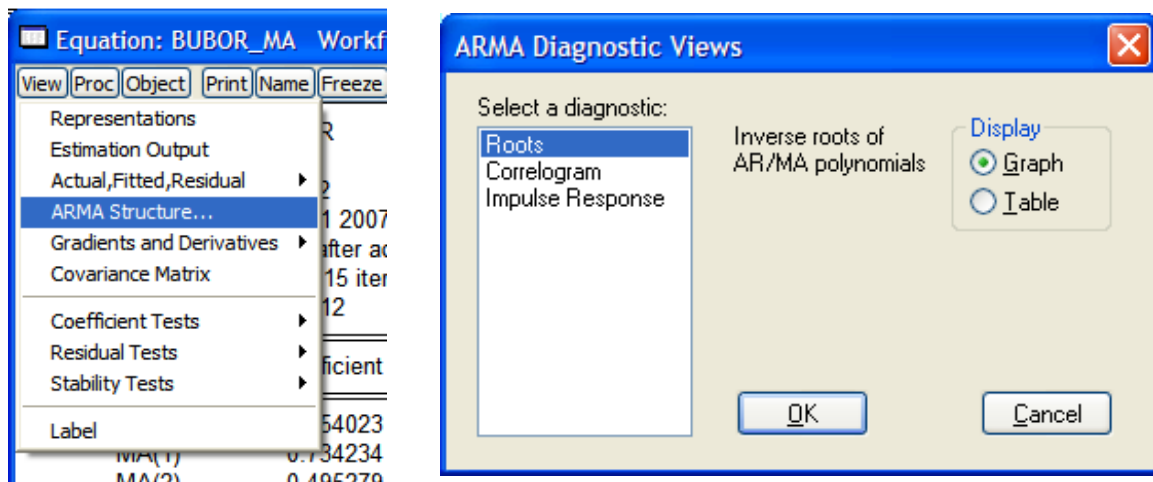
Dependent Variable: BUBOR
 Method: Least Squares
 Sample (adjusted): 1997M01 2007M08
 Included observations: 128 after adjustments
 Convergence achieved after 15 iterations
 Backcast: 1996M09 1996M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	41.54023	5.901126	7.039374	0.0000
MA(1)	0.734234	0.051566	14.23862	0.0000
MA(2)	0.495279	0.026993	18.34853	0.0000
MA(3)	0.863535	0.025672	33.63763	0.0000
MA(4)	0.804961	0.050194	16.03709	0.0000


R-squared	0.838087	Mean dependent var	43.94414
Adjusted R-squared	0.832822	S.D. dependent var	42.18206
S.E. of regression	17.24715	Akaike info criterion	8.571450
Sum squared resid	36588.11	Schwarz criterion	8.682858
Log likelihood	-543.5728	F-statistic	159.1672
Durbin-Watson stat	1.582016	Prob(F-statistic)	0.000000

Inverted MA Roots	.42-.90i	.42+.90i	-.78+.45i	-.78-.45i
-------------------	----------	----------	-----------	-----------

Analiza rădăcinilor ecuației se realizează cu opțiunea *View/ARMA Structure/Roots*:



Rădăcinile polinomului caracteristic pot fi reprezentate atât ca tabel cât și grafic.



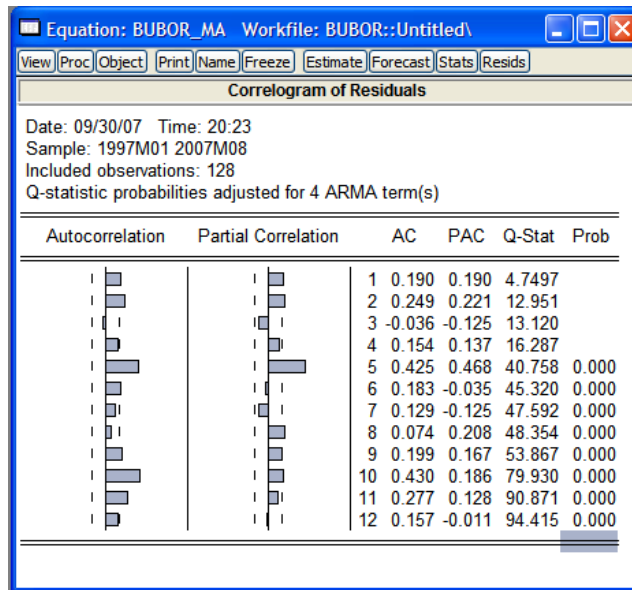
Inverse Roots of AR/MA Polynomial(s)
 Specification: BUBOR C MA(1) MA(2) MA(3) MA(4)
 Sample: 1997M01 2007M12
 Included observations: 128

MA Root(s)	Modulus	Cycle
$0.416806 \pm 0.900818i$	0.992572	5.524002
$-0.783923 \pm 0.450021i$	0.903910	2.397739


No root lies outside the unit circle.
 ARMA model is invertible.

Conform rezultatelor statistice, modulul rădăcinilor polinomului caracteristic este mai mic decât 1, și ca urmare ecuația este stabilă.

Dar, conform corelogramei erorilor, prezentată în graficul de mai jos, există autocorelație serială la al 5-lea lag.



Valoarea efectivă și cea estimată de model a BUBID 1W este prezentată în graficul de mai jos.



Estimarea modelului AR

Specificația modelului este AR(1)

Dependent Variable: BUBOR

Method: Least Squares

Sample (adjusted): 1997M02 2007M08

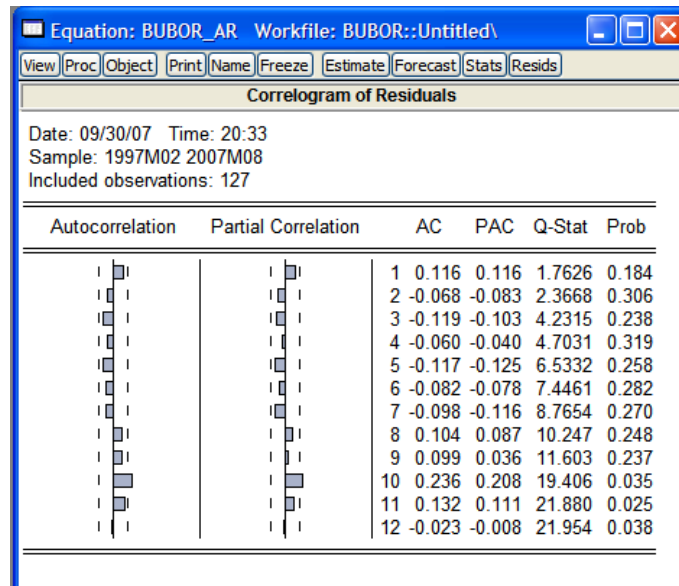
Included observations: 127 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.985180	2.639138	1.888943	0.0612
BUBOR(-1)	0.878633	0.043240	20.32007	0.0000


R-squared	0.767617	Mean dependent var	43.85480
Adjusted R-squared	0.765758	S.D. dependent var	42.33696
S.E. of regression	20.49047	Akaike info criterion	8.893420
Sum squared resid	52482.45	Schwarz criterion	8.938210
Log likelihood	-562.7322	F-statistic	412.9052
Durbin-Watson stat	1.709848	Prob(F-statistic)	0.000000

Coeficientul termenului AR este mai mic decât 1, deci ecuația este stabilă.

De asemenea, conform corelogramei erorilor, nu există corelație serială a erorilor.



Valorile efective și cele estimate ale variabilei dependente sunt prezentate în graficul de mai jos.



Estimarea modelului *ARMA*

Specificația modelului este *ARMA(1, 10)*

Dependent Variable: BUBOR

Method: Least Squares

Sample (adjusted): 1997M02 2007M08


Included observations: 127 after adjustments

Convergence achieved after 21 iterations

Backcast: 1996M04 1997M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
BUBOR(-1)	0.974210	0.017718	54.98466	0.0000
MA(5)	-0.243541	0.056540	-4.307386	0.0000
MA(6)	-0.226437	0.055472	-4.081987	0.0001
MA(7)	-0.332302	0.055472	-5.990446	0.0000
MA(10)	0.476373	0.060775	7.838351	0.0000
R-squared	0.867500	Mean dependent var		43.85480
Adjusted R-squared	0.863156	S.D. dependent var		42.33696
S.E. of regression	15.66150	Akaike info criterion		8.378862
Sum squared resid	29924.46	Schwarz criterion		8.490837
Log likelihood	-527.0577	Durbin-Watson stat		2.297258
Inverted MA Roots	.88+.16i	.88-.16i	.56+.83i	.56-.83i
	-.02-.90i	-.02+.90i	-.53+.73i	-.53-.73i
	-.89+.33i	-.89-.33i		

Conform rezultatelor statistice, modulul rădăcinilor polinomului caracteristic este mai mic decât 1, și ca urmare ecuația este stabilă.

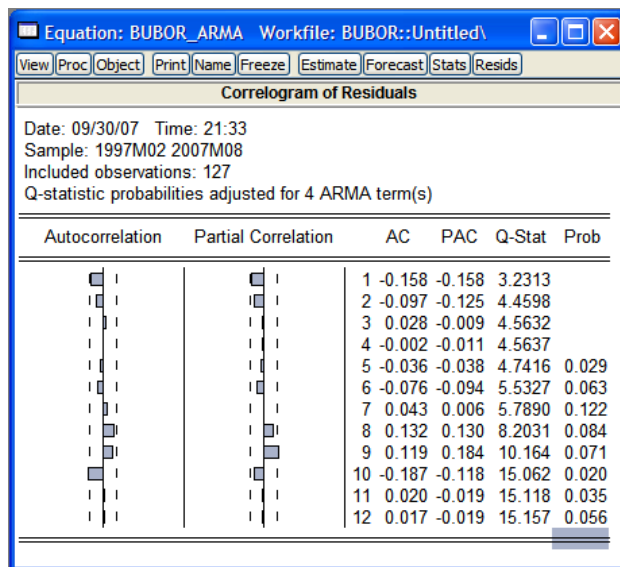


Inverse Roots of AR/MA Polynomial(s)
 Specification: BUBOR BUBOR(-1) MA(5) MA(6)
 MA(7) MA(10)
 Sample: 1997M01 2007M12
 Included observations: 127


MA Root(s)	Modulus	Cycle
$0.558806 \pm 0.826275i$	0.997494	6.436651
$-0.890402 \pm 0.332511i$	0.950463	2.256737
$-0.528267 \pm 0.734115i$	0.904428	2.863081
$-0.022438 \pm 0.897521i$	0.897802	3.937348
$0.882301 \pm 0.159193i$	0.896548	35.19821

No root lies outside the unit circle.
 ARMA model is invertible.

De asemenea, conform corelogramei erorilor, nu există corelație serială la 1 la sută nivel de relevanță.



Valorile efective și cele estimate ale variabilei dependente sunt prezentate în graficul de mai jos.



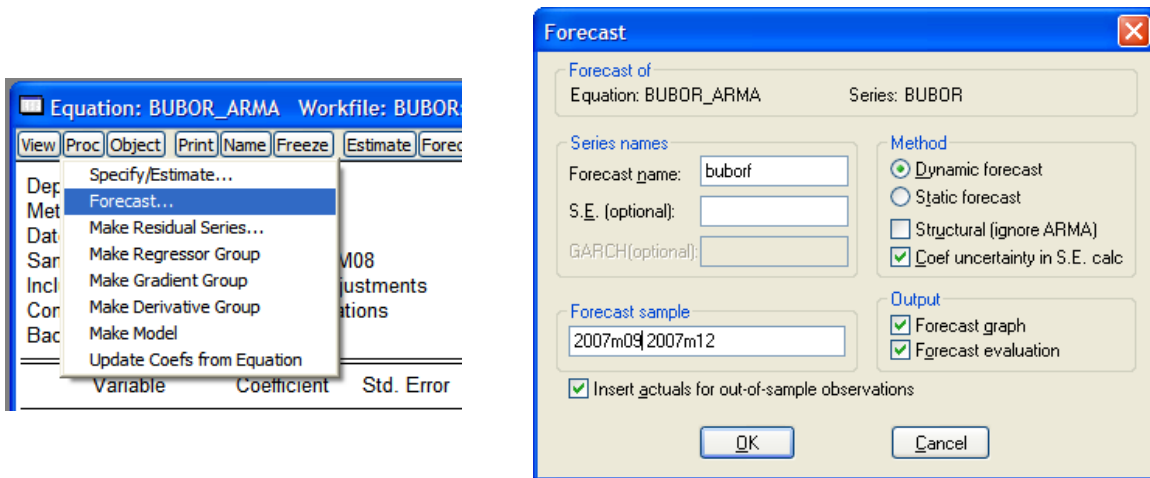
Indicatorii statistici pentru cele trei specificații de modele sunt prezentați în tabelul de mai jos.

	MA(4)	AR(1)	ARMA(1,10)
<i>Adjusted R-squared</i>	0.832822	0.765758	0.863156
<i>Akaike info criterion</i>	8.571450	8.893420	8.378862
<i>Schwarz criterion</i>	8.682858	8.938210	8.490837

Conform tuturor celor trei criterii (cea mai mare valoare a \bar{R}^2 și, respectiv, cele mai mici valori înregistrate de criteriile informaționale), este aleasă specificația $ARMA(1, 10)$.

Pe baza acestei specificații se va prognoza dobânda BUBOR 1W pentru lunile septembrie – decembrie 2007.


Opțiunea pentru realizarea de prognoze este *Proc/Forecast* apelată din fereastra ecuației de regresie.



Opțiunile disponibile din fereastra *Forecast* sunt:

- *Forecast sample* – perioada pentru care se realizează prognoza. În cazul de față este septembrie 2007 – decembrie 2007.
- *Method*:
 - *Dynamic forecast* – prognozează valoarea în perioada $t + 1$ pe baza datelor efective până în momentul t , apoi pentru toate perioadele următoare folosește datele deja prognozate începând din momentul $t + 1$.
 - *Static forecast* – prognozează o observație înainte numai pe baza datelor efective.

Utilizând o prognoză dinamică, valorile prognozate și marjele de eroare (simbolizate cu linii roșii întrerupte) sunt prezentate în graficul de mai jos.



Capitolul VI. Modele cu date panel

VI. 1. Utilizarea modelelor cu date panel

Modelele cu date panel constau în estimarea de ecuații de regresie în care sunt folosite serii care sunt în același timp atât serii de timp cât și date crosssecționale.

De exemplu, dacă dispunem de serii de timp pentru evoluția pe o anumită perioadă a acțiunilor mai multor companii și dorim să determinăm cum influențează anumite variabile macroeconomice randamentul acelor acțiuni, o soluție este utilizarea de modele cu date panel. Astfel, cu ajutorul acestui tip de modele poate fi determinat un singur coeficient care să exprime impactul unei variabile macroeconomice asupra randamentului unui grup de companii.

Modelele cu date panel permit:

- Rezumarea printr-un singur coeficient al impactului unei variabile asupra unui grup de serii de timp variabile dependente (grup de companii, de țări, etc.).
- Estimarea de coeficienți specifici (constantă sau coeficienți ai variabilelor independente) pentru fiecare serie de timp considerată ca variabilă dependentă – efecte fixe.
- Gruparea variabilelor dependente în categorii și estimarea impactului categoriei din care face parte variabila dependentă asupra evoluției acesteia.

VI. 2. Estimarea modelelor cu date panel în EViews

În vederea studierii impactului așteptărilor pieței bancare asupra spread-ului practicat de către bănci, au fost estimate, utilizând metodologia *panel data*, ecuații pentru spread-urile active și pasive pentru persoane fizice și juridice funcție de așteptările operatorilor bancari referitoare la evoluția viitoare a ratei inflației și dobânzilor din piața monetară. Spread-ul activ a fost calculat ca diferență dintre dobânzile active pentru clienții nebankari neguvernamentali și rata dobânzii de intervenție a BNR, iar spread-ul pasiv a fost calculat ca diferență dintre dobânda de intervenție a BNR și ratele dobânzii pasive pentru clienții nebankari neguvernamentali. Ca urmare, spread-ul total este suma dintre cele două măsuri.

Eșantionul pe care s-au estimat regresiile a fost format din 13 bănci.

Perioada pe care s-a realizat analiza este ianuarie 2005 – iulie 2005, rezultând un număr de 84 de observații.

Date utilizate:

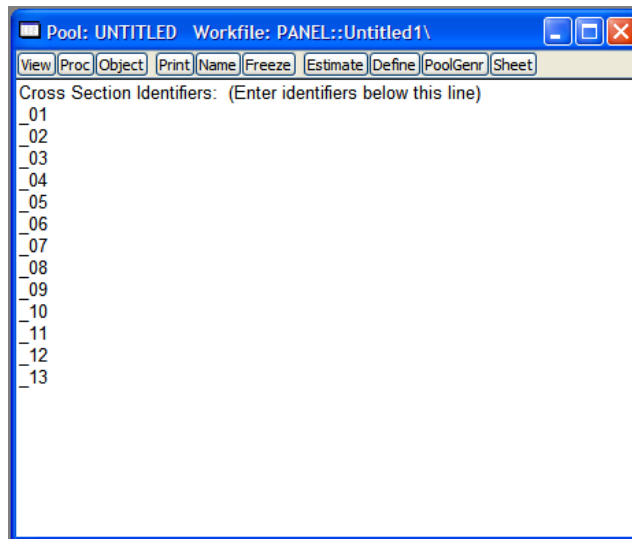
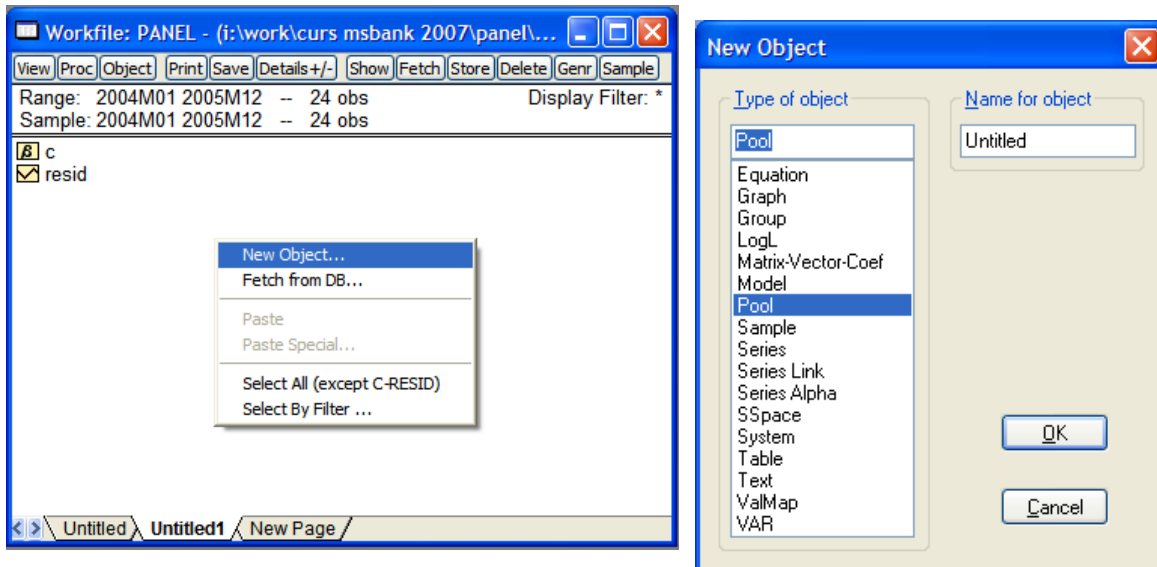
- Rata dobânzii active practicate pentru persoane fizice (ACT_PF);
- Rata dobânzii active practicate pentru persoane juridice, clienți nebancari, neguvernamentali (ACT_PJ);
- Rata dobânzii pasive practicate pentru persoane fizice (PAS_PF);
- Rata dobânzii pasive practicate pentru persoane juridice, clienți nebancari neguvernamentali (PAS_PJ);
- Rata dobânzii la operațiunile de sterilizare ale BNR (RN_BNR);
- Rata dobânzii bonificate de BNR pentru rezervele minime obligatorii în lei (DOB_RMO);
- Rata anuală a inflației așteptată de operatorii bancari peste 24 de luni (A_INFL_24);
- Deviația standard a răspunsurilor participanților la sondaj cu privire la rata anuală a inflației așteptate peste 12 luni (A_INFL_12_DEV), utilizată ca variabilă proxy pentru incertitudinea din piața bancară cu privire la evoluția inflației din următoarele 12 luni;
- Rata dobânzii pentru depozitele pe piața monetară cu scadența de o săptămână așteptate de operatorii din sistemul bancar pentru un orizont de 12 luni (RN_1W_12).

Conform rezultatelor econometrice, spread-ul activ, atât pentru persoane fizice cât și pentru persoane juridice, este influențat de așteptările privind rata inflației pe următoarele 24 de luni și de volatilitatea dobânzii de intervenție a BNR (aproximată prin valoarea absolută a modificărilor lunare ale acesteia).

Astfel, atât o majorare a anticipațiilor inflaționiste cât și o creștere a volatilității ratei dobânzii de intervenție conduc la majorarea spread-ului activ.

Cum era de așteptat, rata de dobândă bonificată de BNR pentru depozitele minime obligatorii este corelată negativ cu spread-ul, în sensul că o majorare a acesteia conduce la reducerea spread-ului (datorită reducerii costului fondurilor atrase).

Definirea modelului panel re realizează cu click buton dreapta mouse selectarea opțiunii New object/Pool

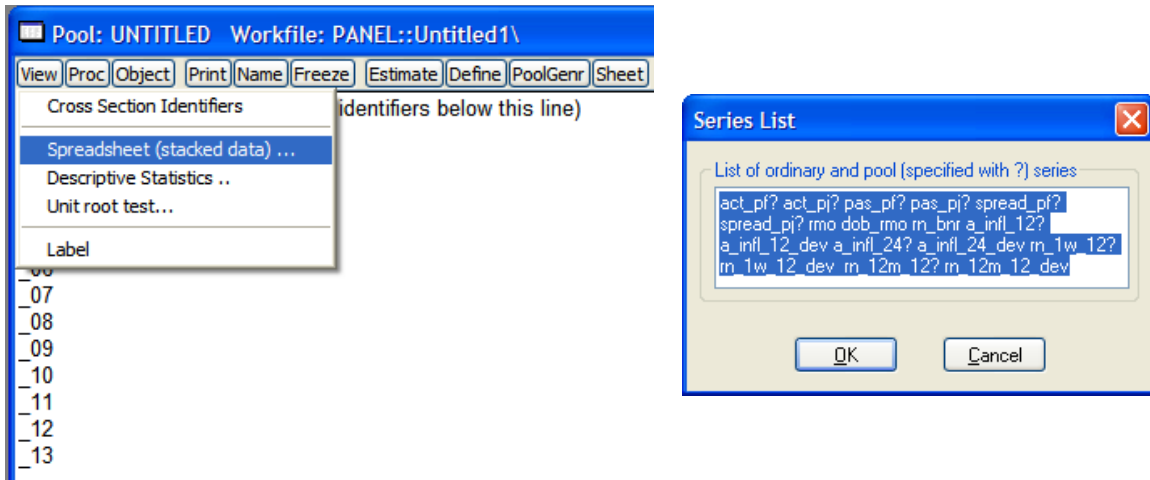


În fereastra Cross Section Identifiers se introduc datele de identificare a seriilor de date crossecționale. În cazul de față $_x$, unde x reprezintă banca. Astfel, fiecare serie de date care se referă la banca x , va avea terminația $_x$.

Cu opțiunea View/Spreadsheet (stacked data) se definesc seriile specifice fiecărei bănci și seriile comune tuturor băncilor. Seriile se separă cu spațiu.

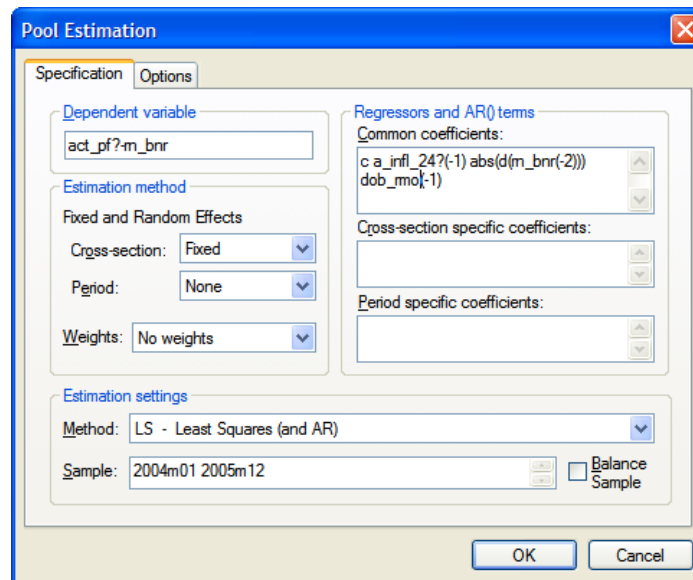
Dacă seriile sunt comune tuturor băncilor (de exemplu rata de sterilizare a BNR, rn_bnr) seriile se definesc tipărindu-se numele lor.

Dacă, în schimb este o serie specifică fiecărei bănci (cum este cazul, de exemplu, așteptărilor privind rata inflației pentru următoarele 24 de luni, a_infl_24), seria se definește tipărind numele acesteia și ? ($a_infl_24?$). În acest fel se generează câte o serie a_infl_24 pentru fiecare banca, serie având terminația $_01$ până la $_13$.



Apoi seriile (atât cele comune cât și cele pentru fiecare bancă) se introduc în tabel co *copy și paste*.

Ecuția de regresie se estimează cu opțiunea *Estimate* apelată din fereastra modelului panel.



Opțiunile disponibile sunt:

- *Dependent variable* – variabila dependentă. Dacă seriile sunt specifice fiecărei bănci se folosește caracterul ?.
- *Regressors and AR() terms*:
 - *Common coefficients* – variabilele independente comune. De asemenea, dacă seriile sunt specifice fiecărei bănci se folosește caracterul ?.
 - *Cross-section specific coefficients* – variabile specifice fiecărei bănci. În acest caz se va estima câte un coeficient pentru fiecare bancă.
- *Estimation method*:

- *Fixed and Random Effects* – dacă se introduc efecte fixe sau efecte aleatoare.
- *Weights* – se alege metoda de estimare, metodă care poate să țină cont de autocorelația erorilor și de heteroskedasticitate.

Estimările econometrice sunt prezentate în tabelele de mai jos.

Persoane fizice

Dependent Variable: ACT_PF?-RN_BNR

Method: Pooled Least Squares

Sample (adjusted): 2005M01 2005M07

Included observations: 7 after adjustments

Cross-sections included: 13

Total pool (unbalanced) observations: 84

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	6.765733	4.985221	1.357158	0.1792
A_INFL_24?(-1)	1.656481	0.914590	1.811172	0.0745
ABS(D(RN_BNR(-2)))	0.479254	0.160356	2.988678	0.0039
DOB_RMO(-1)	-0.815756	0.218100	-3.740277	0.0004
Fixed Effects (Cross)				
_01--C	3.516078			
_02--C	0.905852			
_03--C	-4.735097			
_04--C	0.278803			
_05--C	2.714437			
_06--C	-4.188903			
_07--C	-4.893096			
_08--C	-1.829393			
_09--C	-0.853592			
_10--C	4.154242			
_11--C	0.885616			
_12--C	3.170805			
_13--C	4.375301			

Effects Specification

Cross-section fixed (dummy variables)

R-squared	0.734933	Mean dependent var	14.42240
Adjusted R-squared	0.676462	S.D. dependent var	3.906075
S.E. of regression	2.221790	Akaike info criterion	4.604147
Sum squared resid	335.6718	Schwarz criterion	5.067159
Log likelihood	-177.3742	F-statistic	12.56926
Durbin-Watson stat	1.527998	Prob(F-statistic)	0.000000

Persoane juridice

Dependent Variable: ACT_PJ?-RN_BNR
 Method: Pooled Least Squares
 Sample (adjusted): 2005M01 2005M07
 Included observations: 7 after adjustments
 Cross-sections included: 13
 Total pool (unbalanced) observations: 84

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.913003	3.831831	0.238268	0.8124
A_INFL_24?(-1)	1.448644	0.702989	2.060692	0.0432
ABS(D(RN_BNR(-2)))	0.454094	0.123256	3.684154	0.0005
DOB_RMO(-1)	-0.355659	0.167640	-2.121559	0.0375
Fixed Effects (Cross)				
_01--C	-5.443339			
_02--C	2.078863			
_03--C	-1.012100			
_04--C	-0.762182			
_05--C	2.232951			
_06--C	-5.844925			
_07--C	1.399169			
_08--C	3.272944			
_09--C	1.465961			
_10--C	-0.405522			
_11--C	-1.299828			
_12--C	1.946907			
_13--C	4.696545			

Effects Specification

Cross-section fixed (dummy variables)

R-squared	0.762877	Mean dependent var	8.847317
Adjusted R-squared	0.710571	S.D. dependent var	3.174343
S.E. of regression	1.707752	Akaike info criterion	4.077877
Sum squared resid	198.3165	Schwarz criterion	4.540889
Log likelihood	-155.2708	F-statistic	14.58477
Durbin-Watson stat	1.666125	Prob(F-statistic)	0.000000

În cazul spread-ului pasiv, conform rezultatelor econometrice, atât pentru persoanele fizice cât și pentru cele juridice, asupra acestuia își pun amprenta așteptările în privința evoluțiilor în următoarele 12 luni a ratelor dobânzii cu scadența de o săptămână, evoluția ratei dobânzii de sterilizare a BNR și incertitudinea în privința ratei inflației așteptate în următoarele 12 luni.

Astfel, anticiparea unei creșteri a ratei dobânzii pe piața monetară conduce la majorarea spread-ului. O explicație a acestui rezultat ar fi faptul că, în general, durata activelor este superioară duratei pasivelor (riscul de modificare a ratei dobânzii în sensul creșterii are un impact negativ ce nu este compensat în totalitate de impactul pozitiv asupra pasivelor), și ca urmare modificarea ratei dobânzii are efecte asimetrice asupra profitabilității. Astfel, creșterea dobânzii ar trebui să conducă la majorarea spread-ului. Aceasta este explicația și în cazul celeilalte variabile explicative – evoluția ratei dobânzii la operațiunile de sterilizare.

De asemenea, o majorare a incertitudinii cu privire la rata inflației conduce la creșterea spread-ului.

Rezultatele estimărilor econometrice sunt prezentate în tabelele de mai jos.

Persoane fizice

Dependent Variable: RN_BNR-PAS_PF?

Method: Pooled Least Squares

Sample (adjusted): 2005M01 2005M07

Included observations: 7 after adjustments

Cross-sections included: 13

Total pool (unbalanced) observations: 84

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.337440	1.035142	-1.292036	0.2007
RN_1W_12?(-1)	0.141256	0.049085	2.877769	0.0053
A_INFL_12_DEV(-1)	3.914145	2.020029	1.937667	0.0568
D(RN_BNR(-1))	0.850040	0.102701	8.276861	0.0000
Fixed Effects (Cross)				
_01--C	3.131380			
_02--C	2.789540			
_03--C	-1.556827			
_04--C	0.639623			
_05--C	1.432939			
_06--C	2.100246			
_07--C	-0.007815			
_08--C	0.166481			
_09--C	-1.142894			
_10--C	-2.221507			

_11--C	-3.607794
_12--C	-1.586480
_13--C	-2.490128

Effects Specification

Cross-section fixed (dummy variables)

R-squared	0.875738	Mean dependent var	1.062269
Adjusted R-squared	0.848327	S.D. dependent var	2.527695
S.E. of regression	0.984416	Akaike info criterion	2.976106
Sum squared resid	65.89703	Schwarz criterion	3.439119
Log likelihood	-108.9965	F-statistic	31.94872
Durbin-Watson stat	1.812217	Prob(F-statistic)	0.000000

Persoane juridice

Dependent Variable: RN_BNR-PAS_PJ?

Method: Pooled Least Squares

Sample (adjusted): 2005M01 2005M07

Included observations: 7 after adjustments

Cross-sections included: 13

Total pool (unbalanced) observations: 84

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-3.231045	0.898741	-3.595079	0.0006
RN_1W_12?(-1)	0.441803	0.042617	10.36672	0.0000
A_INFL_12_DEV(-1)	7.083072	1.753850	4.038586	0.0001
D(RN_BNR(-1))	0.943739	0.089168	10.58385	0.0000
Fixed Effects (Cross)				
_01--C	-0.256768			
_02--C	1.184713			
_03--C	-1.211410			
_04--C	0.113818			
_05--C	1.972395			
_06--C	-1.387390			
_07--C	2.614700			
_08--C	-0.363632			
_09--C	-0.560105			
_10--C	-0.916297			
_11--C	-0.282755			
_12--C	-1.574537			
_13--C	0.080688			

Effects Specification

Cross-section fixed (dummy variables)

R-squared	0.844103	Mean dependent var	3.770087
Adjusted R-squared	0.809714	S.D. dependent var	1.959340
S.E. of regression	0.854699	Akaike info criterion	2.693508
Sum squared resid	49.67468	Schwarz criterion	3.156521
Log likelihood	-97.12734	F-statistic	24.54573
Durbin-Watson stat	1.970847	Prob(F-statistic)	0.000000

În concluzie, conform estimărilor econometrice, asupra spread-ului dintre dobânzile active și pasive își pun amprenta:

- Atât anticipațiile inflaționiste cât și gradul lor de incertitudine;
- Anticipațiile cu privire evoluția ratei dobânzii pe piața monetară;
- Atât evoluția ratei dobânzii la operațiunile BNR, cât și nivelul volatilității acestei rate a dobânzii.

Capitolul VII. Modelele GARCH

VII.1. Tipuri de modele ARCH

Modelele ARCH au fost introduse de Engle (1982) și generalizate (GARCH) de Bollerslev (1986).

În construirea unui model ARCH trebuie luate în considerare două ecuații distincte: una pentru media condiționată (ecuația de evoluție a randamentelor activului) și una pentru varianța condiționată (ecuația volatilității).

Modelul GARCH (p, q), propus de Bollerslev (1986), are următoarea specificație:

$$r_t = \beta_0 + \sum_{i=1}^m \beta_{1,i} L^i r_t + \sum_{j=1}^n \beta_{2,j} L^j \varepsilon_t + \varepsilon_t$$

$$\varepsilon_t \approx N(0, h_t)$$

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_{1,i} L^i h_t + \sum_{j=1}^q \alpha_{2,j} L^j \varepsilon_t^2$$

unde:

r_t este un proces ARMA(m, n) sau un model Random Walk (atunci când $\beta_{1,i} = 0, i = \overline{1, m}$, și $\beta_{2,j} = 0, j = \overline{1, n}$);

h_t (volatilitatea) este un proces ARCH(q) și GARCH(p);

parametrii α_1 reprezintă persistența volatilității;

parametrii α_2 reprezintă viteza de reacție a volatilității la șocurile din piață.

Pentru a nu fi un proces exploziv (volatilitate explozivă), trebuie îndeplinită condiția

$$\sum_{i=1}^p \alpha_{1,i} + \sum_{j=1}^q \alpha_{2,i} < 1$$

În plus, coeficienții termenilor ARCH și GARCH trebuie să fie subunitari și pozitivi.

Interpretat într-un context financiar, acest model descrie modul în care un agent încearcă să prognozeze volatilitatea pentru următoarea perioadă pe baza mediei pe termen lung (α_0) a varianței, a varianței anterioare (termenul GARCH) și a informațiilor privind volatilitatea observată în perioada anterioară (termenul ARCH). Dacă randamentul activului din perioada anterioară a fost, în mod neașteptat, mare în valoare absolută, agentul va mări varianța așteptată în perioada următoare.

Modelul acceptă și fenomenul de *volatility clustering*, situația în care modificărilor mari ale cursului activelor financiare este probabil să le urmeze în continuare variații mari ale acestuia.

Testele efectuate pe piețele financiare mature au evidențiat o viteză de reacție a volatilității cursului de schimb, în general, inferioară plafonului de 0,25 și un grad de persistență a acesteia, superior pragului de 0,7.

Modelul *GARCH* a fost ulterior extins, pentru a relaxa anumite ipoteze sau pentru încorpora asimetria impactului randamentului cursului activelor financiare sau a separa volatilitatea în trend și volatilitate pe termen scurt.

Cele mai cunoscute extensii sunt:

- *GARCH* integrat (*IGARCH*),
- *GARCH in Mean* (*GARCH-M*),
- *Threshold ARCH* (*TARCH*),
- *GARCH* exponențial (*EGARCH*).

Modelul *IGARCH*

Presupunând că, $\varepsilon_t = \sqrt{h_t} v_t$ unde v_t este independent și identic distribuit cu media zero și dispersia 1 și h_t îndeplinește specificația *GARCH*(p, q):

$$h_t = k + \delta_1 h_{t-1} + \delta_2 h_{t-2} + \dots + \delta_p h_{t-p} + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_q \varepsilon_{t-q}^2,$$

adăugând ε_t la ambii termeni ai ecuației și scriind $\alpha_i = \alpha'_i - \delta_i$ rezultă

$$\varepsilon_t^2 = k + (\delta_1 + \alpha_1) \varepsilon_{t-1}^2 + (\delta_2 + \alpha_2) \varepsilon_{t-2}^2 + \dots + (\delta_r + \alpha_r) \varepsilon_{t-r}^2 + w_t - \delta_1 w_{t-1} - \delta_2 w_{t-2} - \dots - \delta_q w_{t-q}$$

unde $w_t = \varepsilon_t^2 - h_t$ și $p = \max\{p, q\}$. h_t este valoarea prognozată pentru ε_t iar $w_t = \varepsilon_t^2 - h_t$ este eroarea asociată acestei prognoze.

Rezultă că ε_t urmează un proces *ARMA*. Acest proces *ARMA* va avea un *unit root* dacă

$$\sum_{i=1}^p \delta_i + \sum_{j=1}^q \alpha_j = 1.$$

Engle și Bollerslev (1986) numesc modelul care satisface condiția de mai sus *GARCH* integrat sau *IGARCH*.

Dacă ε_t urmează un proces *IGARCH*, atunci varianța necondiționată a lui ε_t este infinită (un șoc într-o anumită perioadă nu se atenuază), deci nici ε_t și nici ε_t^2 nu satisfac condițiile unui proces staționar în covarianță (*covariance-stationary*).

Modelul *GARCH-in-Mean* (*GARCH-M*)

Teoria financiară sugerează ca un activ cu un risc perceput ca ridicat, în medie, va avea un randament superior. Presupunând că r_t este descompus într-o componentă anticipată de agenți la momentul $t - 1$ (notată μ_t) și o componentă neanticipată (notată ε_t), atunci:

$$r_t = \mu_t + \alpha_t.$$

În plus, teoria sugerează faptul că randamentul mediu (μ_t) este corelat cu varianța sa (h_t).

Modelul *ARCH-M*, introdus de Engle, Lilien și Robins (1987) este obținut prin introducerea în ecuația randamentelor a varianței sau a deviației standard condiționate (h_t sau $\sqrt{h_t}$).

Efectul percepției unui risc ridicat este cuantificat de coeficientul lui h_t din ecuația randamentului (ω):

$$r_t = \beta_0 + \sum_{i=1}^m \beta_{1,i} L^i r_t + \sum_{j=1}^n \beta_{2,j} L^j \varepsilon_t + \omega h_t + \varepsilon_t.$$

Modele *ARCH* asimetrice

Pe piețele financiare s-a observat că agenții percep volatilitatea în mod diferit, funcție de semnul variației zilnice a cursului activului financiar respectiv. De exemplu, pentru acțiuni, mișcările în jos ale pieței sunt urmate de o volatilitate mai mare decât mișcările în sens crescător de aceeași amplitudine.

Cele mai utilizate modele *ARCH* care permit analiza răspunsului asimetric la șocuri sunt modelele *Threshold ARCH (TARCH)* și *GARCH Exponential (EGARCH)*.

Modelul *TARCH*, introdus în mod independent de Zakoian (1990) și Glosten, Jaganathan și Runkle (1993), are următoarea specificație pentru ecuația varianței (*TARCH(p,q)*):

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_{1,i} L^i h_t + \sum_{j=1}^q \alpha_{2,j} L^j \varepsilon_t^2 + \lambda \varepsilon_{t-1}^2 d_{t-1},$$

unde $d_t = 1$ dacă $\varepsilon_t < 0$ și $d_t = 0$ în caz contrar.

În acest model, veștile bune ($\varepsilon_t < 0$) și veștile rele ($\varepsilon_t > 0$) au efecte diferite asupra varianței condiționate – veștile bune au un impact de α_1 în timp ce veștile rele au un impact de $\alpha_1 + \lambda$. Dacă $\lambda \neq 0$, atunci efectul informațiilor asupra volatilității este asimetric.

Modelul *EGARCH*, propus de Nelson (1991) are următoarea specificație pentru ecuația varianței condiționate:

$$\log(h_t) = \omega + \beta \log(h_{t-1}) + \alpha \left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| + \lambda \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}}.$$

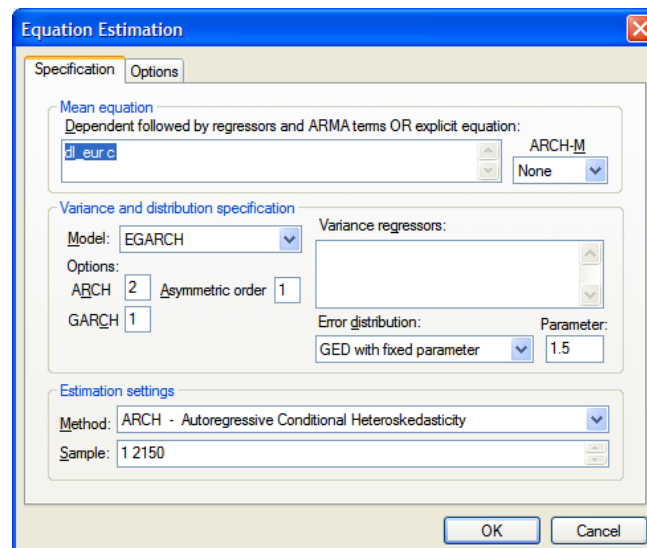
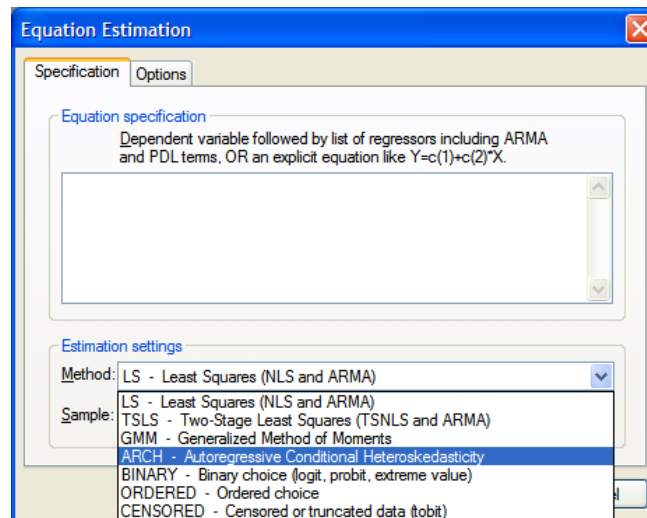
Confirm acestui model, efectul informațiilor este exponențial (și nu pătratic) iar varianța prognozată va fi obligatoriu non-negativă. Impactul informațiilor este asimetric dacă $\lambda \neq 0$.

VII.2. Estimarea modelelor ARCH în EViews

Se calculează, utilizând modele ARCH/GARCH volatilitatea cursului EUR/RON pentru perioada ianuarie 1999 – mai 2007 pentru o serie cu frecvență zilnică.

Seria evoluțiilor zilnice ale cursului de schimb (calculate ca diferență de logaritmi naturali, $\ln x_t - \ln x_{t-1}$) este denumită *dl_eur*.

Specificarea ecuației ARCH: click buton dreapta mouse în fereastra fișierului de lucru, alegerea opțiunii *New object/Equation* și se selectează din meniul *Method* opțiunea *ARCH – Autoregressive Conditional Heteroskedasticity*.



Opțiunile disponibile sunt:

- *Mean Equation* – specificarea ecuației variabilei cărei i se calculează volatilitatea (în cazul de față a ecuației evoluției zilnice a cursului de schimb).
- *ARCH-M* – dacă modelul este *ARCH in Mean* – adică dacă în ecuația de regresie a evoluției cursului este introdusă și volatilitatea acestuia.
- *Variance and distribution specification* – specificarea ecuației varianței (volatilității) cursului de schimb:
 - *Model* – tipul modelului: *GARCH, EGARCH*.
 - *ARCH* – termenii *ARCH*.
 - *GARCH* – termenii *GARCH*.
 - *Asymetric order* – dacă se introduce asimetrie în ecuația de regresie a varianței.
 - *Variance regressors* – dacă se introduc variabile independente în ecuația de regresie a varianței.
 - *Error distribution* – distribuția erorilor (în cazul în care se presupune că distribuția erorilor nu este normală și se dorește corectarea ecuației de varianță pentru ne-normalitatea erorilor).

Condițiile ce trebuie îndeplinite de coeficienții unui model *GARCH* sunt:

- Coeficienții ecuației varianței să fie pozitivi;
- Suma coeficienților ecuației varianței să fie mai mică decât 1. În caz contrar, modelul este *GARCH* integrat (*I-GARCH*), iar volatilitatea este explozivă.

Modelele *EGARCH* sunt mai puțin restrictive, neavând condiții impuse valorilor coeficienților ecuației volatilității.

Conform estimărilor, pentru cursul EUR/RON modele *GARCH* estimate au fost *GARCH* integrate.

De exemplu, modelul *GARCH(1, 1)* este:

Dependent Variable: DL_EUR
 Method: ML - ARCH (Marquardt) - Normal distribution
 Sample (adjusted): 2 2148
 Included observations: 2147 after adjustments
 Convergence achieved after 19 iterations
 Variance backcast: ON
 $GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)$

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000198	8.77E-05	2.260467	0.0238

Variance Equation

C	2.50E-07	5.08E-08	4.926018	0.0000
RESID(-1)^2	0.138819	0.009128	15.20872	0.0000
GARCH(-1)	0.868095	0.008286	104.7609	0.0000
R-squared	-0.001355	Mean dependent var	0.000427	
Adjusted R-squared	-0.002757	S.D. dependent var	0.006208	
S.E. of regression	0.006216	Akaike info criterion	-7.718359	
Sum squared resid	0.082811	Schwarz criterion	-7.707792	
Log likelihood	8289.659	Durbin-Watson stat	1.848831	

Ca urmare, a fost estimat un model $EGARCH(2,1,1)$ (acesta fiind mai puțin restrictiv). Modelul a acceptat atât coeficient de asimetrie în ecuația de volatilitate cât și volatilitatea cursului EUR/RON (măsurată prin abaterea medie pătratică) în ecuația de medie.

Ecuația de regresie a modelului este prezentată mai jos.

Dependent Variable: DL_EUR

Method: ML - ARCH (Marquardt) - Generalized error distribution (GED)

Sample (adjusted): 2 2148

Included observations: 2147 after adjustments

Convergence achieved after 25 iterations

Variance backcast: ON

LOG(GARCH) = C(3) + C(4)*ABS(RESID(-1)/@SQRT(GARCH(-1))) +
C(5)*ABS(RESID(-2)/@SQRT(GARCH(-2))) + C(6)*RESID(-1)
/@SQRT(GARCH(-1)) + C(7)*LOG(GARCH(-1))

	Coefficient	Std. Error	z-Statistic	Prob.
@SQRT(GARCH)	0.112635	0.039554	2.847620	0.0044
C	-0.000457	0.000156	-2.932430	0.0034

Variance Equation

C(3)	-0.284286	0.056336	-5.046247	0.0000
C(4)	0.399824	0.049811	8.026844	0.0000
C(5)	-0.170567	0.049394	-3.453202	0.0006
C(6)	-0.026267	0.013602	-1.931131	0.0535
C(7)	0.989348	0.004282	231.0737	0.0000

GED PARAMETER	1.293394	0.047198	27.40373	0.0000
---------------	----------	----------	----------	--------

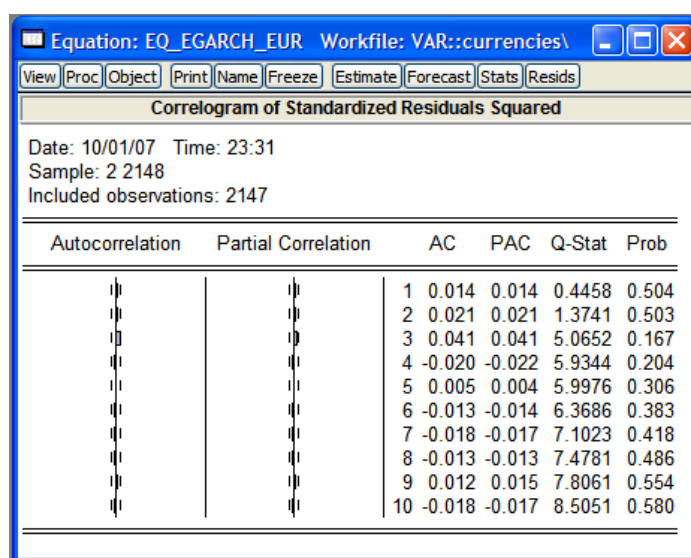
R-squared	0.002000	Mean dependent var	0.000427
Adjusted R-squared	-0.001266	S.D. dependent var	0.006208
S.E. of regression	0.006212	Akaike info criterion	-7.788111
Sum squared resid	0.082534	Schwarz criterion	-7.766977

Log likelihood	8368.537	F-statistic	0.612409
Durbin-Watson stat	1.855328	Prob(F-statistic)	0.746122

Coeficientul volatilității cursului din ecuația de medie, fiind pozitiv, arată că, atunci când volatilitatea crește, RON-ul se depreciază (cursul EUR/RON crește).

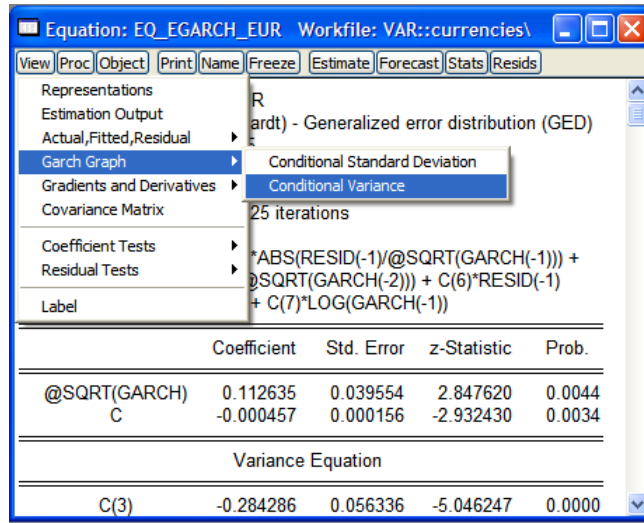
Coeficientul de asimetrie din ecuația volatilității este $c(6)$ este semnificativ din punct de vedere statistic și arată că, dacă în perioada anterioară cursul a crescut, volatilitatea se reduce.

Conform corelogramei erorilor pătratice (prezentată în graficul de mai jos), nu mai există termeni ARCH suplimentari.




Pe baza ecuație de volatilitate estimate, se generează seria istorică de volatilitate condiționată. Volatilitatea poate fi măsurată prin varianță sau abatere medie patratică (radicalul varianței).

Seria de volatilitate se reprezintă grafic cu ajutorul opțiunii *View/GARCH Graph/Conditional Standard Deviation* sau *Conditional Variance* accesată din fereastra ecuației de regresie.



Volatilitatea (măsurată prin abaterea medie pătratică) a cursului EUR/RON este prezentată în graficul de mai jos.



Capitolul VIII. Modele cu vectori autoregresivi (VAR)

VIII.1. Definiție și utilizare

Un model VAR (Vector Autoregression) permite tratarea simetrică a tuturor variabilelor din model, în sensul că nu presupune implicit exogeneitatea unei anumite variabile (cum se întâmplă în cazul OLS sau în cazul analizei funcției transfer). VAR-ul este de dorit a fi utilizat atunci când nu știm sigur că o anumită variabilă este exogenă.

În cazul unui model VAR cu două variabile vom permite ca evoluția variabilei x să fie influențată de valori anterioare (*lag-uri*) ale lui x , precum și de valori curente și anterioare ale lui y . De asemenea, vom presupune că y este influențat de *lag-uri* ale sale, precum și de valori curente sau anterioare ale lui x .

Prin urmare, fie sistemul bivariat simplu (forma structurală a sistemului sau forma primitivă):

$$\begin{aligned}x_t &= a_{11} + a_{12}x_{t-1} + a_{13}y_t + a_{14}y_{t-1} + \varepsilon_{xt} \\y_t &= a_{21} + a_{22}y_{t-1} + a_{23}x_t + a_{24}x_{t-1} + \varepsilon_{yt}\end{aligned}$$

unde se presupune că atât x , cât și y sunt variabile staționare, iar ε_{xt} și ε_{yt} sunt zgomote albe și necorelate (condiții esențiale pentru scrierea corectă a unui VAR în general).

Cele două ecuații de mai sus constituie un sistem VAR de ordinul întâi, din moment ce lungimea *lag*-ului este de o perioadă. Având în vedere modalitatea de scriere a sistemului, acesta încorporează feedback – se permite influențarea reciprocă între x și y . De exemplu, a_{13} cuantifică impactul contemporan (direct) din partea unei modificări unitare a lui y_t asupra lui x_t . Mai mult, dacă a_{23} este diferit de zero, atunci ε_{xt} are impact contemporan indirect asupra lui y_t ; dacă a_{14} este diferit de zero, atunci ε_{yt} are impact contemporan indirect asupra lui x_t .

Ecuațiile anterioare nu sunt în formă redusă având în vedere că este permis impactul contemporan al unei variabile asupra altei variabile (forma redusă este necesară pentru implementarea practică a unui asemenea sistem). Folosind matrici sistemul poate fi rescris astfel:

$$\begin{bmatrix} 1 & -a_{13} \\ -a_{23} & 1 \end{bmatrix} \begin{bmatrix} x_t \\ y_t \end{bmatrix} = \begin{bmatrix} a_{11} \\ a_{21} \end{bmatrix} + \begin{bmatrix} a_{12} & a_{14} \\ a_{24} & a_{22} \end{bmatrix} \begin{bmatrix} x_{t-1} \\ y_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{xt} \\ \varepsilon_{yt} \end{bmatrix}$$

sau:

$B \cdot z_t = \Gamma_0 + \Gamma_1 \cdot z_{t-1} + \varepsilon_t$, unde:

$$\begin{bmatrix} 1 & -a_{13} \\ -a_{23} & 1 \end{bmatrix} = B, \begin{bmatrix} x_t \\ y_t \end{bmatrix} = z_t,$$
$$\Gamma_0 = \begin{bmatrix} a_{11} \\ a_{21} \end{bmatrix}, \Gamma_1 = \begin{bmatrix} a_{12} & a_{14} \\ a_{24} & a_{22} \end{bmatrix}, \varepsilon_t = \begin{bmatrix} \varepsilon_{xt} \\ \varepsilon_{zt} \end{bmatrix}$$

Multiplicarea cu B^{-1} permite obținerea formei standard a VAR:

$$z_t = A_0 + A_1 \cdot z_{t-1} + e_t$$

Noul sistem se scrie astfel:

$$x_t = a_{10} + a_{11}x_{t-1} + a_{12}y_{t-1} + e_{1t}$$
$$y_t = a_{20} + a_{21}x_{t-1} + a_{22}y_{t-1} + e_{2t}$$

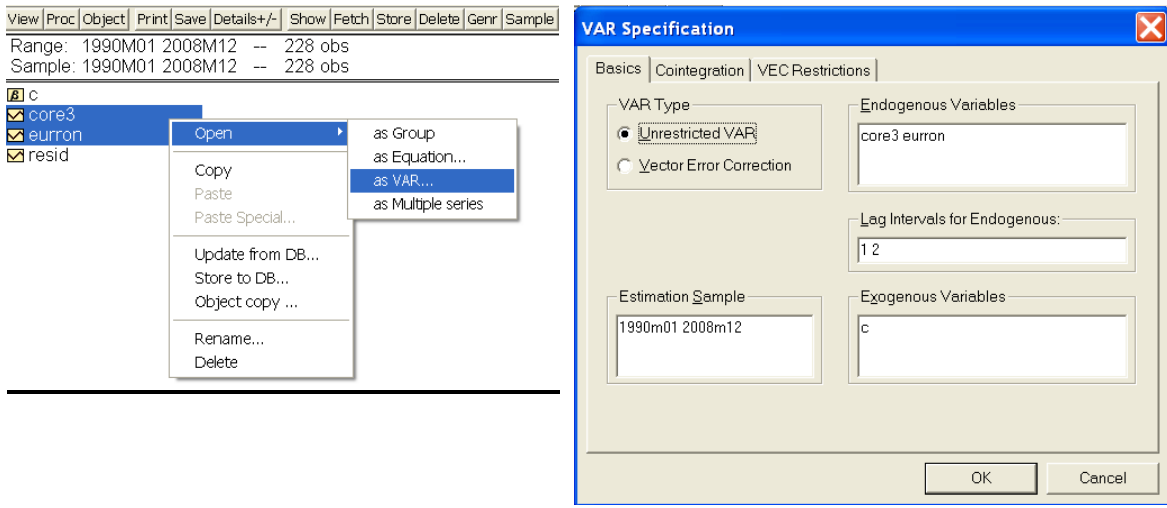
și se numește VAR în forma standard.

Foarte important de reținut este aspectul conform căruia eroarea e este o combinație a erorilor ε având în vedere că $e_t = B^{-1}\varepsilon_t$.

Fiindcă atât ε_{xt} și ε_{zt} sunt zgomote albe, rezultă că e_{1t} și e_{2t} au medie nulă, varianța constantă și nu sunt corelate serial luate individual. În consecință, acestea sunt procese staționare, însă trebuie notat că pot fi corelate serial între ele (în general, covarianța lor este diferită de zero). Șocurile sunt necorelate doar dacă nu există impact contemporan între variabilele sistemului.

VIII.2. Construirea unui model VAR

Să pornim prin alcătuirea unui model VAR folosind programul econometric Eviews. Variabilele care se includ în model au la bază teoria economică (deși VAR-ul permite includerea de variabile fără o anumită legătură *a priori*). În acest scop vom folosi două serii (pentru început): CORE3 ca măsură a inflației de bază și cursul de schimb EUR/RON. Prin selectarea simultană a celor două serii și click buton dreapta mouse în interiorul paginii de lucru, selectarea opțiunii *Open as VAR*, se obține fereastra din dreapta (mai jos).



Celelalte opțiuni disponibile sunt:

- *As Group* – permite vizualizarea seriilor în cadrul unui grup
- *As Equation* – permite deschiderea seriilor direct într-o nouă ecuație
- *As multiple series* – permite deschiderea individuală a celor două serii

VAR-ul nou creat poartă denumirea de *Untitled*. Pentru schimbarea acesteia se folosește butonul *Name*.

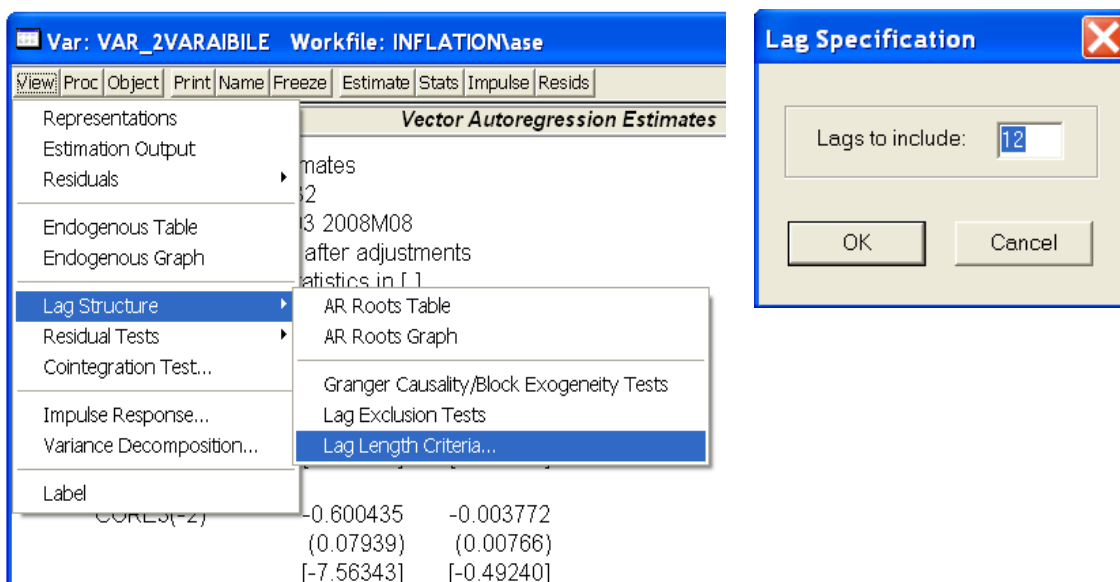
Așa cum am precizat anterior, variabilele din componența modelului *VAR* trebuie să fie staționare. Eventualele teste de staționaritate vor confirma caracterul nestaționar al ambelor serii. Prin urmare, este necesară transformarea acestora în serii staționare prin logaritmare și prin aplicarea operatorului de primă diferență. Acest lucru se obține în Eviews scriind formula $dlog(...)$.

Există o dezbateră intensă în literatură dacă *VAR*-ul poate fi alcătuit din variabile nestaționare. Sims, unul din părinții *VAR*, recomandă o astfel de strategie pentru că ea ar surprinde legăturile dintre variabile și nu estimarea parametrilor. Tot el spune că diferențierea duce la pierderea de informație, cum ar fi cea existentă între serii cointegrate. Prin urmare, dacă scopul este estimarea unui model *VEC* (*Vector Error Correction*), este permisă utilizarea de serii nestaționare. Altfel, variabilele trebuie diferențiate. Mai mult, dacă se urmărește estimarea unui model structural, diferențierea seriilor devine obligatorie.

VIII.3. Alegerea numărului de lag-uri pentru un model VAR

După crearea modelului VAR urmează etapa stabilirii numărului de lag-uri (rareori se întâmplă ca opțiunea implicită să fie cea corectă). În acest scop se alege din meniul *View/Lag structure/Lag Length Criteria*.

În fereastra următoare se introduce numărul de lag-uri care este, de regulă, 36 pentru date lunare, 12 pentru date trimestriale, etc. Noi vom folosi 12 lag-uri chiar dacă avem date lunare fiindcă eșantionul nu este unul foarte mare. Se poate verifica suficiența acestui număr până la numărul maxim de lag-uri permis.



Rezultatul obținut este prezentat mai jos și, după cum se poate observa, toate criteriile aleg un singur lag.

Celelalte opțiuni disponibile sunt:

- *AR Roots Table* – permite vizualizarea în cadrul unui tabel a inversului rădăcinilor polinomului AR caracteristic.
- *AR Roots Graph* – permite vizualizarea grafică a inversului rădăcinilor polinomului AR caracteristic.
- *Pairwise Granger Causality Tests* – permite realizarea de teste tip Granger, precum și testarea dacă o anumită variabilă poate fi tratată ca exogenă sau endogenă.
- *Lag Exclusion Tests* – realizează teste de excludere a fiecărui lag din cadrul modelului VAR.

EViews - [Var: VAR_2VARIABLE Workfile: INFLATIONase]

File Edit Object View Proc Quick Options Window Help

View Proc Object Print Name Freeze Estimate Stats Impulse Resids

VAR Lag Order Selection Criteria
 Endogenous variables: DLOG(CORE3) DLOG(EURRON)
 Exogenous variables: C
 Date: 10/05/08 Time: 19:48
 Sample: 1990M01 2008M12
 Included observations: 91

Lag	LogL	LR	FPE	AIC	SC	HQ
0	570.5402	NA	1.28e-08	-12.49539	-12.44021	-12.47313
1	656.4573	166.1694*	2.12e-09*	-14.29577*	-14.13021*	-14.22898*
2	657.4262	1.831343	2.27e-09	-14.22915	-13.95323	-14.11783
3	661.9221	8.300099	2.24e-09	-14.24005	-13.85376	-14.08420
4	664.1446	4.005362	2.33e-09	-14.20098	-13.70433	-14.00061
5	665.3848	2.180632	2.48e-09	-14.14033	-13.53331	-13.89543
6	669.6075	7.238923	2.47e-09	-14.14522	-13.42783	-13.85580
7	672.9798	5.632794	2.51e-09	-14.13142	-13.30367	-13.79748
8	673.7891	1.316215	2.70e-09	-14.06130	-13.12318	-13.68282
9	677.7103	6.204979	2.72e-09	-14.05957	-13.01108	-13.63657
10	680.6005	4.446392	2.80e-09	-14.03517	-12.87632	-13.56765
11	682.1405	2.301553	2.97e-09	-13.98111	-12.71188	-13.46906
12	682.6968	0.806954	3.23e-09	-13.90542	-12.52583	-13.34884

* indicates lag order selected by the criterion
 LR: sequential modified LR test statistic (each test at 5% level)
 FPE: Final prediction error
 AIC: Akaike information criterion
 SC: Schwarz information criterion
 HQ: Hannan-Quinn information criterion

Lungimea *lag*-urilor într-un model VAR este importantă pentru că trebuie să surprindă dinamica sistemului fără să consume prea multe grade de libertate. Gradele de libertate scad rapid prin luarea în considerare a multor *lag*-uri. De asemenea, dacă sunt prea puține *lag*-uri, modelul nu este specificat corect, iar dacă sunt prea multe, se pierd grade de libertate. Prin urmare, testarea se face prin utilizarea celui mai mare număr de *lag*-uri ce este și plauzibil sau ce este permis de eșantionul studiat.

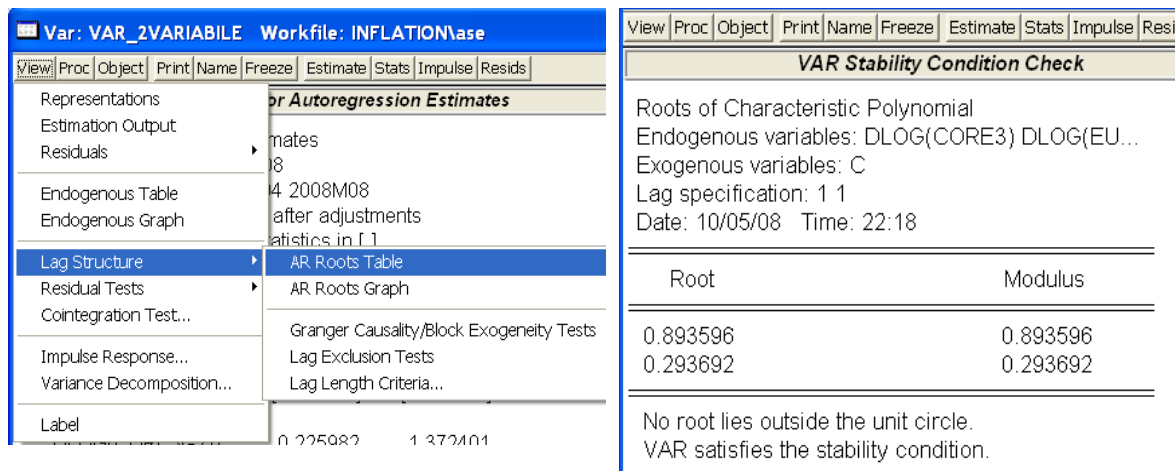
Testul de excludere a *lag*-urilor poate fi utilizat pentru a verifica rezultatul testului de selecție a numărului de *lag*-uri sau pentru a stabili un alt număr de *lag*-uri, dacă rezultatul testului privind lungimea *lag*-urilor nu a fost relevant.

O altă modalitate de stabilire a numărului de *lag*-uri este studierea indicatorului *R* pătrat ajustat al fiecărei ecuații. Dacă prin mărirea *lag*-urilor se îmbunătățește *R* pătrat ajustat, *lag*-urile respective aduc informație suplimentară.

VIII.4. Stabilitatea și staționaritatea unui model VAR

Stabilitatea în cadrul unei ecuații de ordinul întâi impune o valoare sub-unitară coeficientului primului *lag*. Prin analogie, în cazul unui model VAR este necesar ca expansiunea lui A_1 la puterea n să tindă spre zero.

Testul se realizează prin *View/Lag structure/AR Roots Table*.



View | Proc | Object | Print | Name | Freeze | Estimate | Stats | Impulse | Resi

VAR Stability Condition Check

Roots of Characteristic Polynomial
Endogenous variables: DLOG(CORE3) DLOG(EU...
Exogenous variables: C
Lag specification: 1 1
Date: 10/05/08 Time: 22:18

Root	Modulus
0.893596	0.893596
0.293692	0.293692

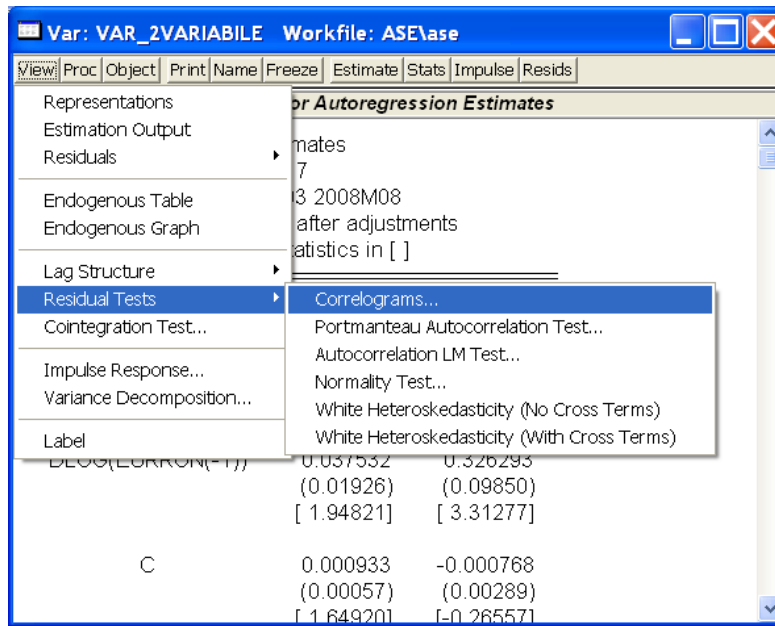
No root lies outside the unit circle.
VAR satisfies the stability condition.

În cazul modelului nostru ambele rădăcini sunt subunitare, ceea ce înseamnă că modelul este stabil și putem studia funcții de răspuns la șoc, etc.

VIII.5. Stabilitatea și staționaritatea unui model VAR

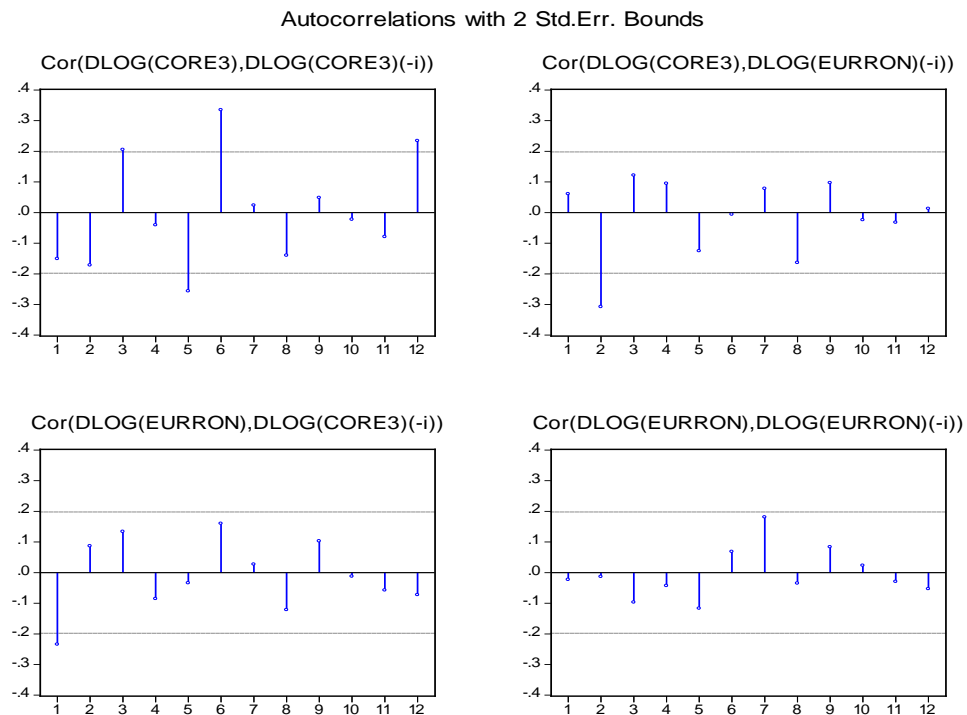
Ca și în cazul regresiei OLS, etapa de testare a reziduurilor ecuațiilor este foarte importantă pentru că trebuie respectate aceleași ipoteze. Nerespectarea lor poate duce la concluzii greșite privind, de exemplu, eroarea standard și concluziile formulate pot fi, în realitate, false.

Testele reziduurilor se realizează prin *View/Residual Tests*



și opțiunile sunt:

- **Correlograms:** afișează corelograma autocorelațiilor pe eșantion pentru reziduurile estimate prin VAR și pentru numărul de lag-uri specificat. Afișarea corelogramei este disponibilă în trei modalități (mai jos este prezentată reprezentarea grafică). Liniile punctate sunt obținute prin înmulțirea erorii standard cu doi.



- Portmanteau: calculează testul multivariat Box-Pierce/Ljung-Box Q-statistics pentru corelație serială până la un anumit *lag* specificat. Ipoteza nulă este de lipsă a autocorelației până la lag-ul specificat. Testul de mai jos respinge ipoteza nulă, deci erorile ecuațiilor din VAR sunt corelate serial.

VAR Residual Portmanteau Tests for Autocorrelations

H0: no residual autocorrelations up to lag h

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

Sample: 1990M01 2008M12

Included observations: 102

Lags	Q-Stat	Prob.	Adj Q-Stat	Prob.	df
1	7.618884	NA*	7.694319	NA*	NA*
2	20.25355	0.0004	20.58168	0.0004	4

*The test is valid only for lags larger than the VAR lag order.

df is degrees of freedom for (approximate) chi-square distribution

- Testul de autocorelație *LM* : este vorba de testul multivariat *LM* pentru corelație serială până la un anumit *lag*. Din nou, se concluzionează că există autocorelație la ambele *lag*-uri și modelul trebuie re-specificat.

VAR Residual Serial Correlation LM Tests

H0: no serial correlation at lag order h

Date: 10/01/08 Time: 10:11

Sample: 1990M01 2008M12

Included observations: 102

Lags	LM-Stat	Prob
1	15.33917	0.0040
2	14.17839	0.0067

Probs from chi-square with 4 df.

- Testul de normalitate: extensia multivariată a testului Jarque-Bera în care se compară momentele de ordinul 3 și 4 cu cele ale distribuției normale. Din motive de simplificare, de regulă se alege ordonarea Cholesky (pentru care contează ordonarea variabilelor din *VAR*). Probabilitatea de acceptare a ipotezei nule este

0, deci reziduurile nu sunt normal distribuite, ceea ce reprezintă o încălcare a ipotezelor modelului VAR.

VAR Residual Normality Tests

Orthogonalization: Cholesky (Lutkepohl)

H0: residuals are multivariate normal

Sample: 1990M01 2008M12

Included observations: 102

Component	Skewness	Chi-sq	df	Prob.
1	0.782269	10.40306	1	0.0013
2	0.503019	4.301483	1	0.0381
Joint		14.70454	2	0.0006

Component	Kurtosis	Chi-sq	df	Prob.
1	5.968347	37.44712	1	0.0000
2	3.358338	0.545727	1	0.4601
Joint		37.99284	2	0.0000

Component	Jarque-Bera	df	Prob.
1	47.85017	2	0.0000
2	4.847210	2	0.0886
Joint	52.69738	4	0.0000

➤ Testul *White* de heteroskedasticitate: reziduurile prezintă heteroskedasticitate.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Sample: 1990M01 2008M12

Included observations: 102

Joint test:

Chi-sq	df	Prob.
51.31746	12	0.0000

Individual components:

Dependent	R-squared	F(4,97)	Prob.	Chi-sq(4)	Prob.
res1*res1	0.365124	13.94641	0.0000	37.24260	0.0000
res2*res2	0.052785	1.351357	0.2566	5.384028	0.2501
res2*res1	0.061429	1.587142	0.1839	6.265727	0.1802

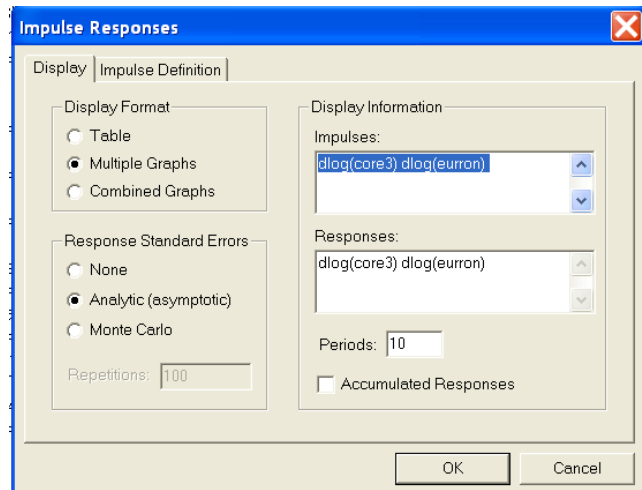
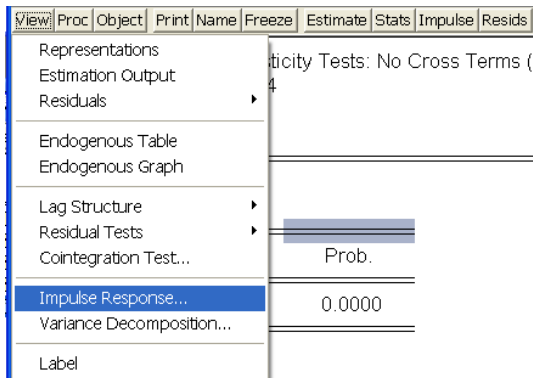
VIII.6. Funcții de impuls-răspuns

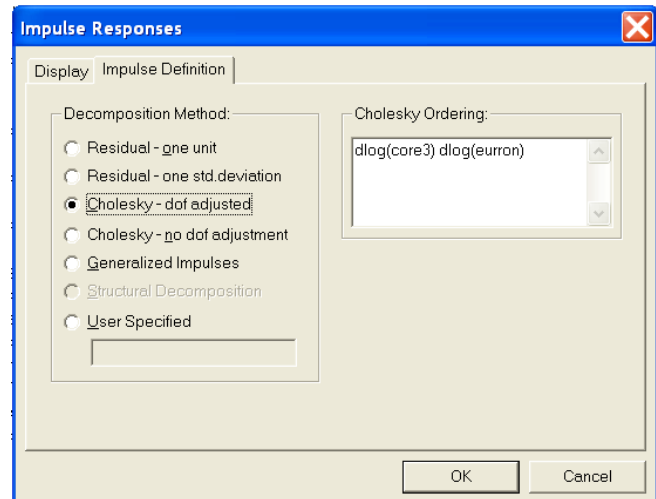
Modelul VAR poate fi scris ca un vector de medii mobile (VMA) și permite studierea impactului unui șoc asupra evoluției variabilei dependente. În meniul View se alege *Impulse response*.

Formatul de afișare poate fi grafic sau tabel, iar benzile de încredere pot fi obținute prin proceduri analitice sau estimare Monte Carlo. Numărul de perioade pentru care se dorește răspunsul la șoc este de circa 16 pentru date trimestriale și circa 36 pentru date lunare.

Definiția impulsurilor contează mult deoarece:

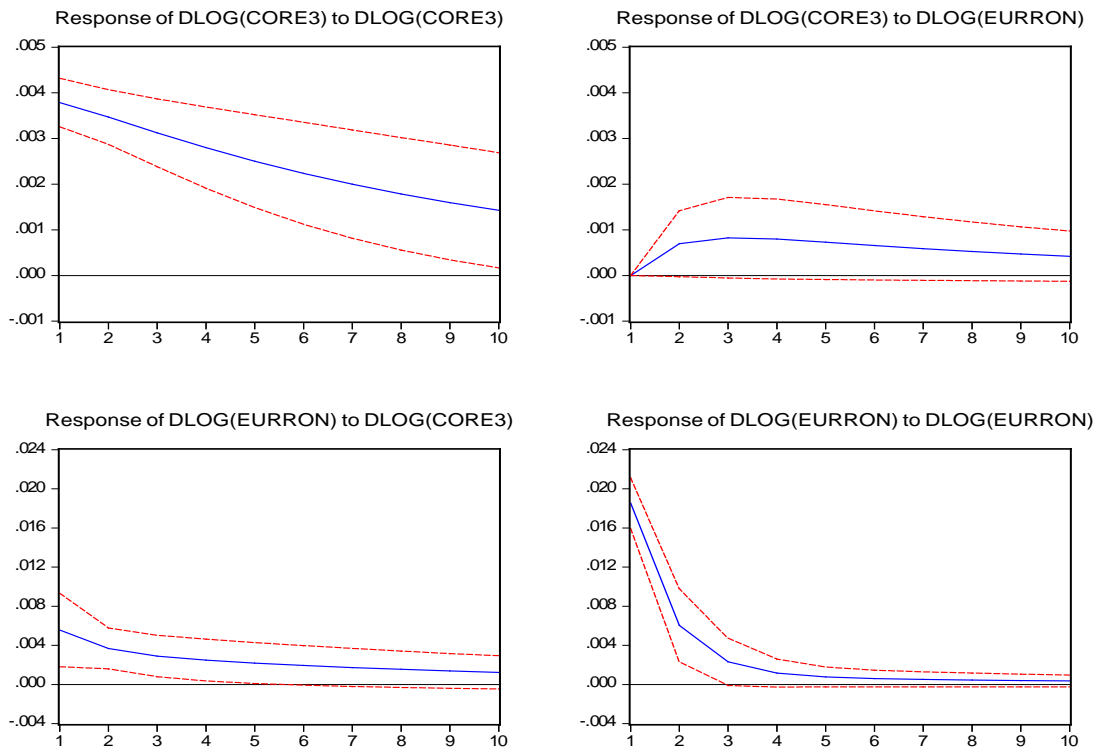
- în cazul descompunerii Cholesky contează ordonarea variabilelor dacă acestea sunt corelate între ele;
- în cazul descompunerii generalizate nu contează ordonarea variabilelor;
- în cazul descompunerii structurale, aceasta poate fi utilizată doar dacă a fost specificat anterior un model structural cu restricțiile necesare.





Vizualizarea grafică este prezentată mai jos și se poate identifica atât un răspuns al inflației la cursul de schimb, cât și invers. Aceste rezultate trebuie privite cu rezerve având în vedere rezultatele testelor, precum și fiindcă benzile din graficul care prezintă răspunsul inflației includ și zero, deci răspunsul s-ar putea să nu fie semnificativ.


Response to Cholesky One S.D. Innovations ± 2 S.E.



VIII.7. Descompunerea varianței

Procedura este similară cu cea de obținere a funcțiilor de impuls-răspuns. Descompunere varianței indică în ce măsură o anumită variabilă poate explica evoluția varianței altei variabile. De exemplu, varianța cursului de schimb explică sub 10% din varianța ratei inflației.

Variance Decomposition



Capitolul IX. Modele Value at Risk (VaR)

IX.1. Măsura VaR

Valoarea la risc (VaR) este o încercare de a reprezenta printr-un singur număr riscul total dintr-un portofoliu de active financiare. Această măsură a fost introdusă de către J. P. Morgan în 1994 și în prezent este folosită pe scară largă atât de către instituțiile financiare cât și în trezoreriile corporațiilor și în fondurile de investiții. De asemenea, și Comitetul de Supraveghere Bancară al Băncii Reglementelor Internaționale o folosește pentru calculul cerințelor de capital pentru bănci.

VaR -ul reprezintă pierderea estimată a unui portofoliu fix de instrumente financiare pe un orizont fix de timp iar utilizarea acestui indicator implică alegerea arbitrară a doi parametri: perioada de deținere a instrumentelor financiare (orizontul de timp) și nivelul de relevanță. Conform Acordului de la Basel privind Adekvarea Capitalului, orizontul de timp este de două săptămâni (10 zile), iar nivelul de relevanță este de 1 la sută.

În practică sunt utilizate mai multe metode de calcul al VaR , cele mai cunoscute fiind metoda analitică, metoda istorică și simularea Monte Carlo. Alegerea metodei de calcul depinde de:

- instrumentele financiare asupra cărora poate fi aplicată;
- acuratețea măsurilor de risc, inclusiv ipotezele statistice pe care se bazează;
- cerințele de implementare (modelele de evaluare a riscului, descompunerea riscului, cerințele de date);
- sistemele informatice necesare;
- ușurința de comunicare a rezultatelor către utilizatori.

IX.2. VaR analitic

Ipoteza pe care se bazează această metodă este că randamentele activelor din portofoliu (R) pe orizontul de deținere (h) sunt normal distribuite, având media μ și deviația standard σ : $R \sim N(\mu, \sigma)$.

Dacă valoarea prezentă a portofoliului este S , VaR -ul pentru orizontul de h zile, cu nivelul de relevanță $100(1 - \alpha)\%$ este:

$$VaR_{h,\alpha} = -x_\alpha S,$$

unde x_α este cea mai mică percentilă α a distribuției $N(\mu, \sigma)$.

Folosind transformarea normală, putem scrie $Z_\alpha = \frac{(x_\alpha - \mu)}{\sigma}$, de unde rezultă:

$$x_\alpha = Z_\alpha \sigma + \mu,$$

unde Z_α este cea mai mică percentilă α a distribuției normale standard.

Din cele două relații de mai sus rezultă:

$$VaR = -(Z_\alpha \sigma + \mu)S .$$

Metoda analitică una din cele mai simple și ușor de implementat metodologii de calcul al VaR, ea bazându-se pe estimări ale parametrilor pe baza datelor istorice (volatilitate, coeficienți de corelație, randamente medii ale activelor).

Principalul dezavantaj al acestei metode este ipoteza statistică pe care se bazează – evoluția prețului activelor financiare are o distribuție normală, ipoteză care rar este îndeplinită în practică. Alte dezavantaje ale acestei metode rezultă din faptul că multe senzitivități (volatilități, coeficienți de corelație) sunt variabile în timp, iar această variabilitate are un impact semnificativ asupra măsurilor de risc în special în cazul portofoliilor care conțin opțiuni. De asemenea, metoda analitică nu este recomandată în cazul portofoliilor care conțin *payoff*-uri discontinue (de exemplu opțiuni cu bariere).

IX.3. VaR calculat pe baza simulării Monte Carlo

Simularea Monte Carlo presupune specificarea proceselor aleatoare pentru factorii de risc ai portofoliului, a modului în care aceștia afectează portofoliul și simularea unui număr mare de evoluții a acestor factori și implicit de valori finale ale portofoliului pe baza acestor ipoteze. Fiecare simulare conduce la un posibil profit/pierdere. Dacă este simulat un număr suficient de mare de valori posibile ale profitului/pierderii, atunci se poate construi densitatea de probabilitate pentru profitul/pierdere posibilă și se poate genera VaR-ul pe baza celei mai mici percentile a distribuției.

Metodologie analizei Monte Carlo pentru prețul unei acțiuni, S , este prezentată după cum urmează. Presupunând că S urmează o mișcare Browniană geometrică, atunci:

$$\frac{dS}{S} = \mu dt + \sigma dW ,$$

unde :

μ este randamentul așteptat pe unitatea de timp,

σ este volatilitatea cursului spot al acțiunii,

dW este un proces Wiener, care poate fi scris $dW = \varphi(dt)^{\frac{1}{2}}$, unde φ este o variabilă aleatoare și are o distribuție normală standard. Substituind pentru dW se obține:

$$\frac{dS}{S} = \mu dt + \sigma \varphi (dt)^{\frac{1}{2}} .$$

Randamentul instantaneu al prețului acțiunii, $\frac{dS}{S}$, evoluează funcție de trend, μdt și de termenul aleatoriu φ . În practică, în general se folosește modelul în timp discret. Astfel, dacă Δt reprezintă frecvența de timp la care se măsoară randamentul prețului acțiunii, atunci,

$$\frac{\Delta S}{S} = \mu \Delta t + \sigma \varphi \sqrt{\Delta t},$$

unde ΔS reprezintă modificarea prețului acțiunii în intervalul de timp Δt , iar $\frac{\Delta S}{S}$ reprezintă randamentul acțiunii în timp discret.

Randamentul acțiunii este considerat a avea o distribuție normală, cu media $\mu \Delta t$ și deviația standard $\sigma \sqrt{\Delta t}$.

Presupunând că dorim simularea evoluției prețului acțiunii pentru o perioadă de lungime T , atunci divizăm T într-un număr mare, N , de sub-perioade, Δt ($\Delta t = \frac{T}{N}$). Considerăm o valoare inițială a lui S , $S(0)$, se extrage o valoare aleatoare pentru φ și se determină valoarea acțiunii pentru prima sub-perioadă. Acest proces se repetă pentru toate sub-perioadele Δt . Acest proces se reia pentru a genera un număr suficient de mare de traiectorii ale cursului acțiunii. Cu cât numărul de simulări ale traiectoriei prețului acțiunii este mai mare, cu atât distribuția simulată a cursului acțiunii la momentul T se apropie de distribuția reală a prețului la finalul orizontului avut în vedere.

VaR -ul estimat al cursului acțiunii se determină pe baza distribuției prețului acțiunii la momentul T , $S(T)$.

Principalele avantaje ale simulării Monte Carlo sunt:

- poate fi capturată o varietate mare de comportamente ale pieței,
- poate aborda eficient *payoff*-urile neliniare sau dependente de traiectoria cursului,
- poate captura riscul inclus în scenarii care nu presupun modificări extreme ale pieței,
- poate, de asemenea, furniza informații despre impactul scenariilor extreme.

Principalul dezavantaj al acestei metodologii de calcul al VaR constă în necesitatea ridicată de putere de calcul.

IX.4. VaR istoric

Această metodologie se bazează pe ipoteza că informațiile incluse în prețurile din trecutul apropiat sunt suficiente pentru cuantificarea riscului din viitorul apropiat.

Modelul de bază pentru calculul VaR prin simulare istorică constă în calculul unei serii ipotetice de profit și pierdere (P/L) sau randamente pentru portofoliul curent, pentru o perioadă istorică specifică. Aceste randamente sunt măsurate pe un interval standard de timp (de exemplu o zi) pe un set suficient de mare de observații istorice. Presupunând că portofoliul este format din n active, și pentru fiecare activ i , randamentul este calculat

pentru fiecare interval T . Dacă $r_{i,t}$ este randamentul activului i pentru sub-perioada t , și A_i este suma investită în activul i , atunci P/L -ul simulat pentru portofoliul curent în sub-perioada t este:

$$(P/L)_t = \sum_{i=1}^n A_i r_{i,t}.$$

Calculând P/L pentru toți t , se obține P/L -ul ipotetic pentru portofoliul curent pentru tot eșantionul. VaR -ul este estimat pe baza distribuției seriei P/L .

Alte metodologii pentru calculul VaR istoric ponderează valorile P/L folosite în construirea distribuției seriei P/L .

Astfel, Boudoukh, 1998, consideră că informațiile noi au un conținut informațional, referitor la riscurile viitoare, mai mare decât informațiile vechi, și, ca urmare, este justificată ponderarea valorilor P/L funcție de vârstă astfel încât informațiile mai noi să aibă o pondere mai mare.

În cazul în care volatilitatea activelor este variabilă, datele pot fi ponderate funcție de volatilitatea contemporană estimată (Hull și White, 1998). Astfel, presupunând că se dorește estimarea VaR pentru ziua T , considerând $r_{i,t}$ randamentul istoric al activului i în ziua t , $\sigma_{i,t}$ volatilitatea prognozată în ziua $t - 1$ a randamentului activului i pentru ziua t și $\sigma_{i,T}$ cea mai recentă prognoză a volatilității activului i , randamentele efective $r_{i,t}$ sunt înlocuite cu randamentele ajustate funcție de volatilitate, $r_{i,t}^*$:

$$r_{i,t}^* = \frac{\sigma_{i,T}}{\sigma_{i,t}} r_{i,t}.$$

Principalele avantaje ale simulării istorice sunt:

- Această metodologie este intuitivă și simplă din punct de vedere conceptual, ca urmare fiind simplu de comunicat către management.
- Permite simularea evenimentelor istorice extreme.
- Sunt ușor de implementat pentru orice tip de poziții, inclusiv contracte derivate.
- Datele necesare sunt ușor de procurat.
- Deoarece nu sunt dependente de ipoteze referitoare la parametrii de evoluție a piețelor, această metodologie se poate acomoda distribuțiilor leptokurtotice, celor cu asimetrie și altor distribuții non-normale.
- Simularea istorică poate fi modificată în sensul acordării unei influențe mai mari anumitor observații (în funcție de anotimp, vechime, volatilitate).

Principala deficiență a simulării istorice este legată de faptul că rezultatele sunt complet dependente de setul de date folosit:

- Dacă în perioada folosită pentru calculul *VaR* piețele au fost neobișnuit de calme (sau de volatile) și condițiile s-au schimbat între timp, simularea istorică va produce estimări ale *VaR* care sunt prea mici (mari) pentru riscurile actuale.
- Simularea istorică prezintă dificultăți în luarea în considerare a modificărilor în evoluția piețelor intervenite în perioada luată în considerare.
- Măsurile *VaR* obținute prin simulare istorică nu captează riscul asociat producerii unor evenimente plauzibile în viitor dar care nu s-au întâmplat în trecut.

IX.5. Utilizarea modelelor de volatilitate în calculul *VaR*

IX.5.1. Calculul *VaR* utilizând *EWMA*

Modelul *EWMA* (*Exponentially Weighted Moving Average*) pentru estimarea volatilității a fost propus de către RiskMetrics în anul 1996. Conform acestei abordări, volatilitatea curentă, $\hat{\sigma}_t$, depinde (este o media ponderată a) de randamentul anterior și de volatilitatea anterioară:

$$\hat{\sigma}_t^2 = (1 - \lambda)r_{t-1}^2 + \lambda\hat{\sigma}_{t-1}^2$$

unde

λ reprezintă o constantă de ponderare,

r_{t-1} o – randamentul în perioada anterioară.

Parametrul λ arată persistența volatilității activului financiar, cu cât acesta este mai mare cu atât un șoc apărut la un moment dat în piață este mai persistent. Parametrul $1 - \lambda$ arată rapiditatea cu care volatilitatea activului răspunde la un șoc indiferent de direcție, cu cât acest parametru este mai mare, cu atât reacția volatilității la șoc este mai mare. RiskMetrics utilizează o valoare a λ pentru date zilnice de 0,94.

Volatilitatea calculată prin modele *EWMA* poate fi încorporată în modele *VaR* în următoarele moduri:

- Simulare istorică cu ponderarea datelor funcție de volatilitate. Randamentele istorice sunt standardizate pe baza volatilității condiționate.
- Simulare Monte Carlo utilizând *EWMA*. Randamentele pot fi simulate considerând că urmează o distribuție normală, dar matricea de covarianță este creată utilizând *EWMA*.
- *VaR* analitic utilizând *EWMA*.

În generarea matricei de covarianță este folosită o ecuație analogă ecuației varianței:

$$\hat{\sigma}_{12,t} = (1 - \lambda)r_{1,t-1}r_{2,t-1} + \lambda\hat{\sigma}_{12,t-1},$$

unde:

$\hat{\sigma}_{12,t}$ reprezintă covarianța dintre activele 1 și 2,

$r_{1,t-1}$ și $r_{2,t-1}$ reprezintă randamentele celor două active în perioada anterioară.

Odată ce matricea de covarianță a fost definită, aceasta poate fi folosită pentru calculul VaR utilizând fie metoda analitică (indicată pentru portofolii simple), fie simularea Monte Carlo (pentru portofolii ce includ opțiuni).

În simularea analitică, VaR -ul pentru h zile, cu nivelul de relevanță α este:

$$VaR_{\alpha,h} = Z_{\alpha} P \sigma$$

unde:

Z_{α} este valoarea critică a distribuției normale standard pentru α nivel de relevanță,

P – valoarea curentă a portofoliului,

σ – deviația standard prognozată pentru un orizont de h zile.

Deviația standard este calculată pe baza unei matrice de covarianță a randamentelor pentru h zile:

- reprezentată la nivel de active:

$$\sigma = \sqrt{w'Vw}$$

unde:

$w = (w_1, w_2, \dots, w_n)$ reprezintă ponderile activelor în portofoliu,

V reprezintă prognoza, pe un orizont de h zile, a matricei de covarianță pentru randamentele activelor incluse în portofoliul.

- reprezentată la nivel de factor de risc:

$$\sigma = \sqrt{\beta'V\beta}$$

unde:

$\beta = (\beta_1, \beta_2, \dots, \beta_n)$ reprezintă factorii de sensibilitate ai portofoliului,

V reprezintă prognoza, pe un orizont de h zile, a matricei de covarianță pentru randamentele factorilor de risc.

În cazul portofoliilor simple, prognoza matricei de covarianță pe un orizont de h zile se obține aplicând regula \sqrt{t} , multiplicând matricea de covarianță pentru un orizont de o zi cu \sqrt{h} . Dar această metodologie va conduce la rezultate incorecte în cazul portofoliilor care au incluse și opțiuni, în acest caz fiind indicată utilizarea unei matrice de covarianță pentru orizontul h .

IX.5.2. Calculul VaR utilizând modele **GARCH**

Aceste modele permit calculul VaR prin luarea în considerare a impactului asupra volatilității viitoare a evenimentelor recente. De asemenea, cele două serii (randamente și volatilitatea) fiind serii staționare, aceste modele permit prognoza volatilității pentru fiecare sub-perioadă (zi) a orizontului avut în vedere pentru calculul VaR . De exemplu, pentru a obține o prognoză a volatilității pentru următoarele 10 zile, se însumează cele 10 varianțe, se multiplică cu $\frac{250}{10}$ și se extrage rădăcina pătrată.

Includerea modelelor *GARCH* în calculul *VaR*, ca și în cazul modelelor *EWMA*, poate fi realizată prin:

- *VaR* analitic, similar ca în cazul *EWMA*, prin utilizarea unei matrice de covarianță bazată pe modele *GARCH*.
- Simulare istorică în care datele sunt ponderate funcție de volatilitate – datele sunt standardizate funcție de volatilitatea lor estimată prin modele *GARCH*.
- Simulare Monte Carlo. Evoluția randamentelor poate fi simulată pe baza unei matrice de covarianță calculate pe bază de modele *GARCH*, ceea ce permite atât simularea evoluției volatilității cât și simularea evoluției randamentelor activelor – ceea ce reprezintă un avantaj în cazul în care portofoliul conține și opțiuni.

Pentru calculul matricei de covarianță, coeficientul de corelație poate fi considerat constant și calculată covarianța funcție de coeficienții de corelație și varianțe:

$$\sigma_{ij,t+1} = \rho_{ij} \sigma_{i,t+1} \sigma_{j,t+1},$$

unde:

$\sigma_{ij,t+1}$ reprezintă covarianța dintre cele două active *i* și *j*,

ρ_{ij} – coeficientul de corelație dintre cele două active,

$\sigma_{i,t+1}$ și $\sigma_{j,t+1}$ reprezintă varianțele celor două active.

În practică a fost sugerată chiar utilizarea modelelor *GARCH* pentru modelarea directă P/L-ului portofoliului și calculul *VaR* funcție de volatilitatea condiționată a acestuia, în acest fel evitându-se calculul matricelor de covarianță.

IX.6. Calculul *VaR* pentru un portofoliu de acțiuni

Considerând un portofoliu format din patru acțiuni – Antibiotice Iași (ATB), Impact București (IMP), Turbomecanica (TBM) și Banca Transilvania (TLV) având ponderi egale, se calculează *VaR*-ul portofoliului pe baza metodologiilor descrise în Capitolul VIII. Calculul *VaR* va fi realizat pe date zilnice, perioada analizată fiind ianuarie 1999 – mai 2007.

Măsurile *VaR* calculate sunt: *VaR* analitic, *VaR* istoric, *VaR* prin maparea pozițiilor pe baza modelului *CAPM*, *VaR* pe baza de volatilitate *EWMA* și *VaR* pe bază de volatilitate estimată prin modele *GARCH*.

Conform testului *ADF*, seriile randamentelor celor patru acțiuni, indicelui BET și portofoliului sunt staționare, iar conform testului Jarque Berra seriile randamentelor nu au o distribuție normală (ci leptokurtotică).





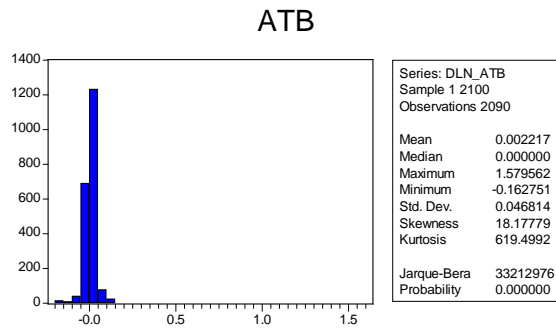
Testul de staționaritate *ADF*

	t-statistic	Probabilitate asociată
ATB	-45.0283	0.0001
IMP	-27.9898	0.0000
TBM	-45.7567	0.0001
TLV	-31.7558	0.0000
BET	-36.4676	0.0000
Portofoliu	-11.4080	0.0000

Valorile critice asociate testului *ADF*

Nivel de relevanță	t-statistic
1%	-3.43330
5%	-2.86273
10%	-2.56745

Testul Jarque-Berra



Cele patru momente ale distribuțiilor sunt prezentate în tabelul de mai jos. Ca urmare, măsurile *VaR* bazate pe ipoteza distribuției normale a seriilor pot subestima riscul.

Momentele distribuțiilor seriilor de randamente

	Medie	Deviație standard	Asimetrie	Kurtotică
ATB	0.0022	0.0468	18.1778	619.4992
IMP	0.0012	0.0402	-0.3704	12.4466
TBM	0.0019	0.0511	20.7436	732.6264
TLV	0.0024	0.0301	3.7545	77.5376
BET	0.0015	0.0158	-0.0568	9.0518
Portofoliu	0.0019	0.0234	6.5188	132.5431







Matricea de corelație dintre cele patru acțiuni, calculată pe baza eșantionului de date pentru perioada analizată, este:

Coefficienții de corelație ai seriilor de randamente

	ATB	IMP	TBM	TLV
ATB	1	0.08	0.09	0.07
IMP	0.08	1	0.05	0.06
TBM	0.09	0.05	1	0.05
TLV	0.07	0.06	0.05	1

Evoluția randamentelor zilnice pentru perioada analizată este prezentată în graficele de mai jos. Din grafice se observă fenomenul de *volatility clustering*, care considerat împreună cu distribuția leptokurtotică a randamentelor, conduce la concluzia că măsurile *VaR* calculate pe baza ipotezei normalității datelor tind să subestimeze riscul. În această situație sunt recomandate măsurile *VaR* care țin cont de volatilitatea variabilă a acțiunilor (*EWMA* și *GARCH*).

Evoluția randamentelor zilnice ale acțiunilor și a portofoliului



Pentru calculul VaR prin metoda analitică a fost calculată deviația standard a P/L -ului portofoliului de acțiuni pe ultimele 250 de zile, σ_p , și pe baza acestei serii, considerând o valoare a portofoliului de o unitate monetară (1 RON), un nivel de relevanță de 1 la sută și un orizont de prognoză de 10 zile a fost generată măsura VaR pe baza relației $VaR = 2.32635 \cdot \sigma_p \cdot \sqrt{10}$.

Pentru calculul VaR prin simulare istorică, măsura VaR pentru un orizont de 10 zile a fost considerată percentila 1 la sută pentru seria de randamente zilnice ale portofoliului de acțiuni înmulțită cu $\sqrt{10}$.






Pentru calculul VaR prin $EWMA$, luând în considerare un coeficient λ pentru date zilnice de 0,94, pornind, ca observație inițială, de la abaterea medie pătratică istorică au fost generate seriile de volatilitate pentru cele patru monede, conform relației

$$\hat{\sigma}_t^2 = (1 - \lambda)r_{t-1}^2 + \lambda\hat{\sigma}_{t-1}^2,$$

iar apoi, pe baza coeficienților de corelație istorici a fost calculată seria volatilității portofoliului. Seriile de volatilități $EWMA$ sunt prezentate în graficele de mai jos.

Măsura VaR care încorporează volatilitățile calculate pe baza metodologiei $EWMA$ a fost generată prin metoda analitică, orizontul de timp fiind de 10 zile, iar nivelul de relevanță de 1 la sută.

**Volatilitatea zilnică a seriilor de cursuri de schimb și a portofoliului
calculată pe baza metodologiei EWMA**



Specificația modelelor *ARCH* utilizate a fost aleasă funcție de testele de autocorelație a erorilor (modelele să nu prezinte autocorelație), testele de autocorelație a erorilor pătratice (să nu existe termeni *ARCH* suplimentari), suma și semnul coeficienților *ARCH* și *GARCH* (să nu existe procese *ARCH* integrate iar volatilitatea să fie strict mai mare decât zero). Ecuația de volatilitate pentru cele patru acțiuni este determinată după cum urmează:

Relația de calcul pentru această măsura de *VaR* este:

$$VaR_{EWMA} = 2.32635 \cdot \sigma_{p_EWMA} \cdot \sqrt{10},$$

unde σ_{p_EWMA} reprezintă volatilitatea portofoliului calculată pe baza volatilității *EWMA* a celor patru acțiuni.

Pentru încorporarea volatilității calculate prin modele *GARCH*, au fost calculate volatilitățile seriilor randamentelor acțiunilor incluse în portofoliu și a portofoliului prin modele *GARCH*, *EGARCH* și *TARCH*, cu distribuții de erori generalizate (*Generalised Error Distribution, GED*), având în vedere că distribuția seriilor nu este normală. Conform estimărilor, coeficientul *GED* a fost mai mic decât 2 ceea ce concordă cu ipoteza distribuției leptokurtotice a datelor.

Modelele *GARCH* estimate sunt prezentate în tabelele de mai jos.

ATB – GARCH(1,1)

Dependent Variable: DLN_ATB

Method: ML - ARCH (Marquardt) - Generalized error distribution (GED)

Sample (adjusted): 2 2091

Included observations: 2090 after adjustments

Convergence achieved after 369 iterations

Variance backcast: ON

GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	4.80E-06	0.000448	0.010706	0.9915
Variance Equation				
C	0.000259	1.74E-05	14.88917	0.0000
RESID(-1)^2	0.565227	0.063491	8.902477	0.0000
GARCH(-1)	0.202583	0.030073	6.736352	0.0000
GED PARAMETER	1.201038	0.016458	72.97498	0.0000
R-squared	-0.002234	Mean dependent var		0.002217
Adjusted R-squared	-0.004157	S.D. dependent var		0.046814

S.E. of regression	0.046911	Akaike info criterion	-4.557171
Sum squared resid	4.588325	Schwarz criterion	-4.543667
Log likelihood	4767.244	Durbin-Watson stat	1.966671

IMP – TARCH(1,1,1)

Dependent Variable: DLN_IMP

Method: ML - ARCH (Marquardt) - Generalized error distribution (GED)

Sample (adjusted): 2 2091

Included observations: 2090 after adjustments

Failure to improve Likelihood after 20 iterations

Variance backcast: ON

GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*RESID(-1)^2*(RESID(-1)<0)
+ C(5)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	6.55E-07	0.000263	0.002493	0.9980

Variance Equation

C	6.59E-05	1.17E-05	5.626147	0.0000
RESID(-1)^2	0.236443	0.041600	5.683800	0.0000
RESID(-1)^2*(RESID(-1)<0)	-0.174430	0.041201	-4.233653	0.0000
GARCH(-1)	0.779160	0.021360	36.47797	0.0000

GED PARAMETER	0.863561	0.032980	26.18441	0.0000
---------------	----------	----------	----------	--------

R-squared	-0.000901	Mean dependent var	0.001208
Adjusted R-squared	-0.003303	S.D. dependent var	0.040241
S.E. of regression	0.040308	Akaike info criterion	-4.495144
Sum squared resid	3.385916	Schwarz criterion	-4.478939
Log likelihood	4703.426	Durbin-Watson stat	1.804807

TBM – TARCH(1,1,1)

Dependent Variable: DLN_TBM

Method: ML - ARCH (Marquardt) - Generalized error distribution (GED)

Sample (adjusted): 2 2091

Included observations: 2090 after adjustments

Convergence achieved after 31 iterations

Variance backcast: ON

GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*RESID(-1)^2*(RESID(-1)<0)
+ C(5)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
--	-------------	------------	-------------	-------

C	1.42E-05	0.000505	0.028193	0.9775
Variance Equation				
C	0.000224	1.77E-05	12.65842	0.0000
RESID(-1)^2	0.219177	0.030526	7.180124	0.0000
RESID(-1)^2*(RESID(-1)<0)	-0.088261	0.031463	-2.805261	0.0050
GARCH(-1)	0.438176	0.035206	12.44611	0.0000
GED PARAMETER	1.201112	0.012932	92.87931	0.0000
R-squared	-0.001346	Mean dependent var	0.001890	
Adjusted R-squared	-0.003749	S.D. dependent var	0.051122	
S.E. of regression	0.051217	Akaike info criterion	-4.640161	
Sum squared resid	5.466790	Schwarz criterion	-4.623955	
Log likelihood	4854.968	Durbin-Watson stat	2.000499	

TLV – GARCH(1,1)

Dependent Variable: DLN_TLV

Method: ML - ARCH (Marquardt) - Generalized error distribution (GED)

Sample (adjusted): 2 2091

Included observations: 2090 after adjustments

Convergence achieved after 112 iterations

Variance backcast: ON

GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	2.24E-06	0.000313	0.007136	0.9943
Variance Equation				
C	8.81E-05	8.79E-06	10.02665	0.0000
RESID(-1)^2	0.280243	0.021989	12.74448	0.0000
GARCH(-1)	0.444706	0.030250	14.70095	0.0000
GED PARAMETER	1.092402	0.010476	104.2764	0.0000
R-squared	-0.006242	Mean dependent var	0.002376	
Adjusted R-squared	-0.008172	S.D. dependent var	0.030051	
S.E. of regression	0.030174	Akaike info criterion	-5.063941	
Sum squared resid	1.898285	Schwarz criterion	-5.050436	
Log likelihood	5296.818	Durbin-Watson stat	2.096818	

Portofoliu – EGARCH(1,1)

Dependent Variable: DLN_PORTOFOLIU

Method: ML - ARCH (Marquardt) - Generalized error distribution (GED)

Sample (adjusted): 2 2091

Included observations: 2090 after adjustments

Convergence achieved after 38 iterations

Variance backcast: ON

LOG(GARCH) = C(2) + C(3)*ABS(RESID(-1)/@SQRT(GARCH(-1))) +
C(4)*LOG(GARCH(-1))

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001263	0.000241	5.230850	0.0000
Variance Equation				
C(2)	-0.494389	0.057658	-8.574443	0.0000
C(3)	0.305973	0.032896	9.301278	0.0000
C(4)	0.966439	0.005821	166.0242	0.0000
GED PARAMETER	1.069191	0.027914	38.30279	0.0000
R-squared	-0.000797	Mean dependent var		0.001923
Adjusted R-squared	-0.002717	S.D. dependent var		0.023377
S.E. of regression	0.023409	Akaike info criterion		-5.424265
Sum squared resid	1.142504	Schwarz criterion		-5.410760
Log likelihood	5673.357	Durbin-Watson stat		1.836015

Volatilitatea pentru un orizont de 10 zile a fost calculată ca radical din suma varianțelor la momentele $t, t+1, \dots, t+9$.







Volatilitățile pe un orizont de 10 zile seriilor și ale portofoliului sunt prezentate în graficele de mai jos.

Pe baza acestei volatilități a fost calculată măsura VaR pentru un nivel de relevanță de 1 la sută, conform relației:

$$VaR = 2.32535 \cdot \sigma_{ARCH},$$

unde σ_{ARCH} reprezintă volatilitatea portofoliului calculată prin modele $GARCH$, pentru un orizont de 10 zile.

**Volatilitatea cursurilor acțiunilor și a portofoliului
calculată prin modele *GARCH***




unde $ST_DEV_ARCH_PORTOFOLIULI_AN$ reprezintă volatilitatea portofoliului calculată prin metoda analitică, pe baza volatilităților celor patru acțiuni incluse în portofoliu și a coeficienților de corelație dintre acestea (considerați constanți pentru perioada analizată), iar $ST_DEV_ARCH_PORTOFOLIULI$ este volatilitatea portofoliului calculată printr-un model *GARCH* pentru randamentele portofoliului.

Măsurile *VaR* calculate pe baza celor cinci metodologii de mai sus sunt prezentate în graficele de mai jos împreună cu randamentele pe 10 zile ale portofoliului, înmulțite cu -1 pentru comparabilitate (cu măsurile *VaR*).

Conform rezultatelor:

- Modelul bazat pe *EWMA* a performat cel mai bine, în perioada analizată producând o singură eroare, în 1841 de observații (incadrându-se în nivelul de relevanță de 1 la sută).
- De asemenea și modelul pe bază de simulare istorică, modelul analitic și modelele bazate pe estimarea volatilității prin modele *GARCH* se încadrează în nivelul de relevanță de 1 la sută (au produs fiecare câte două erori în 1841 de observații pentru modelul analitic și modelul istoric și, respectiv, 2072 de observații pentru modelele *GARCH*). Dintre aceste patru modele se detașează modelele bazate pe *GARCH*, care față de celelalte două implică cerințe de capital mai reduse.
- Dintre cele două modele *GARCH*, modelul bazat pe metoda analitică implică cerințe de capital inferioare modelului *GARCH* aplicat randamentelor portofoliului, dar în același timp implică cerințe de calcul superioare.

Măsurile VaR bazat pe mapare a pozițiilor, istoric, analitic și EWMA



Măsurile VaR calculate pe bază de modele GARCH

