

République Algérienne Démocratique et Populaire

Ministère de l'enseignement supérieur
Et de la recherche scientifique

Université M'Hamed BOUGARA de Boumerdes
Faculté Des Sciences Economiques , Commerciales
Et des Sciences De Gestion



وزارة التعليم العالي و البحث العلمي
جامعة أحمد بوقرة بومرداس

كلية العلوم الاقتصادية ، التجارية
و علوم التسيير

مطبوعة بيداغوجية تحت عنوان:

تطبيقات على البرمجيات "برنامج STATA في الاقتصاد القياسي"

تخصص : اقتصادي كمي

موجهة لطلبة: السنة ثانية ماستر

قسم : العلوم الاقتصادية

من إعداد: د. جمعاسي ابراهيم

السنة الجامعية: 2019/2018

6	مقدمة عامة
8	المحور الأول: مدخل لبيانات السلاسل الزمنية.
8	1. إنشاء المتغيرات الزمنية
10	2. إنشاء المتغيرات المتأخرة و الفروقات
11	3. التصريح بالبعد الزمني للبيانات
12	المحور الثاني : دراسة استقرارية السلاسل الزمنية
12	1. اختبار جذر الوحدة
12	1.1. اختبار ديكي فولر (1979)
12	1.2. اختبار ديكي فولر الموسع
13	1.3. دراسة منحنى الارتباط الذاتي
16	2. مثال حول دراسة الاستقرارية
19	3. تطبيق حول الاستقرارية
21	المحور الثالث : نماذج ARIMA
21	1. تعريف
21	1.1. نماذج الانحدار الذاتي AR
21	1.2. نماذج المتوسط المتحرك MA
21	1.3. نماذج ARMA(p,q)
21	1.4. نماذج ARIMA(p,d,q)
22	2. مثال لنماذج ARIMA
22	2.1. اختيار نماذج ARIMA
22	2.2. اختبار نموذج ARIMA(1,1,1)
24	2.3. مقارنة نماذج ARIMA
24	3. نموذج ARIMA مع وجود آثار الفصلية
27	المحور الرابع نماذج الانحدار الذاتي VAR ; VEC
27	1. نموذج VAR
27	1.1. تعريف
27	1.2. مثال بتغيرين تفسريين
28	2. كيفية التنفيذ على البرنامج
28	2.1. تحديد درجة التأخير
29	1.3. دراسة السببية لقرانجر Granger

30	3.دوال الاستجابة
30	3.1. مفهوم دوال الاستجابة
31	3.2. تنفيذ دوال الاستجابة على برنامج Stata
33	4.مثال ثاني نموذج VAR
33	4.1. تقديم البيانات
34	4.2. الخصائص و التطور البياني للسلسلة
35	4.3. المنهج القياسي
43	1.تطبيق 1 حول تفسير جدول التأخيرات
44	المحور الخامس: نماذج ARCH ; GARCH
44	1.نماذج ARCH , GARCH
44	1.1. تعريف
47	1.2. كيفية قراءة مخرجات نموذج ARCH
50	1.3. مثال تطبيقي لنموذج ARCH
53	1.4. مثال تطبيقي لنموذج ARCH بمسار ARMA
55	المحور السادس : التنبؤ باستعمال المسح الاسي
55	1.المسح الاسي البسيط
55	1.1. تعريف
55	1.2. كيفية تنفيذ التنبؤ الاسي البسيط في البرنامج
56	1.3. مثال تطبيقي
58	1.4. مقارنة نموذج ARIMA مع المسح الاسي البسيط
59	1.5. معالجة القيم الناقصة في العينة
62	2.المسح الاسي الثنائي
62	2.1. تعريف
63	2.2. مثال المسح الاسي ذو اتجاه عام محلي
65	2.3. اختيار المعلمة المثلى للتنبؤ
66	3.التنبؤ باستعمال طريقة Holt – Winters
66	1.3. تعريف
66	3.2. التنبؤ بدون وجود مركبة الفصلية Holt – Winters
71	3.3. التنبؤ بوجود المركبة الفصلية Holt – Winters
75	الملاحق

يندرج هذا العمل في إطار البرنامج المسطر لطلبة الماجستير في الاقتصاد الكمي، فهو يتناول أحد أهم البرامج القياسية ألا وهو برنامج Stata. و نعتمد في هذه المطبوعة على الطبعة الخامسة عشر (15) الصادرة في سنة 2017 و التي تحتوي على آخر التحديثات الخاصة بالبرنامج.

إن هذه المطبوعة تجمع بين ما هو نظري للاقتصاد القياسي و ما هو تطبيقي باستعمال برنامج Stata ففي كل مرة نعتمد على أمثلة لتوضيح كيفية تقدير النماذج القياسية. فهي الجزء الثاني للمطبوعة الاولى تحت عنوان **مدخل لبرنامج Stata**. نعمل في هذه الطبعة على اعطاء الاهمية لبعض النماذج القياسية الاكثر استعمالا في مذكرات التخرج لطلبة الاقتصاد الكمي. فنبين في كل مرة الخطوات التي يجب اتباعها لتقدير النموذج، وكذا الاختبارات التي يتطلبها النموذج المقدر مع إعطاء تفسيرات في كل مرة تكون ضرورية. ففي كل فصل نعطي لمحة عن الإطار النظري، كيفية تنفيذ و تقدير النماذج بإعطاء الصيغ الصحيحة و هذا بالاعتماد على مثال تطبيقي. و نركز اكثر على بعض النماذج المتعلقة بالسلاسل الزمنية.

إن الهدف الرئيسي من هذه المطبوعة هو إعطاء فرصة للطلاب من أجل التعمق في البرنامج و ليس إنجاز دليل استعمال شامل إلا أنها تبقى فعالة. فهي تجيب عن أهم الأسئلة التي يطرحها الطالب عند إنجاز مذكرة التخرج كما يجعله مستقلا في عمله.

و من أجل هذا فإن المطبوعة مقسمة إلى ستة محاور :

المحور الأول مخصص لإعطاء لمحة عن كيفية ادخال البيانات الزمنية.

المحور الثاني دراسة استقرارية السلاسل الزمنية

المحور الثالث نماذج ARIMA

المحور الرابع نماذج الانحدار الذاتي VEC ; VAR

المحور الخامس نماذج ARCH ; GARCH

المحور السادس التنبؤ باستعمال المسح الاسي

المحور الأول: مدخل لبيانات السلاسل الزمنية.

1. إنشاء المتغيرات الزمنية

إن إنشاء المتغيرات الزمنية في برنامج *stata* خاص نوعاً ما، إذ يجب إتباع بعض الخطوات و نبدأ أولاً بالمتغيرات الزمنية السنوية. المتغيرات الزمنية السنوية التي تكون فيه الوحدة هي السنة سهلة الانشاء فيكفي كتابة السنوات مباشرة مثل 2000، 2001، 2002،... الخ.

أما المتغيرات الزمنية اليومية فهنا يجب :

- إدخال البيانات في قاعدة البيانات على الشكل التالي مثلا 2000/02/02 و تسمية المتغير (مثل jour).
- إنشاء متغير جديد يحمل اسم جديد (مثل jour1) متبوع بشرط المحتوى الذي يكون على شكل:

```
gen jour1=daily(jour, "DMY")
```

- إعلام البرنامج بإظهار البيانات على شكل نصي أي February 02, 2000 و هذا باستعمال التعليمات:

```
format %tdMonth_DD,_CCYY jour1
```

لتكون النتيجة كما يلي:

```
. gen jour1=daily(jour, "DMY")
. format %tdMonth_DD,_CCYY jour1
. list
```

	jour	jour1
1.	02/02/2000	February 02, 2000
2.	03/02/2000	February 03, 2000
3.	04/02/2000	February 04, 2000
4.	05/02/2000	February 05, 2000
5.	06/02/2000	February 06, 2000
6.	07/02/2000	February 07, 2000
7.	08/02/2000	February 08, 2000
8.	09/02/2000	February 09, 2000
9.	10/02/2000	February 10, 2000
10.	11/02/2000	February 11, 2000
11.	12/02/2000	February 12, 2000

ملاحظة: التعليمات *daily* تعلم البرنامج على أن البيانات تكون من نمط يومي. الحروف *DMY* معناه يوم، شهر و سنة. و في تحويل لبيانات العددية إلى نصية فإن بيانات يومية لكل الشهر، *%tdMonth_DD*. أما الميزة بعد الفاصلة *_CCYY* نضيف إظهار الشهر و السنة.

أما المتغيرات الزمنية الشهرية فهنا يجب :

- إدخال البيانات في قاعدة البيانات على الشكل التالي مثلا 2000/02 و تسمية المتغير (مثل mois).

- إنشاء متغير جديد يحمل اسم جديد (مثل mois1) متبوع بشرط المحتوى الذي يكون على شكل

```
gen mois1=monthly( mois, "MY")
```

- إعلام البرنامج بإظهار البيانات على شكل نصي أي February, 2000 و هذا باستعمال التعليمة :

```
format %tmMonth,_CCYY mois1
```

لتكون النتيجة كما يلي:

```
. gen mois1=monthly( mois, "MY")
. format %tmMonth,_CCYY mois1
. list mois mois1
```

	mois	mois1
1.	10/2014	October, 2014
2.	11/2014	November, 2014
3.	12/2014	December, 2014
4.	01/2015	January, 2015
5.	02/2015	February, 2015
6.	03/2015	March, 2015
7.	04/2015	April, 2015
8.	05/2015	May, 2015
9.	06/2015	June, 2015
10.	07/2015	July, 2015
11.	08/2015	August, 2015
12.	09/2015	September, 2015

و في حالة المتغيرات الزمنية الفصلية نقوم :

- ادخال البيانات على شكل متغير مستمر من 1 الى عدد الفصول مثال 21 فصل و يحمل اسم t مثلا.

- انشاء متغير جديد تحت اسم t2 الذي يحتوي على الرمز tq لاعلام أن البيانات فصلية، ثم بين قوسين سنة بداية الفصول و q1 للفصل الأول. و نكتب :

```
gen t2=tq(2000q1)+t-1
```

- إعلام البرنامج بإظهار البيانات على شكل السنة و الفصل و هذا باستعمال التعليمة :

```
format %tqCCYY-!Qq t2
```

أمثلة :

```
. gen t2=tq(2000q1)+t-1
. format %tqCCYY-!Qq t2
. gen t3=tq(2000q1)+t-4
. format %tqCCYY-!Qq t3
. gen t22=tq(2000q1)+t-2
. format %tqCCYY-!Qq t22
. list t t2 t22 t3
```

	t	t2	t22	t3
1.	1	2000-Q1	1999-Q4	1999-Q2
2.	2	2000-Q2	2000-Q1	1999-Q3
3.	3	2000-Q3	2000-Q2	1999-Q4
4.	4	2000-Q4	2000-Q3	2000-Q1
5.	5	2001-Q1	2000-Q4	2000-Q2
6.	6	2001-Q2	2001-Q1	2000-Q3
7.	7	2001-Q3	2001-Q2	2000-Q4
8.	8	2001-Q4	2001-Q3	2001-Q1
9.	9	2002-Q1	2001-Q4	2001-Q2
10.	10	2002-Q2	2002-Q1	2001-Q3
11.	11	2002-Q3	2002-Q2	2001-Q4
12.	12	2002-Q4	2002-Q3	2002-Q1
13.	13	2003-Q1	2002-Q4	2002-Q2
14.	14	2003-Q2	2003-Q1	2002-Q3

2. إنشاء المتغيرات المتأخرة و الفروقات

قبل التطرق الى مختلف التعليمات الخاصة بالنماذج القياسية نوضح بعض الصيغ الخاصة بإنشاء متغيرات متأخرة، الفروقات انطلاقا من السلسلة الاصلية، وهنا لابد من استعمال التعليمات الخاصة بإنشاء المتغيرات generate أو gen و هذه بعض الحالات:

التعليمة	الهدف من التعليمة
gen y=L.x	من أجل إنشاء متغير متأخر بفترة زمنية واحدة للمتغير X و يحمل اسم y
gen y=L2.x	من أجل إنشاء متغير متأخر بفترتين زمنيتين للمتغير X و يحمل اسم y
gen y=F.x	من أجل إنشاء متغير يساوي X_{t+1} يحمل اسم y
gen y=F2.x	من أجل إنشاء متغير يساوي X_{t+2} يحمل اسم y
gen y=D.x	من أجل إنشاء متغير الفرق الاول ل X أي $(X_t - X_{t-1})$ يحمل اسم y
gen y=D2.x	من أجل إنشاء متغير الفرق الاول ل X أي $(X_t - X_{t-2})$ يحمل اسم y

3. التصريح بالبعد الزمني للبيانات

من بين أهم الخطوات التي يجب على الطالب القيام بهذا عند دراسة السلاسل الزمنية أو بيانات البانل في برنامج Stata هو التصريح أو اعلام البرنامج بالمتغير الذي يمثل البعد الزمني في الدراسة عكس برنامج Eviews الذي نعلمه بالبعد الزمني عند إنشاء السلسلة. و من اجل هذا نستعمل التعليمة التالية `tsset` متبوعة بالمتغير الذي يحتوي على الزمن ، ونكتب

```
tsset mois
```

حيث أن `mois` مثلا يمثل البعد الزمني فهي بيانات شهرية. و في حالة استعمال البيانات البانل فإنه يجب كتابة الصيغة التالية:

```
xtset mois pays
```

المحور الثاني : دراسة استقرارية السلاسل الزمنية

1. اختبار جذر الوحدة¹

1.1. اختبار ديكي فولر (1979)

يسمح هذا الاختبار بالكشف عن استقرارية سلسلة زمنية او لا و هذا بتحديد هل الاتجاه العام هو تحديدي او ستوكستيك.

أن النماذج التي تسمح بإنجاز هذه الاختبارات هي ثلاث. فأساس هذا الاختبار بسيط : اذا كانت الفرضية الصفرية $H_0: \phi_1=1$ تم قبولها في احدى النماذج الثلاث فان المسار هو اذن غير مستقر.

$$[1] x_t = \phi_1 x_{t-1} + \varepsilon_t$$

نموذج انحدار ذاتي من الدرجة 1

$$[2] x_t = \phi_1 x_{t-1} + \beta + \varepsilon_t$$

نموذج انحدار ذاتي مع وجود الثابت

$$[3] x_t = \phi_1 x_{t-1} + bt + c + \varepsilon_t$$

نموذج انحدار ذاتي مع وجود اتجاه عام

اذا كانت H_0 محققة فان السلسلة x_t غير مستقرة مهما كان النموذج المعتمد.

في النموذج الثالث اذا قبلنا الفرضية البديلة $H_1: \phi_1 < 1$ و معلمة β معنوية مختلفة عن الصفر اذن المسار هو من نوع TS، يمكن ارجاعه مستقر و هذا بحساب البواقي مقارنة بالاتجاه العام المقدر عن طريق المربعات الصغرى.

تحت الفرضية الصفرية فان عدة أمور إحصائية لا يمكن أن تطبق من أجل اختبارها خاصة ما تعلق بتوزيع ستيفودنت للمعلمة ϕ_1 فان ديكي فولر اقترح استعمال $(\hat{\phi}_1 - 1)$ بدل $\hat{\phi}_1$

اذن يمكن اختبار $H_0: \phi_1 = 1$ أو $H_0: \phi_1 - 1 = 0$

قواعد هذا الاختيار هي :

نقوم بتقدير عن طريق المربعات الصغرى معلمة ϕ_1 الممثلة ب $\hat{\phi}_1$ بالنسبة للنماذج 1 و 2 و 3 . هذا التقدير يوفر احصائية $t\hat{\phi}_1$ فاذا كانت قيمة هذه الإحصائية المحسوبة أكبر أو تساوي القيمة الجدولة اذن نقبل الفرضية الصفرية بوجود جذر الوحدة، فالمسار غير مستقر. ان برنامج Stata يقوم بحساب القيم الحرجة ل $t\hat{\phi}_1$

1.2. اختبار ديكي فولر الموسع

إن اختبار ديكي فولر الموضح سابقا يفترض أن حد الخطأ هو عبارة عن ضجيج أبيض إلا أنه لا يوجد أي سبب من أجل ان تكون هذه الفرضية محققة. و على هذا الاساس فان اختبار

¹ Bourbounais, R, (2004) Econométrie, DUNOD, p233.234.

ديكي فولر الموسع يأخذ بعين الاعتبار الارتباط الذاتي للأخطاء و هذا من خلال عرض AR(p-1) بالنسبة للأخطاء: و يصبح النموذج على شكل :

$$\text{modèle(4): } \Delta x_t = \rho x_{t-1} - \sum_{j=2}^{\rho} \phi_j \Delta x_{t-j+1} + \varepsilon_t$$

$$\text{modèle(5): } \Delta x_t = \rho x_{t-1} - \sum_{j=2}^{\rho} \phi_j \Delta x_{t-j+1} + c + \varepsilon_t$$

$$\text{modèle(6): } \Delta x_t = \rho x_{t-1} - \sum_{j=2}^{\rho} \phi_j \Delta x_{t-j+1} + c + b_t + \varepsilon_t$$

مع ε_t يكون iid

1.3. دراسة منحني الارتباط الذاتي

من أجل استغلال الارتباط الذاتي و الذي هو عبارة عن ارتباط متغير بقيمه السابقة نستعمل التعليمات corrgram . ان عدد التأخيرات يتحدد عن طريق النظرية اي مسار AIC و BIC أو الخبرة و الممارسة. و نكتب في نافذة البرنامج الخاصة بالتعليمات :

corrgram unemp lags(12)

و يكون شكل المخرجات للبرنامج على الشكل التالي.

. corrgram unemp, lags(12)

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]	[Partial	Autocor]			
1	0.9641	0.9650	182.2	0.0000						
2	0.8921	-0.6305	339.02	0.0000						
3	0.8045	0.1091	467.21	0.0000						
4	0.7184	0.0424	569.99	0.0000						
5	0.6473	0.0836	653.86	0.0000						
6	0.5892	-0.0989	723.72	0.0000						
7	0.5356	-0.0384	781.77	0.0000						
8	0.4827	0.0744	829.17	0.0000						
9	0.4385	0.1879	868.5	0.0000						
10	0.3984	-0.1832	901.14	0.0000						
11	0.3594	-0.1396	927.85	0.0000						
12	0.3219	0.0745	949.4	0.0000						

العمود الاول يمثل عدد التأخيرات هنا تم تحديدها ب 12 تأخير.

العمود الثاني AC يمثل الارتباط بين القيم الحالية لمتغير (معدل البطالة مثلا unemp) و قيمه للفصول الثلاث هو 0,8045 . يمكن استعمال AC من أجل تحديد قيم q في مسار MA(q) فقط في السلاسل الزمنية.

العمود الثالث PAC يمثل ان الارتباط بين القيم الحالية لمتغير (معدل البطالة unemp) و قيمه للفصول الثلاث هو 0.1091 بدون اثر التأخيرين السابقين. PAC لا يمكن ان يستعمل لتحديد p في مسار AR(p) الا في السلاسل المستقرة.

العمود الرابع يمثل احصائية Box-Pierce "اختبار Q" حيث ان الفرضية الصفرية اين كل الارتباطات الى غاية التأخير k تساوي الصفر. هذه السلسلة تمثل ارتباط ذاتي معنوي كما تمثله القيمة الاحتمالية Prob>Q حيث ان لكل k أصغر من 0.05 نرفض الفرضية الصفرية. التأخيرات ليست مرتبطة ذاتيا.

العمود الخامس يمثل منحنى AC يمثل تنازل بطيء للاتجاه العام و هذا يدل على عدم استقرارية السلسلة.


العمود السادس يمثل منحنى PAC و الذي يمثل نقاط بعد التأخير الثاني و هذا معناه ان التأخيرات الاخرى هي مرآة للتأخير الثاني.

من أجل استغلال سلسلتين زمنيتين نستعمل التعليمة $xcorr^2$ و نكتب

```
xcorr gdp unemp, lags(10) xlabel(-10(1)10,grid)
```

المنحنى التالي يمثل الارتباط بين معدل النمو الفصلي للدخل و معدل البطالة. عند استعمال $xcorr$ نضيف المتغير التابع أولا و المتغير التفسيري ثانيا.

² StataCorp, 2015, Stata time-series reference manual release 14, a stata press publication, college station, texas. P.899.



أو

xcorr gdp unemp, lags(10) table

عند التأخير 0، هناك ارتباط فوري سلبي بين معدل النمو للدخل و معدل البطالة. هذا معناه انخفاض في الدخل يؤدي الى الزيادة فوري في معدلات البطالة.

LAG	CORR	⁻¹ [Cross-correlation] ¹
-10	-0.1080	
-9	-0.1052	
-8	-0.1075	
-7	-0.1144	
-6	-0.1283	
-5	-0.1412	
-4	-0.1501	
-3	-0.1578	
-2	-0.1425	
-1	-0.1437	
0	-0.1853	
1	-0.1828	
2	-0.1685	
3	-0.1177	
4	-0.0716	
5	-0.0325	
6	-0.0111	
7	-0.0038	
8	0.0168	
9	0.0393	
10	0.0419	

في حالة كثرة التأخيرات هذا يمكن ان يزيد من الخطأ في التنبؤات، اما في حالة القلة فهذا يمكن ان يترك معلومات هامة جانبا. الخبرة، المعرفة و النظريات هي أفضل وسيلة لتحديد عدد التأخيرات اللازمة. كما ان هناك معايير المعلومات التي يمكن ان تحدد عدد التأخيرات المناسب. ثلاث معايير تسعمل : معيار المعلومات (SBIC (critère d'information bayésien de Schwarz ، معيار (AIC (Akaike، و معيار (HQIC (Hannan et quinn ، يمكن الحصول على كل هذه المعلومات باستعمال التعليلة varsoc التي سترها فيما بعد.

2. مثال حول دراسة الاستقرارية

في المثال التالي لدينا البيانات التالية:

YEARS	Y	DY
1970	5	.
1971	2	-3
1972	6	4
1973	1	-5
1974	7	6
1975	8	1
1976	5	-3
1977	5	0
1978	6	1
1979	3	-3
1980	3	0
1981	7	4
1982	8	1
1983	8	0
1984	8	0
1985	8	0
1986	1	-7
1987	2	1
1988	2	0
1989	3	1
1990	2	-1
1991	4	2
1992	3	-1
1993	2	-1
1994	1	-1
1995	1	0

نبدأ دائما بالنموذج الثالث بوجود اتجاه عام، إذا كانت قيمة $\phi_1 < 1$ و معلمة الاتجاه العام معنوية فإن المسار هو من نوع TS.

للقيام باختيار ديكي فولر الموسع ADF على برنامج Stata يجب اعلام البرنامج بمتغيرة الزمن و هي في هذا المثال YEARS من سنة 1971 الى 1995 و نكتب مايلي :

```
tsset YEARS
```


يظهر لنا البرنامج التأكيد التالي

```
. tsset YEARS
      time variable:  YEARS, 1970 to 1995
              delta:  1 unit
```

ثم نقوم باختبار ADF بالضغط على

Statistics / time series / Test / augmented Dickey-Fuller unit-roots test

ثم نبين المتغير المراد دراسة استقراريته و تحديد نوع النموذج 1 أو 2 أو 3 .



فيما يخص النموذج الثالث بوجود اتجاه عام نختار الخاصية Include trend term in regression مع اختيار display regression table و ترك التأخيرات بالصفر. كما يمكن الحصول على نفس النتائج من خلال كتابة التعليمة التالية :

```
dfuller Y, trend regress lags(0)
```

فالتعليمة dfuller لتنفيذ اختبار ديكي فولر الموسع على المتغيرة Y. الخاصية المضافة بعد الفاصلة trend لإضافة الاتجاه العام في الانحدار. الخاصية lags(0) لتحديد درجة التأخر، هنا التأخير يساوي صفر أي نستعمل البيانات على المستوى. و كذلك تفيد عدد الفروقات المدمجة في المتغيرات التفسيرية. الخاصية regress لإظهار نتائج التقدير بعد إجراء الاختبار.

المحور الثاني : دراسة استقرارية السلاسل الزمنية

Dickey-Fuller test for unit root Number of obs = 25

Test Statistic	Z(t) has t-distribution		
	1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-2.826	-2.500	-1.714

p-value for Z(t) = 0.0048

D.Y	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
Y					
L1.	-.5474359	.1936916	-2.83	0.010	-.9481175 - .1467543
_cons	2.248718	.9800106	2.29	0.031	.2214116 4.276024

نلاحظ في الجدول ان المتغير L1.Y معنوي لأن القيمة الاحتمالية لإحصائية سيودنت تساوي 0.010 و هي أصغر من 0.05.

أما الثابت فهي معنوية كذلك لان القيمة الاحتمالية لإحصائية سيودنت تساوي 0.031 و هي أصغر من 0.05.

و يوفر الجدول قيمة إحصائية Z(t) و هي أصغر من القيم الحرجة نرفض الفرضية الصفرية بوجود جذر الوحدة و منه السلسلة مستقرة. هنا لدينا -2.826 أصغر من القيم الثلاث (أي -2.500, -1.714, -1.319)

3. تطبيق حول الاستقرارية

كيف نفسير الجدول التالي من مخرجات البرنامج

```
. dfuller unemp, lag(5)
```

Augmented Dickey-Fuller test for unit root Number of obs = 187

Unit root	Test Statistic	Interpolated Dickey-Fuller		
		1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-2.597	-3.481	-2.884	-2.574

MacKinnon approximate p-value for Z(t) = 0.0936

```
. dfuller unempD1, lag(5)
```

Augmented Dickey-Fuller test for unit root Number of obs = 186

No unit root	Test Statistic	Interpolated Dickey-Fuller		
		1% Critical Value	5% Critical Value	10% Critical Value
Z(t)	-5.303	-3.481	-2.884	-2.574

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

20

الحل :

إن اختبار ديكي فولر من بين الاختبارات الأكثر استعمالاً لدراسة الاستقرارية. الفرضية الصفريية هي أن السلسلة تحتوي على جذر الوحدة. في الجدول اعلاه نلاحظ أن سلسلة البطالة لها جذر الوحدة لأنها توجد داخل المجال المقبول. من بين الطرق لمعالجة الاتجاه الستوكاستيك (جذر الوحدة) هو العمل بالفرق الأول للمتغير (الاختبار التالي ادناه).

المحور الثالث : نماذج ARIMA

1. تعريف

عندما تكون سلسلة Y_t غير مستقرة يجب القيام بالنمذجة بالاستعانة بالمسار $ARIMA(p,d,q)$ حيث أن d يمثل درجة الفروقات أو (التكامل)³.

1.1. نماذج الانحدار الذاتي AR

إن نموذج $AR(p)$ انحدار ذاتي من درجة p يعرف

$$y_t - \Phi_1 y_{t-1} - \Phi_2 y_{t-2} - \dots - \Phi_p y_{t-p} = \varepsilon_t$$

حيث أن $\Phi_1, \Phi_2, \dots, \Phi_p$ هي المعلمات سالبة أو موجبة التي نريد تقديرها

1.2. نماذج المتوسط المتحرك MA

نموذج $MA(q)$ من درجة q يعطى بالشكل التالي

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

حيث أن $\theta_1, \theta_2, \dots, \theta_q$ هي المعلمات التي نريد تقديرها.

إن نموذج $MA(q)$ له منحني الارتباط الذاتي بسيط محدد بالقيم المعنوية الاولى ل q و بمنحني بياني للارتباط الذاتي الجزئي للتأخيرات يتناقص هندسيا.

1.3. نماذج ARMA(p,q)

هي عبارة عن مزج بين المسارين السابقين الانحدار الذاتي $AR(p)$ و المتوسطات المتحركة $MA(q)$ و يرمز له ب $ARMA(p,q)$ و يكون على الشكل التالي:

$$y_t - \theta_1 y_{t-1} - \theta_2 y_{t-2} - \dots - \theta_p y_{t-p} = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

1.4. نماذج ARIMA(p,d,q)

إن مسار $ARIMA(p,d,q)$ هو عبارة عن autoregressive integrated moving average من درجة p,d,q بالنسبة للسلسلة y_t و تكتب على الشكل التالي:

$$(1 - \Phi_1 B - \dots - \Phi_p B^p) \nabla^d y_t = (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t$$

حيث أن B هو عبارة التأخير حيث ان $By_1 = y_{t-1}$ و $B^p y_t = y_{t-p}$ و أن ∇^d هو عبارة عن الفروقات من درجة d ($d \geq 0$) و هو موجب، (Φ_1, \dots, Φ_p) و $(\theta_1, \dots, \theta_q)$ هي معلمات يجب تقديرها.

أن السلسلة y_t غير مستقرة و السلسلة $w_t = \nabla^d y_t$ هي مستقرة.

³ Enders, W. 2004. Applied Econometric Time Series. 2nd ed. New York: Wiley. P 63.

إن تقدير معالم مسار ARIMA(p,d,q) للسلسلة غير المستقرة y_t يصبح تقدير معالم مسار ARMA(p, q) للسلسلة المستقرة w_t .

2. مثال لنماذج ARIMA

سنتناول في هذا المحور كيفية تقدير نماذج ARIMA (المتوسطات المتحركة) لسلسلة wpi. فبعد دراسة مختلف الحالات توصلنا الى النماذج التالية:

S. N°	ARIMA
1	ARIMA(1,1,1)
2	ARIMA(1,1,2)
3	ARIMA(1,1,3)
4	ARIMA(1,1,4)
5	ARIMA(1,1,5)
6	ARIMA(1,1,6)
7	ARIMA(1,2,1)
8	ARIMA(4,2,1)
9	ARIMA(9,2,1)


2.1. اختيار نماذج ARIMA

يقوم البرنامج بتحليل السلاسل الزمنية و اختيار المسار الانسب للتنبؤ الخاص بسلسلة wpi. و من أجل هذا نقوم بالضغط على :

Statistique/ tiems serie/ ARIMA

2.2. اختبار نموذج ARIMA(1,1,1)

تظهر نافذة بعد اتباع الخطوات السابقة و منه يجب تحديد خصائص نموذج ARIMA. فبعد تحديد نوع النموذج، نختار المتغير المدروس كمتغير تابع ثم نحدد درجة الانحدار الذاتي (p) درجة التكامل (d) و درجة المتوسطات المتحركة (q)



او كتابة التعليمة التالية:

arima wpi, arima(1,1,1)

Sample: 1960q2 - 1990q4
 Log likelihood = -135.3513
 Number of obs = 123
 Wald chi2(2) = 310.64
 Prob > chi2 = 0.0000

D.wpi	OPG		z	P> z	[95% Conf. Interval]	
	Coef.	Std. Err.				
wpi						
_cons	.7498197	.3340968	2.24	0.025	.0950019	1.404637
ARMA						
ar						
L1.	.8742288	.0545435	16.03	0.000	.7673256	.981132
ma						
L1.	-.4120458	.1000284	-4.12	0.000	-.6080979	-.2159938
/sigma	.7250436	.0368065	19.70	0.000	.6529042	.7971829

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

نلاحظ في الجدول أعلاه ان قيمة المعقولية العظمى يجب ان يكون كبيرا (نهمل الاشارة السالبة) و هنا القيمة تساوي 135,35 ونقارنها بقيم النماذج الاخرى .

اما معلمة الانحدار الذاتي AR يجب أن تكون أقل من الواحد(1) و معنوية عند 5% و في هذا المثال نلاحظ ان المعلمة معنوية من خلال احصائية ستيدنت و التي تساوي 16,03 و معلمة أقرب الى الواحد(0.874) و هذا معناه أن السلسلة wpi يمكن أن تكون غير مستقرة. أما فيما

يخص معلمة MA فتساوي (-0.412) . لدينا $Simma=0.725$ ، و لدينا أيضا في مخرجات البرنامج قيم AIC و BIC

2.3. مقارنة نماذج ARIMA

بعد الحصول على مختلف القيم للإحصائيات السابقة الخاصة بكل نموذج نقوم باختيار النموذج الانسب حسب:

- تحديد النموذج الذي تكون فيه معلمات AR و MA معنوية وأقل من الواحد، (في هذا المثال كل النماذج لها معلمات معنوية و أقل من الواحد و هذا معناه عدم استقرارية السلسلة)،
- تحديد النماذج حسب معيار AIC و BIC (النموذج الذي تكون فيه القيم صغيرة هو الافضل) و هنا نستنتج أن نموذج ARIMA(9,2 ;1) هو الافضل.



3. نموذج ARIMA مع وجود آثار الفصلية

بعد دراسة السلسلة بالفرق الاول، اختار Enders نموذج الفروقات بالغايريم من اجل ثبات التباين في فروقات السلاسل. المنحنى البياني التالي يوضح ذلك و من أجل ذلك نكتب:

twoway (tsline wpi)

twoway (tsline D.wpi)



يعطي لنا البرنامج المنحنيات التالية:



من خلال منحنى الارتباط الذاتي و الارتباط الذاتي الجزئي و نتائج التقديرات السابقة تم تحديد نموذج ARMA عند الفرق الاول للسلسلة اللوغاريتمية. ونكتب من أجل هذا

```
ac D.ln_wpi, ylabels(-.4(.2).6)
```

```
pac D.ln_wpi, ylabels(-.4(.2).6)
```



عند اضافة عبارة الارتباط الذاتي و عبارة MA(1) و MA(4) لتحديد اثار الفصلية. يصبح النموذج على الشكل التالي:

$$\Delta \ln(wpi_t) = \beta_0 + \rho_1 \{ \Delta \ln(wpi_{t-1}) - \beta_0 \} + \theta_1 \epsilon_{t-1} + \theta_4 \epsilon_{t-4} + \epsilon_t$$

و لتقدير النموذج في Stata نكتب

```
arima D.ln_wpi, ar(1) ma(1 4)
```

تكون مخرجات البرنامج على الشكل التالي :

ARIMA regression

Sample: 1960q2 - 1990q4 Number of obs = 123
 Wald chi2(3) = 333.60
 Log likelihood = 386.0336 Prob > chi2 = 0.0000

D.ln_wpi	OPG		z	P> z	[95% Conf. Interval]	
	Coef.	Std. Err.				
ln_wpi _cons	.0110493	.0048349	2.29	0.022	.0015731	.0205255
ARMA						
ar						
L1.	.7806991	.0944946	8.26	0.000	.5954931	.965905
ma						
L1.	-.3990039	.1258753	-3.17	0.002	-.6457149	-.1522928
L4.	.3090813	.1200945	2.57	0.010	.0737003	.5444622
/sigma	.0104394	.0004702	22.20	0.000	.0095178	.0113609

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

نلاحظ أن هناك ارتباط ذاتي عند المستوى يقدر ب0,781 وهناك تأثير سلبي في الفصل الأول (-0.399) و موجب في الفصل الرابع (0,309). و هذا مه قيمة احتمالية لاحصائية ستيودنت اصغر من 0,05.

المحور الرابع نماذج الانحدار الذاتي VAR ; VEC

1. نموذج VAR

1.1. تعريف

يطبق هذا النموذج في حالة غياب تكامل مشترك بين سلسلتين غير مستقرتين Y_{1t} و Y_{2t} و $Y_{1t} \sim I(1)$ و $Y_{2t} \sim I(1)$ و غياب وجود سببية بين السلسلتين المستقرتين ΔY_{1t} و ΔY_{2t} و $\Delta Y_{1t} \sim I(0)$ و $\Delta Y_{2t} \sim I(0)$ تسمح لنا بتقدير نموذج VAR. نموذج VAR شعاع الانحدار الذاتي ذات k متغير و p تاخير و نكتب $VAR(p)$

$$Y_t = \alpha_0 + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t$$

1.2. مثال بتغيرين تفسريين

في هذا المثال سنرى كيفية تطبيق نموذج شعاع الانحدار الذاتي مع ثلاث (3) متغيرات و هي كل من الزمنية من سنة 1980 الى 2010.

	obs	EDU	GDP	INV
1.	1980	60	67	5
2.	1981	65	65	6
3.	1982	66	67	7
4.	1983	67	54	6
5.	1984	65	54	12
6.	1985	67	56	12
7.	1986	64	53	13
8.	1987	67	45	9
9.	1988	68	45	13
10.	1989	67	56	12
11.	1990	67	56	5
12.	1991	68	45	6
13.	1992	69	45	7
14.	1993	70	78	3
15.	1994	60	65	12
16.	1995	67	65	13
17.	1996	68	67	14
18.	1997	69	78	23
19.	1998	69	56	45
20.	1999	70	89	15
21.	2000	71	45	12
22.	2001	71.5	67	4
23.	2002	72	65	7
24.	2003	71.5	68	23
25.	2004	72.3	90	22
26.	2005	74	67	21
27.	2006	74	78	18
28.	2007	75	78	19
29.	2008	75.5	89	25
30.	2009	75	56	21
31.	2010	76.5	90	12

إذا كانت المتغيرات غير مستقرة عند المستوى نذهب لدراسة الاستقرارية عند الفروقات.
مراحل اختيار النموذج

- نموذج VAR(p) يحتوي على p تأخير لكل متغير في كل معادلة.
- في نموذج بمتغيرين فان عدد المعاملات في كل معادلة هو $1 + 2p$ ، العدد الاجمالي هو إذن $2(1 + 2p) = 2 + 4p$
- في نموذج ب k متغير فان عدد المعاملات في كل معادلة هو $1 + kp$ ، العدد الاجمالي هو إذن $k(1 + 2p) = k + 2kp$
- كيف يمكن تحديد p ؟

المقاربة المشتركة هي معيار المعلومات خاصة AIC
نختار الاقل عدد

2. كيفية التنفيذ على البرنامج

2.1 تحديد درجة التأخير

من أجل الحصول على درجات الابطاء الخاصة بنموذج VAR أو VECM نستعمل التعليمة varsoc . و من أجل حساب المعايير للمتغيرين X و Y الى الحد الاقصى للتأخيرات نستعمل الخصية maxlag(pmax) و نكتب

varsoc x y, maxlag(pmax)

و التي تعطي لنا الجدول التالي

. varsoc rate gdp, maxlag(8)

Selection-order criteria
Sample: 1955q3 - 2013q4

Number of obs = 234

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	-908.041				8.18559	7.77813	7.79004	7.80766
1	-882.051	51.979	4	0.000	6.78308	7.59018	7.62591*	7.67878*
2	-876.011	12.081	4	0.017	6.66587*	7.57274*	7.63228	7.7204
3	-874.997	2.0279	4	0.731	6.83834	7.59826	7.68162	7.80499
4	-869.617	10.76*	4	0.029	6.75844	7.58647	7.69364	7.85226
5	-867.435	4.3637	4	0.359	6.86471	7.60201	7.73299	7.92687
6	-865.116	4.6376	4	0.327	6.9647	7.61638	7.77118	8.0003
7	-861.706	6.8213	4	0.146	7.00073	7.62142	7.80003	8.06441
8	-861.084	1.2442	4	0.871	7.20695	7.65029	7.85272	8.15234

Endogenous: rate gdp
Exogenous: _cons

نلاحظ في النتائج أن معيار AIC اختار $p = 3$ و معيار BIC اختار $p = 2$. نسجل هنا ان قيمة AIC من اجل $p = 3$ في الجدول هي $AIC=7.553$ و هي مختلفة عندما قمنا بتقدير نموذج VAR (3) ($AIC=7.553$) توجد المعلومة عند تقدير النموذج في اعلى الجدول على اليمين.

هذا الاختلاف ناتج انه من اجل مقارنة AIC فان كل التقديرات تنتج من عينة مشتركة، و في هذه الحالة فانها تحذف ثمانية مشاهدات الاولى لانه تم تحديد التأخير ب 8. إذن التعليلة varsoc صحيحة.

1.3. دراسة السببية لقرانجر Granger

ليكن لدينا نموذج $VAR(p)$ مع سلسلتين Y_{1t} و Y_{2t} مستقرتين :

$$\begin{cases} Y_{1t} = \gamma_1 + \alpha_{11}y_{1t-1} + \alpha_{12}y_{1t-2} + \dots + \alpha_{1p}y_{1t-p} + \beta_{11}y_{2t-1} + \beta_{12}y_{2t-2} + \dots + \beta_{1p}y_{2t-p} + \varepsilon_{1t} \\ Y_{2t} = \gamma_2 + \alpha_{21}y_{1t-1} + \alpha_{22}y_{1t-2} + \dots + \alpha_{2p}y_{1t-p} + \beta_{21}y_{2t-1} + \beta_{22}y_{2t-2} + \dots + \beta_{2p}y_{2t-p} + \varepsilon_{2t} \end{cases}$$

يقتضي هذا الاختبار وضع فرضيتين:

- Y_{2t} لا يسبب Y_{1t} إذا ما تم قبول الفرضية الصفرية التالية $\beta_{11} = \beta_{12} = \beta_{13} = \dots = \beta_{1p} = 0$
- Y_{1t} لا يسبب Y_{2t} إذا ما تم قبول الفرضية الصفرية التالية $\alpha_{21} = \alpha_{22} = \alpha_{23} = \dots = \alpha_{2p} = 0$

يعتمد هذا الاختبار على اختبار الفرضيتين السابقتين بالاستعانة باختبار فيشر العادي.

و من أجل اختبار السببية حسب قرانجر نستعمل التعليلة vargranger بعد تقدير نموذج var او svar و نكتب

vargranger

و نتحصل على الجدول التالي للمثال السابق

جدول السببية الخاص بمثال edu inv

3. دوال الاستجابة

3.1. مفهوم دوال الاستجابة⁴

سنرى في هذه النقطة كيفية استخراج دوال الاستجابة و تفسيرها في برنامج Stata و نعتمد على مثال يحتوى على متغير gdp و rate.

		Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
rate	rate						
	L1.	-.0687148	.0650433	-1.06	0.291	-.1961972	.0587677
	L2.	.0106681	.0624896	0.17	0.864	-.1118092	.1331454
	gdp						
	L1.	.0779384	.0140999	5.53	0.000	.0503032	.1055737
	L2.	.0037657	.0150392	0.25	0.802	-.0257106	.0332421
	_cons	-.2639241	.0718976	-3.67	0.000	-.4048407	-.1230075
gdp	rate						
	L1.	-.6844941	.2904269	-2.36	0.018	-1.25372	-.1152678
	L2.	-.7395324	.2790243	-2.65	0.008	-1.28641	-.1926549
	gdp						
	L1.	.3160889	.0629578	5.02	0.000	.192694	.4394839
	L2.	.190147	.0671521	2.83	0.005	.0585313	.3217626
	_cons	1.579774	.3210322	4.92	0.000	.950562	2.208985

التفسير يصعب تفسير العدد الكبير للمعاملات لنموذج VAR لذا فإن أهم أدوات التفسير هي

دوال الاستجابة Réponses impulsionnelles

- تحليل دوال الاستجابة في حالة (1) VAR بدون ثابت

$$y_t = \alpha_{11} y_{t-1} + \beta_{11} x_{t-1} + e_{1t}$$

$$x_t = \alpha_{21} y_{t-1} + \beta_{21} x_{t-1} + e_{2t}$$

ان دوال الاستجابة تعبر عن المسار الزمني ل y و x استجابة لصددمات.

ان الاخطاء يمكن ان تكون مرتبطة لذا يجب orthogonalisons

$$e_{1t} = u_{1t}$$

$$e_{2t} = \rho e_{1t} + u_{2t}$$

$$= \rho u_{1t} + u_{2t}$$

النموذج المتعامد Orthogonalized Model

⁴ Greene Wilam, (2002) ,Econometric analysis, Upper Saddle River, New Jersey, FIFTH EDITION, p. 593.594

$$y_t = \alpha_{11} y_{t-1} + \beta_{11} x_{t-1} + u_{1t}$$

$$x_t = \alpha_{21} y_{t-1} + \beta_{21} x_{t-1} + \rho u_{1t} + u_{2t}$$

إن الصدمات u_1 و u_2 غير مرتبطة إذن فان :

- الصدمة على y تؤثر على y و x خلال الفترة t .
- الصدمة على x لا تؤثر على x خلال الفترة t .

فدوال الاستجابة هي مسارات الزمنية ل y و x استجابة لصدمات u_1 و u_2 .

نفترض أن $y = 0$ و $x = 0$ و نحدد $u_1 = 1$ فان أثر y و x

$$y_1 = \alpha_{11} 0 + \beta_{11} 0 + 1 = 1$$

$$x_1 = \alpha_{21} 0 + \beta_{21} 0 + \rho 1 = \rho$$

$$y_2 = \alpha_{11} y_1 + \beta_{11} x_1 = \alpha_{11} + \beta_{11} \rho$$

$$x_2 = \alpha_{21} y_1 + \beta_{21} x_1 = \alpha_{21} + \beta_{21} \rho$$

$$y_3 = \alpha_{11} y_2 + \beta_{11} x_2 = \alpha_{11} (\alpha_{11} + \beta_{11} \rho) + \beta_{11} (\alpha_{21} + \beta_{21} \rho)$$

$$x_3 = \alpha_{21} y_2 + \beta_{21} x_2 = \alpha_{21} (\alpha_{11} + \beta_{11} \rho) + \beta_{21} (\alpha_{21} + \beta_{21} \rho)$$

فدوال الاستجابة هي مسارات الزمنية ل y و x استجابة لصدمات u_1 و u_2 و تم الحصول عليها بهذه المعادلات التراجعية. و هي بدلالة معاملات النموذج VAR المقدر .

أثر الصدمات على المتغيرات

في نموذج بمتغيرين، هناك 4 دوال استجابة.


- أثر على y للصدمة على y (u_1)
- أثر على y للصدمة على x (u_2)
- أثر على x للصدمة على y (u_1)
- أثر على x للصدمة على x (u_2)

في نموذج ب k متغير، هناك k^2 دالة استجابة.

3.2. تنفيذ دوال الاستجابة على برنامج Stata

ان برنامج Stata يحسب اليا لدوال الاستجابة باستعمال التعليمة `varbasic` ، فتنشأ مصفوفة $k \times k$ لدوال الاستجابة.

GDP/Interest Rate Example



التفسير

تسمية المنحنى ب "Graphs by irfname, impulse variable, and response variable" : معناه

- impulse variable معناه مصدر الصدمة
- response variable معناه المتغير الاستجابة
- في الاعلى على اليسار "varbasic, gdp, gdp" معناه أثر لصدمة على gdp على مسار الزمني ل gdp
- في الاعلى على اليمين "varbasic, gdp, rate" معناه أثر صدمة gdp على المسار الزمني rate.
- في الاسفل على اليسار «varbasic, rate, gdp» معناه أثر صدمة rate على المسار الزمني gdp.
- في الاسفل على اليمين (varbasic, rate, rate) معناه أثر صدمة rate على المسار الزمني rate.

ملاحظة: إن المنحنيات السابقة تتم إنشائها بنفس السلم لذا يصعب قراءتها لذا من الافضل إنشاء منحنيات لكل استجابة .


و من أجل هذا نكتب

Irf graph oirf, impulse(gdp) response (rate)

و هذا يسمح بإنشاء استجابة لأثر صدمة الدخل على مسار نسبة الفائدة.


GDP on GDP

. irf graph oirf, impulse(gdp) response(gdp)




GDP on Interest Rates

. irf graph oirf, impulse(gdp) response(rate)




Interest Rates on Interest Rates

. irf graph oirf, impulse(rate) response(rate)



Interest Rates on Interest Rates

. irf graph oirf, impulse(rate) response(rate)



4. مثال ثاني نموذج VAR

4.1. تقديم البيانات

في هذا المثال سنستعين بمثال يتم تحميله من ملف Excel و الذي يحتوي على البيانات التالية :

- معدل الصرف TC
- لوغاريتم معدل الصرف LTC
- معدل المؤشر للبنك المركزي TD
- الكتلة النقدية BM
- لوغاريتم الكتلة النقدية LBM

- الفرق الاول الكتلة النقدية DLBM
- نسبة التضخم TI

كما أن البيانات هي بيانات شهرية من جانفي 2001 الى ديسمبر 2010 و تحتوي على 132 مشاهدة، لذا كان من الضروري إضافة عمود في ملف Excel يمثل الزمن و يحمل اسم Mois مثلا .

ملاحظة : البيانات الزمنية في برنامج Stata لها خصية و أن كل شهر يمثل برقم و ان رقم 1 يمثل سنة 1960 و منه فإن شهر جانفي 2001 نتحصل عليه عن طريق العملية التالية:
41=1960-2001

نضرب العدد 41 في 12 شهر و هذا يساوي 492

و منه فإن شهر جانفي 2001 يمثل بالعدد 492 و هكذا نضيف واحد لكل شهر الى غاية تكوين سلسلة ل 132 مشاهدة تكون اخرتها ديسمبر 2011.

و بعد الانتهاء من تكملة بيانات الزمن في ملف Excel يتم تحميله الى البرنامج حسب الخطوات التالية:

- بعد فتح البرنامج نضغط على File/import/Excel
- بعدها نبحث عن الملف (أنظر الصورة)
- و بعدها نقوم بتغيير نمط المتغير الزمني (الذي كان عبارة عن أرقام تبدأ ب 492....) و نكتب التعليمة التالية :

```
format %tmMonth_CCYY Mois
```

و الان نعلم البرنامج بالمتغير الذي يمثل الزمن و هذا باستعمال التعليمة التالية

```
tsset Mois
```

و يتم التأكيد على هذا بظهور النتيجة التالية

```
. tsset Mois
      time variable:  Mois, January 2001 to December 2011
      delta:         1 month
```

4.2. الخصائص و التطور البياني للسلسلة

• التوزيع الطبيعي :

أول شيء نبدأ به معرفة ما إذا كانت السلسلة تتبع التوزيع الطبيعي أو لا و نستعمل التعليمة التالية

sktest TD BM TI TC

و نتحصل على النتائج التالية :

. sktest TD BM TI TC

Variable	Obs	Skewness/Kurtosis tests for Normality			
		Pr(Skewness)	Pr(Kurtosis)	adj chi2(2)	joint Prob>chi2
TD	132	0.0000	0.0084	29.53	0.0000
BM	132	0.0001	0.4165	13.00	0.0015
TI	132	0.0000	0.0000	.	0.0000
TC	132	0.0000	0.0000	.	0.0000


من خلال الجدول نلاحظ.....

• التمثيل البياني

كما أنه يمكن انجاز التمثيل البياني لكل سلسلة من اجل معرفة تطور البيانات خلال الزمن و هذا بكتابة التعليمة التالية :

twoway (tsline TD)

و نتحصل على المنحى التالي :



4.3. المنهج القياسي

و من خلاله سنتطرق الى كل من :

- دراسة الاستقرارية
- تحديد التأخير الامثل و تقدير النموذج
- اختبار السببية

- دراسة ديناميكية نموذج VAR

أ- المنحنى البياني *corrélogramme*

يمكن استخراج المنحنى البياني للارتباط الذاتي من خلال التعليمة التالية

corrgram TD, lags(11)

الكتابة بعد الفاصلة عبارة عن خصية إضافية نطلب من خلالها للبرنامج إظهار التمثيل الباني الى غاية التأخير 11 و في حالة حذفه فإن التمثيل يتوقف عند عدد معين من التأخيرات.

نتحصل على التمثيل التالي للسلسلة TD

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	0.9193	0.9226	114.12	0.0000						
2	0.8353	-0.0597	209.04	0.0000						
3	0.7688	0.1221	290.1	0.0000						
4	0.7024	-0.0370	358.27	0.0000						
5	0.6109	-0.2141	410.26	0.0000						
6	0.5112	-0.0200	446.94	0.0000						
7	0.4134	-0.0911	471.12	0.0000						
8	0.3290	0.0711	486.56	0.0000						
9	0.2470	0.0023	495.34	0.0000						
10	0.1653	-0.0225	499.3	0.0000						
11	0.0830	-0.0408	500.31	0.0000						

نلاحظ هنا أن الجدول يشمل على سبعة (7) أعمدة ، فالعمود الاول يمثل عدد التأخيرات LAG ، و بعدها احصائية الارتباط الذاتي AC، ثم تليها احصائية الارتباط الذاتي الجزئي PAC، و بعدها احصائية Q لتليها القيمة الاحتمالية لنفس الاحصائية ، و في الاخير نجد رسمين للتمثيل البياني ل AC و PAC

ب- دراسة الاستقرار

• اختبار ديكي فولر و الذي سبق ذكره في المثال السابق و هنا نكتب

dfuller TD, trend regress lags(0)

نتحصل على البيانات التالية:

المحور الرابع نماذج الانحدار الذاتي VAR ; VEC

Dickey-Fuller test for unit root Number of obs = 131

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z (t)	-2.495	-4.030	-3.446

MacKinnon approximate p-value for Z(t) = 0.3306

D.TD	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
TD						
L1.	-.07748	.0310569	-2.49	0.014	-.1389313	-.0160287
_trend	-.0003415	.0284266	-0.01	0.990	-.0565883	.0559054
_cons	2.623679	2.789114	0.94	0.349	-2.895059	8.142416

من خلال الجدول التالي نلاحظ احصائية $Z(t) = -2.495$ و هي بالقيمة المطلقة أصغر من قيم الحرجة عند المستويات الثلاث. و منه فإننا لا نستطيع رفض الفرضية الصفرية التي تنص على وجود جذر الوحدة أي ان السلسلة غير مستقرة. إضافة لهذا فإن الجدول يوفر لنا معلمات المتغيرات مع قيم ستيودنت الخاصة بها حيث ان معلمة الاتجاه العام $_trend$ تساوي -0.00034 مع القيمة الاحتمالية لاحصائية ستيودنت (0.99) اكبر من 0.05 و منه فاننا نرفض النموذج الثلاث الذي ينص على وجود اتجاه عام في النموذج. كما يوفر لنا قيم الخاصة بالثابت و المتغير المبطن بدرجة واحدة L1.TD

- اختبار فليب بيرون و هو اختبار لوجود جذر الوحدة و نكتب التعليمة التالية

pperron TD, lags(11)

Phillips-Perron test for unit root Number of obs = 131
Newey-West lags = 11

Test Statistic	Interpolated Dickey-Fuller		
	1% Critical Value	5% Critical Value	10% Critical Value
Z (rho)	-9.924	-19.903	-13.762
Z (t)	-2.580	-3.500	-2.888

MacKinnon approximate p-value for Z(t) = 0.0972

ج. تحديد التأخير الامثل

من أجل تحديد التأخير الامثل لمتغير ما أو للنموذج نستعمل التعليمة التالية varsoc متبوعة باسم المتغير و نكتب :

varsoc TD

نتحصل على جدول المخرجات التالي:

Selection-order criteria

Sample: May 2001 - December 2011

Number of obs = 128

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	-626.263				1056.91	9.80098	9.81003	9.82326
1	-497.466	257.59*	1	0.000	143.492*	7.80415*	7.82226*	7.84871*
2	-497.208	.51462	1	0.473	145.167	7.81576	7.84291	7.8826
3	-496.226	1.9643	1	0.161	145.21	7.81603	7.85225	7.90516
4	-496.135	.18336	1	0.668	147.288	7.83023	7.87549	7.94163

Endogenous: TD

Exogenous: _cons

يتضح في الجدول أعلاه وجود عدة احصائيات و هي :

- العمود الاول خاص بالتأخيرات lag و يأخذ البرنامج تلقائيا عدد التأخيرات بأربع (4) و يمكن تحديد هذا العدد بإضافة الخاصية maxlag(n) و يعوض n بالعدد الذي نريده كأقصى تأخير مثلا 7
- العمود الثاني خاص باحصائية لوغار يتم المعقولة العظمى LL
- العمود الثالث خاص بنسبة المعقولة العظمى LR
- العمود الرابع يمثل درجات الحرية df
- العمود الخامس يمثل p.....
- العمود السادس يشمل على احصائية العلاقة النهائية للأخطاء المتنبئ بها FPE
- العمود السابع خاص بمعيار AIC Akaike
- العمود الثامن خاص بمعيار HQIC Hannan & Quinn
- العمود الاخير خاص بمعيار SBIC Schwarz

و من خلال الجدول نلاحظ وجود الاشارة * أمام بعض القيم و هذا ما يدل على التأخير الامثل حسب كل معيار و هنا فان التأخير الامثل للمتغير المدروس هو 1. في بعض الحالات فان معيار يحدد تأخيرا مخالفا للاخر.

و يمكن استعمال هذه التعليمة بعد تقدير نموذج var أو vecm و هذا بكتابة التعليمة التالية

varsoc TD BM TI TC

المحور الرابع نماذج الانحدار الذاتي VAR ; VEC

```

. var TD BM TI TC
Vector autoregression

Sample: March 2001 - December 2011      Number of obs   =      130
Log likelihood = -3521.019                AIC              =   54.72336
FPE           = 6.86e+18                   HQIC             =   55.04603
Det(Sigma_ml) = 3.94e+18                   SBIC             =   55.51745

Equation      Parms      RMSE      R-sq      chi2      P>chi2
-----
TD            9          11.4192   0.8916   1068.995   0.0000
BM            9          15280.4   0.9941   21961.03   0.0000
TI            9          4.23944   0.1144   16.79535   0.0323
TC            9          3170.87   0.0067   .8726173   0.9989
    
```

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
TD						
TD						
L1.	.8813534	.0869362	10.14	0.000	.7109616	1.051745
L2.	-.0121694	.0824701	-0.15	0.883	-.1738078	.1494689
BM						
L1.	.0000652	.0000635	1.03	0.304	-.0000592	.0001896
L2.	-.0000657	.0000646	-1.02	0.309	-.0001923	.0000609
TI						
L1.	.7643729	.2340052	3.27	0.001	.3057311	1.223015
L2.	.3797031	.2166027	1.75	0.080	-.0448305	.8042366
TC						
L1.	.0000293	.0003165	0.09	0.926	-.0005911	.0006497
L2.	-.0001895	.0003166	-0.60	0.550	-.00081	.0004311
_cons	2.542222	2.115022	1.20	0.229	-1.603146	6.68759
BM						
TD						
L1.	-259.4189	116.3313	-2.23	0.026	-487.424	-31.4138
L2.	224.1518	110.3551	2.03	0.042	7.859833	440.4438
BM						
L1.	.6682446	.0849134	7.87	0.000	.5018174	.8346718
L2.	.3605681	.0864274	4.17	0.000	.1911735	.5299627
TI						
L1.	-34.09958	313.1277	-0.11	0.913	-647.8185	579.6193
L2.	221.3307	289.8411	0.76	0.445	-346.7473	789.4087
TC						
L1.	-.1369426	.4235528	-0.32	0.746	-.9670908	.6932055
L2.	-.1203859	.4236654	-0.28	0.776	-.9507549	.7099831
_cons	2108.921	2830.16	0.75	0.456	-3438.089	7655.932
TI						
TD						
L1.	.0276659	.0322754	0.86	0.391	-.0355927	.0909244
L2.	.0046341	.0306173	0.15	0.880	-.0553747	.0646429
BM						
L1.	3.15e-06	.0000236	0.13	0.893	-.000043	.0000493
L2.	-4.01e-06	.000024	-0.17	0.867	-.000051	.000043
TI						
L1.	.1868687	.0868753	2.15	0.031	.0165963	.3571411
L2.	-.162036	.0804145	-2.02	0.044	-.3196456	-.0044264
TC						
L1.	-.0000377	.0001175	-0.32	0.749	-.000268	.0001926
L2.	-.0000469	.0001175	-0.40	0.690	-.0002772	.0001835
_cons	.6778296	.7852096	0.86	0.388	-.8611528	2.216812
TC						
TD						
L1.	.0950284	24.14027	0.00	0.997	-47.21904	47.4091
L2.	-5.927577	22.90013	-0.26	0.796	-50.81102	38.95586
BM						
L1.	-.0037723	.0176207	-0.21	0.830	-.0383081	.0307635
L2.	.0035581	.0179348	0.20	0.843	-.0315936	.0387097
TI						
L1.	-14.93149	64.97812	-0.23	0.818	-142.2863	112.4233
L2.	-8.184072	60.14584	-0.14	0.892	-126.0678	109.6996
TC						
L1.	-.0192469	.0878928	-0.22	0.827	-.1915136	.1530198
L2.	-.0197635	.0879162	-0.22	0.822	-.192076	.152549
_cons	1225.173	587.2955	2.09	0.037	74.09524	2376.251

د. دراسة السببية لقرانجر Granger

و تستعمل هذه التعليمة بعد تقدير نموذج var او svar و نكتب

vargranger

و نتحصل على جدول المخرجات التالي:

Granger causality Wald tests

Equation	Excluded	chi2	df	Prob > chi2
TD	TI	12.368	2	0.002
TD	LTC	.33488	2	0.846
TD	DLBM	.43643	2	0.804
TD	ALL	16.275	6	0.012
TI	TD	3.0035	2	0.223
TI	LTC	17.966	2	0.000
TI	DLBM	2.2969	2	0.317
TI	ALL	32.484	6	0.000
LTC	TD	.32401	2	0.850
LTC	TI	2.7851	2	0.248
LTC	DLBM	.614	2	0.736
LTC	ALL	3.8808	6	0.693
DLBM	TD	3.2643	2	0.196
DLBM	TI	1.9981	2	0.368
DLBM	LTC	9.3508	2	0.009
DLBM	ALL	14.177	6	0.028

يوفر لنا احصائية wald و منه يمكن معرفة من يسبب الاخر حسب ما رأيناه فيما سبق عند عرض سببية قرانجر.

و من اجل الحصول على قيمنكتب التعليمة varstable بعد تقدير النموذج

varstable

و نتحصل على الجدول التالي :

Eigenvalue stability condition

Eigenvalue	Modulus
.9003692	.900369
.7666697 + .02768365i	.767169
.7666697 - .02768365i	.767169
.04181293 + .484051i	.485854
.04181293 - .484051i	.485854
-.334476 + .02021665i	.335086
-.334476 - .02021665i	.335086
.05773717	.057737

All the eigenvalues lie inside the unit circle.

VAR satisfies stability condition.

و من أجل معرفة هل تتبع السلاسل التوزيع الطبيعي نستعمل التعليمة التالية:

varnorm

و نتحصل على الاحصائيات التالية الخاصة بكل متغير

Jarque-Bera test

Equation	chi2	df	Prob > chi2
TD	1307.671	2	0.00000
BM	220.779	2	0.00000
TI	3502.323	2	0.00000
TC	8.1e+04	2	0.00000
ALL	8.6e+04	8	0.00000

Skewness test

Equation	Skewness	chi2	df	Prob > chi2
TD	-1.3496	39.462	1	0.00000
BM	.1561	0.528	1	0.46746
TI	2.9649	190.465	1	0.00000
TC	10.964	2604.372	1	0.00000
ALL		2834.827	4	0.00000


Kurtosis test

Equation	Kurtosis	chi2	df	Prob > chi2
TD	18.301	1268.208	1	0.00000
BM	9.3767	220.251	1	0.00000
TI	27.727	3311.857	1	0.00000
TC	123.43	7.9e+04	1	0.00000
ALL		8.3e+04	4	0.00000

هـ. دوال الاستجابة

نكتب التعليمة varbasic متبوعة بالمتغيرات التالية TD BM TI TC و نتحصل على :

المحور الرابع نماذج الانحدار الذاتي VAR ; VEC



و. التكامل المشترك باستعمال اختبار جوهنسن

نستعمل التعليمة vecrank متبوعة بالمتغيرات المراد دراستها . و نتحصل على الجدول التالي:

```
. vecrank TD BM TI TC
```

Johansen tests for cointegration

Trend: constant Number of obs = 130
Sample: March 2001 - December 2011 Lags = 2

maximum				5%	
rank	parms	LL	eigenvalue	trace statistic	critical value
0	20	-3598.5083	.	154.9794	47.21
1	27	-3560.531	0.44249	79.0248	29.68
2	32	-3532.5579	0.34972	23.0786	15.41
3	35	-3524.5789	0.11552	7.1207	3.76
4	36	-3521.0186	0.05330		

تحتوي الجدول على قيم الاحصائية للاثر و القيم الحرجة عند 5 بالمئة.

1. تطبيق 1 حول تفسير جدول التأخيرات

Selection-order criteria
Sample: 1959q4 - 2005q1

Number of obs = 182

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	-1294.75				5293.32	14.25	14.2642	14.2852
1	-467.289	1654.9	4	0.000	.622031	5.20098	5.2438	5.30661
2	-401.381	131.82	4	0.000	.315041	4.52067	4.59204	4.69672*
3	-396.232	10.299	4	0.036	.311102	4.50804	4.60798	4.75451
4	-385.514	21.435*	4	0.000	.288988*	4.43422*	4.56268*	4.7511
5	-383.92	3.1886	4	0.527	.296769	4.46066	4.61766	4.84796
6	-381.135	5.5701	4	0.234	.300816	4.47401	4.65956	4.93173
7	-379.062	4.1456	4	0.387	.307335	4.49519	4.70929	5.02332
8	-375.483	7.1585	4	0.128	.308865	4.49981	4.74246	5.09836
9	-370.817	9.3311	4	0.053	.306748	4.4925	4.76369	5.16147
10	-370.585	.46392	4	0.977	.319888	4.53391	4.83364	5.27329

Endogenous: gdp cpi
Exogenous: cons

- عندما تكون المعايير الثلاث متفقة فان اختيار يكون سهل لكن ماذا يحدث عندما تكون النتائج متناقضة؟

بعض الدراسات تنصح عند استعمال نموذج VAR ان معيار AIC يكون اكثر دقة في حالة البيانات الشهرية ، اما معيار HQIC يوظف أفضل مع البيانات الفصلية على عينات تفوق 120 مشاهدة ، وأن معيار SBIC يكون افضل مع اي حجم للعينة للبيانات الفصلية (في حالة نماذج CVE) في هذا المثال لدينا بيانات فصلية مع عينة تتكون من 180 مشاهدة إذن معيار HQIC يعطي تاخير ب أربع درجات و هذا ما اعطاه كذلك معيار AIC

المحور الخامس: نماذج ARCH ; GARCH

1. نماذج ARCH , GARCH

1.1. تعريف

سنرى في هذا المحور كيفية استعمال برنامج Stata من أجل تقدير عدة نماذج حيث يكون التباين المتغير المفسر يتغير عبر الزمن و هي عادة تسمى بنماذج ARCH.

ففي هذه النماذج يتم عادة تجميع الفترات ذات التقلبات القوية في جهة و التقلبات الضعيفة في جهة أخرى. و تقوم نماذج ARCH بتقدير التقلبات المستقبلية انطلاقا من التقلبات السابقة.

نماذج ARCH او GARCH هي نماذج الهدف منها هو نمذجة التباين (variance) ، واكثر استخدامها يكون في نماذج البيانات المالية، لان الاتجاه الحديث لدى المستثمرين لا ينصب فقط على دراسة والتنبؤ بالعوائد المتوقعة من الاسهم والسندات في اسواق المال، وانما يهتمون ايضا بعنصر المخاطرة او عدم التأكد (uncertainty) ، ولدراسة عدم التأكد فنحن بحاجة الى نماذج خاصة تتعامل مع تقلب (volatility) قيم الاسهم عبر سلسلة زمنية او ما يمكن ان نطلق عليه بتباين السلسلة (variance) ، والنماذج التي تتعامل مع هذا النوع من التباين تنتمي الى ما يمكن تسميته بأسرة نماذج ARCH.

وكما هو معلوم في التحليل القياسي التقليدي ان تباين الحد العشوائي يفترض ان يكون ثابتا عبر الزمن او ما يعرف بفرضية ثبات التباين (homoskedasticity assumption) ، ولكن في البيانات المالية وايضا البيانات الاقتصادية الاخرى غالبا لا يتحقق هذا الشرط حيث يظهر تباين وتقلب مختلف في فترات السلسلة، ولو اخذنا على سبيل المثال أي سلسلة لاحد الاسهم في اسواق المال لوجدنا ان هناك تقلب عالي واحيانا تقلب منخفض عبر الفترات المختلفة للسلسلة، وهذا يعني ان القيم المتوقعة لحد الخطاء العشوائي ستكون اكبر او اقل عبر الفترات المختلفة. وفترات التقلب في العرف المالي تعني فترات المخاطرة او عدم التأكد، ومعروف في التحليل المالي ان فترات المخاطرة (وهي التقلب الكبير او التباين الكبير) تتركز في فترات معينة ويعقبها فترات اقل تقلبا (اقل تباين) وايضا تتركز في فترات معينة، وهذه الانماط تعرف لدى المحللين الماليين بفترات الهيجان (wild) وتاخذ صورة قرن الثور، وفترات الركود او السبات (calm) وتاخذ صورة الدب. وعلى ذلك يستنتجون ان التغيرات الكبيرة في عوائد الاسهم يعقبها تغيرات اخرى مقابلة لها. وهذا ما يعرف في تحليل اسواق المال بتكدس او تركيز التقلبات في فترات معينة.

وعلى ذلك فان تحقق فرضية ثبات التباين في الغالب تكون محدودة جدا، وفي هذه الحالة من الافضل فحص نمط هذا التقلب في التباين، ومعرفة لماذا التباين يعتمد على سلوكه التاريخي او الزمني، وبمصلح اخر ادق: فحص التباين المشروط (conditional variance) للنموذج تحت الدراسة، وليس التباين غير المشروط (unconditional variance) والذي يمثل التنبؤ بالتباين على المدى البعيد للسلسلة، وهذا النوع من التباين يعامل كتباين ثابت.

وللتوضيح، نفترض ان مستثمر يخطط لشراء سهم معين في فترة زمنية (t) ويريد ان يبيع السهم عند فترة زمنية (t+1)، فبالنسبة لهذا المستثمر، فان التنبؤ بمعدل عائد السهم وحده فقط ليس كافيا، وانما عليه ان يهتم ويعرف تباين عائد السهم خلال الفترة. وبناء على ذلك فان المستثمر سيكون مهتما بفحص سلوك التباين المشروط لسلسلة عوائد السهم وذلك من اجل تقدير مستوى الخطورة او المجازفة او عدم التاكيد لهذا السهم في فترة زمنية معينة .

ولذلك جاءت هذه التقنية لنمذجة سلوك التباين المشروط (conditional variance) وبعبارة اخرى (conditional heteroskedasticity) ومن هذه التسمية اخذت الحروف (CH) في اسم النموذج (ARCH) وبعدها جاء مفهوم نمذجة التباين المشروط للانحدار الذاتي (Autoregressive Conditional Heteroskedasticity) ويرمز له (ARCH). واول من قدم هذه الفكرة كان (Robert F. Engle) في بحث حول تقدير تباين التضخم في المملكة المتحدة وعنوانه :


Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of the United Kingdom Inflation

والمنشور عام 1982م، وقد ادى هذا النوع من النمذجة تحول كبير في الاقتصاد القياسي التطبيقي ، وظهرت نماذج مختلفة في هذا الاطار منها نموذج الارتش العام (Generalized ARCH) واختصارا (GARCH) و من أجل تنفيذ هذا النموذج نكتب:

$$\text{arch } y \text{ x , arch}(1,2)$$

أو بالضغط على : statistique-tiems serie-arch

ثم نختار المتغير المفسر و المتغيرات التفسيرية و درجات التأخير



و نكتب معادلة النموذج البسيط على الشكل التالي⁵:

$$y_t = x_t\beta + \varepsilon_t$$

$$\text{var}(\varepsilon_t) = \sigma_t^2 = \gamma_0 + A(\sigma, \varepsilon) + B(\sigma, \varepsilon)^2$$

If no options are specified, $A() = B() = 0$, and the model collapses to linear regression. The following options add to $A()$ (α , γ , and κ represent parameters to be estimated):

Option	Terms added to $A()$
<code>arch()</code>	$A() = A() + \alpha_{1,1}\varepsilon_{t-1}^2 + \alpha_{1,2}\varepsilon_{t-2}^2 + \dots$
<code>garch()</code>	$A() = A() + \alpha_{2,1}\sigma_{t-1}^2 + \alpha_{2,2}\sigma_{t-2}^2 + \dots$
<code>saarch()</code>	$A() = A() + \alpha_{3,1}\varepsilon_{t-1} + \alpha_{3,2}\varepsilon_{t-2} + \dots$
<code>tarch()</code>	$A() = A() + \alpha_{4,1}\varepsilon_{t-1}^2(\varepsilon_{t-1} > 0) + \alpha_{4,2}\varepsilon_{t-2}^2(\varepsilon_{t-2} > 0) + \dots$
<code>aarch()</code>	$A() = A() + \alpha_{5,1}(\varepsilon_{t-1} + \gamma_{5,1}\varepsilon_{t-1})^2 + \alpha_{5,2}(\varepsilon_{t-2} + \gamma_{5,2}\varepsilon_{t-2})^2 + \dots$
<code>narch()</code>	$A() = A() + \alpha_{6,1}(\varepsilon_{t-1} - \kappa_{6,1})^2 + \alpha_{6,2}(\varepsilon_{t-2} - \kappa_{6,2})^2 + \dots$
<code>narchk()</code>	$A() = A() + \alpha_{7,1}(\varepsilon_{t-1} - \kappa_7)^2 + \alpha_{7,2}(\varepsilon_{t-2} - \kappa_7)^2 + \dots$

⁵ StataCorp, 2015, Stata time-series reference manual release 14, a stata press publication, college station, texas, p 16.

معادلة y_t يمكن ان تحتوي على المتوسط أو شكل ARMA

$$y_t = x_t\beta + \sum_i \psi_i g(\sigma_{t-1}^2) + \text{ARMA}(p, q) + \varepsilon_t$$

و كما رأينا سابقا فان كل النماذج يمكن أن تحتوي على خصائص معينة و في هذا النوع من النماذج لابد من تحديد عدد التأخيرات التي تدرج في النموذج، ففي اكثر الحالات فان هذا التأخير يساوي الواحد.

فاذا اردنا تقدير نموذج من الدرجة الاولى لمتغير cpi مثلا نكتب:

arch cpi, arch(1) garch(1)

و اذا اردنا اضافة متغير تفسيري الدخل (wage) مثلا كتبنا

arch cpi wage, arch(1) garch(1)

و إذا أردنا لاحدى الخصائص أن تكون درجة التأخير 1 و 2 يجب تحديدها (2/1) و نكتب

arch cpi wage, arch(1 /2) garch(1)

1.2. كيفية قراءة مخرجات نموذج ARCH

ينقسم جدول مخرجات نموذج ARCH الى عدة تقسيمات و هذا حسب نوع النموذج الذي نريد تقديره. فكل قسم يعبر عن معادلة تفصل بخط افقي⁶.

⁶ StataCorp, 2015, Stata time-series reference manual release 14, a stata press publication, college station, texas, p19

op.depvar	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
depvar					
x1	# ...				
x2					
L1.	# ...				
L2.	# ...				
_cons	# ...				
ARCHM					
sigma2	# ...				
ARMA					
ar					
L1.	# ...				
ma					
L1.	# ...				
HET					
z1	# ...				
z2					
L1.	# ...				
L2.	# ...				
ARCH					
arch					
L1.	# ...				
garch					
L1.	# ...				
aparch					
L1.	# ...				
etc.					
_cons	# ...				
POWER					
power	# ...				

المعدلات 1 و 2 و 3 تعبر عن النموذج المتوسط على شكل

$$y_t = x_t\beta + \sum_i \psi_i g(\sigma_{t-1}^2) + \text{ARMA}(p, q) + \varepsilon_t$$

المعادلة الاولى تعطي قيم B و المعادلة تسمى في الجدول [depvar] اي المتغير المفسر و اذا كان ب d.cpi فانه يسمى ب [cpi].

أما معلمة x_1 في هذا المثال فتسمى ب [depvar]_b[x1]

معلمة التأخير 2 ل x_2 فتسمى ب [depvar]_b[L2.x2]

المعادلة [ARCHM] تعطي لنا المعلمات ψ فاذا كان النموذج يحتوي على حدود النموذج ARCH-in-mean بالمعنى. فمعظم نماذج ARCH بالمعنى لا تدرج الا تبين الزمن

بحيث ان $\sum_i \psi_i g(\sigma_{t-1}^2)$ يصبح $\psi_i(\sigma_t^2)$

المعلمة σ_t^2 تسمى بـ [ARCHM]_b[sigma2] و إذا كان النموذج يحتوي على تأخير في σ_t^2 فإن المعلمة المضافة تصبح [ARCHM]_b[L1.sigma2]

و إذا حددنا تحويلاً في $g()$ فإن الخاصية archmexp() فإن المعلمة تصبح [ARCHM]_b[sigma2ex] و [ARCHM]_b[L1.sigma2ex] وهكذا... مصطلح sigma2ex يعبر عن $g(\sigma_t^2)$ و هي القيمة المحولة للتباين المشروط.

معادلة [ARMA] تعطي لنا معلمة نموذج إذا كان يحتوي على خاصية ARMA و هنا يمكن أن نجد اما متغير واحد أو اثنين و هما ar و ma. المعادلات الآتية 1 و 2 و 3 تعبر عن نموذج عدم ثبات التجانس.

فأول معادلة هي الخاصة بـ [HET] و تعطي لنا تعدد لعدم ثبات التباين إذا كانت مدرجة في النموذج و هنا يجب تحديد المتغيرات و درجة التأخير و تسمى بـ [HET]_b[ma, ar] معادلة نموذج [ARCH] تعطي معادلة ARCH و GARCH و هكذا.

فاذا حددنا arch(1) و garch(1) فإن التباين المشروط يصبح:

$$\sigma_t^2 = \gamma_0 + \alpha_{1,1}(\varepsilon_{t-1}^2) + \alpha_{2,1}(\sigma_{t-1}^2)$$

و تسمى المعلمة [ARCH]_b[_cons] و تمثل γ_0

و تسمى المعلمة [ARCH]_b[L.arch] و تمثل $\alpha_{1,1}$

و تسمى المعلمة [ARCH]_b[L.garch] و تمثل $\alpha_{2,1}$

المعادلة Power يظهر فقط اذا ما تم تكييف نموذج التباين عند الشكل الثالث و نكتب المعلمة و تسمى المعلمة ρ بـ [ARCH]_b[power]

ان المعطيات المتعارف عليها لمعلمة المقدر لـ ARCH و GARCH هي K_i, γ_i, α_i و التي تظهر في جدول (), C (), B (), A ()

Option	1st parameter	2nd parameter	Common parameter
arch()	$\alpha_1 = [\text{ARCH}]_b[\text{arch}]$		
garch()	$\alpha_2 = [\text{ARCH}]_b[\text{garch}]$		
saarch()	$\alpha_3 = [\text{ARCH}]_b[\text{saarch}]$		
tarch()	$\alpha_4 = [\text{ARCH}]_b[\text{tarch}]$		
aarch()	$\alpha_5 = [\text{ARCH}]_b[\text{aarch}]$	$\gamma_5 = [\text{ARCH}]_b[\text{aarch}_e]$	
narch()	$\alpha_6 = [\text{ARCH}]_b[\text{narch}]$	$\kappa_6 = [\text{ARCH}]_b[\text{narch}_k]$	
narchk()	$\alpha_7 = [\text{ARCH}]_b[\text{narch}]$	$\kappa_7 = [\text{ARCH}]_b[\text{narch}_k]$	
abarch()	$\alpha_8 = [\text{ARCH}]_b[\text{abarch}]$		
atarch()	$\alpha_9 = [\text{ARCH}]_b[\text{atarch}]$		
sdgarch()	$\alpha_{10} = [\text{ARCH}]_b[\text{sdgarch}]$		
earch()	$\alpha_{11} = [\text{ARCH}]_b[\text{earch}]$	$\gamma_{11} = [\text{ARCH}]_b[\text{earch}_a]$	
egarch()	$\alpha_{12} = [\text{ARCH}]_b[\text{egarch}]$		
parch()	$\alpha_{13} = [\text{ARCH}]_b[\text{parch}]$		$\varphi = [\text{POWER}]_b[\text{power}]$
tparch()	$\alpha_{14} = [\text{ARCH}]_b[\text{tparch}]$		$\varphi = [\text{POWER}]_b[\text{power}]$
aparch()	$\alpha_{15} = [\text{ARCH}]_b[\text{aparch}]$	$\gamma_{15} = [\text{ARCH}]_b[\text{aparch}_e]$	$\varphi = [\text{POWER}]_b[\text{power}]$
nparch()	$\alpha_{16} = [\text{ARCH}]_b[\text{nparch}]$	$\kappa_{16} = [\text{ARCH}]_b[\text{nparch}_k]$	$\varphi = [\text{POWER}]_b[\text{power}]$
nparchk()	$\alpha_{17} = [\text{ARCH}]_b[\text{nparch}]$	$\kappa_{17} = [\text{ARCH}]_b[\text{nparch}_k]$	$\varphi = [\text{POWER}]_b[\text{power}]$
pgarch()	$\alpha_{18} = [\text{ARCH}]_b[\text{pgarch}]$		$\varphi = [\text{POWER}]_b[\text{power}]$


1.3. مثال تطبيقي لنموذج ARCH

سنرى في هذا المثال البسيط مؤشر العام لاسعار الجملة في الولايات المتحدة الامريكية **wpi** خلال الفترة 1960-1990 و هي بيانات فصلية. نعتبر هذا النموذج من نوع **ARIMA-TS**.

نطبق هذا النموذج على المتغير المعدل $\ln wpi_t - \ln wpi_{t-1}$

	wpi	t	ln_wpi
1.	30.7	1960q1	3.424263
2.	30.8	1960q2	3.427515
3.	30.7	1960q3	3.424263
4.	30.7	1960q4	3.424263
5.	30.8	1961q1	3.427515
6.	30.5	1961q2	3.417727
7.	30.5	1961q3	3.417727
8.	30.6	1961q4	3.421
9.	30.7	1962q1	3.424263
10.	30.6	1962q2	3.421
11.	30.7	1962q3	3.424263
12.	30.7	1962q4	3.424263
13.	30.6	1963q1	3.421
14.	30.5	1963q2	3.417727
15.	30.6	1963q3	3.421
16.	30.7	1963q4	3.424263
17.	30.7	1964q1	3.424263
18.	30.6	1964q2	3.421
19.	30.7	1964q3	3.424263

المنحنى البياني التالي يمثل الفروقات القوية و الضعيفة للتقلبات و هذا ما يجعل هذا المثال انسب لنموذج ARCH



و من أجل التوضيح نبدأ أولاً بالخطوة الأولى و هي تقدير نموذج البسيط باستعمال المربعات الصغرى ثم نقوم باختبار ARCH و من أجل هذا نستعمل اختبار Engle LM test من خلال التعليمة `estat archlm`

`arch cpi wage, arch(1) garch(1)`

و لتقدير المربعات الصغرى نكتب

`reg D.ln_wpi`

و بعدها نكتب

`estat archlm, lag(1)`

`. regress D.ln_wpi`

Source	SS	df	MS	Number of obs	=	123
Model	0	0	.	F(0, 122)	=	0.00
Residual	.02521709	122	.000206697	Prob > F	=	.
Total	.02521709	122	.000206697	R-squared	=	0.0000
				Adj R-squared	=	0.0000
				Root MSE	=	.01438

D.ln_wpi	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
_cons	.0108215	.0012963	8.35	0.000	.0082553 .0133878

المحور الخامس: نماذج ARCH ; GARCH

```
. . estat archlm, lags(1)
LM test for autoregressive conditional heteroskedasticity (ARCH)
```

lags (p)	chi2	df	Prob > chi2
1	8.366	1	0.0038

H0: no ARCH effects vs. H1: ARCH(p) disturbance

بما أن اختبار LM يبين لنا قيمة $p=0.0038$ و هذا جيد لأنه أصغر من 0,05 فاننا نرفض الفرضية الصفرية لغياب اثار ARCH(1) ومنه نستطيع تقدير معاملات ARCH(1) و هذا بتحديد ARCH(1). ان النموذج من الدرجة الاولى المعمول arch هو الشكل الاكثر استعمالا في التباين المشروط و يكتب عموما على شكل GARCH(1,1).

و لتقدير النموذج ذو مسار GARCH(1,1) للسلسلة ذات الفروقات lag نكتب :

arch D.ln_wpi, arch(1) garch(1)

ARCH family regression

```
Sample: 1960q2 - 1990q4      Number of obs   =      123
Distribution: Gaussian      Wald chi2(.)    =      .
Log likelihood =    373.234  Prob > chi2     =      .
```

D.ln_wpi	OPG		z	P> z	[95% Conf. Interval]	
	Coef.	Std. Err.				
ln_wpi _cons	.0061167	.0010616	5.76	0.000	.0040361	.0081974
ARCH						
arch L1.	.4364123	.2437428	1.79	0.073	-.0413147	.9141394
garch L1.	.4544606	.1866606	2.43	0.015	.0886127	.8203086
_cons	.0000269	.0000122	2.20	0.028	2.97e-06	.0000508

و لقد قدرنا معلمة ARCH(1)=0.436

GARCH(1)=0.454

و منه نموذج GARCH(1,1) يكتب

$$y_t = 0.0061 + \varepsilon_t$$

$$\sigma_t^2 = 0.436\varepsilon_{t-1}^2 + 0.454\sigma_{t-1}^2$$

$$y_t = \ln(wpi_t) - \ln(wpi_{t-1}) \text{ حيث أن}$$

نلاحظ أن اختبار wald و القيمة الاحتمالية للنموذج المشار اليه يعطي قيم ناقصة (.) لان البرنامج يعتبر الاختبار على نموذج للمعادلة المتوسطة. و هذا عادة، المعادلة المتوسطة لا تحتوي الا على ثابت و منه فلا يوجد شيئاً لاختباره.

1.4. مثال تطبيقي لنموذج ARCH بمسار ARMA

يعتمد في هذا المثال على GARCH(1,1) للتباين المشروط و نقوم بنمذجة المتوسط على اعتباره مسار ARMA مع AR(1) و MA(1) مع التأخير الرابع ل MA(1). و هذا حتى نستطيع مراقبة الاثار الفصلية و نكتب.

arch D.ln_wpi, ar(1) ma(1 4) garch(1)

و نتحصل على المخرجات التالية

ARCH family regression -- ARMA disturbances

Sample: 1960q2 - 1990q4 Number of obs = 123
 Distribution: Gaussian Wald chi2(3) = 153.56
 Log likelihood = 399.5144 Prob > chi2 = 0.0000

D.ln_wpi	OPG		z	P> z	[95% Conf. Interval]	
	Coef.	Std. Err.				
ln_wpi						
_cons	.0069541	.0039517	1.76	0.078	-.000791	.0146992
ARMA						
ar						
L1.	.7922674	.1072225	7.39	0.000	.5821153	1.00242
ma						
L1.	-.341774	.1499943	-2.28	0.023	-.6357574	-.0477905
L4.	.2451724	.1251131	1.96	0.050	-.0000447	.4903896
ARCH						
arch						
L1.	.2040449	.1244991	1.64	0.101	-.0399688	.4480587
garch						
L1.	.6949687	.1892176	3.67	0.000	.3241091	1.065828
_cons	.0000119	.0000104	1.14	0.253	-8.52e-06	.0000324

و لتوضيح بالتدقيق ما قمنا بتقديره يمكن ان نكتب النموذج على شكل :

$$y_t = 0.007 + 0.792(y_{t-1} - 0.007) - 0.342\varepsilon_{t-1} + 0.245\varepsilon_{t-4} + \varepsilon_t$$

$$\sigma_t^2 = 0.204\varepsilon_{t-1}^2 + 0.695\sigma_{t-1}^2$$

$$y_t = \ln(wpi_t) - \ln(wpi_{t-1})$$

حيث أن

معلمة arch(1) تساوي 0.204 و هي غير معنوية لكن معلمة arch(1) و garch(1) معنوية كلياً. و يمكن التأكد باختبار

Test [ARCH]L1.arch [ARCH]L1.arch

```
. test [ARCH]L1.arch [ARCH]L1.garch

( 1)  [ARCH]L.arch = 0
( 2)  [ARCH]L.garch = 0

      chi2( 2) =    84.92
      Prob > chi2 =    0.0000
```

المحور السادس : التنبؤ باستعمال المسح الاسي

ان أسلوب التمهيد الأسّي هو نوع من أنواع المتوسطات المتحركة يستخدم بكثرة في التنبؤ ويطبق بكفاءة عالية في الحاسوب تتضمن هذه الطريقة أسلوبين: المسح الأسّي البسيط و المسح الأسّي الثنائي . و سنرى كذلك التنبؤ باستعمال المتوسطات المتحركة.

1. المسح الاسي البسيط

1.1.1 تعريف

هذا الأسلوب يصلح للاستخدام في حالة السلاسل الزمنية التي لا يتضح اتجاهها او نمطها الموسمي. يعطى بالصيغة التالية⁷

$$S_t = \alpha X_t + (1 - \alpha)S_{t-1} \quad t = 1, \dots, T$$

حيث أن S_0 يمثل القيمة البداية (الانطلاق). و منه انه يمكن كتابة التنبؤ بالمسح الاسي بالشكل التالي:

$$S_t = \alpha \sum_{k=0}^{T-1} (1 - \alpha)^k X_{T-k} + (1 - \alpha)^T S_0$$

1.2. كيفية تنفيذ التنبؤ الاسي البسيط في البرنامج

إن اجراء التنبؤ في برنامج Stata باستعمال طريقة المسح الاسي يتم باستعمال التعليمة `tssmooth` و التي تسمح بانشاء سلسلة جديدة تحمل اسما محدد و هذا حسب نوع المسح الاسي المختار. فمعامل المسح يمكن ان يختار على أساس تقليل من مجموع مربعات الاخطاء في العينة. كما ان المسح باستعمال المتوسطات المتحركة غير خطية يستعمل عادة من اجل الحصول على الاتجاه العام او إشارة لسلسلة زمنية.

تجدد الإشارة الى ان عدة مراجع توفر مقدمات جيدة حول طرق المسح الاسي مثل Chatfield (2004)⁸ الذي يبين كيفية ادماج هذه الطرق في تحليل السلاسل الزمنية عموما. كما أن كل من Montgomery, Johnson et Gardiner (1990); Abraham et Ledolter (1983); Bowerman, O'Connell et Koehler (2005); et Chatfield (2001) يبينون استعمال هذه الطرق في التنبؤ في السلاسل الزمنية.

⁷ StataCorp, 2015, Stata time-series reference manual release 14, a stata press publication, college station, texas, p.662.

⁸ Chatfield, C. 2004. The Analysis of Time Series: An Introduction. 6th ed. Boca Raton, FL: Chapman & Hall/CRC.

1.3. مثال تطبيقي

نستعمل هنا مثالا خاص بالتنبؤ بالمبيعات لثلاث مراحل قادمة مع الاخذ بعين الاعتبار معامل المسح يساوي 0.4. من أجل ذلك نكتب في نافذة البرنامج (انظر الملحق من أجل الحصول على قاعدة البيانات المستعملة في هذا المثال).


```
tssmooth exponential sm1=sales, parms(.4) forecast(3)
```

نتحصل على المخرجات التالية

```
exponential coefficient = 0.4000
sum-of-squared residuals = 8345
root mean squared error = 12.919
```

نشاهد في المخرجات معامل المسح يساوي 0,40 و قيمة مجموع مربعات الاخطاء التنبؤ تساوي 8345. و على هذا الاساس يقوم البرنامج بالتنبؤ بالقيم الجديدة و تكون في المتغير الذي يكون اسمه sm1 و يضيف قيم الفترات الثلاث. و الان نقارن بين القيم المشاهدة و تلك المتنبؤ بها و ذلك عن طريق منحنى بياني التالي و نكتب

```
line sm1 sales t, title("single exponential forecast") ytitle(Sales) xtitle(Time)
```



نلاحظ في المنحنى أن السلسلة المتنبؤ بها يمكن ان لا تتعدل سريعا للتغيرات في السلسلة الحالية. ان معامل المسح يتحكم في معدل تعديل التنبؤ. القيم الضعيفة تتعدل التنبؤ

ببطئ. كما ان قيمة معامل المسح المختار 0.4 صغيرة جدا. أحد الطرق من أجل التحكم في هذا الاختيار نترك البرنامج يختار هذا المعامل تلقائيا و هو المعامل الذي يقلل مجموع مربع أخطاء التنبؤ.
و نكتب

```
tssmooth exponential sm2=sales, forecast(3)
```

نتحصل على


```
computing optimal exponential coefficient (0,1)
```

```
optimal exponential coefficient = 0.7815
sum-of-squared residuals = 6727.7056
root mean squared error = 11.599746
```

مخرجات البرنامج تبين أن قيمة $\alpha=0.4$ صغيرة جدا و أن معامل المسح الامثل هو 0,7815 . المنحى التالي يبين أن التنبؤ الجديد يتبع السلسلة بتقارب أكثر من التنبؤ السابق.

و نعيد رسم المنحنى من جديد و نكتب

```
line sm2 sales t, title("single exponential forecast with optimal alph") ytitle(sales) xtitle(Time)
```



لقد ذكرنا فيما سبق أن التنبؤات الاسية البسيطة هي الامثل من نموذج ARIMA(0,1,1) . أعطى Chatfield (2001, 90)⁹ النتيجة المفيدة التالية التي تربط معامل مسار MA في نموذج ARIMA(0,1,1) مع معامل المسح الاسي البسيط . في ARIMA(0,1,1) يتحصل عليه عن طريق:

$$x_t - x_{t-1} = \epsilon_t + \theta\epsilon_{t-1}$$

حيث أن ϵ_t هو عبارة عن ضجيج أبيض.

و بما ان $\hat{\theta}$ هي تقدير ل θ و هو تنبؤ الامثل بخطوة واحدة ل \hat{x}_{t+1} هو

$$\hat{x}_{t+1} = x_t + \hat{\theta}\epsilon_t$$

لان ϵ_t غير مشاهدة، و يمكن أن تعوض ب

$$\hat{\epsilon}_t = x_t - \hat{x}_{t-1}$$

و لدينا $x_{t+1} = x_t + \hat{\theta}(x_t - \hat{x}_{t-1})$

و نضع $\hat{\alpha} = 1 + \hat{\theta}$ و باعادة الترتيب نتحصل على

$$\hat{x}_{t+1} = (1 + \hat{\theta})x_t - \hat{\theta}\hat{x}_{t-1}$$

$$\hat{x}_{t+1} = \hat{\alpha}x_t - (1 - \hat{\theta})\hat{x}_{t-1}$$

1.4 مقارنة نموذج ARIMA مع المسح الاسي البسيط

لمقارنة تقديرات معامل المسح الاسي الامثل 0.7815 مع تقديرات المتحصل عليها من مسار TS لنموذج arima. سنرى في الجدول اسفله انه بعد تعديل نموذج ARIMA (0,1,1) للبيانات حول المبيعات ثم نقوم بحذف التقدير ل α . التقديرين ل α متقاربة كثيرا..... $\hat{\theta}$ و لهذا نكتب

$$arima\ salesn, arima(0,1,1)\ nolog$$

لدينا جدول المخرجات التالي:

⁹ The Analysis of Time Series: An Introduction. 6th ed. Boca Raton, FL: Chapman & Hall/CRC. P 90.

ARIMA regression

Sample: 2 - 50

Number of obs = 49

Wald chi2(1) = 1.41

Log likelihood = -189.6034

Prob > chi2 = 0.2347

D.sales	OPG		z	P> z	[95% Conf. Interval]	
	Coef.	Std. Err.				
sales						
_cons	.5025469	1.382727	0.36	0.716	-2.207548	3.212641
ARMA						
ma						
L1.	-.1986561	.1671699	-1.19	0.235	-.5263031	.1289908
/sigma	11.58992	1.240607	9.34	0.000	9.158378	14.02147

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

و من أجل معرفة معامل نكتب:

$di\ 1+_b[ARMA :L.ma]$

و نتحصل على قيمة 0,8013487

1.5. معالجة القيم الناقصة في العينة

إن مسألة القيم الناقصة تعالج حسب موقع القيم الناقصة إما في وسط العينة أو في بداية أو في نهاية العينة. في الحالة الأولى نتبع خطوة واحدة و هي

إن التعليمة `tssmooth exponential` عينة باستعمال `if` و `in`.... ز.

أ- معالجة القيم الناقصة في وسط العينة

في هذا المثال لدينا المشاهدة رقم 28 ناقصة. فالتنبؤ للمشاهدة 29 متكررة في السلسلة الجديدة. بالاستعمال المسح الاسي البسيط و معامل المسح يساوي 0,7 نتنبئ بالقيم الثلاث الاتية من خلال اضافة الخصية `forecast(3)`

نكتب التعليمة التالية:

`tssmooth exponential sm1=sales, parms(.7) forecast(3)`

نتحصل على النتائج التالية

exponential coefficient = 0.7000
sum-of-squared residuals = 6775.1
root mean squared error = 11.641

و بعدها نقوم بانشاء متغير جديد يحمل اسم sales2 و الذي يساوي المتغير sales إذا كانت المشاهدة 28 ناقصة.

```
generate sales2=sales if t!=28
```

و بعدها اعادة التنبؤ

```
tssmooth exponential sm3=sales2, parms(.7) forecast(3)
```

لدينا النتائج التالية:

```
. generate sales2=sales if t!=28
(4 missing values generated)

. tssmooth exponential sm3=sales2, parms(.7) forecast(3)

exponential coefficient =      0.7000
sum-of-squared residuals =     6842.4
root mean squared error =     11.817
```

و من أجل إظهار القيم نكتب

```
list t sales2 sm3 if t>25 & t<31
```

تظهر لنا القيم التالية

```
. . list t sales2 sm3 if t>25 & t<31
```

	t	sales2	sm3
26.	26	1011.5	1007.5
27.	27	1028.3	1010.3
28.	28	.	1022.9
29.	29	1028.4	1022.9
30.	30	1054.8	1026.75

بما أن قيم الفترة 28 ناقصة فان التنبؤ بالفترة 28 استعملت في مكانها. هذا معناه ان معادلة التحيين للفترة 29 هي

$$S_{29} = \alpha S_{28} + (1 - \alpha)S_{28} = S_{28}$$

هذا ما يفسر لماذا التنبؤ ل $t = 28$ مكررة.

و بما أننا استعملنا طريقة المسح الاسي البسيط فان فقدان هذه المشاهدة لا يكون له أثر في الفترات اللاحقة.

و الان ننشئ متغير يبين الفرق بين القيم المتنبئ بها و القيم الاصلية و نكتب

```
gen diff=sm3-sm1 if t>28
```

ثم نظهر السلسلة و لتكون محصورة بين المشاهدة رقم 28 و 39 و نكتب

```
list t diff if t>28 & t<39
```

	t	diff
29.	29	-3.5
30.	30	-1.050049
31.	31	-.3150635
32.	32	-.0946045
33.	33	-.0283203
34.	34	-.0085449
35.	35	-.0025635
36.	36	-.0008545
37.	37	-.0003662
38.	38	-.0001221

أ. معالجة القيم الناقصة في بداية و في نهاية العينة

سنرى الان مثلا عندما تكون قيم ناقصة في بداية و نهاية العينة.

نقوم أولا باتشاء متغير جديد يحمل اسم sales3 و هو يحمل قيم المتغير السابق sales بشرط ان تكون الفترة أكبر من 2 و أقل من 49 و نكتب

```
generate sales3=sales if t>2 & t<49
```

ثم نقوم بالمسح الاسي البسيط مع معامل يساوي 0,7

```
tssmooth exponential sm4=sales3, parms(.7) forecast(3)
```

نتحصل على

```
exponential coefficient = 0.7000
sum-of-squared residuals = 6215.3
root mean squared error = 11.624
```

ثم نقوم باظهار المتغيرات

. list t sales sales3 sm4 if t<5 | t>45

	t	sales	sales3	sm4
1.	1	1031	.	.
2.	2	1022.1	.	.
3.	3	1005.6	1005.6	1016.787
4.	4	1025	1025	1008.956
46.	46	1055.2	1055.2	1057.2
47.	47	1056.8	1056.8	1055.8
48.	48	1034.5	1034.5	1056.5
49.	49	1041.1	.	1041.1
50.	50	1056.1	.	1041.1
51.	51	.	.	1041.1
52.	52	.	.	1041.1
53.	53	.	.	1041.1

هذا الجدول يوضح أن القيم الناقصة في بداية العينة أو في نهايتها يؤدي إلى حالة العينة المبتورة. فالسلسلة الجديدة تبدأ بقيم غير ناقصة و تبدأ بالتنبؤ مباشرة بعدها ثم تتوقف. فالفترة التي توجد مباشرة بعد آخر قيمة حقيقية يصبح التنبؤ باستعمال المسح الاسي قيمة ثابتة. فبعد نهاية القيم الحقيقية تعوض القيم الناقصة بالقيم المتنبئ بها. و هذا ما يفسر لماذا السلسلة المتنبئ بها ثابتة.

2. المسح الاسي الثنائي

2.1. تعريف

تعتبر من انطباق طرق التنبؤ باستخدام السلاسل الزمنية خاصة التي تتميز باتجاه متزايد أو متناقص. وميزة هذه الطريقة أنها تعطي أوزان كبيرة للقيم القريبة في السلسلة الزمنية وأوزان أقل للقيم البعيدة. إن المسح الاسي الثنائي أو المضاعف يستعمل في حالات أين يمكن للسلسلة ان تكون متقاربة محلياً مثل :

$$\hat{x}_t = m_t + b_t t$$

حيث أن \hat{x}_t هي القيمة الممسوحة أو المتنبئ بها للسلسلة x و العبارات m_t و b_t تتغير مع الزمن. للمزيد حول استعمال المسح الاسي الثنائي انظر (Abraham et Ledolter (1983),

Bowerman, O'Connell et Koehler (2005), ainsi que Montgomery, Johnson et Gardiner (1990),
Chatfield (2001, 2004)

ان المسح الأسّي البسيط يعطى من الشكل التالي

$$S_t = \alpha x_t + (1 - \alpha)S_{t-1}$$

حيث ان α معامل المسح الثابت و x_t يمثل السلسلة الاصلية. و نتحصل على المسح الاسي الثنائي بمسح السلسلة الممسوحة.

$$S_t^2 = \alpha S_t + (1 - \alpha)S_{t-1}^2$$


أن قيم S_0 و S_0^2 ضرورية من أجل بداية المسار. و حسب Montgomery, Johnson et Gardiner (1990) فانه يجب الحصول على قيم S_0 و S_0^2 انطلاقا من انحدار القيم الاولى ل N_{pre} حيث $x_t = (1, \dots, N_{pre} - t_0)$. تلقائيا فان N_{pre} يساوي نصف عدد المشاهدات في العينة. و يمكن ان يحدد باستعمال الخصية (`samp0()`)، وان قيم S_0 و S_0^2 يمكن أن تحدد كذلك باستعمال الخصية (`s0()`)

من أجل استعمال المسح الاسي الثنائي نستعمل التعليمة `tssmooth dexponential`¹⁰

2.2. مثال المسح الاسي ذو اتجاه عام محلي

لنفترض أننا نتوفر على بعض البيانات الخاصة بالمبيعات الشهرية للكتب و نريد مسح هذه السلسلة. المنحنى البياني التالي يبين وجود اتجاه عام محلي عبر الزمن. و نريد استعمال المسح الأسّي الثنائي.

¹⁰ StataCorp, 2015, Stata time-series reference manual release 14, a stata press publication, college station, texas, p654-655.



المثال التالي يبين أن المسح الاسي الثنائي يتطلب مسح السلسلة الممسوحة. و بما ان قيم البداية تعالج كقيم معدومة و منه تفقد قيمتين عند مسح السلسلة .

نكتب

```
tssmooth exponential double sm1=sales, p(.7) s0(1031)
```

نتحصل على

```
. tssmooth exponential double sm1=sales, p(.7) s0(1031)
```

```
exponential coefficient =      0.7000
sum-of-squared residuals =      13923
root mean squared error =      13.192
```

ثم نقوم بالمسح للمرة الثانية

```
tssmooth exponential double sm2=sm1, p(.7) s0(1031)
```

و نتحصل على

```
exponential coefficient =      0.7000
sum-of-squared residuals =      7698.6
root mean squared error =      9.8098
```

ثم نقوم بالمسح الاسي الثنائي

```
tssmooth dexponential double sm2=sales, p(.7) s0(1031 1031)
```

نتحصل على

```

double-exponential coefficient = 0.7000
sum-of-squared residuals      = 3724.4
root mean squared error       = 6.8231

```

و بعدها نقوم بانشاء متغير جديد يحمل اسم sm2c و هو عبارة عن f2.sm2

```
generate double sm2c = f2.sm2
```

ثم نظهر السلسلتين مع اظهار عشر مشاهدات فقط

```
list sm2b sm2c in 1/10
```

	sm2b	sm2c
1.	1031	1031
2.	1028.3834	1028.3834
3.	1030.6306	1030.6306
4.	1017.8182	1017.8182
5.	1022.938	1022.938
6.	1026.0752	1026.0752
7.	1041.8587	1041.8587
8.	1042.8341	1042.8341
9.	1035.9571	1035.9571
10.	1030.6651	1030.6651

كما أن طريقة المسح الاسي الثنائي يمكن أن تعتبر كالية للتنبؤ. فهي طريقة مقيدة لطريقة Holt-Winters و التي سنراها فيما بعد. و تستعمل عندما يكون النموذج من نوع ARIMA (0,2,2). هذه الطريقة تنتج تنبؤات ل \hat{x}_t من اجل

$$t = t_1, \dots, T + \text{forecast}()$$

هذه التنبؤات تحصل عليها بدلالة السلاسل الممسوحة و السلاسل الممسوحة الممسوحة. و ل

$$t \in [t_0, T]$$

$$\hat{x}_t = \left(2 + \frac{\alpha}{1 - \alpha}\right) S_t - \left(1 + \frac{\alpha}{1 - \alpha}\right) S_t^2$$

2.3. اختيار المعلمة المثلى للتنبؤ

عموما عند استعمال التنبؤ لا نعرف معلمة المسح. فالتعليمة tssmooth dexponential تحسب التنبؤات بالمسح الاسي الثنائي لسلسلة و تتحصل على معامل المسح الامثل و هذا بالبحث عن المعامل الذي يقلل مجموع مربعات البواقي للتنبؤ في العينة.

المنحنى البياني التالي يبين بيانات المبيعات باستعمال المسح الاسي المضاعف. التنبؤات الديناميكية خارج العينة ليست ثابتة مثلما كان الحال في المسح الاسي البسيط.

3. التنبؤ باستعمال طريقة¹¹ Holt – Winters

1.3. تعريف

ان معادلة التنبؤ باستعمال طريقة Holt – Winters تكون على الشكل التالي:

$$\hat{x}_{t+1} = a_t + b_t t$$

حيث ان \hat{x}_{t+1} هي السلسلة المتنبئ بها للسلسلة الاصلية x_t ، و a_t هو متوسط متحرك عبر الزمن و b_t هو معامل الزمن. و كما كتب (1985) Gardner فان طريقة Holt – Winters تنتج تنبؤات مثلى لنموذج ARIMA (0,2,2). كما يمكن اعتبار هذه الطريقة امتداد لطريقة المسح الاسي الثنائي بمعاملين محددتين أو مختارين و الذين يقللان من مجموع مربعات أخطاء بواقي التنبؤ.

في حالة للسلسلة x_t ما هما معاملات المسح؟ و القيم الاولى a_0 و b_0 و منه فمعادلات المعاملات تكتب على الشكل التالي

$$a_t = \alpha x_t + (1 - \alpha)(a_{t-1} + b_{t-1})$$

$$b_t = \beta(a_t + a_{t-1}) + (1 - \beta)b_{t-1}$$

و منه فان السلسلة المتنبئ بها ل x_t معطاة ب :

$$\hat{x}_{t+\tau} = a_t + b_t \tau$$

3.2. التنبؤ بدون وجود مركبة الفصلية Holt – Winters

3.2.1. مختلف الصيغ المستعملة في البرنامج

إن التعليلة `tssmooth hwinters` تستعمل من أجل مسح أو التنبؤ الذي يمكن ان يتم نمذجته كاتجاه عام خطي حيث ان المعلمة تتغير عبر الزمن. بعض الكتابات باستعمال طريقة هولت وينتر¹²

- القيام تمسح باستعمال المسح بدون مركبة الاتجاه العام ل Holt – Winters للمتغير y نكتب

¹¹ Chatfield, C., and M. Yar. 1988. Holt-Winters forecasting: Some practical issues. Statistician 37: 129–140.

¹² StataCorp, 2015, Stata time-series reference manual release 14, a stata press publication, college station, texas. P 669.

tssmooth hwinters smooth = y

- نفس الشيء بالنسبة للحالة السابقة لكن التنبؤ يكون لعشر فترات فقط نكتب

tssmooth hwinters smooth = y , forecast (10)

- و إذا أردنا أن نحدد مرتبة المشاهدة التي يبدأ منها التنبؤ نضيف الخصية $s0()$

tssmooth hwinters smooth = y , forecast (10) s0(111 112)

- و إذا أردنا تحديد قيم معامل المسح ب 0,5 و 0,3 نكتب

tssmooth hwinters smooth = y , forecast (10) s0(111 112) parms(.5 .3)

3.2.2. التنبؤ بسلسلة عن طريق معاملات خاصة

سنبين في هذا المثال كيفية استعمال المسح بطريقة Holt - Winters باستعمال معاملات خاصة. كما يبين كذلك أن طريقة Holt - Winters يمكن أن تتبع سلسلة ذات متوسط و معامل متحرك عبر الزمن.

لنفترض أن لدينا بيانات للمبيعات شهرية للكتب دائما و نريد التنبؤ بالمبيعات بايتعمال هذه الطريقة.

نكتب في نافذة البرنامج التعليمات التالية للتنبؤ بالسلسلة الجديدة تحت اسم hw1 باستعمال معاملات 0,7 و 0,3 و التنبؤ لثلاث فترات

tssmooth hwinters hw1 = sales , parms (.7 .3) forecast (3)

نتحصل على المخرجات التالية:

```
. tssmooth hwinters hw1=sales, parms(.7 .3) forecast(3)
```

Specified weights:

alpha = 0.7000

beta = 0.3000


sum-of-squared residuals = 2301.046

root mean squared error = 6.192799

و لمقارنة السلسلتين عن طريق منحنى بياني نكتب

line sales hw1 t, title("Holt-Winters Forecast with alpha=.7 and beta=.3") ytitle(Sales) xtitle(Time)

نتحصل على المنحنى التالي



نلاحظ من خلال المنحنى ان التنبؤات الخاصة بمبيعات الكتب في تناقص خطي.

3.2.3. اختيار القيم الاولى

يبين المنحنى السابق أن القيم الاولى في السلسلة الخطية ثابتة يمكن ان تؤثر على تعديل السلسلة المتنبئ بها بالنسبة للملاحظات الاولى. فالمثال السابق يستعمل الطريقة الالية للحصول على القيم الاولى للتكرارات. فالنتيجة أسفله تبين أنه بالنسبة لبعض المشاكل، فان القيم الاولى المبنية على اساس الفروقات تعطي افضل تعديل في العينة بالنسبة للملاحظات الاولى.

إلا ان القيم الاولى المبنية على أساس الفروقات ليست دائما قيم اكبر من القيم الأولية المبنية على الانحدار. و كما تمثله النتائج اسفله بالنسبة للسلسلة طويلة نوعا ما فان التنبؤات تكون تقريبا نفسها.

و من اجل ذلك نكتب:

```
tssmooth hwinters hw2=sales, parms (.7 .3) forecast(3) diff
```

نتحصل على قيم معامل $\alpha = 0,7$ و $\beta = 0,3$

```
Specified weights:
alpha = 0.7000
beta = 0.3000
sum-of-squared residuals = 2261.173
root mean squared error = 6.13891
```

و الان نظهر النتائج التنبؤات الخاصة بالمشاهدات الخمس الاولى و المشاهدات أكبر من المرتبة 57 و نكتب

```
list hw1 hw2 if _n<6 | _n>57
```

و نتحصل على الجدول التالي:

	hw1	hw2	
1.	93.31973	97.80807	خمس مشاهدات الاولى
2.	98.40002	98.11447	
3.	100.8845	99.2267	
4.	98.50404	96.78276	
5.	93.62408	92.2452	
58.	116.5771	116.5771	المشاهدات بعد المرتبة 57
59.	119.2146	119.2146	
60.	119.2608	119.2608	
61.	111.0299	111.0299	
62.	109.2815	109.2815	
63.	107.5331	107.5331	

فعندما معاملات المسح تكون مختارة من اجل تقليل مجموع مربعات الاخطاء للتنبؤ، فتغيير القيم الاولى يمكن أن تؤثر على اختيار..... و عندما نغير القيم الاولى نتحصل على القيم المثلى مختلفة ل... و منه تنبؤات مختلفة كذلك. فعموما عندما يتطابق نموذج Holt – Winters مع البيانات فان البحث عن المعاملات المسح المثلى تسير دائما جيدا.

3.2.4. التنبؤ باستعمال المعاملات المثلى

في هذا المثل سنتنبئ بمبيعات الكتب بالاستعانة بالقيم التي تقلل مجموع مربعات الاخطاء للتنبؤ في العينة.

نكتب :

```
tssmooth hwinters hw3=sales, forecast(3)
```

```

. tssmooth hwinters hw3=sales, forecast(3)
computing optimal weights

Iteration 0:   penalized RSS = -2632.2073   (not concave)
Iteration 1:   penalized RSS = -1982.8431
Iteration 2:   penalized RSS = -1976.423
Iteration 3:   penalized RSS = -1975.9174
Iteration 4:   penalized RSS = -1975.9036
Iteration 5:   penalized RSS = -1975.9036

Optimal weights:
                    alpha = 0.8209
                    beta  = 0.0067
penalized sum-of-squared residuals = 1975.904
sum-of-squared residuals = 1975.904
root mean squared error = 5.738617


```

فالمنحنى البياني التالي يبين البيانات و التنبؤات باستعمال القيم المثلى للمعاملات

المقارنة بين هذا المنحنى و المنحنى السابق يبين كيف ان مختلف خيارات التنبؤ يمكن ان تعطي تنبؤات مختلفة جدا. فعوض تناقص المبيعات بشكل خطي فان التنبؤ الجديد يهتم بتزايد خطي للمبيعات.

نكتب لاطهار المنحنى

```
line sales hw3 t, title("Holt-Winters Forecast with optimal alpha and beta ") ytitle(Sales) xtitle(Time)
```



3.3. التنبؤ بوجود المركبة الفصلية Holt – Winters

3.3.1. مختلف الصيغ المستعملة في البرنامج

إن التعليمة `tssmooth shwinters` تقوم بتنفيذ طريقة Holt – Winters بوجود مركبة الفصلية و تكتب بعدها اسم المتغير و تقوم بإنشاء متغير جديد للقيم المتنبئ بها. و هذه بعض الحالات العامة التي يمكن أن نحتاج إليها عند استعمال هذه الطريقة فب التنبؤ. - القيام تمسح باستعمال المسح مع وجود مركبة الفصلية ل Holt – Winters للمتغير y نكتب

$$tssmooth shwinters smooth = y$$

- نفس الشيء بالنسبة للحالة السابقة لكن التنبؤ يكون لعشر فترات فقط نكتب

$$tssmooth shwinters smooth = y, forecast (10)$$

- و إذا أردنا أن نحدد مرتبة المشاهدة التي يبدأ منها التنبؤ نكتب

$$tssmooth shwinters smooth = y, forecast (10) s0(111 112)$$

- و إذا أردنا تحديد قيم معامل المسح ب 0,5 و 0,3 و 0,7 نكتب

$$tssmooth shwinters smooth = y, forecast (10) s0 (111 112) parms(.5 .3 .7)$$

- و إذا أردنا تكييف قيم الفصلية للحالة السابقة نكتب

$$tssmooth shwinters smooth = y, forecast (10) s0 (111 112) parms(.5 .3 .7) normalisent$$

3.3.2. النموذج الجدائي مع وجود المركبة الفصلية

تعتمد هذه الطريقة على سلاسل زمنية ذات المركبة الفصلية حيث أن شدة مركبة الفصلية تزداد مع السلسلة. كما أن هذه الطريقة تتكيف أحسن مع بيانات التي تعطى على الشكل التالي:

$$x_{t+j} = (\mu_t + \beta_j)S_{t+j} + \epsilon_{t+j}$$

حيث ان x_{t+j} هي السلسلة، t هي متغير الزمن في اللحظة t ، S_{t+j} هي مركبة الفصلية في الفترة t و ϵ_{t+j} حد الخطأ

أ. التنبؤ انطلاقاً من النموذج الجدائي

لدينا بيانات فصلية حول متبيعات اللحوم لمنتج ما في سنوات 90. و تتميز هذه البيانات بوجود مركبة الفصلية و اتجاه عام في تزايد. نستعمل طريقة Holt – Winters الجدائية للتنبؤ بالمبيعات لسنة 2000. و بما انه تم تحديد البيانات بانها فصلية لا نحتاج الى تحديد الخصية `.period ()` و نكتب

```
tssmooth shwinters shw1 = sales , forecast (4)
```

```
. . tssmooth shwinters shw1 = sales , forecast (4)
computing optimal weights


Iteration 0:   penalized RSS = -189.34609   (not concave)
Iteration 1:   penalized RSS = -108.68038   (not concave)
Iteration 2:   penalized RSS = -106.24548
Iteration 3:   penalized RSS = -106.141
Iteration 4:   penalized RSS = -106.14093
Iteration 5:   penalized RSS = -106.14093

Optimal weights:
                alpha = 0.1310
                beta  = 0.1428
                gamma = 0.2999
penalized sum-of-squared residuals = 106.1409
sum-of-squared residuals = 106.1409
root mean squared error = 1.628964
```

و الان نظهر التنبؤات على شكل منحنى بياني و نكتب مايلي:

```
line sales shw1 t, title("Multiplicative Holt-Winters forecast") xtitle(Time) ytitle(Sales)
```

يطهر لنا المنحنى البيانات مع التنبؤات المتحصل عليها



3.3.3. النموذج التجميعي مع وجود المركبة الفصلية

تعتبر هذه الطريقة مشابهة للسابقة لكن الاثار الفصلية يفترض أن يكون تجميعي و ليس جدائي. تتنبؤ هذه الطريقة بالسلاسل التي يمكن ان نعبر عنها بالشكل التالي:

$$x_{t+j} = (\mu_t + \beta_j) + S_{t+j} + \epsilon_{t+j}$$

مثال للتنبؤ باستعمال النموذج التجميعي

في هذا المثال نكيف البيانات السابقة مع النموذج التجميعي من اجل التنبؤ بالمبيعات للسنة المقبلة. و هنا نستعمل الخصية من `snt_v()` أجل حفظ الشروط المتعلقة بالفصلية لآخر سنة في المتغير الجديد يحمل اسم `seas`

و نكتب

```
tssmooth shwinters shwa = sales , forecast (4) snt_v(seas) normalize additive
```

```
computing optimal weights
```


```
Iteration 0: penalized RSS = -190.90242 (not concave)
Iteration 1: penalized RSS = -108.8357
Iteration 2: penalized RSS = -108.25359
Iteration 3: penalized RSS = -107.68187
Iteration 4: penalized RSS = -107.66444
Iteration 5: penalized RSS = -107.66442
Iteration 6: penalized RSS = -107.66442
```

```
Optimal weights:
```

```
alpha = 0.1219
beta = 0.1580
gamma = 0.3340
penalized sum-of-squared residuals = 107.6644
sum-of-squared residuals = 107.6644
root mean squared error = 1.640613
```

تبين المخرجات ان النموذج التجميعي هو أفضل تعديل بالنسبة للعينة و المنحنى البياني التالي يبين أن تنبؤات النموذج التجميعي أكبر من تنبؤات النموذج الجدائي.

```
line sales shw1 shwa t if t>tq(2000q1), title("Multiplicative and additive Holt-Winters forecast")
xtitle(Time) ytitle(Sales) legend(cols(1))
```



و من أجل التأكد من ان مركبة الفصلية المقدرة صحيحة نسجل مركبات الفصلية للسنة
الاخيرة و نكتب

```
list t seas <.
```

	t	seas
37.	1999q1	-2.7533393
38.	1999q2	-.91752573
39.	1999q3	1.8082417
40.	1999q4	1.8626233

المخرجات التالية تبين ان اشارات مركبات الفصلية المقدرة تتماشى و حدسنا.

بيانات المسح الاسي

	t	sales	sm1	sm2	sm2b	sm2c
1.	1	1031	1031	1031	1031	1031
2.	2	1025.66	1031	1031	1028.3834	1028.3834
3.	3	1033.45	1027.262	1031	1030.6306	1030.6306
4.	4	1004.07	1031.5937	1028.3834	1017.8182	1017.8182
5.	5	1030.62	1012.3271	1030.6306	1022.938	1022.938
6.	6	1028.4	1025.1322	1017.8182	1026.0752	1026.0752
7.	7	1057.71	1027.4198	1022.938	1041.8587	1041.8587
8.	8	1040.95	1048.6231	1026.0752	1042.8341	1042.8341
9.	9	1028.62	1043.2521	1041.8587	1035.9571	1035.9571
10.	10	1026.42	1033.0098	1042.8341	1030.6651	1030.6651
11.	11	1029.85	1028.3971	1035.9571	1029.7896	1029.7896
12.	12	1039.91	1029.4144	1030.6651	1034.67	1034.67
13.	13	1049.3	1036.7616	1029.7896	1042.2781	1042.2781
14.	14	1035.12	1045.5388	1034.67	1039.4556	1039.4556
15.	15	1027.87	1038.2459	1042.2781	1033.5248	1033.5248
16.	16	1007.65	1030.983	1039.4556	1020.3126	1020.3126
17.	17	1016.36	1014.6502	1033.5248	1017.1869	1017.1869
18.	18	995.6004	1015.8473	1020.3126	1006.3282	1006.3282
19.	19	1006.47	1001.6745	1017.1869	1005.4206	1005.4206
20.	20	981.8704	1005.0316	1006.3282	993.79933	993.79933
21.	21	986.7004	988.81878	1005.4206	989.27496	989.27496
22.	22	1005.26	987.33594	993.79933	996.70065	996.70065
23.	23	994.8505	999.88309	989.27496	996.46237	996.46237
24.	24	1012.37	996.36025	996.70065	1004.2359	1004.2359
25.	25	1020.62	1007.5674	996.46237	1012.964	1012.964
26.	26	1026.801	1016.7046	1004.2359	1020.5294	1020.5294
27.	27	1032.911	1023.7717	1012.964	1027.277	1027.277
28.	28	1027.35	1030.1689	1020.5294	1027.9203	1027.9203
29.	29	1044.42	1028.196	1027.277	1036.0633	1036.0633
30.	30	1024.82	1039.5531	1027.9203	1031.2871	1031.2871
31.	31	1027.55	1029.2402	1036.0633	1029.0263	1029.0263
32.	32	1021.41	1028.0574	1031.2871	1025.091	1025.091
33.	33	1024.8	1023.4045	1029.0263	1024.5945	1024.5945
34.	34	1025.82	1024.3816	1025.091	1025.1505	1025.1505
35.	35	1008.87	1025.3888	1024.5945	1017.2233	1017.2233
36.	36	1021.35	1013.8259	1025.1505	1018.5321	1018.5321
37.	37	1019.66	1019.0931	1017.2233	1019.2028	1019.2028
38.	38	996.1004	1019.4902	1018.5321	1007.943	1007.943
39.	39	990.7704	1003.1173	1019.2028	998.51502	998.51502
40.	40	1001.17	994.47447	1007.943	998.96765	998.96765
41.	41	1010.9	999.16163	998.51502	1004.8554	1004.8554
42.	42	1009.16	1007.3788	998.96765	1007.4948	1007.4948
43.	43	1019.45	1008.6259	1004.8554	1013.5906	1013.5906
44.	44	1009.07	1016.203	1007.4948	1011.9243	1011.9243
45.	45	1002.12	1011.2102	1013.5906	1006.9704	1006.9704
46.	46	996.8004	1004.8473	1011.9243	1001.5412	1001.5412
47.	47	1014.21	999.21444	1006.9704	1007.2605	1007.2605
48.	48	982.7503	1009.7116	1001.5412	995.76522	995.76522
49.	49	988.9203	990.83868	1007.2605	991.37663	991.37663
50.	50	1013.62	989.49581	995.76522	1001.8811	1001.8811

51.	51	1019.55	1006.383	991.37663	1011.4844	1011.4844
52.	52	1008.81	1015.6001	1001.8811	1011.0384	1011.0384
53.	53	1005.1	1010.8472	1011.4844	1008.0886	1008.0886
54.	54	1009.12	1006.8244	1011.0384	1008.3286	1008.3286
55.	55	1011.77	1008.4315	1008.0886	1010.0367	1010.0367
56.	56	1023.15	1010.7687	1008.3286	1016.6161	1016.6161
57.	57	1028.86	1019.4358	1010.0367	1023.2079	1023.2079
58.	58	1041.5	1026.033	1016.6161	1032.7645	1032.7645
59.	59	1039.37	1036.8602	1023.2079	1036.8615	1036.8615
60.	60	1030.17	1038.6173	1032.7645	1033.9516	1033.9516
61.	61	1027.3	1032.7045	1036.8615	1030.4306	1030.4306
62.	62	1041.56	1028.9216	1033.9516	1035.5673	1035.5673
63.	63	1077.45	1037.7688	1030.4306	1056.5524	1056.5524
64.	64	1078.27	1065.5459	1035.5673	1069.0828	1069.0828
65.	65	1092.22	1074.4531	1056.5524	1081.548	1081.548
66.	66	1081.7	1086.8902	1069.0828	1082.7445	1082.7445
67.	67	1089.11	1083.2573	1081.548	1085.9714	1085.9714
68.	68	1074.25	1087.3544	1082.7445	1080.5185	1080.5185
69.	69	1065.12	1078.1816	1085.9714	1072.4827	1072.4827
70.	70	1069.02	1069.0387	1080.5185	1070.0629	1070.0629
71.	71	1071.05	1069.0259	1072.4827	1070.329	1070.329
72.	72	1073.51	1070.4431	1070.0629	1071.9118	1071.9118
73.	73	1059.7	1072.5902	1070.329	1066.0706	1066.0706
74.	74	1069.72	1063.5673	1071.9118	1067.3333	1067.3333
75.	75	1063.07	1067.8744	1066.0706	1065.3581	1065.3581
76.	76	1088.75	1064.5115	1067.3333	1076.6425	1076.6425
77.	77	1080.76	1081.4787	1065.3581	1079.6759	1079.6759
78.	78	1074.3	1080.9759	1076.6425	1077.3149	1077.3149
79.	79	1053.67	1076.3031	1079.6759	1065.5166	.
80.	80	1069.87	1060.4602	1077.3149	1066.5881	.

بيانات المسح الاسي (معالجة البيانات الناقصة)

	t	sales	sm1	sales2	sm3	diff
1.	1	1031	1017.568	1031	1017.568	.
2.	2	1022.1	1026.97	1022.1	1026.97	.
3.	3	1005.6	1023.561	1005.6	1023.561	.
4.	4	1025	1010.988	1025	1010.988	.
5.	5	1022.8	1020.797	1022.8	1020.797	.
6.	6	1031.2	1022.199	1031.2	1022.199	.
7.	7	1020.5	1028.5	1020.5	1028.5	.
8.	8	1032.9	1022.9	1032.9	1022.9	.
9.	9	1034.9	1029.9	1034.9	1029.9	.
10.	10	1043.4	1033.4	1043.4	1033.4	.
11.	11	1046.4	1040.4	1046.4	1040.4	.
12.	12	1029.6	1044.6	1029.6	1044.6	.
13.	13	1006.1	1034.1	1006.1	1034.1	.
14.	14	1003.5	1014.5	1003.5	1014.5	.
15.	15	1007.8	1006.8	1007.8	1006.8	.
16.	16	1026.5	1007.5	1026.5	1007.5	.
17.	17	1003.8	1020.8	1003.8	1020.8	.
18.	18	1007.9	1008.9	1007.9	1008.9	.
19.	19	995.1998	1008.2	995.1998	1008.2	.
20.	20	1009.1	999.0999	1009.1	999.0999	.
21.	21	1004.1	1006.1	1004.1	1006.1	.
22.	22	1006.7	1004.7	1006.7	1004.7	.
23.	23	1008.1	1006.1	1008.1	1006.1	.
24.	24	1007.5	1007.5	1007.5	1007.5	.
25.	25	1007.5	1007.5	1007.5	1007.5	.
26.	26	1011.5	1007.5	1011.5	1007.5	.
27.	27	1028.3	1010.3	1028.3	1010.3	.
28.	28	1027.9	1022.9	.	1022.9	.
29.	29	1028.4	1026.4	1028.4	1022.9	-3.5
30.	30	1054.8	1027.8	1054.8	1026.75	-1.050049
31.	31	1060.7	1046.7	1060.7	1046.385	-.3150635
32.	32	1051.5	1056.5	1051.5	1056.405	-.0946045
33.	33	1052	1053	1052	1052.972	-.0283203
34.	34	1070.3	1052.3	1070.3	1052.292	-.0085449
35.	35	1063.9	1064.9	1063.9	1064.897	-.0025635
36.	36	1078.2	1064.2	1078.2	1064.199	-.0008545
37.	37	1079	1074	1079	1074	-.0003662
38.	38	1088.5	1077.5	1088.5	1077.5	-.0001221
39.	39	1089.2	1085.2	1089.2	1085.2	0
40.	40	1072	1088	1072	1088	0
41.	41	1076.8	1076.8	1076.8	1076.8	0
42.	42	1052.8	1076.8	1052.8	1076.8	0
43.	43	1062	1060	1062	1060	0
44.	44	1056.4	1061.4	1056.4	1061.4	0
45.	45	1056.9	1057.9	1056.9	1057.9	0
46.	46	1055.2	1057.2	1055.2	1057.2	0
47.	47	1056.8	1055.8	1056.8	1055.8	0
48.	48	1034.5	1056.5	1034.5	1056.5	0
49.	49	1041.1	1041.1	1041.1	1041.1	0
50.	50	1056.1	1041.1	1056.1	1041.1	0
51.	51	.	1051.6	.	1051.6	0
52.	52	.	1051.6	.	1051.6	0
53.	53	.	1051.6	.	1051.6	0

بيانات المسح الاسي مع وجود المركبة الفصلية

	t	sales	shw1	shwa	seas
1.	1990q1	100	97.29033	97.22871	.
2.	1990q2	97.84603	99.61392	99.63411	.
3.	1990q3	98.84029	100.3836	100.4294	.
4.	1990q4	100.8275	101.6817	101.7617	.
5.	1991q1	98.90981	99.50168	99.70743	.
6.	1991q2	100.9992	100.1402	100.145	.
7.	1991q3	101.9653	101.2806	101.2755	.
8.	1991q4	104.1229	103.0723	103.0763	.
9.	1992q1	99.74297	101.2029	101.1208	.
10.	1992q2	102.3116	102.1388	102.1815	.
11.	1992q3	104.2382	103.1614	103.1822	.
12.	1992q4	105.8506	105.1386	105.1461	.
13.	1993q1	102.8379	102.5266	102.5164	.
14.	1993q2	104.604	104.1844	104.211	.
15.	1993q3	106.5201	105.5383	105.5625	.
16.	1993q4	106.9322	107.4801	107.4565	.
17.	1994q1	101.7508	104.559	104.5234	.
18.	1994q2	107.551	105.8172	105.8787	.
19.	1994q3	106.7199	107.4929	107.5374	.
20.	1994q4	108.2395	108.7732	108.7317	.
21.	1995q1	103.035	105.1662	105.3358	.
22.	1995q2	107.8659	107.6965	107.8101	.
23.	1995q3	107.6514	108.4557	108.4764	.
24.	1995q4	107.3684	109.7419	109.7001	.
25.	1996q1	102.7467	105.3475	105.7025	.
26.	1996q2	107.6782	108.3296	108.4496	.
27.	1996q3	111.0517	108.6066	108.6315	.
28.	1996q4	112.0229	109.8515	109.7463	.
29.	1997q1	103.7079	105.9599	105.7841	.
30.	1997q2	104.9966	109.5714	109.6237	.
31.	1997q3	110.0057	110.1034	110.2309	.
32.	1997q4	109.8376	110.8531	110.8895	.
33.	1998q1	104.5891	105.2447	105.7516	.
34.	1998q2	107.5621	108.3382	108.2516	.
35.	1998q3	109.6842	110.495	110.5812	.
36.	1998q4	111.4588	110.8508	110.8536	.
37.	1999q1	108.9672	105.4948	105.5505	-2.7533393
38.	1999q2	108.7656	109.1733	109.0433	-.91752573
39.	1999q3	112.9617	111.4466	111.4192	1.8082417
40.	1999q4	111.9473	112.5864	112.5338	1.8626233
41.	2000q1	.	107.8217	107.602	.
42.	2000q2	.	110.0606	109.6742	.
43.	2000q3	.	112.9292	112.6363	.
44.	2000q4	.	113.2981	112.927	.

بيانات المسح الاسي مع تحديد المعاملات المسح

	t	sales	hw1	hw2	hw3
1.	1	97.80807	93.31973	97.80807	93.31973
2.	2	99	98.40002	98.11447	98.02462
3.	3	96	100.8845	99.2267	99.85123
4.	4	92	98.50404	96.78276	97.69468
5.	5	97	93.62408	92.2452	93.99359
6.	6	94	96.36903	95.38244	97.45141
7.	7	99	94.59502	93.9333	95.58928
8.	8	94	98.48786	98.06256	99.37876
9.	9	99	95.21326	94.9482	95.92372
10.	10	98	98.5261	98.36478	99.426
11.	11	104	98.70947	98.61314	99.2247
12.	12	104	104.0755	104.0189	104.1401
13.	13	100	105.6694	105.6367	105.0198
14.	14	96	102.1571	102.1383	101.8664
15.	15	103	97.01035	96.99973	97.98576
16.	16	104	101.6242	101.6182	103.0642
17.	17	113	104.2072	104.2039	104.7999
18.	18	119	113.1286	113.1268	112.5437
19.	19	118	121.238	121.2371	118.8916
20.	20	121	122.2909	122.2904	119.203
21.	21	128	124.4356	124.4354	121.7313
22.	22	125	130.7276	130.7274	127.9647
23.	23	120	129.3124	129.3123	126.6025
24.	24	129	123.4322	123.4322	122.2178
25.	25	119	129.1374	129.1374	128.8574
26.	26	111	121.7201	121.7201	121.784
27.	27	115	111.6437	111.6437	113.8907
28.	28	116	112.1256	112.1256	115.7662
29.	29	108	113.7838	113.7838	116.9243
30.	30	114	107.4667	107.4667	110.5158
31.	31	107	111.1435	111.1435	114.3121
32.	32	113	106.4764	106.4764	109.2059
33.	33	118	110.6463	110.6463	113.2372
34.	34	125	116.9415	116.9415	118.0899
35.	35	137	125.4223	125.4223	124.7433
36.	36	130	138.7979	138.7979	135.8529
37.	37	130	136.063	136.063	132.0648
38.	38	132	133.9693	133.9693	131.3749
39.	39	131	134.3277	134.3277	132.8965
40.	40	125	133.0363	133.0363	132.3377
41.	41	117	126.7613	126.7613	127.2721
42.	42	118	117.2289	117.2289	119.7413
43.	43	116	115.2311	115.2311	119.2035
44.	44	112	113.3933	113.3933	117.4478
45.	45	116	109.7493	109.7493	113.8199
46.	46	123	112.7688	112.7688	116.4654
47.	47	127	120.7232	120.7232	122.7213
48.	48	121	127.2276	127.2276	127.1489
49.	49	118	123.6712	123.6712	122.9831
50.	50	113	119.3133	119.3133	119.7469

51.	51	126	113.1801	113.1801	115.0257
52.	52	118	123.1324	123.1324	124.9115
53.	53	126	119.4402	119.4402	120.0776
54.	54	122	125.3101	125.3101	125.8111
55.	55	112	123.576	123.576	123.5338
56.	56	117	113.6248	113.6248	114.8538
57.	57	118	114.8482	114.8482	117.4149
58.	58	120	116.5771	116.5771	118.6978
59.	59	119	119.2146	119.2146	120.5765
60.	60	110	119.2608	119.2608	120.0835
61.	61	.	111.0299	111.0299	112.552
62.	62	.	109.2815	109.2815	113.2977
63.	63	.	107.5331	107.5331	114.0433

بيانات المسح الاسي البسيط

	t	sales	sml
1.	1	1031	1017.568
2.	2	1022.1	1022.941
3.	3	1005.6	1022.604
4.	4	1025	1015.803
5.	5	1022.8	1019.482
6.	6	1031.2	1020.809
7.	7	1020.5	1024.965
8.	8	1032.9	1023.179
9.	9	1034.9	1027.068
10.	10	1043.4	1030.2
11.	11	1046.4	1035.48
12.	12	1029.6	1039.848
13.	13	1006.1	1035.749
14.	14	1003.5	1023.889
15.	15	1007.8	1015.733
16.	16	1026.5	1012.56
17.	17	1003.8	1018.136
18.	18	1007.9	1012.401
19.	19	995.1998	1010.601
20.	20	1009.1	1004.44
21.	21	1004.1	1006.304
22.	22	1006.7	1005.422
23.	23	1008.1	1005.933
24.	24	1007.5	1006.8
25.	25	1007.5	1007.08

26.	26	1011.5	1007.248
27.	27	1028.3	1008.949
28.	28	1027.9	1016.689
29.	29	1028.4	1021.173
30.	30	1054.8	1024.064
31.	31	1060.7	1036.358
32.	32	1051.5	1046.095
33.	33	1052	1048.257
34.	34	1070.3	1049.754
35.	35	1063.9	1057.973
36.	36	1078.2	1060.344
37.	37	1079	1067.486
38.	38	1088.5	1072.092
39.	39	1089.2	1078.655
40.	40	1072	1082.873
41.	41	1076.8	1078.524
42.	42	1052.8	1077.834
43.	43	1062	1067.821
44.	44	1056.4	1065.493
45.	45	1056.9	1061.856
46.	46	1055.2	1059.873
47.	47	1056.8	1058.004
48.	48	1034.5	1057.523
49.	49	1041.1	1048.314
50.	50	1056.1	1045.428
51.	51	.	1049.697
52.	52	.	1049.697
53.	53	.	1049.697

- Bourbounais, R, (2004) Econométrie, DUNOD, p233.234.
 - Chatfield, C., and M. Yar. 1988. Holt-Winters forecasting: Some practical issues. *Statistician* 37: 129–140.
 - Enders, W. 2004. *Applied Econometric Time Series*. 2nd ed. New York: Wiley. P 63.
 - Greene Wilam, (2002) ,*Econometric analysis*, Upper Saddle River, New Jersey, FIFTH EDITION, p. 593.594.
 - StataCorp, 2015, *Stata time-series reference manual release 14*, a stata press publication, college station, texas
 - *The Analysis of Time Series: An Introduction*. 6th ed. Boca Raton, FL: Chapman & Hall/CRC. P 90.
-
- DSS Online Training Section <http://dss.princeton.edu/training/>
 - UCLA Resources to learn and use STATA <http://www.ats.ucla.edu/stat/stata/>
 - DSS help-sheets for STATA http://dss/online_help/stats_packages/stata/stata.htm
 - *Introduction to Stata* (PDF), Christopher F. Baum, Boston College, USA. “A 67-page description of Stata, its key features and benefits, and other useful information.” <http://fmwww.bc.edu/GStat/docs/StataIntro.pdf>
 - STATA FAQ website <http://stata.com/support/faqs/>
 - Princeton DSS Libguides <http://libguides.princeton.edu/dss>