



وزارة التعليم العالي والبحث العلمي
جامعة لونيبي علي - البليدة 02 -
كلية العلوم الاقتصادية والعلوم التجارية وعلوم التسيير
- الشهيد طالب عبد الرحمان -



قسم العلوم: الاقتصادية

دروس في مقياس طرق التنبؤ

السنة الأولى ماستر (تخصص: تحليل اقتصادي واستشراف)
ميدان "العلوم الاقتصادية والتجارية وعلوم التسيير"

السداسي الثاني

من إعداد الأستاذ: حوشين يوسف

دروس في مقياس طرق التنبؤ

فهرس المحتويات:

المحور الأول: الانحدار الخطي وغير الخطي

1. نموذج الانحدار الخطي البسيط
2. نموذج الانحدار الخطي المتعدد
3. الانحدار غير الخطي

المحور الثاني: المعادلات الأنية وكيفية استخدامها في المحاكاة

1. مفهوم المعادلات الأنية
2. الشكل الهيكلي والشكل المختزل لنماذج المعادلات الأنية
3. أنواع الأثار في المعادلات الأنية
4. مشكل التشخيص
5. تقدير المعادلات الأنية
6. المحاكاة والتنبؤ باستخدام المعادلات الأنية
7. مثال تطبيقي للمعادلات الأنية على برنامج إفيوز

المحور الثالث: منهجية بوكس-جينكينز في الأجل القصير

1. الخطوة الأولى: التحليل الأولي
2. الخطوة الثانية: التعرف (التعيين)
3. الخطوة الثالثة: التقدير
4. الخطوة الرابعة: دراسة الصلاحية (التشخيص)
5. الخطوة الخامسة: التنبؤ
6. مثال تطبيقي على برنامج إفيوز حول طريقة بوكس جينكينز

المحور الرابع: منهجية شعاع الانحدار الذاتي

1. شكل نموذج شعاع الانحدار الذاتي VAR
2. تقدير نموذج شعاع الانحدار الذاتي VAR
3. تحديد درجة الإبطاء المثلى لنموذج VAR
4. دراسة استقرارية نموذج VAR
5. التنبؤ باستخدام نموذج VAR
6. مثال تطبيقي شامل لنموذج VAR على برنامج إفيوز

دروس في مقياس طرق التنبؤ

I. المحور الأول: الانحدار الخطي وغير الخطي

سأخصص هذا المحور لنماذج الانحدار، الخطية (البسيط والمتعدد) وغير الخطية.

1. نموذج الانحدار الخطي البسيط:

إن نموذج الانحدار الخطي البسيط هو من أبسط نماذج الانحدار، لأنه يحتوي على متغيرين فقط، فهو بسيط في مركباته وفي تقديره وفي اختبارات الصلاحية التي تطبق عليه.

أ. تعريف نموذج الانحدار الخطي البسيط:

هو النموذج القياسي الذي يتكون من متغيرين فقط، متغير تابع ومتغير مستقل، بحيث تكون العلاقة الرياضية التي تربط بينهما هي علاقة خطية. كما يلي:

$$t = 1, 2, \dots, n \quad Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$$

حيث: Y_t المتغير التابع

X_t المتغير المستقل

ε_t الحد العشوائي (حد الخطأ)

β_0 و β_1 هي معلمات (parameter) نقوم بتقديرها بإحدى طرق التقدير.

t الزمن.

n عدد المشاهدات (حجم العينة).

ملاحظات:

◀ نسمي Y_t متغير تابع لأن قيمه تابعة لقيم المتغير المستقل (قيمه تُحدّد داخل النموذج، فيسمى كذلك بمتغير داخلي أو المتغير المراد تفسيره أو المفسّر)، أما X_t فهو متغير مستقل لأن قيمه مستقلة عن قيم المتغير التابع (قيمه تُحدّد خارج النموذج، فيسمى كذلك بمتغير خارجي أو المتغير المفسّر).

◀ يمكن تقسيم النموذج السابق إلى حدّين: الحد الثابت $(\beta_0 + \beta_1 X_t)$ والحد العشوائي (ε_t) .

ب. فرضيات نموذج الانحدار الخطي البسيط:

لتقدير نموذج الانحدار الخطي البسيط، لابد من توفر مجموعة من الشروط في النموذج. والتي تعرف بفرضيات النموذج، ويمكن

تلخيصها في النقاط التالية:

$$(1) \text{ متوسط الأخطاء معدوم: } E(\varepsilon_t) = 0 \quad \forall t = 1, 2, \dots, n$$

$$(2) \text{ تباين الأخطاء ثابت (متجانس): } V(\varepsilon_t) = \sigma_\varepsilon^2 \quad \forall t = 1, 2, \dots, n$$

$$(3) \text{ التباين بين الأخطاء معدوم: } Cov(\varepsilon_t, \varepsilon_{t'}) = E(\varepsilon_t, \varepsilon_{t'}) = 0 \quad \forall t \neq t'$$

$$(4) \text{ الأخطاء تتبع التوزيع الطبيعي: } \varepsilon_t \sim N(0, \sigma_\varepsilon^2)$$

دروس في مقياس طرق التنبؤ

ج. تقدير نموذج الانحدار الخطي البسيط:

توجد ثلاث معلمات مجهولة في نموذج الانحدار الخطي البسيط والتي يجب تقديرها، معلمتا الانحدار (β_0 و β_1)، وتباين الأخطاء σ_ε^2 .

• تقدير معلمتا النموذج (β_0 و β_1):

من بين أهم طرق تقدير نموذج الانحدار الخطي البسيط، طريقة المربعات الصغرى العادية (Ordinary Least squares -OLS-)، والتي تعتمد على مبدأ تصغير مجموع مربعات أخطاء النموذج.

ليكن لدينا نموذج الانحدار الخطي البسيط التالي: $Y_t = \beta_0 + \beta_1 X_t + \varepsilon_t$.

النموذج المقدر للنموذج السابق هو النموذج التالي: $\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 X_t$.

الأخطاء (أو البواقي، ونرمز لها $\hat{\varepsilon}_t$) هي في الحقيقة الفرق بين النموذج الأول النظري والنموذج الثاني المقدر على العينة. أي أن: $\hat{\varepsilon}_t = Y_t - \hat{Y}_t$.

طريقة المربعات الصغرى العادية تهدف إلى إيجاد قيم مقدرتين للمعلمتين β_0 و β_1 ، من خلال البحث عن أصغر قيمة لمجموع مربعات البواقي (Residual Sum of Squares-RSS or SSR-).

أي: $Min_{\beta_0, \beta_1} (RSS) = Min_{\beta_0, \beta_1} (\sum_{t=1}^n (\hat{\varepsilon}_t)^2)$

لدينا: $\sum_{t=1}^n (\hat{\varepsilon}_t)^2 = \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 = \sum_{t=1}^n (Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_t)^2$

لإيجاد أصغر قيمة للعلاقة السابقة يجب حساب المشتقات الجزئية بالنسبة للمعلمتين β_0 و β_1 ، ثم نعدم هذه المشتقات (مع

كون المشتق الثاني موجب: $\frac{\partial^2 RSS}{\partial \beta_0^2} > 0$).

أي نحل النظام التالي:

$$\left\{ \begin{array}{l} \frac{\partial RSS}{\partial \beta_0} = \frac{\partial \sum_{t=1}^n (Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_t)^2}{\partial \beta_0} = 0 \quad (1) \\ \frac{\partial RSS}{\partial \beta_1} = \frac{\partial \sum_{t=1}^n (Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_t)^2}{\partial \beta_1} = 0 \quad (2) \end{array} \right.$$

من المعادلة الأولى:

$$-2 \sum_{t=1}^n (Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_t) = 0 \Rightarrow \sum_{t=1}^n Y_t = n \hat{\beta}_0 + \hat{\beta}_1 \sum_{t=1}^n X_t$$

$$\hat{\beta}_0 = \frac{1}{n} \sum_{t=1}^n Y_t - \hat{\beta}_1 \frac{1}{n} \sum_{t=1}^n X_t \quad \text{ومنه:}$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} \quad \text{أي:}$$

حيث: \bar{Y}_t هو متوسط Y_t ، و \bar{X}_t هو متوسط X_t .

من المعادلة الثانية:

$$-2 \sum_{t=1}^n (X_t)(Y_t - \hat{\beta}_0 - \hat{\beta}_1 X_t) = 0 \Rightarrow \sum_{t=1}^n X_t Y_t = \hat{\beta}_0 \sum_{t=1}^n X_t + \hat{\beta}_1 \sum_{t=1}^n X_t^2$$

دروس في مقياس طرق التنبؤ

ومنه: $\hat{\beta}_1 \sum_{t=1}^n X_t^2 = \sum_{t=1}^n X_t Y_t - (\bar{Y} - \hat{\beta}_1 \bar{X}) \sum_{t=1}^n X_t = \sum_{t=1}^n X_t Y_t - \bar{Y} \sum_{t=1}^n X_t + \hat{\beta}_1 \bar{X} \sum_{t=1}^n X_t$

ومنه: $\hat{\beta}_1 (\sum_{t=1}^n X_t^2 - \bar{X} \sum_{t=1}^n X_t) = \sum_{t=1}^n Y_t X_t - \bar{Y} \sum_{t=1}^n X_t \Rightarrow \hat{\beta}_1 = \frac{\sum_{t=1}^n X_t Y_t - \bar{Y} \sum_{t=1}^n X_t}{\sum_{t=1}^n X_t^2 - \bar{X} \sum_{t=1}^n X_t}$

$$\hat{\beta}_1 = \frac{\sum_{t=1}^n X_t Y_t - n \bar{X} \bar{Y}}{\sum_{t=1}^n X_t^2 - n \bar{X}^2} \text{ أي:}$$

$$\begin{cases} \hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} \\ \hat{\beta}_1 = \frac{\sum_{t=1}^n X_t Y_t - n \bar{X} \bar{Y}}{\sum_{t=1}^n X_t^2 - n \bar{X}^2} \end{cases}$$

إذن، تقدير معاملات نموذج الانحدار الخطي البسيط هي:

ملاحظة: باستخراج n عامل مشترك من البسط والمقام في الصيغة الرياضية لـ $\hat{\beta}_1$ ، فإن: $\hat{\beta}_1 = \frac{n(\frac{1}{n} \sum_{t=1}^n X_t Y_t - \bar{X} \bar{Y})}{n(\frac{1}{n} \sum_{t=1}^n X_t^2 - \bar{X}^2)}$ ومنه

يمكن كتابة المعلمة المقدرة $\hat{\beta}_1$ كما يلي: $\hat{\beta}_1 = \frac{Cov(X_t, Y_t)}{V(X_t)}$

• تقدير تباين الأخطاء (σ_ε^2):

مقدرة تباين الأخطاء σ_ε^2 هي S_ε^2 ، حيث: $S_\varepsilon^2 = \frac{1}{n-2} \sum (\hat{\varepsilon}_t)^2 - (\bar{\hat{\varepsilon}})^2$ ، وبما أن متوسط الأخطاء معدوم (لأن


$$S_\varepsilon^2 = \frac{\sum \hat{\varepsilon}_t^2}{n-2}, \text{ فإن: } (\sum \hat{\varepsilon}_t = 0)$$

د. تحليل التباين ومعامل التحديد لنموذج الانحدار الخطي البسيط:

سنبدأ أولاً بعرض أهم عناصر تحليل تباين الانحدار الخطي البسيط، ثم حساب معامل التحديد وخصائص المقدرات.

• تحليل تباين النموذج:

ليكن التمثيل البياني لنموذج الانحدار الخطي التالي:



$$\text{لدينا: } \sum (Y_t - \bar{Y})^2 = \sum (\hat{Y}_t - \bar{Y})^2 + \sum (Y_t - \hat{Y}_t)^2$$

أي: مجموع التباين الكلي = مجموع التباين المفسر + مجموع تباين البواقي (TSS=ESS+RSS)

حيث: - Total Sum of Squares-TSS or SST، و- Explained Sum of Squares-ESS or SSE.

دروس في مقياس طرق التنبؤ

يمكن تلخيص ما سبق كما يلي:

المجموع	الصيغة الرياضية
مجموع تباين البواقي (RSS)	$\sum \hat{\varepsilon}_t^2$
مجموع التباين المفسر (ESS)	$\hat{\beta}_1^2 \sum (X_t - \bar{X})^2$ $\hat{\beta}_1 \sum (X_t - \bar{X})(Y_t - \bar{Y})$ $r^2 \sum (Y_t - \bar{Y})^2$
مجموع التباين الكلي (TSS)	$\sum (Y_t - \bar{Y})^2$
$TSS = ESS + RSS$	

يمثل الجدول التالي ملخص لتحليل تباين نموذج الانحدار الخطي البسيط:

مصدر التباين	مجموع المربعات	درجة الحرية	متوسط المربعات	إحصائية فيشر
المتغير المستقل (X)	ESS	1	$ESS/1$	$F_{1,n-2} = \frac{ESS/1}{RSS/n-2}$
الأخطاء (ε)	RSS	n-2	$RSS/n-2$	
المتغير التابع (Y)	TSS	n-1	/	

• معامل التحديد النموذج:

يقيس معامل التحديد (ويرمز له R^2) نسبة التغير في المتغير التابع المفسرة بمعادلة الانحدار (بالتغير المستقل). وحسابه نتبع

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS}$$

ملاحظة: مقدرات المربعات الصغرى العادية هي أفضل تقدير خطي غير متحيز (Best Linear Unbiased Estimator) (BLUE).

هـ. التنبؤ في نموذج الانحدار الخطي البسيط:

بعد تقدير معاملات النموذج بالاعتماد على البيانات المتوفرة للمتغيرين التابع والمستقل ($t = 1, 2, \dots, n$)، يمكن التنبؤ بالقيم المستقبلية للمتغير التابع، إن توفرت لدينا بيانات حول القيم المستقبلية للمتغير المستقل. للقيام بعملية التنبؤ نعتمد على العلاقة التالية:

$$\hat{Y}_h = \hat{\beta}_0 + \hat{\beta}_1 X_h$$

حيث h هو أفق التنبؤ: $h = n + 1, n + 2, \dots$

ومجال الثقة بالنسبة للقيم المتنبأ بها بدرجة ثقة $(1 - \alpha)$ هو:

$$Y_h \in \left[\hat{Y}_h \mp t_{n-2}^\alpha \cdot S_\varepsilon \sqrt{1 + \frac{1}{n} + \frac{(X_h - \bar{X})^2}{\sum (X_t - \bar{X})^2}} \right]$$

دروس في مقياس طرق التنبؤ

و. مثال تطبيقي شامل على برنامج إفيوز Eviews:

ليكن المثال التطبيقي هو دراسة أثر عنصر العمل (اليد العاملة L) على النمو الاقتصادي (مقاس بمؤشر الناتج المحلي الخام GDP) في الجزائر، خلال الفترة الممتدة من سنة 1970 إلى سنة 2018. ولكن قبل ذلك، سنتعرف أولا على برنامج إفيوز، وكيفية فتح ملف عمل وإنشاء سلاسل زمنية عليه.

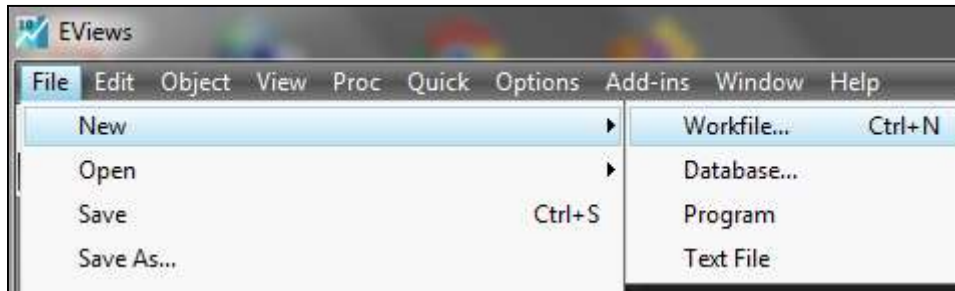
• التعرف على برنامج إفيوز:

برنامج إفيوز (Eviews) هو برنامج مختص في الاقتصاد القياسي وتحليل السلاسل الزمنية، وهو يحتوي على العديد من الأساليب وطرق التقدير، والكثير من الاختبارات الإحصائية لدراسة صلاحية النماذج. وهو يساعد الباحثين في تقدير وتحليل النماذج القياسية والتنبؤ. فتقريبا نستعين ببرنامج إفيوز في مختلف مراحل النمذجة القياسية.

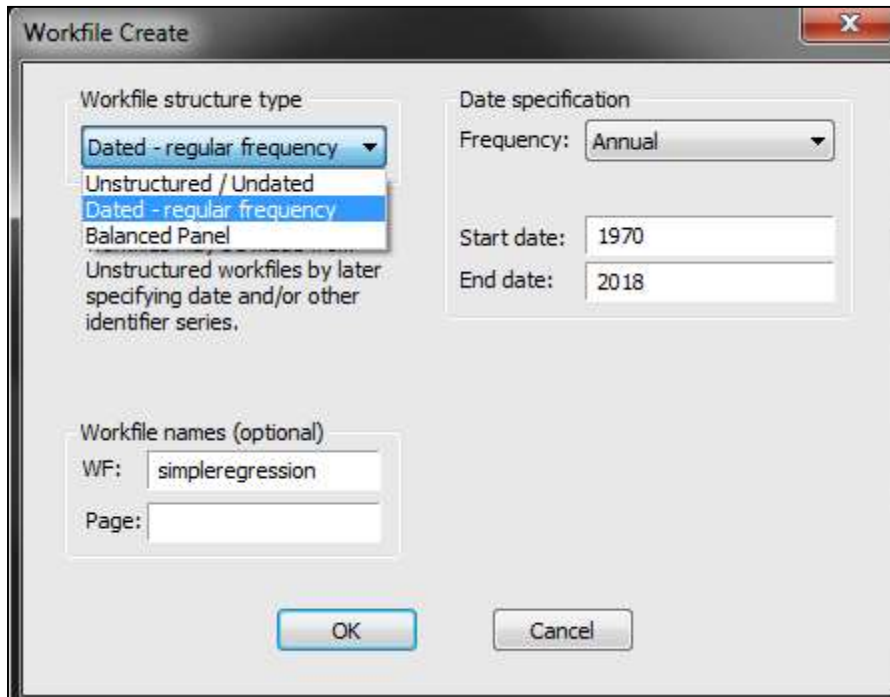
❖ كيفية فتح ملف عمل على برنامج إفيوز:

لفتح ملف عمل جديد (New Workfile) على برنامج إفيوز تتبع الخطوات التالية:

◀ نضغط على File ثم New ثم Workfile:



◀ فنظهر لنا النافذة التالية:



دروس في مقياس طرق التنبؤ

◀ نختار من النافذة السابقة:

✓ **نوع البيانات:** بيانات منتظمة، بيانات غير منتظمة، أو بيانات بانل (في مثالنا نختار بيانات منتظمة (Dated - regular frequency)).

✓ **تعيين التاريخ:** نحدد فيها هل البيانات سنوية، شهرية، أسبوعية، يومية،... إلخ (في مثالنا نختار سنوية (Annual)).

✓ نختار بداية تاريخ البيانات ونهايتها (في مثالنا نختار البداية في 1970 والنهاية في 2018).

✓ كما نسمي ملف العمل (في مثالنا نسميه انحدار بسيط "simpleregression").

✓ ثم نضغط على "OK".

◀ عند الضغط على OK يتم إنشاء ملف عمل جديد بالخصائص التي تم إختيارها:

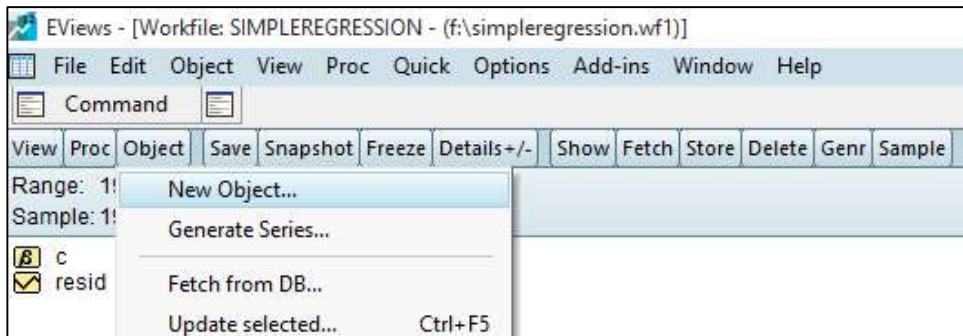


◀ ملف العمل عند إنشائه أول مرة نجد أنه يحتوي على عنصرين فقط: C وهو يعبر عن الحد الثابت، و resid وهو يعبر عن بواقى التقدير. عند الإنشاء يكون هذان العنصران فارغين، ثم يأخذان قيمة عند التقدير.

• **كيفية إدخال البيانات إلى برنامج إفيوز:**

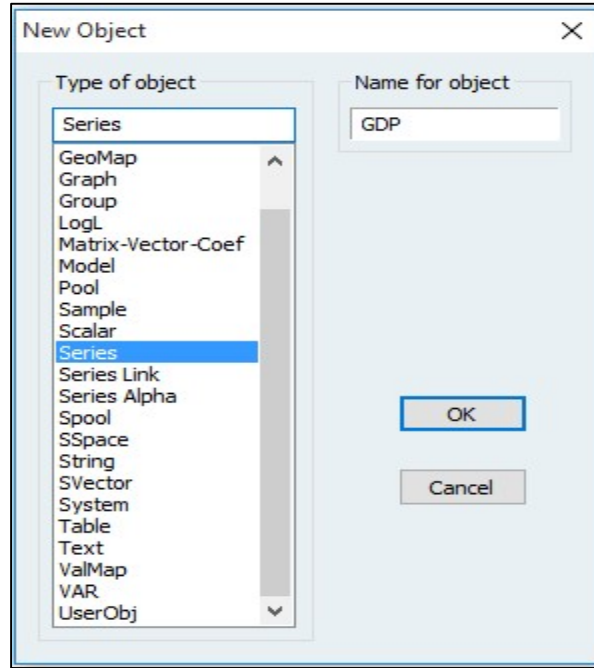
بما أن المثال التطبيقي يخص سلاسل زمنية، فنتبع الخطوات التالية لإدخالها:

◀ نضغط على Object ثم New Object:



◀ فنظهر لنا النافذة التالية:

دروس في مقياس طرق التنبؤ



◀ نختار من النافذة السابقة:

✓ نوع العنصر: في مثالنا نختار سلسلة زمنية (Series)

✓ إعطاء اسم للسلسلة الزمنية: نسميها "GDP"

✓ ثم نضغط على "OK".

◀ عند الضغط على OK يتم إنشاء سلسلة زمنية (فارغة من القيم).

◀ نقوم بإدخال قيم السلسلة، وذلك بالضغط عليها مرتين لفتحها، ثم الضغط على "Edit" لإدخال قيمها.

EViews - [Series: GDP Workfile: SIMPLEREGRESSION::Untitled\]										
File Edit Object View Proc Quick Options Add-ins Window Help										
Command										
View	Proc	Object	Properties	Print	Name	Freeze	Default	Sort	Edit+/-	Smpl+/-
Last updated: 07/16/21 - 18:40										
1970		NA								
1971		NA								
1972		NA								
1973		NA								

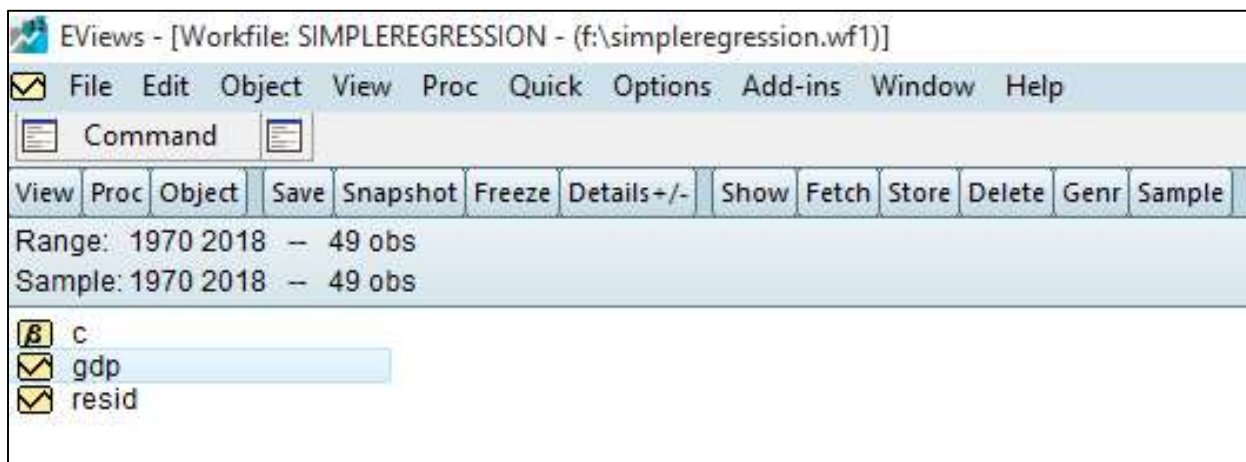
◀ كما يمكن إدخال القيم بنسخ ولصق (Copy-Paste) من إكسل EXCEL مثلا، أو بإحضار مباشرة ملف البيانات

من خلال الخاصية "import".

◀ عند الإنهاء من إدخال بيانات السلسلة، نضغط مجددا على "Edit"، ونغلق ملف السلسلة، فنكون قد أنهينا من إنشاء

سلسلة جديدة تحت اسم GDP.

دروس في مقياس طرق التنبؤ



◀ بنفس الطريقة السابقة نقوم بإدخال جميع السلاسل الزمنية التي نريد دراستها.

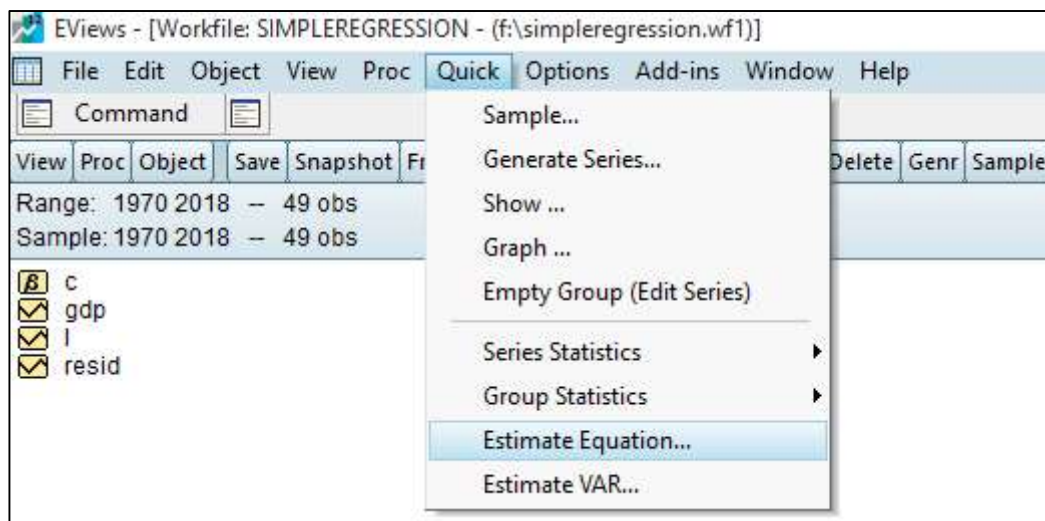
• مثال للانحدار الخطي البسيط على برنامج إفيوز:

❖ تقدير معادلة الانحدار الخطي البسيط:

نموذج الانحدار الخطي البسيط المراد تقديره هو: $GDP_t = \beta_0 + \beta_1 L_t + \varepsilon_t$.

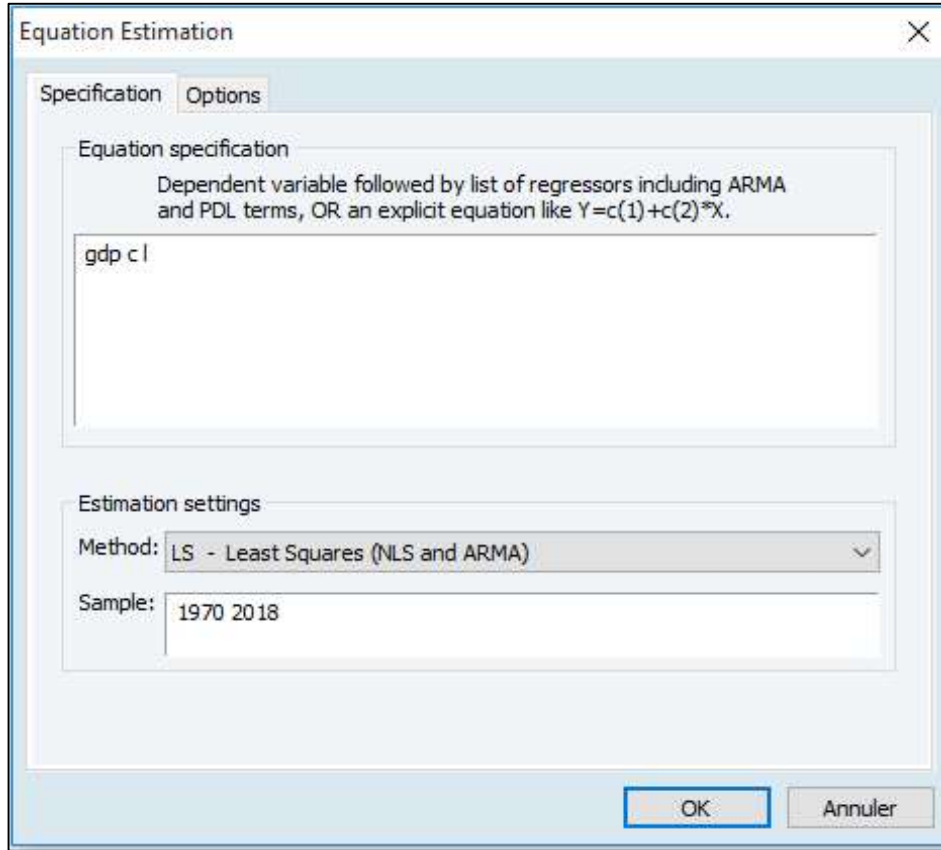
ولتقدير معادلة الانحدار الخطي البسيط على إفيوز نتبع الخطوات التالية:

◀ نضغط على Quick ثم Estimate Equation:



◀ فنظهر لنا النافذة التالية:

دروس في مقياس طرق التنبؤ



◀ من خلال هذه النافذة نقوم بـ:

- ✓ تعيين معادلة الانحدار، بحيث ندخل المتغير التابع (GDP)، ثم الحد الثابت (C)، ثم المتغير المستقل (L) بهذا الترتيب (وإن كان هناك متغيرات أخرى فنترك فراغ ثم ندخل الواحد تلو الآخر).
- ✓ اختيار طريقة التقدير، وهي طريقة المربعات الصغرى العادية (Least Squares).
- ✓ اختيار العينة (Sample)، وفي مثالنا نختار كل سنوات الدراسة (من 1970 إلى 2018).
- ✓ ثم نضغط على "OK".

◀ عند الضغط على OK، تظهر لنا نافذة التقدير التالية:

دروس في مقياس طرق التنبؤ

EViews - [Equation: UNTITLED Workfile: SIMPLEREGRESSION::Untitled\]				
File Edit Object View Proc Quick Options Add-ins Window Help				
Command				
View	Proc	Object	Print	Name Freeze Estimate Forecast Stats Resids
Dependent Variable: GDP				
Method: Least Squares				
Date: 07/16/21 Time: 19:06				
Sample: 1970 2018				
Included observations: 49				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2.05E+12	2.31E+11	-8.877565	0.0000
L	1099775.	35440.90	31.03123	0.0000
R-squared	0.953462	Mean dependent var		4.37E+12
Adjusted R-squared	0.952472	S.D. dependent var		3.29E+12
S.E. of regression	7.18E+11	Akaike info criterion		57.47671
Sum squared resid	2.42E+25	Schwarz criterion		57.55392
Log likelihood	-1406.179	Hannan-Quinn criter.		57.50600
F-statistic	962.9374	Durbin-Watson stat		0.551088
Prob(F-statistic)	0.000000			

◀ من خلال مخرجات إفيوز السابقة، يمكننا كتابة معادلة الانحدار ومختلف التقديرات بالشكل التالي:

$$\widehat{GDP} = -2,05 \times 10^{12} + 1099775 \times L$$

$$.t \quad (-8,88) \quad (31,03)$$

$$.R^2 = 0,95 \quad F = 962,93 \quad n = 49$$

❖ تحليل النتائج والتنبؤ:

أ. تحليل النتائج:

◀ يتبين من النموذج أن للعمل (L) أثر إيجابي على النمو الاقتصادي (GDP) في الجزائر، لأن معلمة العمل موجبة (وجود علاقة طردية).

◀ من قيمة معلمة العمل يتبين أنه إذا زاد عنصر العمل بوحدة واحدة فإن الناتج المحلي الخام سيزيد بـ 1099775 وحدة.

ب. التنبؤ بقيمة الناتج المحلي الخام GDP:


لنفترض توفر بيانات حول العمل في الجزائر للفترة 2019-2023، كما هي موضحة في الجدول التالي:

L	T
10 962 630	2019
11 119 196	2020
11 277 997	2021
11 439 066	2022
11 602 435	2023

دروس في مقياس طرق التنبؤ

◀ للقيام بعملية التنبؤ على برنامج إيفوز يجب أولا تغيير حجم ملف العمل (Resize range workfile)، وذلك باتباع الخطوات التالية:

◀ نضغط على Proc ثم على Structure/Resize Current Page:



◀ فنظهر لنا النافذة التالية:

◀ من خلال هذه النافذة نغير فقط نهاية بيانات ملف العمل (End date)، بجعله 2023 (كان سابقا 2018). ثم نضغط على "OK".

◀ نقوم بعد ذلك بإدخال قيم المتغير المستقل (L) للسنوات 2019-2023.

Series: L Workfile: SIMPLEREGRESSION::Untitled						
View	Proc	Object	Properties	Print	Name	Freeze
2018		10808270				
2019		10962630				
2020		11119196				
2021		11277997				
2022		11439066				
2023		11602435				

◀ ثم نقوم بفتح معادلة تقدير النموذج:

دروس في مقياس طرق التنبؤ

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-2.05E+12	2.31E+11	-8.877565	0.0000
L	1099775.	35440.90	31.03123	0.0000

R-squared	0.953462	Mean dependent var	4.37E+12
Adjusted R-squared	0.952472	S.D. dependent var	3.29E+12
S.E. of regression	7.18E+11	Akaike info criterion	57.47671
Sum squared resid	2.42E+25	Schwarz criterion	57.55392
Log likelihood	-1406.179	Hannan-Quinn criter.	57.50600
F-statistic	962.9374	Durbin-Watson stat	0.551088
Prob(F-statistic)	0.000000		

◀ ثم نضغط على Forecast (التنبؤ)، فتظهر النافذة التالية:

Forecast of
Equation: EQ01 Series: GDP

Series names
Forecast name:
S.E. (optional):
GARCH(optional):

Method
Static forecast
(no dynamics in equation)
 Coef uncertainty in S.E. calc


Forecast sample

Insert actuals for out-of-sample observations

Output
Graph:
 Forecast evaluation

◀ من خلال هذه النافذة نسمي السلسلة المتنبأ بها بالاعتماد على النموذج المقدر (GDPF)، كما نختار عينة التنبؤ (2019-2023)، ثم نضغط على OK، فتظهر لنا سلسلة جديدة في ملف العمل اسمها "GDPF".

دروس في مقياس طرق التنبؤ



◀ وعند فتحها نجد قيم المتغير التابع للسنوات 2019-2023.

Year	GDPF
2019	10005625835117
2020	10177813185696
2021	10352458533085
2022	10529598169854
2023	10709267288798

2. نموذج الانحدار الخطي المتعدد:

على عكس الانحدار الخطي البسيط، فإن نموذج الانحدار الخطي المتعدد يسمح بتعدد المتغيرات المستقلة، بحيث يبحث في أثر متغيرات مستقلة متعددة على المتغير التابع في إطار علاقة خطية.

أ. تعريف نموذج الانحدار الخطي المتعدد:

هو النموذج القياسي الذي يتكون من متغير تابع واحد فقط، وعدة متغيرات مستقلة، بحيث تكون العلاقة الرياضية التي تربط بينهما هي علاقة خطية. كما يلي:

$$t = 1, 2, \dots, n \quad Y_t = \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_k X_{kt} + \varepsilon_t$$

حيث: Y_t المتغير التابع

X_{it} المتغيرات المستقلة ($i = 1, 2, \dots, k$)

ε_t الحد العشوائي (حد الخطأ)

β_i ($i = 1, 2, \dots, k$) هي معاملات النموذج.

t الزمن.

n عدد المشاهدات (حجم العينة).

k عدد المتغيرات المستقلة في النموذج.

دروس في مقياس طرق التنبؤ

يمكن كتابة العلاقة السابقة على الشكل المصفوفي التالي:

$$Y_{n \times 1} = X_{n \times k} B_{k \times 1} + \varepsilon_{n \times 1}$$

$$\varepsilon_{n \times 1} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}, B_{k \times 1} = \begin{pmatrix} \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}, X_{n \times k} = \begin{pmatrix} X_{11} & X_{12} & \cdots & X_{1k} \\ \vdots & \vdots & \vdots & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{nk} \end{pmatrix}, Y_{n \times 1} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} \text{ حيث:}$$

ب. فرضيات نموذج الانحدار الخطي المتعدد:

تمثل فرضيات نموذج الانحدار الخطي المتعدد في النقاط التالية:

$$(1) \text{ متوسط الأخطاء معدوم: } E(\varepsilon_t) = 0 \text{ (أي) } E(\varepsilon_t) = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix} \text{ حيث } E(\varepsilon_t) = E \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix} = \begin{pmatrix} E(\varepsilon_1) \\ \vdots \\ E(\varepsilon_n) \end{pmatrix} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}$$

$$(2) \text{ تباين الأخطاء ثابت (متجانس): } V(\varepsilon_t) = \sigma_\varepsilon^2 I_n \text{ (أي) } V(\varepsilon_t) = \begin{pmatrix} \sigma_\varepsilon^2 & 0 & \cdots & 0 \\ 0 & \sigma_\varepsilon^2 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & \sigma_\varepsilon^2 \end{pmatrix}$$

$$(3) \text{ التباين بين الأخطاء معدوم: } Cov(\varepsilon_t, \varepsilon_{t'}) = 0 \text{ } \forall t \neq t'$$

$$(4) \text{ الأخطاء تتبع التوزيع الطبيعي: } \varepsilon_t \sim N(0, \sigma_\varepsilon^2 I)$$

(5) العلاقة خطية: خطية بالنسبة للمتغيرات وخطية بالنسبة للمعاملات:

$$Y_t = \beta_1 X_{1t} + \beta_2 X_{2t} + \cdots + \beta_k X_{kt} + \varepsilon_t$$

$$(6) \text{ المتغيرات المستقلة غير مترابطة خطيا فيما بينها، فتكون رتبة المصفوفة } X \text{ هي } k: rang(X) = k$$

$$(7) \text{ المصفوفة } X \text{ غير عشوائية (عناصرها أعداد ثابتة).}$$

ج. تقدير نموذج الانحدار الخطي المتعدد:

ستتطرق في هذا العنصر إلى طريقة المربعات الصغرى العادية (Ordinary Least squares -OLS-) لتقدير نموذج

الانحدار الخطي المتعدد.

$$\text{ليكن لدينا نموذج الانحدار الخطي المتعدد التالي: } Y = XB + \varepsilon$$

$$\text{النموذج المقدر للنموذج السابق هو النموذج التالي: } \hat{Y} = X\hat{B}$$

$$\text{حيث } \hat{B} \text{ هو تقدير لشعاع المعلمات } B \text{، أي: } \hat{B}_{k \times 1} = \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_k \end{pmatrix}$$

الأخطاء (أو البواقي، ونرمز لها $\hat{\varepsilon}$) هي الفرق بين النموذج الأول النظري والنموذج الثاني المقدر على العينة. أي أن: $\hat{\varepsilon} = Y - \hat{Y}$

دروس في مقياس طرق التنبؤ

❖ تقدير المعلمات:

طريقة المربعات الصغرى العادية تهدف إلى إيجاد مقدرات المعلمات من خلال البحث عن أصغر قيمة لمجموع مربعات البواقي (RSS).

$$\text{أي: } \text{Min}_B (RSS) = \text{Min}_B (\hat{\varepsilon}'\hat{\varepsilon})$$

$$\text{لدينا: } \hat{\varepsilon}'\hat{\varepsilon} = (Y - \hat{Y})'(Y - \hat{Y}) = [Y' - (X\hat{B})'](Y - X\hat{B}) = (Y' - \hat{B}'X')(Y - X\hat{B})$$

$$\text{ومنه: } \hat{\varepsilon}'\hat{\varepsilon} = Y'Y - Y'X\hat{B} - \hat{B}'X'Y + \hat{B}'X'X\hat{B}$$

$$\frac{\partial RSS}{\partial \hat{B}} = 0 \text{ لإيجاد أصغر قيمة للعلاقة السابقة يجب أن نحسب المشتق ثم نعدمه، أي:}$$

$$\frac{\partial SSR}{\partial \hat{B}} = -2X'Y + 2X'X\hat{B} = 0 \Rightarrow X'X\hat{B} = X'Y \text{ لدينا:}$$

$$\hat{B} = (X'X)^{-1}X'Y \text{ ومنه:}$$

❖ تقدير توقع وتباين مقدرات المعلمات:

$$\hat{B}_{ols} = (X'X)^{-1}X'Y = (X'X)^{-1}X'(XB + \varepsilon) = B + (X'X)^{-1}X'\varepsilon \text{ لدينا:}$$

$$\text{ومنه: } E(\hat{B}_{ols}) = E(B) + (X'X)^{-1}X'E(\varepsilon)$$

$$\text{(تذكير: إذا كان } L = A + B \cdot X \text{، فإن } E(L) = A + B \cdot E(X) \text{)}$$

$$\text{وبما أن: } E(\varepsilon) = 0 \text{، فإن } E(\hat{B}_{ols}) = B$$

$$\text{وكذلك: } V(\hat{B}_{ols}) = (X'X)^{-1}X'V(\varepsilon)X(X'X)^{-1} = V(\varepsilon)(X'X)^{-1}X'X(X'X)^{-1}$$

$$\text{(تذكير: إذا كان } L = A + B \cdot X \text{، فإن } V(L) = BV(X)B' \text{، و } V(L)(X'X(X'X)^{-1} = I \text{)}$$

$$\text{ومنه: } V(\hat{B}_{ols}) = \sigma_\varepsilon^2(X'X)^{-1}$$

$$\hat{B} \sim N(B, \sigma_\varepsilon^2(X'X)^{-1}) \text{ إذن:}$$

❖ تقدير تباين الأخطاء (σ_ε^2):

$$\hat{\sigma}_\varepsilon^2 = \frac{\hat{\varepsilon}'\hat{\varepsilon}}{n-k} \text{ هو تقدير لتباين الأخطاء بطريقة المربعات الصغرى العادية.}$$

د. تحليل التباين، معامل التحديد، وخصائص مقدرات نموذج الانحدار الخطي المتعدد:

• تحليل تباين النموذج:

جدول تحليل تباين نموذج الانحدار الخطي المتعدد:

مصدر التباين	مجموع المربعات	درجة الحرية	متوسط المربعات	إحصائية فيشر
المتغيرات المستقلة (X_i)	ESS	k-1	$ESS/k-1$	$F_{k-1, n-k} = \frac{ESS/k-1}{RSS/n-k}$
الأخطاء (ε)	RSS	n-k	$RSS/n-k$	
المتغير التابع (Y)	TSS	n-1	/	

دروس في مقياس طرق التنبؤ

• معامل تحديد النموذج:

لدينا: $Y = X\hat{B} + \hat{\varepsilon}$ ، و $Y' = \hat{B}'X' + \hat{\varepsilon}'$ ، ومنه: $Y'Y = (\hat{B}'X' + \hat{\varepsilon}')(X\hat{B} + \hat{\varepsilon})$.

أي: $Y'Y = \hat{B}'X'X\hat{B} + \hat{B}'X'\hat{\varepsilon} + \hat{\varepsilon}'X\hat{B} + \hat{\varepsilon}'\hat{\varepsilon}$.

وبما أن $X'\hat{\varepsilon} = \hat{\varepsilon}'X = 0$ ، فإن: $Y'Y = \hat{B}'X'X\hat{B} + \hat{\varepsilon}'\hat{\varepsilon}$.

أي: $TSS = ESS + RSS$.

فيكون: $R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS}$.

وكونه يزداد بزيادة المتغيرات المفسرة إلى النموذج - حتى وإن لم يكن لها علاقة بالظاهرة المدروسة-، فإن الإحصائيين يفضلون

استبداله بمعامل التحديد المعدل (Adjusted R-squared)، الذي يأخذ الصيغة التالية: $\bar{R}^2 = 1 - \frac{RSS/n-k}{SST/n-1}$ أو

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

هـ. التنبؤ في نموذج الانحدار الخطي المتعدد:

بعد تقدير معاملات النموذج بالاعتماد على البيانات السابقة للمتغير التابع والمتغيرات المستقلة ($t = 1, 2, \dots, n$)، يمكن التنبؤ

بالقيم المستقبلية للمتغير التابع، إن توفرت لدينا بيانات حول القيم المستقبلية للمتغيرات المستقلة (لنرمز لها بـ: $H = \begin{pmatrix} X_{1h} \\ X_{2h} \\ \vdots \\ X_{kh} \end{pmatrix}$).

لليقيام بعملية التنبؤ نعلم على العلاقة التالية: $\hat{Y}_h = \hat{\beta}_1 X_{1h} + \hat{\beta}_2 X_{2h} + \dots + \hat{\beta}_k X_{kh}$.

حيث h هو أفق التنبؤ: $h = n + 1, n + 2, \dots$.

يمكن كتابة العلاقة السابقة على الشكل المصفوفي التالي: $\hat{Y}_h = H' \hat{\beta}$.

ومجال الثقة بالنسبة للقيم المتنبأ بها بدرجة ثقة $(1 - \alpha)$ هو:

$$Y_h \in \left[\hat{Y}_h \mp t_{n-k}^\alpha \cdot S_\varepsilon \sqrt{1 + H'(X'X)^{-1}H} \right]$$

و. مثال تطبيقي شامل على برنامج إيفوز Eviews

ليكن المثال التطبيقي هو دراسة أثر عنصري العمل (اليد العاملة L) ورأس المال (k) على النمو الاقتصادي (مقاس بمؤشر

الناتج المحلي الخام GDP) في الجزائر، خلال الفترة الممتدة من سنة 1970 إلى سنة 2018.

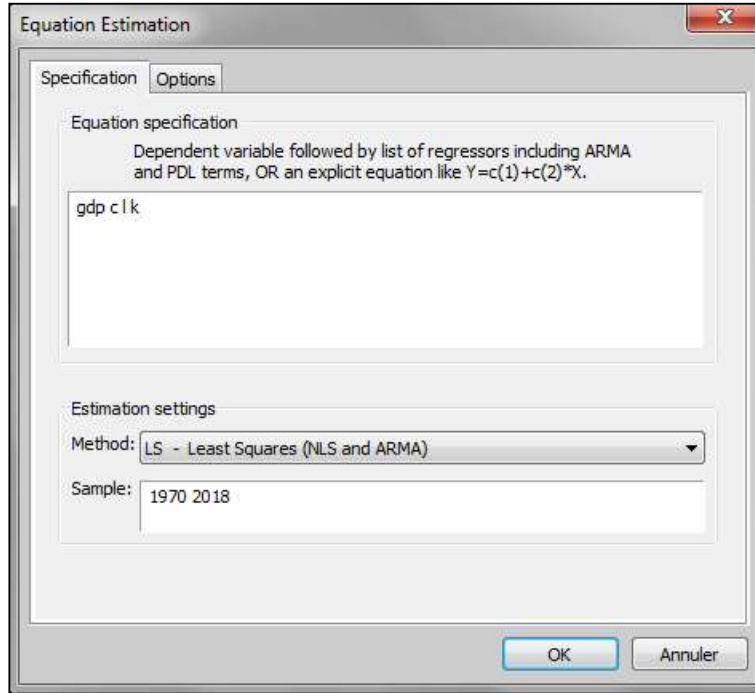
❖ تقدير معادلة الانحدار:

نتبع على برنامج إيفوز نفس الخطوات المطبقة على المثال التطبيقي لنموذج الانحدار الخطي البسيط أعلاه، لفتح ملف عمل،

ولإدخال بيانات الدراسة، ولتقدير معادلة الانحدار الخطي (بالنسبة للانحدار المتعدد: عند تعيين معادلة الانحدار ندخل المتغير التابع

(GDP) ثم الحد الثابت (C) ثم المتغير المستقل الأول (L) ثم المتغير المستقل الثاني (K) بهذا الترتيب).

دروس في مقياس طرق التنبؤ



عند الضغط على OK، تظهر لنا نافذة التقدير التالية:

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-1.43E+12	3.01E+11	-4.751105	0.0000
L	837824.1	95346.38	8.787162	0.0000
K	0.062901	0.021490	2.927040	0.0053
R-squared	0.960769	Mean dependent var	4.37E+12	
Adjusted R-squared	0.959064	S.D. dependent var	3.29E+12	
S.E. of regression	6.66E+11	Akaike info criterion	57.34672	
Sum squared resid	2.04E+25	Schwarz criterion	57.46255	
Log likelihood	-1401.995	Hannan-Quinn criter.	57.39067	
F-statistic	563.2747	Durbin-Watson stat	0.582579	
Prob(F-statistic)	0.000000			

من خلال مخرجات إيفوز السابقة، يمكننا كتابة معادلة الانحدار ومختلف التقديرات بالشكل التالي:

$$GDP = -1,43 \times 10^{12} + (837824)L + (0,06)K$$

$$t \quad (-4,75) \quad (8,78) \quad (2,93)$$

$$R^2 = 0,96 \quad RSS = 2,04 \times 10^{25} \quad F = 563,27$$

$$S_{\varepsilon}^2 = \frac{RSS}{n-3} = \frac{2,04 \times 10^{25}}{46} = 4,43 \times 10^{23} : (\sigma_{\varepsilon}^2) \text{ تقدير تباين الأخطاء}$$

دروس في مقياس طرق التنبؤ

❖ التنبؤ بقيم الناتج المحلي الخام GDP:

لنعتبر توفر بيانات حول العمل ورأس المال في الجزائر للفترة 2019-2023 كما هي موضحة في الجدول التالي:

K	L	t
52 132 662 882 170	10 962 630	2019
55 260 622 655 100	11 119 196	2020
58 576 260 014 406	11 277 997	2021
62 090 835 615 270	11 439 066	2022
65 816 285 752 186	11 602 435	2023

- ◀ للقيام بعملية التنبؤ على برنامج إفيوز نتبع نفس الخطوات المبينة في المثال التطبيقي لنموذج الانحدار الخطي البسيط (تغيير حجم ملف العمل بتغيير نهاية بيانات ملف العمل (End date)، بجعله 2023).
- ◀ نقوم بعد ذلك بإدخال قيم المتغيرات المستقلة (L) و (K) للسنوات 2019-2023.
- ◀ ثم نقوم بفتح النافذة التي تحتوي على تقدير النموذج. ثم نضغط على Forecast، ونسمي السلسلة المتنبأ بها بالاعتماد على النموذج المقدر (GDPF)، كما نختار عينة التنبؤ (2019 - 2023)، ثم نضغط على OK، فتظهر لنا سلسلة جديدة في ملف العمل اسمها "GDPF".
- ◀ وعند فتحها نجد قيم المتغير التابع (GDP) للسنوات 2019-2023.

Year	GDPF Value
2012	9126898454068
2013	9826587389132
2014	9555264184916
2015	10041486122383
2016	10426817654024
2017	10422677796027
2018	10717722143732
2019	11032665043685
2020	11360593166138
2021	11702199026946
2022	12058218586396
2023	12429429465678

دروس في مقياس طرق التنبؤ

3. نماذج الانحدار غير الخطية:

سنخصص هذا المبحث للتعرف على الانحدار غير الخطي وكيفية تقديره والتنبؤ على أساسه.

أ. مفهوم النماذج غير الخطية:

كثيرا ما يكون شكل انتشار النقاط عند تمثيل المتغيرات غير خطي، وعند بناء نموذج قياسي يتعين على الباحث البحث عن أفضل صيغة رياضية معبرة عن العلاقة بين المتغير التابع والمتغيرات المستقلة، بحيث تجعل تقدير العلاقة أكثر دقة وأقرب للواقع. والنماذج غير الخطية هي نماذج رياضية تكون فيها الصيغة الدالية للعلاقة التي تربط المتغير التابع بالمتغير (أو المتغيرات) المستقل (ة) غير خطية، سواءا بالنسبة للمتغيرات أو بالنسبة للمعاملات، أو بالنسبة لهما معا.

$$\leftarrow \text{نموذج غير خطي بالنسبة للمتغير: } Y = \beta_0 + \beta_1 X^2$$

$$\leftarrow \text{نموذج غير خطي بالنسبة للمعاملات: } Y = \lambda X_1 + (1 - \lambda)^2 X_2$$

$$\leftarrow \text{نموذج غير خطي بالنسبة للمتغير وللمعاملات: } Y = \beta_0 + (1 - \lambda)^2 X_1^{\beta_1} + \beta_3 X_2^2$$

ب. أهمية النماذج غير الخطية:

للنماذج غير الخطية أهمية كبيرة في النمذجة القياسية، ويبرز ذلك في عدة جوانب، نلخصها في النقاط التالية:

- ◀ فرضية خطية العلاقة بين المتغيرات غير محققة في العديد من النماذج الاقتصادية.
- ◀ تسمح النماذج غير الخطية بالتقريب الأكثر دقة للعديد من العلاقات بين المتغيرات الاقتصادية.
- ◀ إذا كان النموذج المناسب للبيانات غير خطي، فإن تقدير النموذج غير الخطي لها يجعل مجموع مربعات الأخطاء أقل ما يمكن، وبالتالي معامل التحديد أكبر ما يمكن. والتنبؤ بقيم المتغير التابع يكون أكثر دقة.

ج. بعض نماذج الانحدار غير الخطية:

يمكن تقسيم النماذج غير الخطية من حيث إمكانية تحويلها إلى نماذج خطية إلى مجموعتين، وهما: نماذج غير خطية يمكن تحويلها إلى نماذج خطية، ونماذج غير خطية لا يمكن تحويلها إلى نماذج خطية، وسنركز على النوع الأول لشيوعه وكثرة استخدامه.

من بين أهم النماذج غير الخطية التي يمكن تحويلها إلى نماذج خطية النماذج التالية:

❖ الدالة الأسية البسيطة: هي دالة غير خطية يكون فيها المتغير المستقل قوى عدد حقيقي، ومضروب في عدد حقيقي آخر. لكن

يمكن تحويلها إلى دالة خطية بإدخال اللوغاريتم على الدالة.

$$- \text{الدالة الأسية الأصلية (غير خطية): } Y = \beta_0 X^{\beta_1}$$

$$- \text{النموذج القياسي الموافق بعد إدخال اللوغاريتم (خطي): } \ln(Y_t) = \ln(\beta_0) + \beta_1 \ln(X_t) + \ln(\varepsilon_t)$$

$$\text{فتصبح من الشكل: } Y_t^* = \beta_0^* + \beta_1 X_t^* + \varepsilon_t^*$$

حيث: $Y_t^* = \ln(Y)$ و $\beta_0^* = \ln(\beta_0)$ و $X_t^* = \ln(X_t)$ و $\varepsilon_t^* = \ln(\varepsilon_t)$ و $(t = 1, 2, \dots, n)$.

❖ الدالة الأسية المتعددة: هي دالة غير خطية تكون فيها المتغيرات المستقلة قوى أعداد حقيقية، ومضروبة في عدد حقيقي آخر.

لكن يمكن تحويلها إلى دالة خطية بإدخال اللوغاريتم على الدالة.

دروس في مقياس طرق التنبؤ

— الدالة الأسية المتعددة الأصلية (غير خطية): $Y = \beta_0 X_1^{\beta_1} X_2^{\beta_2} \dots X_k^{\beta_k}$

— النموذج القياسي الموافق بعد إدخال اللوغاريتم (خطي):

$$\ln(Y_t) = \ln(\beta_0) + \beta_1 \ln(X_{1t}) + \beta_2 \ln(X_{2t}) + \dots + \beta_k \ln(X_{kt}) + \ln(\varepsilon_t)$$

$$Y_t^* = \beta_0^* + \beta_1 X_{1t}^* + \beta_2 X_{2t}^* + \dots + \beta_k X_{kt}^* + \varepsilon_t^*$$

حيث: $Y_t^* = \ln(Y)$ و $\beta_0^* = \ln(\beta_0)$ و $X_{it}^* = \ln(X_{it})$ و $\varepsilon_t^* = \ln(\varepsilon_t)$ و $(i = 1, 2, \dots, k)$

$(t = 1, 2, \dots, n)$

❖ الدوال كثرات الحدود:

الدالة كثيرة الحدود هي دالة غير خطية بالنسبة للمتغيرات لاحتوائها على متغيرات بالقوى (مربع (نموذج تربيعي، مكعب (نموذج تكعيبي)، ...). لكن يمكن تقديرها وكأنها دالة خطية باعتبار كل متغير **بالقوى** هو متغير مستقل في النموذج.

بشكل عام كثير الحدود من الدرجة k يكتب على الشكل التالي:

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 + \beta_3 X^3 + \dots + \beta_k X^k$$

النموذج القياسي الموافق (خطي) هو:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \beta_3 X_{3t} + \dots + \beta_k X_{kt} + \varepsilon_t \quad \text{حيث: } t = 1, 2, \dots, n$$

$$X_{kt} = X^k, \dots, X_{3t} = X^3, X_{2t} = X^2, X_{1t} = X$$

❖ الدوال نصف اللوغاريتمية:

الدالة نصف اللوغاريتمية أو شبه اللوغاريتمية هي دالة غير خطية، أين يكون أحد المتغيرات باللوغاريتم. ونميز فيه بين حالتين:

❖ المتغير التابع هو المتغير باللوغاريتم: يمكن تقدير هذه الدالة وكأنها دالة خطية باعتبار لوغاريتم المتغير هو المتغير التابع.

$$\ln(Y) = \beta_0 + \beta_1 X \quad \text{— الدالة النصف لوغاريتمية الأصلية (غير خطية):}$$

$$(Y = e^{\beta_0 + \beta_1 X} \text{ وأصلها هو:})$$

$$Y_t^* = \beta_0 + \beta_1 X_t + \varepsilon_t \quad \text{— النموذج القياسي الموافق بعد تغيير المتغير (خطي):}$$

$$Y_t^* = \ln(Y) \quad \text{حيث: } (t = 1, 2, \dots, n)$$

❖ المتغير المستقل هو المتغير باللوغاريتم: يمكن تقدير هذه الدالة وكأنها دالة خطية باعتبار لوغاريتم المتغير هو المتغير المستقل.

$$Y = \beta_0 + \beta_1 \ln(X) \quad \text{— الدالة النصف لوغاريتمية الأصلية (غير خطية):}$$

$$(e^Y = \beta_0 X^{\beta_1} \text{ وأصلها هو:})$$

$$Y_t = \beta_0 + \beta_1 X_t^* + \varepsilon_t \quad \text{— النموذج القياسي الموافق بعد تغيير المتغير (خطي):}$$

$$X_t^* = \ln(X) \quad \text{حيث: } (t = 1, 2, \dots, n)$$

❖ دوال المعكوس (المقلوب):

دروس في مقياس طرق التنبؤ

دالة المعكوس هي دالة غير خطية، أين يكون المتغير المستقل هو مقلوب متغير ما. لكن يمكن تقدير هذه الدالة وكأنها دالة خطية باعتبار مقلوب المتغير هو المتغير المستقل.

- دالة المعكوس الأصلية (غير خطية): $Y = \beta_0 + \beta_1 \left(\frac{1}{X}\right)$

- النموذج القياسي الموافق بعد تغيير المتغير (خطي): $Y_t = \beta_0 + \beta_1 X_t^* + \varepsilon_t$ حيث $(t = 1, 2, \dots, n)$
 $X_t^* = \frac{1}{X}$

د. كيفية تقدير النماذج غير الخطية:

بما أن هذا النوع من النماذج غير الخطية يمكن تحويلها إلى نماذج خطية، فلتقديرها نقوم بإجراء التحويل المناسب على النموذج غير الخطي لتحويله إلى نموذج خطي، ثم نقدره بطريقة المربعات الصغرى العادية. وقد تطرقنا إلى هذه الطريقة سابقا.

ه. كيفية التعرف على خطية/عدم خطية النماذج القياسية:

للتعرف على العلاقات التي تربط المتغيرات يمكن الاعتماد إما على النظرية الاقتصادية والنماذج النظرية المعروفة، أو على الدراسات السابقة للظاهرة المدروسة، أو من خلال التمثيل البياني للمتغير التابع والمتغيرات المستقلة (سحابة النقاط).
 نميز بين حالتين:

● حالة متغير مستقل واحد فقط:

بشكل عام، للتعرف على العلاقات التي تربط المتغيرات يمكن الاعتماد إما على النظريات والنماذج الرياضية والاقتصادية المعروفة للظاهرة محل الدراسة، أو على الدراسات السابقة لهذه الظاهرة. كما يسمح التمثيل البياني المشترك للمتغير التابع والمتغيرات المستقلة (سحابة النقاط) بتمثيل شكل العلاقة.

ونظرا لأن العديد من النظريات الاقتصادية التي تؤكد وجود علاقات بين المتغيرات لا تقدم شكل لهذه العلاقة، فإن الباحثين يلجؤون إلى بعض الأساليب لتحديد شكلها، ومن ذلك تمثيل بيانات هذه المتغيرات في شكل سحابة نقاط (المتغير التابع على محور والمتغير المستقل على محور آخر) لاكتشاف شكل انتشار البيانات، ومن خلال معاينة هذا الشكل يتم تحديد شكل العلاقة هل هي خطية أم غير خطية. ويمكن الاستعانة بالبرامج الإحصائية الجاهزة لاكتشاف هذه العلاقة (كبرنامج SPSS) من خلال المفاضلة بين مختلف النماذج المقترحة لتمثيل العلاقة.

● حالة عدة متغيرات مستقلة:

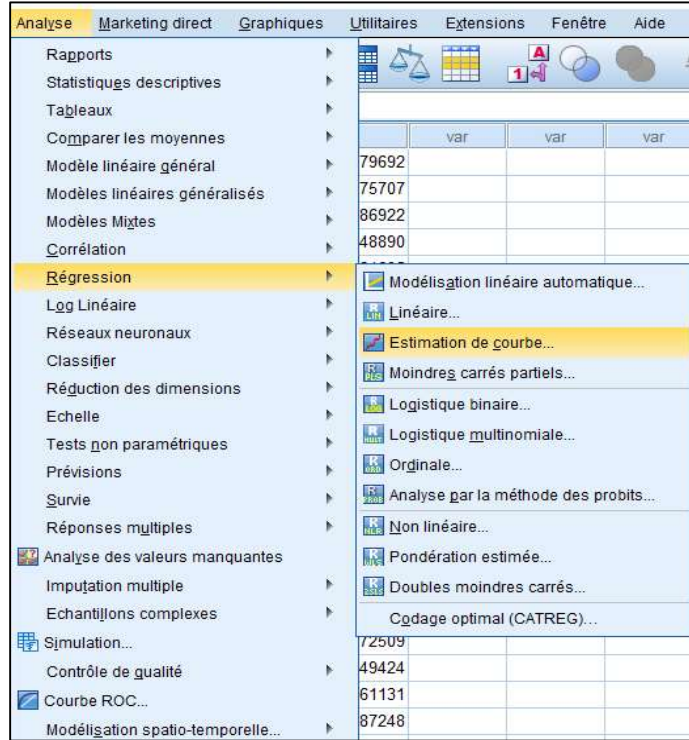
إن من مساوئ دراسة شكل سحابة النقاط، أن هذا الأسلوب مناسب أكثر للنماذج البسيطة والتي تضم متغير مستقل واحد فقط، أما في حالة نموذج متعدد يضم عدة متغيرات مفسرة، فحني وإن حددنا طبيعة العلاقة بين كل متغير مستقل والمتغير التابع، فتطرح إشكالية كيفية الدمج بين هذه العلاقات، هل تدمج بالجمع أو الجداء مثلا؟ فحتى لو كانت العلاقة خطية مثلا بين المتغير التابع وكل متغير مستقل على حدى، فليس هناك ما يضمن أن تكون كذلك في حالة نموذج يضم جميع هذه المتغيرات في نفس الوقت.

وللتغلب على هذه المحدودية، يمكن إما الرجوع للنظرية الاقتصادية أو الدراسات السابقة، أو يقوم الباحثون بتجريب عدة صيغ رياضية محتملة لتفسير العلاقة بين المتغيرات، ثم اختيار الصيغة التي تكون أكثر كفاءة ومعقولة من الناحية الاقتصادية والإحصائية.

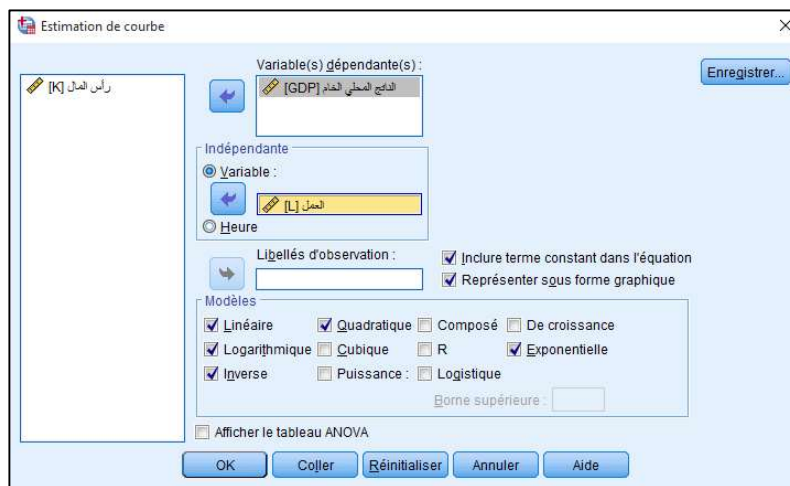
دروس في مقياس طرق التنبؤ

و. النمذجة غير الخطية في حالة متغير مستقل واحد فقط:

سنعتمد على برنامج SPSS للمفاضلة، بعد ادخال البيانات إلى برنامج SPSS، نتبع الخطوات التالية:
نضغط على Analyse ثم régression ثم estimation de courbe:



فتظهر لنا النافذة التالية:



نختار من خلال هذه النافذة:

- ✓ المتغير التابع: مثلا الناتج المحلي الخام GDP
- ✓ المتغير المستقل: مثلا العمل L
- ✓ النموذج (أو النماذج) التي تعبر عن العلاقة بينهما: خطي، لوغاريتمي، معكوس، تربيعي، أسّي، قوى، ...

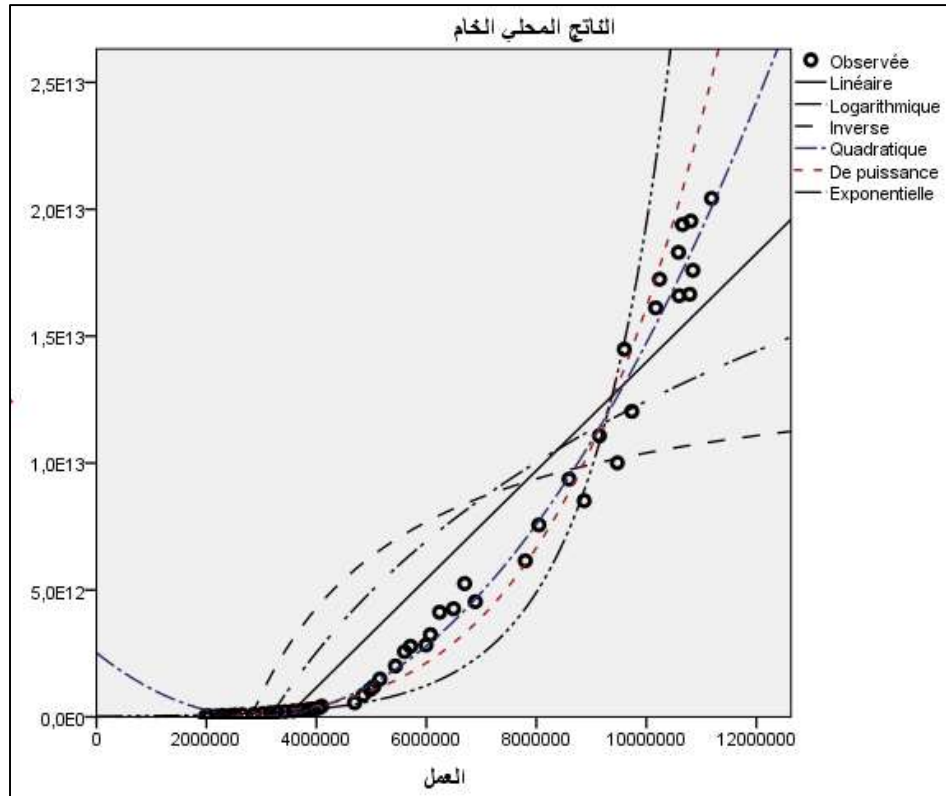
دروس في مقياس طرق التنبؤ

عند الضغط على OK تظهر لنا المخرجات، وتضم أساسا الجدول والتمثيل البياني التاليين:

Récapitulatif du modèle et estimations de paramètres								
Variable dépendante: الناتج المحلي الخام								
Equation	Récapitulatif des modèles					Estimations des paramètres		
	R-deux	F	ddl1	ddl2	Sig.	Constante	b1	b2
Linéaire	,897	424,478	1	49	,000	-7,389E+12	2136579,000	
Logarithmique	,742	141,159	1	49	,000	-1,618E+14	1,081E+13	
Inverse	,536	56,641	1	49	,000	1,448E+13	-4,077E+19	
Quadratique	,987	1767,576	2	48	,000	2,524E+12	-1716816,358	,294
De puissance	,990	4674,200	1	49	,000	2,878E-15	3,964	
Exponentiel	,923	590,550	1	49	,000	1,986E+10	6,887E-7	

La variable indépendante est العمل.

نلاحظ من هذا الجدول أن أفضل نموذج هو نموذج قوى puissance (مع ملاحظة أن معامل التحديد بين النموذجين قريب جدا 0,990-0,987)، كما أن برنامج SPSS يعطينا معلومة أخرى مهمة وهي قيمة إحصائية فيشر Fisher، فنلاحظ أن نموذج القوى له أكبر قيمة لإحصائية فيشر (4674)، والفرق بينها وبين أقرب قيمة لها (التربيعي: 1767) كبير جدا ودال إحصائيا (4674-1767=2707).



يؤكد التمثيل البياني أعلاه النتيجة السابقة، فنلاحظ أن منحى نموذج قوى (وكذلك النموذج التربيعي) هو الأقرب لتمثيل سحابة النقاط.

ومن هنا يتبين أن أفضل نموذج يعبر عن العلاقة بين الناتج المحلي الخام (GDP) وعنصر العمل (L) هو نموذج قوى الذي يأخذ العلاقة التالية:

دروس في مقياس طرق التنبؤ

$$.GDP = 2,88 \times 10^{-15} \times L^{3,96}$$

$$.R^2 = 0,99 \quad F=4674 \quad n=51$$

بنفس الطريقة بالنسبة لتحديد طبيعة العلاقة بين الناتج المحلي الخام (GDP) ورأس المال (K):


Récapitulatif du modèle et estimations de paramètres								
Variable dépendante: الناتج المحلي الخام								
Equation	R-deux	Récapitulatif des modèles				Estimations des paramètres		
		F	ddl1	ddl2	Sig.	Constante	b1	b2
Linéaire	,977	2043,956	1	49	,000	6,701E+11	2,125	
Logarithmique	,768	162,367	1	49	,000	-6,787E+13	2,734E+12	
Inverse	,166	9,723	1	49	,003	6,943E+12	-1,020E+23	
Quadratique	,992	2950,727	2	48	,000	1,341E+11	3,208	-1,279E-13
De puissance	,990	4966,449	1	49	,000	4,091	,986	
Exponentiel	,606	75,338	1	49	,000	3,783E+11	5,315E-13	

La variable indépendante est رأس المال.

نلاحظ من هذا الجدول أنه بالاعتماد على معامل التحديد فإن أفضل نموذج هو النموذج التربيعي ($R^2=0,992$) ثم نموذج قوى ($R^2=0,990$) مع التقارب الكبير بينهما.

لكن إذا نظرنا إلى إحصائية فيشر فإن أفضل نموذج هو نموذج قوى، أين نلاحظ أن نموذج قوى له أكبر قيمة لإحصائية فيشر (4966)، والفرق بينها وبين أقرب قيمة لها (التربيعي: 2950) كبير جدا ودال إحصائيا ($4966-2950=2016$). وهنا أشير إلى ملاحظة مهمة جدا، وهي أنه يفضل مقارنة كل من قيمة F وقيمة معامل التحديد R2 للنماذج وعدم الاكتفاء فقط بمعامل التحديد، لأن هذا الأخير تزيد قيمته بزيادة عدد المتغيرات المفسرة (الانتقال من الخطي إلى التربيعي والتكعبي مثلا). كما يفضل كذلك اختبار الدلالة الإحصائية للفرق بين قيمتي F بين النموذجين اللذان نقارنهما، فإن كانت دالة فالنموذج الثاني أفضل.

دروس في مقياس طرق التنبؤ



يؤكد التمثيل البياني أعلاه النتيجة السابقة، فنلاحظ أن منحنى نموذج قوى (وكذلك النموذج التربيعي) هو الأقرب لتمثيل سحابة النقاط. يتبين مما سبق أن أفضل نموذج هو نموذج قوى، والذي يأخذ المعادلة التالية:

$$.GDP = 4,09 \times K^{0,986}$$

$$.R^2 = 0,99 \quad F=4966 \quad n=51$$

ز. النمذجة غير الخطية في حالة عدة متغيرات مستقلة (مثال تطبيقي على برنامج إفيوز لنموذج غير خطي يمكن تحويله إلى نموذج خطي):

ليكن المثال التطبيقي هو نموذج النمو الاقتصادي لسولو (Solow)، وهو عبارة عن دالة كوب دوقلاس على المستوى الكلي. وهي في أصلها دالة غير خطية، لكن يمكن تحويلها إلى دالة خطية من خلال التحويل اللوغاريتمي.

— دالة كوب دوقلاس الأصلية (غير خطية): $.GDP = \beta_0 K^{\beta_1} L^{\beta_2}$

— النموذج القياسي الموافق بعد إدخال اللوغاريتم (خطي):

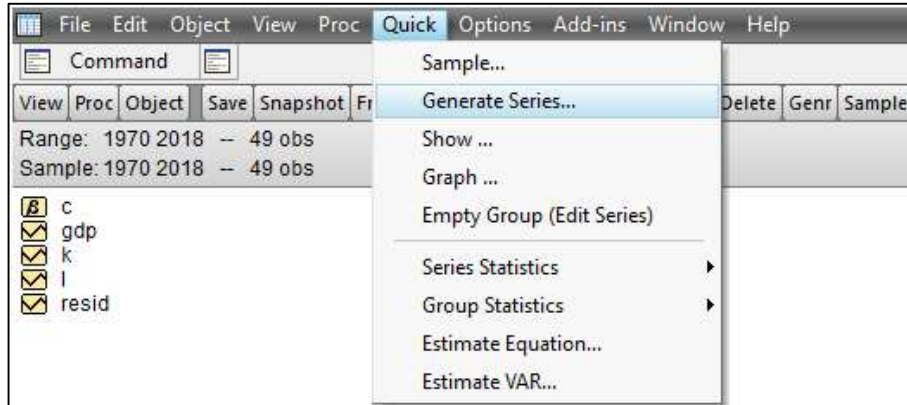
$$.(t = 1,2, \dots, n) \quad \ln(GDP_t) = \ln(\beta_0) + \beta_1 \ln(K_t) + \beta_2 \ln(L_t) + \ln(\varepsilon_t)$$

❖ تقدير معادلة الانحدار:

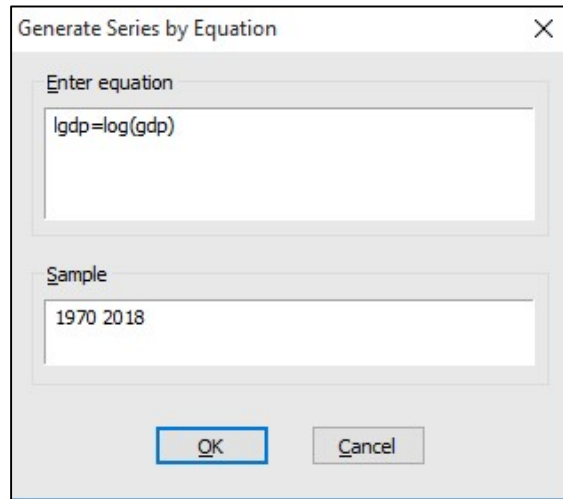
نتبع على برنامج إفيوز نفس الخطوات المطبقة على المثال التطبيقي لنموذج الانحدار الخطي المتعدد. لفتح ملف عمل، ولإدخال بيانات الدراسة، ثم نقوم بإدخال اللوغاريتم على البيانات الأصلية باتباع الخطوات التالية على برنامج إفيوز:

◀ نضغط على Quick ثم على Generate series

دروس في مقياس طرق التنبؤ

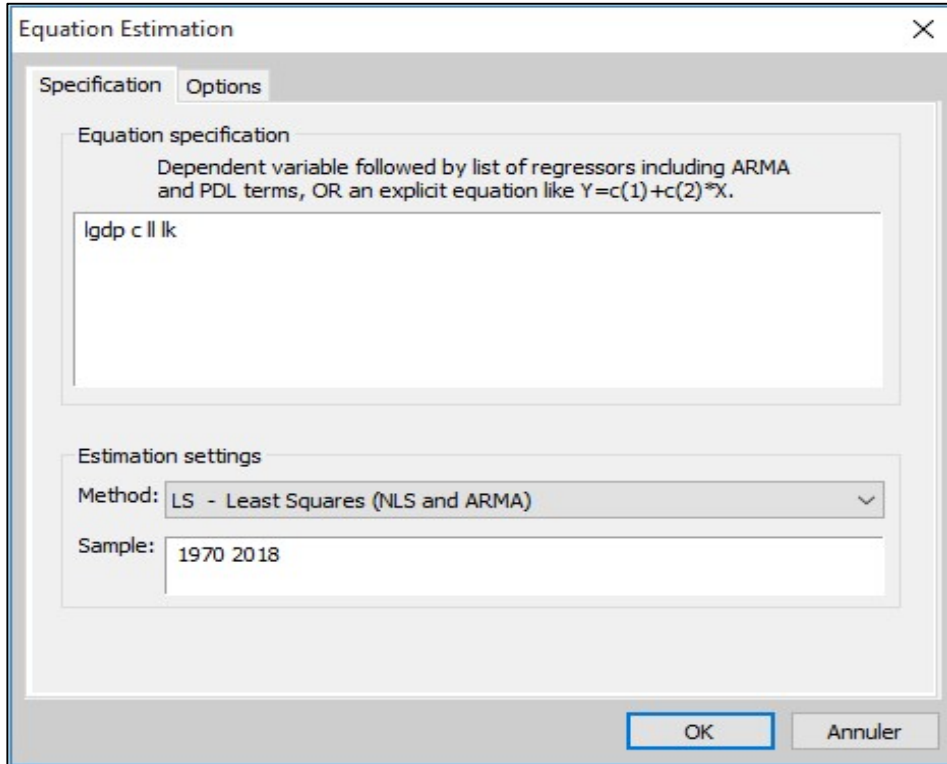


◀ عند الضغط على Generate series تظهر لنا النافذة التالية، والتي ندخل من خلالها صيغة تحويل المتغير GDP إلى متغير جديد LGDP $(\log(\text{GDP}))$:



◀ بنفس الطريقة نقوم بتحويل المتغيرين المستقلين L و K، ويصبح ترميزهم هو: LL، LK.
 ◀ ثم نقوم بتقدير نموذج الانحدار الخطي المتعدد كما يلي:

دروس في مقياس طرق التنبؤ



◀ عند الضغط على OK، تظهر لنا نافذة التقدير التالية:

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Resids
Dependent Variable: LGDP									
Method: Least Squares									
Date: 01/20/21 Time: 11:22									
Sample: 1970 2018									
Included observations: 49									
Variable	Coefficient	Std. Error	t-Statistic	Prob.					
C	5.691470	0.551779	10.31477	0.0000					
LL	1.079181	0.139307	7.746756	0.0000					
LK	0.215857	0.069675	3.098062	0.0033					
R-squared	0.974621	Mean dependent var	28.80639						
Adjusted R-squared	0.973518	S.D. dependent var	0.813700						
S.E. of regression	0.132416	Akaike info criterion	-1.146460						
Sum squared resid	0.806569	Schwarz criterion	-1.030634						
Log likelihood	31.08826	Hannan-Quinn criter.	-1.102516						
F-statistic	883.2674	Durbin-Watson stat	0.560869						
Prob(F-statistic)	0.000000								

◀ من خلال مخرجات إفيوز السابقة، يمكننا كتابة معادلة الانحدار ومختلف التقديرات بالشكل التالي:

$$.LGDP = 5,69 + (1,08)LL + (0,22)LK$$

$$.t \quad (10,31) \quad (7,75) \quad (3,10)$$

$$.R^2 = 0,97 \quad RSS = 0,80 \quad F = 883,27$$

دروس في مقياس طرق التنبؤ

$$S_{\varepsilon}^2 = \frac{RSS}{n-3} = \frac{0,80}{46} = 0,017 : (\sigma_{\varepsilon}^2) \text{ تقدير تباين الأخطاء}$$

❖ تحليل النموذج:

◀ يتبين من النموذج أن لكل من العمل ورأس المال أثر إيجابي على النمو الاقتصادي في الجزائر لأن معلمتا العمل ورأس المال موجبة (وجود علاقة طردية).

◀ إذا زاد العمل بـ 1%، فإن الناتج المحلي الخام سيزيد بـ 1,08%. أما إذا زاد رأس المال بـ 1%، فإن الناتج المحلي الخام سيزيد بـ 0,22%.

◀ يتبين من النموذج أن مساهمة عنصر العمل في النمو الاقتصادي في الجزائر أكبر بكثير من مساهمة رأس المال.

❖ التنبؤ بقيم الناتج المحلي الخام GDP:

لتكن البيانات التالية حول العمل ورأس المال في الجزائر للفترة 2019-2023:

LK	LL	K	L	T
31,58	16,21	52 132 662 882 170	10 962 630	2019
31,64	16,22	55 260 622 655 100	11 119 196	2020
31,70	16,24	58 576 260 014 406	11 277 997	2021
31,76	16,25	62 090 835 615 270	11 439 066	2022
31,82	16,27	65 816 285 752 186	11 602 435	2023

◀ للقيام بعملية التنبؤ على برنامج إفيوز نتبع نفس الخطوات المبينة في المثال التطبيقي لنموذج الانحدار الخطي المتعدد. فيقوم برنامج إفيوز بحساب قيم التنبؤ للمتغير LGDP (السلسلة الجديدة LGDPF):

Year	Value
2019	30.00281
2020	30.03069
2021	30.05857
2022	30.08645
2023	30.11433

دروس في مقياس طرق التنبؤ

◀ ثم نحولها إلى قيم بدون لوغاريتم من خلال التحويل الأسّي (exp). والنتائج موضحة في الجدول التالي:

GDP	LGDP	T
10 716 522 696 294	30,003	2019
11 019 518 472 462	30,031	2020
11 331 079 930 199	30,059	2021
11 651 450 409 206	30,086	2022
11 980 878 538 203	30,114	2023

دروس في مقياس طرق التنبؤ

حيث X_{it} هي المتغيرات الخارجية (الحالية والمبطأة) والمتغيرات الداخلية المبطأة، وهي تعبر عن المتغيرات المحددة مسبقا. و Y_{it} هي المتغيرات الداخلية.

ومن البديهي أنه في كل معادلة بعض المعاملات تكون معدومة (0)، والمتغير الذي يكون معامل واحد (1) هو المتغير التابع. يمكن كتابة نظام المعادلات السابق على الشكل المصفوفي التالي:

$$\begin{pmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \vdots & \alpha_{2m} \\ \vdots & \vdots & \dots & \vdots \\ \alpha_{m1} & \alpha_{m2} & \dots & \alpha_{mm} \end{pmatrix} \begin{pmatrix} Y_{1t} \\ Y_{2t} \\ \vdots \\ Y_{mt} \end{pmatrix} + \begin{pmatrix} \beta_{11} & \beta_{12} & \dots & \beta_{1k} \\ \beta_{21} & \beta_{22} & \vdots & \beta_{2k} \\ \vdots & \vdots & \dots & \vdots \\ \beta_{m1} & \beta_{m2} & \dots & \beta_{mk} \end{pmatrix} \begin{pmatrix} X_{1t} \\ X_{2t} \\ \vdots \\ X_{kt} \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ \vdots \\ \varepsilon_{mt} \end{pmatrix}$$

أي: $A_{m \times m} Y_{m \times 1} + B_{m \times k} X_{k \times 1} = \varepsilon_{m \times 1}$

مع التنبيه إلى وجود بعض المعاملات المعدومة والبعض الأخر المساوي للواحد (متغيرات تابعة). ويسمى هذا الشكل بالشكل الهيكلية للنموذج، ولا يمكن تقديره مباشرة بطريقة المربعات الصغرى العادية (OLS).

ب. الشكل المختزل (المختصر) للمعادلات الأنية (Reduced Form):

يقصد بالشكل المختزل للمعادلات الأنية كتابة كل متغير داخلي بدلالة المتغيرات الخارجية فقط في النموذج (المتغيرات الداخلية بدلالة المتغيرات الخارجية).

ليكن لدينا الشكل الهيكلية لنموذج المعادلات الأنية التالي: $AY + BX = \varepsilon$.

يمكن من هذا الشكل استخراج الشكل المختزل للنموذج بالعملية البسيطة التالية (الانتقال من الشكل الهيكلية إلى الشكل

المختزل) (ضرب النموذج السابق بمعكوس المصفوفة A):

$$.Y = -A^{-1}BX + A^{-1}\varepsilon$$

فتصبح من الشكل المختزل التالي: $.Y = \Gamma X + \mu$

حيث: $\Gamma = -A^{-1}B$ (مصفوفة من الدرجة $m \times k$)، و $\mu = A^{-1}\varepsilon$

من خلال هذا الشكل المختزل، يمكن مباشرة قياس أثر المتغيرات الخارجية (X) على المتغيرات الداخلية (Y)، ويمكن التقدير

بطريقة المربعات الصغرى العادية (OLS).

ج. أمثلة للشكل الهيكلية والشكل المختزل للمعادلات الأنية:

❖ المثال 1:

ليكن النموذج الهيكلية التالي: $\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ y_t = C_t + I_t \end{cases}$

حيث: C الاستهلاك الكلي، Y الدخل الكلي، I الاستثمار الكلي.

لدينا: $C_t = \alpha_0 + \alpha_1(C_t + I_t) + \varepsilon_{1t} = \alpha_0 + \alpha_1 C_t + \alpha_1 I_t + \varepsilon_{1t}$

$$\Rightarrow (1 - \alpha_1)C_t = \alpha_0 + \alpha_1 I_t + \varepsilon_{1t} \Rightarrow C_t = \frac{\alpha_0}{1 - \alpha_1} + \frac{\alpha_1}{1 - \alpha_1} I_t + \frac{1}{1 - \alpha_1} \varepsilon_{1t}$$

$$.y_t = C_t + I_t = \frac{\alpha_0}{1 - \alpha_1} + \frac{\alpha_1}{1 - \alpha_1} I_t + \frac{1}{1 - \alpha_1} \varepsilon_{1t} + I_t$$

كذلك:

دروس في مقياس طرق التنبؤ

$$y_t = \frac{\alpha_0}{1-\alpha_1} + \frac{1}{1-\alpha_1} I_t + \frac{1}{1-\alpha_1} \varepsilon_{1t} \text{ ومنه:}$$

$$\begin{cases} C_t = \frac{\alpha_0}{1-\alpha_1} + \frac{\alpha_1}{1-\alpha_1} I_t + \frac{1}{1-\alpha_1} \varepsilon_{1t} \\ y_t = \frac{\alpha_0}{1-\alpha_1} + \frac{1}{1-\alpha_1} I_t + \frac{1}{1-\alpha_1} \varepsilon_{1t} \end{cases} \text{ فيكون الشكل المختزل للنموذج السابق هو:}$$

$$\begin{cases} C_t = \beta_0 + \beta_1 I_t + \mu_{t1} \\ y_t = \beta_0 + \beta_2 I_t + \mu_{t2} \end{cases} \text{ يمكن كتابته على الشكل المختزل التالي:}$$

نلاحظ أن المتغيرات الداخلية (C_t, Y_t) كتبت بدلالة المتغير الخارجي المحدد مسبقاً فقط (I_t). وفي هذه الحالة يمكن تطبيق طريقة المربعات الصغرى العادية لأن الأخطاء مستقلة عن المتغيرات المستقلة.

❖ المثال 2:

ليكن نموذج الاقتصاد الكلي التالي:

$$\begin{cases} C_t = \alpha_0 + \alpha_1 I_t + \alpha_2 y_t + \alpha_3 C_{t-1} + \varepsilon_{1t} \\ I_t = \beta_0 + \beta_1 y_t + \beta_2 G_{t-1} + \varepsilon_{2t} \\ y_t = C_t + I_t + G_t \end{cases}$$

لدينا المتغيرات الداخلية هي: C الاستهلاك، y الدخل، I الاستثمار.

والمتغيرات المحددة مسبقاً هي: C_{t-1} الاستهلاك مبطاً بدرجة، G الإنفاق العام، C_{t-1} الإنفاق العام مبطاً بدرجة، والحد الثابت.

$$X_t = \begin{pmatrix} 1 \\ C_{t-1} \\ G_t \\ G_{t-1} \end{pmatrix} \text{ و } Y_t = \begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} \text{ ومنه:}$$

أي: $m = 3$ (3 معادلات أو 3 متغيرات داخلية) و $k = 4$ (4 متغيرات محددة مسبقاً).

يمكن كتابة النظام السابق كما يلي:

$$\begin{cases} C_t - \alpha_0 - \alpha_1 I_t - \alpha_2 y_t - \alpha_3 C_{t-1} = \varepsilon_{1t} \\ I_t - \beta_0 - \beta_1 y_t - \beta_2 G_{t-1} = \varepsilon_{2t} \\ y_t - C_t - I_t - G_t = 0 \end{cases}$$

فيكتب على الشكل المصفوفي التالي:

$$\begin{pmatrix} 1 & -\alpha_1 & -\alpha_2 \\ 0 & 1 & -\beta_1 \\ -1 & -1 & 1 \end{pmatrix} \begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} + \begin{pmatrix} -\alpha_0 & -\alpha_3 & 0 & 0 \\ -\beta_0 & 0 & 0 & -\beta_2 \\ 0 & 0 & -1 & 0 \end{pmatrix} \begin{pmatrix} 1 \\ C_{t-1} \\ G_t \\ G_{t-1} \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ 0 \end{pmatrix}$$

هذه الكتابة للنموذج تعبر عن الشكل الهيكل $AY + BX = \varepsilon$

أما الشكل المختزل فيجب كتابة النظام على الشكل التالي ($Y = \Gamma X + \mu$):

دروس في مقياس طرق التنبؤ

$$\begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} = \begin{pmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & \gamma_{14} \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & \gamma_{24} \\ \gamma_{31} & \gamma_{32} & \gamma_{33} & \gamma_{34} \end{pmatrix} \begin{pmatrix} 1 \\ C_{t-1} \\ G_t \\ G_{t-1} \end{pmatrix} + \begin{pmatrix} \mu_{1t} \\ \mu_{2t} \\ 0 \end{pmatrix}$$

$$\Gamma = \begin{pmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & \gamma_{14} \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & \gamma_{24} \\ \gamma_{31} & \gamma_{32} & \gamma_{33} & \gamma_{34} \end{pmatrix} = -A^{-1}B \text{ حيث:}$$

❖ المثال 3:

ليكن نموذج الاقتصاد الكلي التالي:

$$\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ I_t = \beta_0 + \beta_1 y_t + \beta_2 y_{t-1} + \varepsilon_{2t} \\ y_t = C_t + I_t + G_t \end{cases}$$

يمكن كتابة النظام السابق كما يلي:

$$\begin{cases} C_t - \alpha_0 - \alpha_1 y_t = \varepsilon_{1t} \\ I_t - \beta_0 - \beta_1 y_t - \beta_2 y_{t-1} = \varepsilon_{2t} \\ y_t - C_t - I_t - G_t = 0 \end{cases}$$

فيكتب على الشكل المصفوفي التالي:

$$\begin{pmatrix} 1 & 0 & -\alpha_1 \\ 0 & 1 & -\beta_1 \\ -1 & -1 & 1 \end{pmatrix} \begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} + \begin{pmatrix} -\alpha_0 & 0 & 0 \\ -\beta_0 & -\beta_2 & 0 \\ 0 & 0 & -1 \end{pmatrix} \begin{pmatrix} 1 \\ y_{t-1} \\ G_t \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ 0 \end{pmatrix}$$

هذه الكتابة للنموذج تعبر عن الشكل الميكلي $AY + BX = \varepsilon$.أما الشكل المختزل فيجب كتابة النظام على الشكل التالي $(Y = \Gamma X + \mu)$:

$$\begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} = \begin{pmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} \\ \gamma_{21} & \gamma_{22} & \gamma_{23} \\ \gamma_{31} & \gamma_{32} & \gamma_{33} \end{pmatrix} \begin{pmatrix} 1 \\ y_{t-1} \\ G_t \end{pmatrix} + \begin{pmatrix} \mu_{1t} \\ \mu_{2t} \\ 0 \end{pmatrix}$$

لدينا $\Gamma = -A^{-1}B$ ، ومنه:

$$\Gamma = - \begin{pmatrix} 1 & 0 & -\alpha_1 \\ 0 & 1 & -\beta_1 \\ -1 & -1 & 1 \end{pmatrix}^{-1} \begin{pmatrix} -\alpha_0 & 0 & 0 \\ -\beta_0 & -\beta_2 & 0 \\ 0 & 0 & -1 \end{pmatrix}$$

$$|A| = 1 \times \begin{vmatrix} 1 & -\beta_1 \\ -1 & 1 \end{vmatrix} - 0 - 1 \times \begin{vmatrix} 0 & -\alpha_1 \\ 1 & -\beta_1 \end{vmatrix} = 1 - \beta_1 - \alpha_1$$

إيجاد المصفوفة المرافقة:

دروس في مقياس طرق التنبؤ

$$A^* = \begin{pmatrix} + \begin{vmatrix} 1 & -\beta_1 \\ -1 & 1 \end{vmatrix} & - \begin{vmatrix} 0 & -\beta_1 \\ -1 & 1 \end{vmatrix} & + \begin{vmatrix} 0 & 1 \\ -1 & 1 \end{vmatrix} \\ - \begin{vmatrix} 0 & -\alpha_1 \\ -1 & 1 \end{vmatrix} & + \begin{vmatrix} 1 & -\alpha_1 \\ -1 & 1 \end{vmatrix} & - \begin{vmatrix} 1 & 0 \\ -1 & -1 \end{vmatrix} \\ + \begin{vmatrix} 0 & -\alpha_1 \\ 1 & -\beta_1 \end{vmatrix} & - \begin{vmatrix} 1 & -\alpha_1 \\ 0 & -\beta_1 \end{vmatrix} & + \begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix} \end{pmatrix} = \begin{pmatrix} 1 - \beta_1 & \beta_1 & 1 \\ \alpha_1 & 1 - \alpha_1 & 1 \\ \alpha_1 & \beta_1 & 1 \end{pmatrix}$$

$$(A^*)^t = \begin{pmatrix} 1 - \beta_1 & \alpha_1 & \alpha_1 \\ \beta_1 & 1 - \alpha_1 & \beta_1 \\ 1 & 1 & 1 \end{pmatrix} \text{ حساب منقول المصفوفة المرافقة:}$$

$$A^{-1} = \frac{(A^*)^t}{|A|} = \frac{1}{1 - \alpha_1 - \beta_1} \begin{pmatrix} 1 - \beta_1 & \alpha_1 & \alpha_1 \\ \beta_1 & 1 - \alpha_1 & \beta_1 \\ 1 & 1 & 1 \end{pmatrix} \text{ إيجاد مقلوب المصفوفة:}$$

$$\Gamma = -A^{-1}B = -\frac{1}{1 - \alpha_1 - \beta_1} \begin{pmatrix} 1 - \beta_1 & \alpha_1 & \alpha_1 \\ \beta_1 & 1 - \alpha_1 & \beta_1 \\ 1 & 1 & 1 \end{pmatrix} \begin{pmatrix} -\alpha_0 & 0 & 0 \\ -\beta_0 & -\beta_2 & 0 \\ 0 & 0 & -1 \end{pmatrix} \text{ لدينا:}$$

$$\Gamma = -\frac{1}{1 - \alpha_1 - \beta_1} \begin{pmatrix} -\alpha_0(1 - \beta_1) - \alpha_1\beta_0 & -\alpha_1\beta_2 & -\alpha_1 \\ -\alpha_0\beta_1 - \beta_0(1 - \alpha_1) & -\beta_2(1 - \alpha_1) & -\beta_1 \\ -\alpha_0 - \beta_0 & -\beta_2 & -1 \end{pmatrix} \text{ ومنه:}$$

$$\begin{pmatrix} C_t \\ I_t \\ Y_t \end{pmatrix} = \begin{pmatrix} \frac{\alpha_0(1 - \beta_1) + \alpha_1\beta_0}{1 - \alpha_1 - \beta_1} & \frac{\alpha_1\beta_2}{1 - \alpha_1 - \beta_1} & \frac{\alpha_1}{1 - \alpha_1 - \beta_1} \\ \frac{\alpha_0\beta_1 + \beta_0(1 - \alpha_1)}{1 - \alpha_1 - \beta_1} & \frac{\beta_2(1 - \alpha_1)}{1 - \alpha_1 - \beta_1} & \frac{\beta_1}{1 - \alpha_1 - \beta_1} \\ \frac{\alpha_0 + \beta_0}{1 - \alpha_1 - \beta_1} & \frac{\beta_2}{1 - \alpha_1 - \beta_1} & \frac{1}{1 - \alpha_1 - \beta_1} \end{pmatrix} \begin{pmatrix} 1 \\ y_{t-1} \\ G_t \end{pmatrix} + \begin{pmatrix} \mu_{1t} \\ \mu_{2t} \\ 0 \end{pmatrix} \text{ إذن:}$$

هذه الكتابة للنموذج تعبر عن الشكل المختزل $Y = \Gamma X + \mu$

ج. أنواع الآثار في المعادلات الأنية:

يوجد ثلاث أنواع للآثار يمكن قياسها في المعادلات الأنية:

- ❖ الآثر المباشر: ويعطى مباشرة بمعاملات الشكل الهيكلية (المعاملات الهيكلية).
- ❖ الآثر الكلي: ويعطى مباشرة بمعاملات الشكل المختزل (وهو مجموع الآثر المباشر والآثر غير المباشر). وهو كلي لأنه يأخذ بعين الاعتبار استقلالية المتغيرات الداخلية.
- ❖ الآثر غير المباشر: وهو الفرق بين الآثر الكلي والآثر المباشر، ويحسب بعد حل النظام. ولهذا فإن عدم ظهور متغير ما في معادلة ما لا يعني أن هذا المتغير ليس له أثر على المتغير التابع لهذه المعادلة بل قد يكون له أثر غير مباشرة (لا يظهر مباشرة في المعادلة).

مثال (المثال 3 أعلاه): لدينا النموذج التالي (الشكل الهيكلية):

$$\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ I_t = \beta_0 + \beta_1 y_t + \beta_2 y_{t-1} + \varepsilon_{2t} \\ y_t = C_t + I_t + G_t \end{cases}$$

دروس في مقياس طرق التنبؤ

$$\begin{pmatrix} C_t \\ I_t \\ Y_t \end{pmatrix} = \begin{pmatrix} \frac{\alpha_0(1-\beta_1)+\alpha_1\beta_0}{1-\alpha_1-\beta_1} & \frac{\alpha_1\beta_2}{1-\alpha_1-\beta_1} & \frac{\alpha_1}{1-\alpha_1-\beta_1} \\ \frac{\alpha_0\beta_1+\beta_0(1-\alpha_1)}{1-\alpha_1-\beta_1} & \frac{\beta_2(1-\alpha_1)}{1-\alpha_1-\beta_1} & \frac{\beta_1}{1-\alpha_1-\beta_1} \\ \frac{\alpha_0+\beta_0}{1-\alpha_1-\beta_1} & \frac{\beta_2}{1-\alpha_1-\beta_1} & \frac{1}{1-\alpha_1-\beta_1} \end{pmatrix} \begin{pmatrix} 1 \\ y_{t-1} \\ G_t \end{pmatrix} + \begin{pmatrix} \mu_{1t} \\ \mu_{2t} \\ 0 \end{pmatrix}$$

نريد مثلا البحث عن أثر الدخل مبطاً بدرجة (y_{t-1}) على الاستثمار (I_t) ، فنميز بين 3 آثار، وهي:

❖ الأثر المباشر: ويعطى مباشرة بمعلمة الشكل الهيكلية β_2 .

❖ الأثر الكلي: ويعطى مباشرة بمعلمة الشكل المختزل $\frac{\beta_2(1-\alpha_1)}{1-\alpha_1-\beta_1}$.

❖ الأثر غير المباشر: يمكن حسابه على النحو التالي (تفكيك الأثر الكلي إلى مباشر وغير مباشر):

$$\frac{\beta_2(1-\alpha_1)}{1-\alpha_1-\beta_1} = \frac{\beta_2(1-\alpha_1)+\beta_1\beta_2-\beta_1\beta_2}{1-\alpha_1-\beta_1} = \frac{\beta_2(1-\alpha_1-\beta_1)+\beta_1\beta_2}{1-\alpha_1-\beta_1} = \beta_2 + \frac{\beta_1\beta_2}{1-\alpha_1-\beta_1}$$

ومنه الأثر غير المباشر هو $\frac{\beta_1\beta_2}{1-\alpha_1-\beta_1}$.

د. **مشكل التشخيص (أو التعريف أو التوصيف أو التمييز) (The identification Problem)**:

تشير مشكلة التعريف إلى إمكانية أو عدم إمكانية حساب المعالم الهيكلية لنموذج المعادلات الآتية انطلاقاً من معالم النموذج المختزل. وللتأكد من إمكانية تشخيص (تعريف) نموذج المعادلات الآتية يجب دراسة مدى تحقق شرطين أساسيين، وهما شرط الترتيب وشرط الرتبة.

أ. **شرط الترتيب (Order Condition)**:

وهو شرط ضروري ولكنه غير كافي للتوصيف، ومصطلح ترتيب يشير إلى ترتيب الموصوفة، وهو عدد أسطر أو أعمدة المصفوفة. لتكن:

m عدد المتغيرات الداخلية في النموذج (أو أيضاً عدد المعادلات).

m_i عدد المتغيرات الداخلية في المعادلة i ($i = 1, 2, \dots, m$).

k عدد المتغيرات المحددة مسبقاً في النموذج (بما في ذلك الحد الثابت).

k_i عدد المتغيرات المحددة مسبقاً في المعادلة i (بما في ذلك الحد الثابت).

شرط الترتيب (إمكانية التقدير) هو: $(m - m_i) + (k - k_i) \geq m - 1$. ويكتب كذلك بهذا الشكل:

$$(k + m) - (m_i + k_i) \geq m - 1. \text{ ويمكن التعبير عن هذا الشرط كما يلي (بالنسبة للمعادلة 1):}$$

$$k - k_i \geq m_i - 1$$

أي أن عدد المتغيرات المحددة مسبقاً المقصاة من المعادلة i يجب أن يكون على الأقل يساوي عدد المتغيرات الداخلية الظاهرة في المعادلة i مطروح منها واحد.

نميز بين ثلاث حالات ممكنة للتشخيص بحسب شرط الترتيب:

• إذا كان $k - k_i < m_i - 1$ ، فإن المعادلة ناقصة تشخيص (under-identified).

دروس في مقياس طرق التنبؤ

- إذا كان $k - k_i = m_i - 1$ ، فإن المعادلة مشخصة تماما (exactly-identified) (حل وحيد).
 - إذا كان $k - k_i > m_i - 1$ ، فإن المعادلة زائدة تشخيص (over-identified) (على الأقل حل).
- ب. شرط الرتبة (**Rank Condition**):

شرط الترتيب السابق الذكر هو شرط ضروري ولكن غير كاف للتوصيف، بمعنى أنه حتى إذا توفر هذا الشرط، قد توجد معادلة لا يمكن توصيفها. أما شرط الرتبة فهو شرط ضروري وكافي. فقد يتحقق شرط الترتيب لكن المعادلة تكون غير معرفة لعدم تحقق شرط الرتبة.

ويقصد بالرتبة رتبة المصفوفة، والتي يتم تحديدها من قيمة المحدد إن كان معدوما أم لا. فإذا كان المحدد غير معدوم فالمصفوفة تامة الرتبة (الرتبة تساوي درجة المصفوفة)، أما إذا كان معدوما فالمصفوفة أقل رتبة (الرتبة أقل من درجة المصفوفة). في نموذج يحتوي على m معادلة، تكون معادلة ما معرفة إذا كان: على الأقل يوجد محدد (لمصفوفة) غير معدوم من الدرجة $(m - 1) \times (m - 1)$ يمكن إنشاؤها (المصفوفة) انطلاقا من معاملات المتغيرات (الداخلية والمحددة مسبقا) المقصاة من هذه المعادلة (لكن موجودة في معادلات أخرى من النموذج). فتكون رتبة هذه المصفوفة هي $(m - 1)$. تطبيقيا، تتبع الخطوات التالية:

- ✓ نقوم بترتيب جميع المعلمات الهيكلية (الشكل الهيكلي) بدلالة كل المتغيرات (الداخلية والخارجية).
- ✓ نُنشأ مصفوفة عناصرها هي المعلمات المقصاة من المعادلة المختبرة (والموجودة في المعادلات الأخرى).
- ✓ نقوم بحساب محدد المصفوفة المتحصل عليها.
- ✓ إذا كانت المصفوفة المستخرجة من المعالم الهيكلية غير مربعة، عندها يستوجب تجزئتها إلى كافة المصفوفات الجزئية الممكنة ذات الدرجة $(m - 1) \times (m - 1)$. وتكون المعادلة مشخصة إذا وجد على الأقل من بين محددات هذه المصفوفات الجزئية محدد غير معدوم.
- ✓ القرار: نميز بين حالتين:

- إذا كان المحدد معدوم فإن المعادلة غير مشخصة.
- إذا كان المحدد غير معدوم فإن المعادلة مشخصة (إما مشخصة تماما أو زائدة تشخيص).

ج. تشخيص النموذج ككل:

بعد دراسة مدى تحقق شروط التشخيص لكل معادلة من معادلات النموذج، نحكم على تشخيص النموذج ككل بإحدى الحالات التالية:

- النموذج يكون ناقص تشخيص إذا كانت معادلة من النموذج ناقصة تشخيص.
- النموذج يكون مشخص تماما إذا كانت كل معادلاته مشخصة تماما.
- النموذج يكون زائد تشخيص إذا كانت معادلات النموذج إما مشخصة تماما أو زائدة تشخيص.

دروس في مقياس طرق التنبؤ

د. أمثلة:

$$\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ y_t = C_t + I_t \end{cases} \quad \text{المثال 1 السابق: ليكن النموذج الهيكلي التالي:}$$

$$\begin{cases} C_t - \alpha_0 - \alpha_1 y_t = \varepsilon_{1t} \\ y_t - C_t - I_t = 0 \end{cases} \quad \text{يمكن كتابة النظام السابق كما يلي:}$$

فيكتب على الشكل المصفوفي التالي:

$$\begin{pmatrix} 1 & -\alpha_1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} C_t \\ y_t \end{pmatrix} + \begin{pmatrix} -\alpha_0 & 0 \\ 0 & -1 \end{pmatrix} \begin{pmatrix} 1 \\ I_t \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ 0 \end{pmatrix}$$

نشكل الجدول الموالي للتسهيل:

المتغيرات الداخلية ($m = 2$)		المتغيرات المحددة مسبقا ($k = 2$)		المعادلة i
C_t	y_t	1	I_t	
1	$-\alpha_1$	$-\alpha_0$	0	1
-1	1	0	-1	2

- شرط الترتيب:

نستعين بالجدول التالي:

القرار	$m_i - 1$	$k - k_i$	k_i	k	m_i	m	المعادلة i
مشخصة تماما	1	1	1	2	2	2	1
معادلة تعريفية غير معنية	/	/	/		/		2

- شرط الرتبة:

بالنسبة للمعادلة 1: ننشئ المصفوفة لها عنصر واحد فقط هو: (-1). وبما أن قيمته غير معدومة، فالمعادلة الأولى مشخصة.

- تشخيص النموذج ككل: يتبين من شرطي الترتيب والرتبة أن النموذج مشخص تماما.

❖ المثال 2 السابق: ليكن نموذج الاقتصاد الكلي التالي:

$$\begin{cases} C_t = \alpha_0 + \alpha_1 I_t + \alpha_2 y_t + \alpha_3 C_{t-1} + \varepsilon_{1t} \\ I_t = \beta_0 + \beta_1 y_t + \beta_2 G_{t-1} + \varepsilon_{2t} \\ y_t = C_t + I_t + G_t \end{cases}$$

يمكن كتابة النظام السابق كما يلي:

$$\begin{cases} C_t - \alpha_0 - \alpha_1 I_t - \alpha_2 y_t - \alpha_3 C_{t-1} = \varepsilon_{1t} \\ I_t - \beta_0 - \beta_1 y_t - \beta_2 G_{t-1} = \varepsilon_{2t} \\ y_t - C_t - I_t - G_t = 0 \end{cases}$$

فيكتب على الشكل المصفوفي التالي:

دروس في مقياس طرق التنبؤ

$$\cdot \begin{pmatrix} 1 & -\alpha_1 & -\alpha_2 \\ 0 & 1 & -\beta_1 \\ -1 & -1 & 1 \end{pmatrix} \begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} + \begin{pmatrix} -\alpha_0 & -\alpha_3 & 0 & 0 \\ -\beta_0 & 0 & 0 & -\beta_2 \\ 0 & 0 & -1 & 0 \end{pmatrix} \begin{pmatrix} 1 \\ C_{t-1} \\ G_t \\ G_{t-1} \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ 0 \end{pmatrix}$$

نشكل الجدول التالي للتسهيل:

المتغيرات الداخلية ($m = 3$)			المتغيرات المحددة مسبقا ($k = 4$)				المعادلة i
C_t	I_t	y_t	1	C_{t-1}	G_t	G_{t-1}	
1	$-\alpha_1$	$-\alpha_2$	$-\alpha_0$	$-\alpha_3$	0	0	1
0	1	$-\beta_1$	$-\beta_0$	0	0	$-\beta_2$	2
-1	-1	1	0	0	-1	0	3

- شرط الترتيب:

نستعين بالجدول التالي:

القرار	$m_i - 1$	$k - k_i$	k_i	k	m_i	m	المعادلة i
مشخصة تماما	2	2	2	4	3	3	1
زائدة تشخيص	1	2	2		2		2
معادلة تعريفية غير معنية	/	/	/	/	/	/	3

- شرط الرتبة:

بالنسبة للمعادلة 1: ننشئ المصفوفة التالية: $\begin{pmatrix} 0 & -\beta_2 \\ -1 & 0 \end{pmatrix}$.بما أن المصفوفة المتحصل عليها مربعة، فنحسب مباشرة محددها كما يلي: $\begin{vmatrix} 0 & -\beta_2 \\ -1 & 0 \end{vmatrix} = \beta_2$.
بما أن المحدد غير معدوم، فالمعادلة الأولى مشخصة.بالنسبة للمعادلة 2: ننشئ المصفوفة التالية: $\begin{pmatrix} 1 & -\alpha_3 & 0 \\ -1 & 0 & -1 \end{pmatrix}$.

بما أن المصفوفة المتحصل عليها ليست مربعة، فنجزؤها إلى 3 مصفوفات مربعة، ثم نحسب المحددات كما يلي:

$$\begin{vmatrix} -\alpha_3 & 0 \\ 0 & -1 \end{vmatrix} = \alpha_3 \quad \text{و} \quad \begin{vmatrix} 1 & 0 \\ -1 & -1 \end{vmatrix} = -1 \quad \text{و} \quad \begin{vmatrix} 1 & -\alpha_3 \\ -1 & 0 \end{vmatrix} = -\alpha_3$$

بما أن المحددات غير معدومة، فالمعادلة الثانية مشخصة.

- تشخيص النموذج ككل: يتبين من شرطي الترتيب والرتبة أن النموذج زائد تشخيص.

دروس في مقياس طرق التنبؤ

❖ المثال 3 السابق: لدينا النموذج التالي (الشكل الهيكلي):

$$\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ I_t = \beta_0 + \beta_1 y_t + \beta_2 y_{t-1} + \varepsilon_{2t} \\ y_t = C_t + I_t + G_t \end{cases}$$

يمكن كتابة النظام السابق كما يلي:

$$\begin{cases} C_t - \alpha_0 - \alpha_1 y_t = \varepsilon_{1t} \\ I_t - \beta_0 - \beta_1 y_t - \beta_2 y_{t-1} = \varepsilon_{2t} \\ y_t - C_t - I_t - G_t = 0 \end{cases}$$

فيكتب على الشكل المصفوفي التالي ($AY + BX = \varepsilon$):

$$\begin{pmatrix} 1 & 0 & -\alpha_1 \\ 0 & 1 & -\beta_1 \\ -1 & -1 & 1 \end{pmatrix} \begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} + \begin{pmatrix} -\alpha_0 & 0 & 0 \\ -\beta_0 & -\beta_2 & 0 \\ 0 & 0 & -1 \end{pmatrix} \begin{pmatrix} 1 \\ y_{t-1} \\ G_t \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ 0 \end{pmatrix}$$

نشكل الجدول التالي للتسهيل:

المتغيرات الداخلية ($m = 3$)			المتغيرات المحددة مسبقا ($k = 3$)			المعادلة i
C_t	I_t	y_t	1	y_{t-1}	G_t	
1	0	$-\alpha_1$	$-\alpha_0$	0	0	1
0	1	$-\beta_1$	$-\beta_0$	$-\beta_2$	0	2
-1	-1	1	0	0	-1	3

- شرط الترتيب:

نستعين بالجدول التالي:

القرار	$m_i - 1$	$k - k_i$	k_i	k	m_i	m	المعادلة i
زائدة تشخيص	1	2	1	3	2	3	1
مشخصة تماما	1	1	2		2		2
معادلة تعريفية غير معنية	/	/	/	/	/	/	3

- شرط الرتبة:

بالنسبة للمعادلة 1: ننشئ المصفوفة التالية: $\begin{pmatrix} 1 & -\beta_2 & 0 \\ -1 & 0 & -1 \end{pmatrix}$

بما أن المصفوفة المتحصل عليها ليست مربعة، فنجزؤها إلى 3 مصفوفات مربعة، ثم نحسب المحددات كما يلي:

$$\begin{vmatrix} 1 & -\beta_2 \\ -1 & 0 \end{vmatrix} = -\beta_2 \quad \text{و} \quad \begin{vmatrix} 1 & 0 \\ -1 & -1 \end{vmatrix} = -1 \quad \text{و} \quad \begin{vmatrix} -\beta_2 & 0 \\ 0 & -1 \end{vmatrix} = \beta_2$$

بما أن المحددات غير معدومة، فالمعادلة الأولى مشخصة.

دروس في مقياس طرق التنبؤ

بالنسبة للمعادلة 2: نشئ المصفوفة التالية: $\begin{pmatrix} 1 & 0 \\ -1 & -1 \end{pmatrix}$.

بما أن المصفوفة المتحصل عليها مربعة، فنحسب مباشرة محددها كما يلي: $\begin{vmatrix} 1 & 0 \\ -1 & -1 \end{vmatrix} = -1$.
بما أن المحدد غير معدوم، فالمعادلة الثانية مشخصة كذلك.

– **تشخيص النموذج ككل:** يتبين من شرطي الترتيب والرتبة أن النموذج زائد تشخيص.
هـ. **تقدير المعادلات الآنية:**

في المعادلات الآنية، لا يمكن تطبيق طريقة المربعات الصغرى العادية لأن المتغيرات المستقلة قد تتضمن متغيرات تابعة ويوجد ترابط بين المتغيرات والخطأ العشوائي مما يؤدي إلى الحصول على مقدرات متحيزة. لذلك يتم استخدام طرق أخرى للتقدير منها طريقة المربعات الصغرى على مرحلتين أو المربعات الصغرى غير المباشرة بدلا من المربعات الصغرى العادية.
ونشير إلى أنه إذا كان النموذج ناقص تشخيص، فالتقدير مستحيل. أما إذا كانت المعادلة مشخصة تماما، فيتم التقدير بطريقة المربعات الصغرى غير المباشرة (ILS) (أو طريقة المربعات الصغرى على مرحلتين (2SLS) كذلك). وفي حالة معادلة زائدة تشخيص فنطبق طريقة المربعات الصغرى على مرحلتين (2SLS).

أ. **طريقة المربعات الصغرى غير المباشرة (Indirect Least Squares – ILS):**

طريقة المربعات الصغرى غير المباشرة هي طريقة تقدير للمعادلات المعرفة تماما. وترتكز هذه الطريقة على تطبيق طريقة المربعات الصغرى العادية على المعادلات المعرفة تماما للنموذج في شكله المختزل.
للتقدير بطريقة المربعات الصغرى غير المباشرة نتبع الخطوات التالية:

- الانتقال من الشكل الهيكلية إلى الشكل المختزل للنموذج.
- تقدير كل معادلة من معادلات الشكل المختزل بطريقة المربعات الصغرى العادية (OLS).
- حساب معاملات المعادلات الهيكلية عن طريق العلاقة الجبرية الموجودة بين المعاملات المختزلة والهيكلية (الحل وحيد لأن النموذج معرف تماما).

ليكن لدينا الشكل الهيكلية لنموذج المعادلات الآنية التالي: $AY + BX = \varepsilon$.

يمكن من هذا الشكل استخراج الشكل المختزل للنموذج كما يلي: $Y = -A^{-1}BX + A^{-1}\varepsilon$.

فتصبح من الشكل المختزل التالي: $Y = \Gamma X + \mu$.

حيث: $\Gamma = -A^{-1}B$ (مصفوفة من الدرجة $(m \times k)$)، و $\mu = A^{-1}\varepsilon$.

يمكن التقدير بطريقة المربعات الصغرى العادية لكل معادلة من معادلات النظام السابق. ثم نحسب معاملات الشكل الهيكلية انطلاقا من الشكل المختزل المقدر.

❖ مثال (المثال 1 السابق):

$$\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ y_t = C_t + I_t \end{cases} \text{ الشكل الهيكلية:}$$

دروس في مقياس طرق التنبؤ

❖ مثال (المثال 1 السابق):

$$\begin{cases} C_t = \alpha_0 + \alpha_1 y_t + \varepsilon_{1t} \\ y_t = C_t + I_t \end{cases} \text{ الشكل الهيكلي:}$$

لتقدير هذا النموذج بطريقة 2SLS، تتبع الخطوات التالية:

- نقوم بإجراء انحدار المتغير الداخلي y_t على جميع المتغيرات الخارجية (يوجد متغير خارجي واحد فقط I_t). أي:

$$y_t = c_0 + c_1 I_t + \mu_{1t}$$

- نقدر هذا الانحدار بطريقة OLS، فنحصل على القيم المقدرة: \hat{y}_t (حيث: $\hat{y}_t = \hat{c}_0 + \hat{c}_1 I_t$).- نقوم باستبدال المتغير الداخلي y_t على \hat{y}_t في المعادلة الهيكلية بالقيم المقدرة \hat{y}_t .

$$C_t = \alpha_0 + \alpha_1 \hat{y}_t + \varepsilon_{1t}$$

- نقوم بتقدير هذا النموذج الأخير بطريقة OLS:

$$\hat{C}_t = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{y}_t$$

و. المحاكاة والتنبؤ باستخدام المعادلات الأنية:

بعد تقدير نموذج المعادلات الأنية بإحدى طرق التقدير السابقة الذكر، بحسب شروط التشخيص. فيمكن الاعتماد عليه سواء لتحليل العلاقات بين المتغيرات الاقتصادية الكلية المدرجة في النموذج، مع إمكانية القيام بالمحاكاة من خلال تتبع التغيرات الحاصلة في هذه المتغيرات في حالة حدث تغيير في المدخلات بحسب السياسات الاقتصادية والظروف الاقتصادية للظاهرة محل الدراسة. ويقصد بالمحاكاة العمل على توليد قيم المتغيرات الداخلية من خلال النموذج، والذي يمكن استخدامه كذلك في بناء السيناريوهات. كما يمكن الاعتماد على النموذج المقدر للقيام بعملية التنبؤ بالقيم المستقبلية في الفترات الزمنية المقبلة لهذه المتغيرات الاقتصادية الكلية.

ز. مثال تطبيقي للمعادلات الأنية على برنامج إفيوز:

ليكن نموذج الاقتصاد الكلي التالي (المثال 2 السابق):

$$\begin{cases} C_t = \alpha_0 + \alpha_1 I_t + \alpha_2 y_t + \alpha_3 C_{t-1} + \varepsilon_{1t} \\ I_t = \beta_0 + \beta_1 y_t + \beta_2 G_{t-1} + \varepsilon_{2t} \\ y_t = C_t + I_t + G_t \end{cases}$$

حيث: C_t هي نفقات الاستهلاك النهائي (إجمالي الاستهلاك). y_t هي إجمالي الدخل القومي. I_t هي الاستثمار (وتضمالاستثمار المحلي والاستثمار الأجنبي المباشر). G_t هي النفقات النهائية للحكومة العامة.

بالنسبة للبيانات التي سنطبق عليها هذا المثال، فهي بيانات خاصة بالجزائر خلال الفترة الممتدة من 1970 إلى 2018. وقد

تم الحصول على البيانات من الموقع الرسمي للبنك الدولي، والقيم معبر عنها بالأسعار الثابتة للدولار الأمريكي.

أ. الشكل الهيكلي للنموذج:

يمكن كتابة النظام السابق كما يلي:

دروس في مقياس طرق التنبؤ

$$\begin{cases} C_t - \alpha_0 - \alpha_1 I_t - \alpha_2 y_t - \alpha_3 C_{t-1} = \varepsilon_{1t} \\ I_t - \beta_0 - \beta_1 y_t - \beta_2 G_{t-1} = \varepsilon_{2t} \\ y_t - C_t - I_t - G_t = 0 \end{cases}$$

فيكتب على الشكل المصفوي التالي:

$$\begin{pmatrix} 1 & -\alpha_1 & -\alpha_2 \\ 0 & 1 & -\beta_1 \\ -1 & -1 & 1 \end{pmatrix} \begin{pmatrix} C_t \\ I_t \\ y_t \end{pmatrix} + \begin{pmatrix} -\alpha_0 & -\alpha_3 & 0 & 0 \\ -\beta_0 & 0 & 0 & -\beta_2 \\ 0 & 0 & -1 & 0 \end{pmatrix} \begin{pmatrix} 1 \\ C_{t-1} \\ G_t \\ G_{t-1} \end{pmatrix} = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ 0 \end{pmatrix}$$

ب. تشخيص النموذج: تبين سابقا عند تشخيص هذا المثال 2 من شرطي الترتيب والرتبة أن هذا النموذج زائد تشخيص.

ج. تقدير النموذج: بما أن النموذج زائد تشخيص، فتكون الطريقة المناسبة للتقدير هي طريقة المربعات الصغرى على مرحلتين (2SLS). وللتقدير وفق المربعات الصغرى على مرحلتين على برنامج إفيوز فهناك طريقتين:

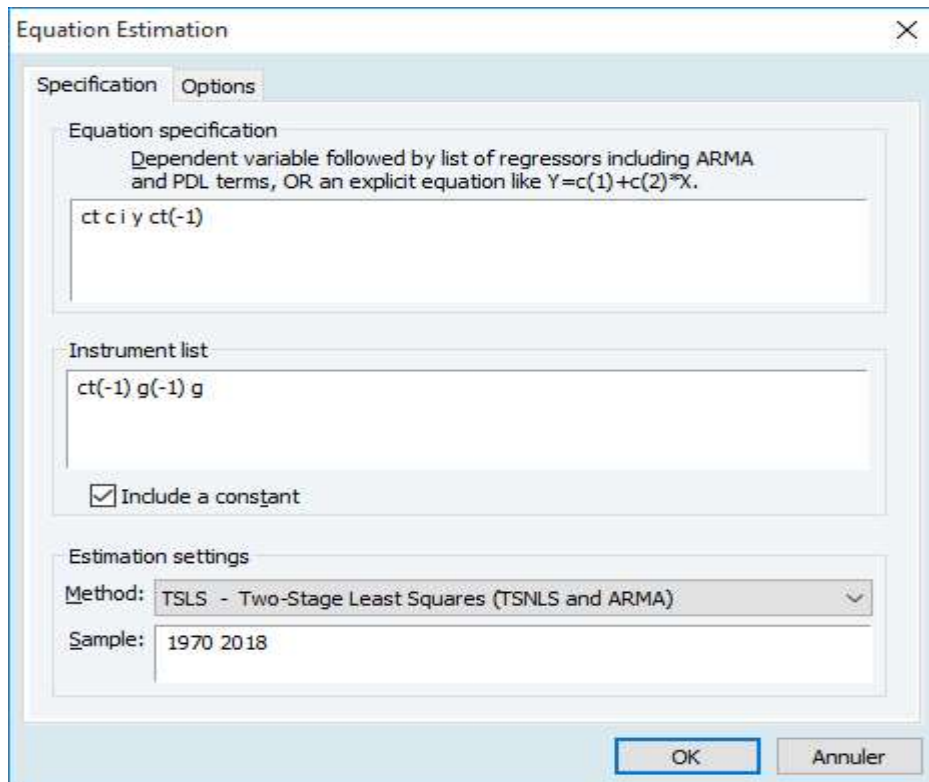
❖ الطريقة الأولى للتقدير: تسمح هذه الطريقة بتقدير كل معادلة على حدى، وتنبع على برنامج إفيوز الخطوات التالية:

◀ بعد إدخال بيانات النموذج إلى البرنامج، نضغط على Quick ثم Estimate Equation، فتظهر لنا النافذة التالية ونختار منها:

- كتابة المعادلة (الأولى): $ct \ c \ i \ y \ c(-1)$

- تحديد المتغيرات الأداة (وهي الخارجية في النموذج): $G(-1) \ G(-1) \ G$ (مع وجود الحد الثابت a constant).

- نختار طريقة التقدير (TSLS).



دروس في مقياس طرق التنبؤ

◀ عند الضغط على OK تظهر لنا مخرجات التقدير للمعادلة الأولى التالية:

Dependent Variable: CT				
Method: Two-Stage Least Squares				
Date: 02/12/23 Time: 14:06				
Sample (adjusted): 1971 2018				
Included observations: 48 after adjustments				
Instrument specification: CT(-1) G(-1) G				
Constant added to instrument list				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	3.33E+09	1.85E+09	1.803404	0.0782
I	0.253342	0.106543	2.377846	0.0218
Y	0.226999	0.060283	3.765551	0.0005
CT(-1)	0.428793	0.155989	2.748867	0.0086
R-squared	0.992004	Mean dependent var	5.65E+10	
Adjusted R-squared	0.991459	S.D. dependent var	2.49E+10	
S.E. of regression	2.30E+09	Sum squared resid	2.32E+20	
F-statistic	1828.560	Durbin-Watson stat	0.577917	
Prob(F-statistic)	0.000000	Second-Stage SSR	8.96E+19	
J-statistic	2.73E-39	Instrument rank	4	

◀ بالنسبة للمعادلة الثانية، نغير فقط كتابة المعادلة (الثانية): $I c y G(-1)$ ، كما يلي:

Equation Estimation X

Specification Options

Equation specification
Dependent variable followed by list of regressors including ARMA and PDL terms, OR an explicit equation like $Y=c(1)+c(2)*X$.

$i c y g(-1)$

Instrument list
 $ct(-1) g(-1) g$

Include a constant

Estimation settings
Method: TSLS - Two-Stage Least Squares (TSNLS and ARMA) v
Sample: 1970 2018

OK Annuler

◀ عند الضغط على OK، تظهر لنا نتائج التقدير التالية:

دروس في مقياس طرق التنبؤ

Dependent Variable: I
 Method: Two-Stage Least Squares
 Date: 02/12/23 Time: 14:11
 Sample (adjusted): 1971 2018
 Included observations: 48 after adjustments
 Instrument specification: CT(-1) G(-1) G
 Constant added to instrument list

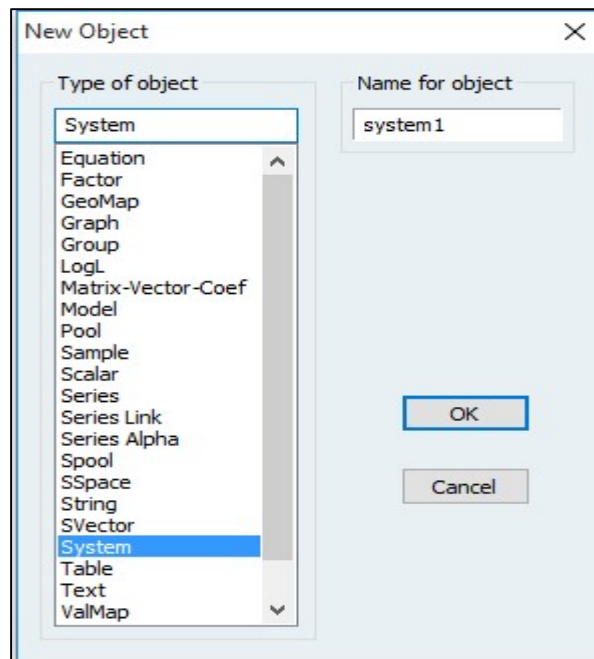
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-3.79E+10	1.96E+10	-1.928819	0.0601
Y	1.793491	1.172535	1.529584	0.1331
G(-1)	-5.222796	4.971182	-1.050615	0.2990
R-squared	0.599220	Mean dependent var	3.42E+10	
Adjusted R-squared	0.581408	S.D. dependent var	2.50E+10	
S.E. of regression	1.62E+10	Sum squared resid	1.17E+22	
F-statistic	44.02950	Durbin-Watson stat	0.191633	
Prob(F-statistic)	0.000000	Second-Stage SSR	6.32E+21	
J-statistic	3.877026	Instrument rank	4	
Prob(J-statistic)	0.048951			

انطلاقاً من تقدير معادلتين السابقتين، فإن تقدير النموذج هو:

$$\begin{cases} \hat{C}_t = 3.33 \times 10^9 + 0.253342I_t + 0.226999y_t + 0.428793C_{t-1} \\ \hat{I}_t = -3.79 \times 10^{10} + 1.793491y_t - 5.222796G_{t-1} \\ y_t = C_t + I_t + G_t \end{cases}$$

❖ الطريقة الثانية للتقدير: تسمح هذه الطريقة بتقدير كل معادلات النموذج في نفس الوقت (تقدير للنظام ككل)، وتنبع على برنامج إفيوز الخطوات التالية:

بعد إدخال بيانات النموذج إلى البرنامج، نضغط Object ثم New Object، فتظهر لنا النافذة التالية ونختار منها: نظام System1. ونسميه System1.



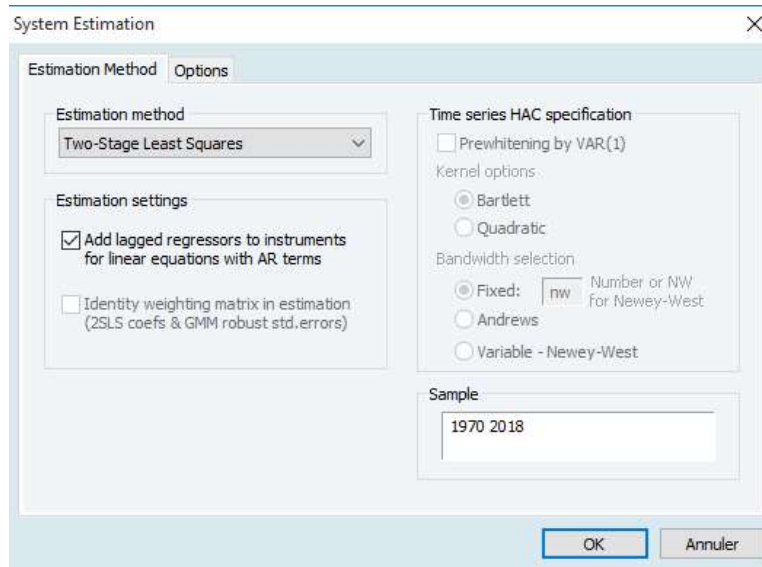
عند الضغط على OK تظهر لنا صفحة فارغة لكتابة النظام، فنكتب نظامنا كما يلي:

دروس في مقياس طرق التنبؤ

```
EViews - [System: SYSTEM1 Workfile: SEM_EX3::Untitled\]
File Edit Object View Proc Quick Options Add-ins Window Help
Command
View Proc Object Print Name Freeze InsertTxt Estimate Spec Stats Resids
ct = c(1) + c(2)*i + c(3)*y + c(4)*ct(-1)
i = c(5) + c(6)*y + c(7)*g(-1)
inst c ct(-1) g(-1) g
```

نحدد المتغيرات الأداة (وهي الخارجية في النموذج): $G(-1)$ $G(-1)$ c $ct(-1)$ بكتابتها في آخر سطر بعد كتابة التعليمات `.inst`

نضغط بعد ذلك على `Estimate`، فتظهر لنا النافذة التالية والتي نحدد منها طريقة التقدير (TSLS):



عند الضغط على `OK` يظهر لنا تقدير النظام السابق كما يلي:

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	3.33E+09	1.85E+09	1.803404	0.0747
C(2)	0.253342	0.106543	2.377846	0.0196
C(3)	0.226999	0.060283	3.765551	0.0003
C(4)	0.428793	0.155989	2.748867	0.0072
C(5)	-3.75E+10	1.95E+10	-1.920790	0.0580
C(6)	1.771320	1.166417	1.518600	0.1324
C(7)	-5.128765	4.945242	-1.037111	0.3025
Determinant residual covariance		1.11E+39		
Equation: CT = C(1) + C(2)*I + C(3)*Y + C(4)*CT(-1)				
Instruments: C CT(-1) G(-1) G				
Observations: 48				
R-squared	0.992004	Mean dependent var	5.65E+10	
Adjusted R-squared	0.991459	S.D. dependent var	2.49E+10	
S.E. of regression	2.30E+09	Sum squared resid	2.32E+20	
Durbin-Watson stat	0.577917			
Equation: I = C(5) + C(6)*Y + C(7)*G(-1)				
Instruments: C CT(-1) G(-1) G				
Observations: 48				
R-squared	0.603392	Mean dependent var	3.42E+10	
Adjusted R-squared	0.585765	S.D. dependent var	2.50E+10	
S.E. of regression	1.61E+10	Sum squared resid	1.16E+22	
Durbin-Watson stat	0.189573			

دروس في مقياس طرق التنبؤ

انطلاقاً من الجدول أعلاه، فإن تقدير النموذج هو:

$$\begin{cases} \hat{C}_t = 3.33 \times 10^9 + 0.253342I_t + 0.226999y_t + 0.428793C_{t-1} \\ \hat{I}_t = -3.75 \times 10^{10} + 1.77132y_t - 5.128765G_{t-1} \\ y_t = C_t + I_t + G_t \end{cases}$$

د. التنبؤ باستخدام النموذج المقدر:

لنعتبر توفر بيانات حول الدخل والنفقات العامة في الجزائر، ونريد التنبؤ بالقيم المستقبلية للاستهلاك والاستثمار. القيم المتوفرة خلال الفترة 2019-2023 موضحة في الجدول التالي:

G	Y	t
38999893823	170852454641	2019
39896891382	171028778571	2020
40814519884	171205284472	2021
41753253842	171381972531	2022
42713578681	171558842936	2023

للقيام بعملية التنبؤ على برنامج إفيوز نتبع نفس الخطوات المبينة في المثال التطبيقي لنموذج الانحدار الخطي المتعدد.

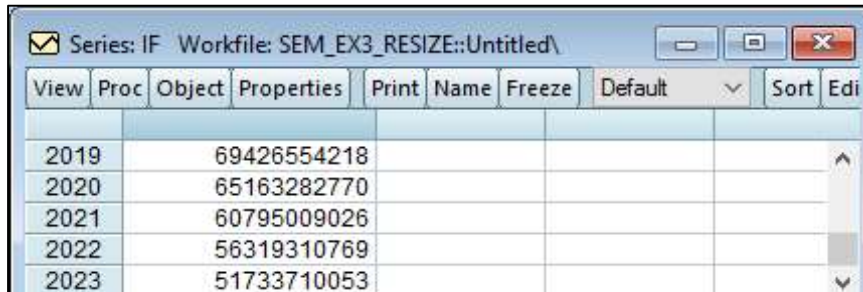
نقوم بعد ذلك بإدخال قيم المتغيرين (Y) و (G) للسنوات 2019-2023.

ثم نقوم بفتح النافذة التي تحتوي على تقدير النموذج. ثم نضغط على Forecast، ونسمي السلسلة المتنبأ بها بالاعتماد

على النموذج المقدر (IF)، كما نختار عينة التنبؤ (2019 - 2023)، ثم نضغط على OK، فتظهر لنا سلسلة جديدة

في ملف العمل اسمها "IF".

وعند فتحها نجد قيم المتغير التابع (الاستثمار IF) للسنوات 2019-2023.



Year	Value
2019	69426554218
2020	65163282770
2021	60795009026
2022	56319310769
2023	51733710053

نتبع نفس الخطوات للتنبؤ للاستهلاك (CT) للسنوات 2019-2023 في المعادلة الثانية (مع الإشارة إلى أننا سنستخدم

على القيم التنبؤية للاستثمار للسنوات 2019-2023 المحسوبة أعلاه):

دروس في مقياس طرق التنبؤ


View	Proc	Object	Properties	Print	Name	Freeze	Default	Sc
		2019	107659981841					
		2020	104827879220					
		2021	102546893462					
		2022	100475049040					
		2023	98465081484					

هـ. المحاكاة وتحليل السيناريوهات باستخدام النموذج المقدر:

للقيام بالمحاكاة وتحليل السيناريوهات على برنامج إفيوز نتبع الخطوات التالية:

◀ نبحث عن الحل الأولي للنظام.

◀ في ملف العمل نضلل المعادلتين ثم نضغط بيمين الفأرة ونفتحها كنموذج as model كما يلي:

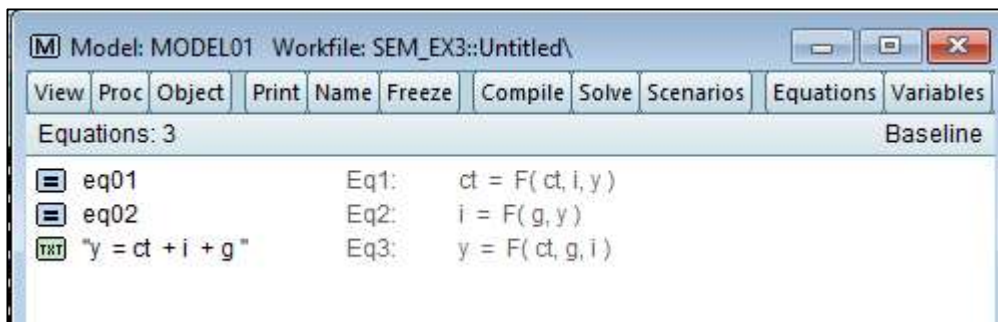


◀ وهكذا نكون قد أدخلنا المعادلات السلوكية للنظام، نضيف الآن المعادلة التعريفية، وذلك بالضغط على يمين الفأرة واختيار

insert، فتظهر لنا النافذة التالية والتي نكتب فيها المعادلة التعريفية.

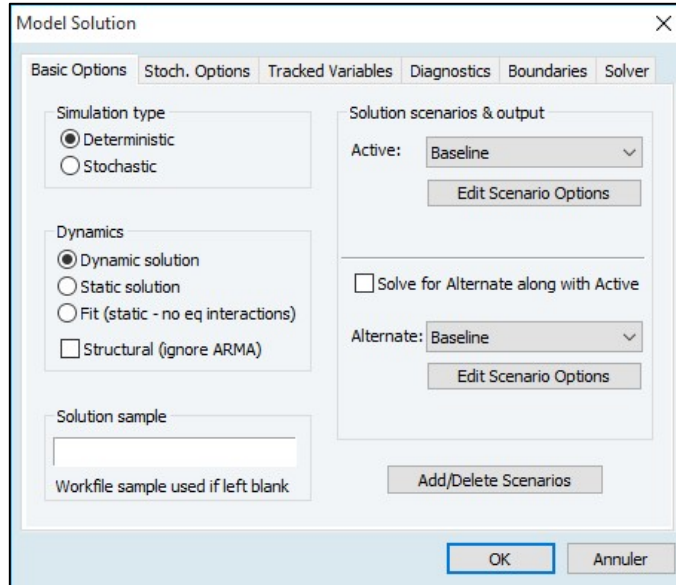


◀ الآن أصبح النموذج يضم المعادلات الثلاثة (ونسماه Model1):



◀ لحل النموذج نضغط على أيقونة Solve لتظهر لنا النافذة التالية:


دروس في مقياس طرق التنبؤ



◀ عند الضغط على OK يتم حل النظام (الحل الأولي للنظام)، فتظهر لنا النافذة التالية، والتي يؤكد على أن النموذج قابل للحل (المعادلات زائدة تشخيص)، وتشير هذه النافذة إلى عدد التكرارات ونوع المحاكاة والخوارزمية المستخدم، وكذلك تواريخ بدء وانتهاء التكرار:

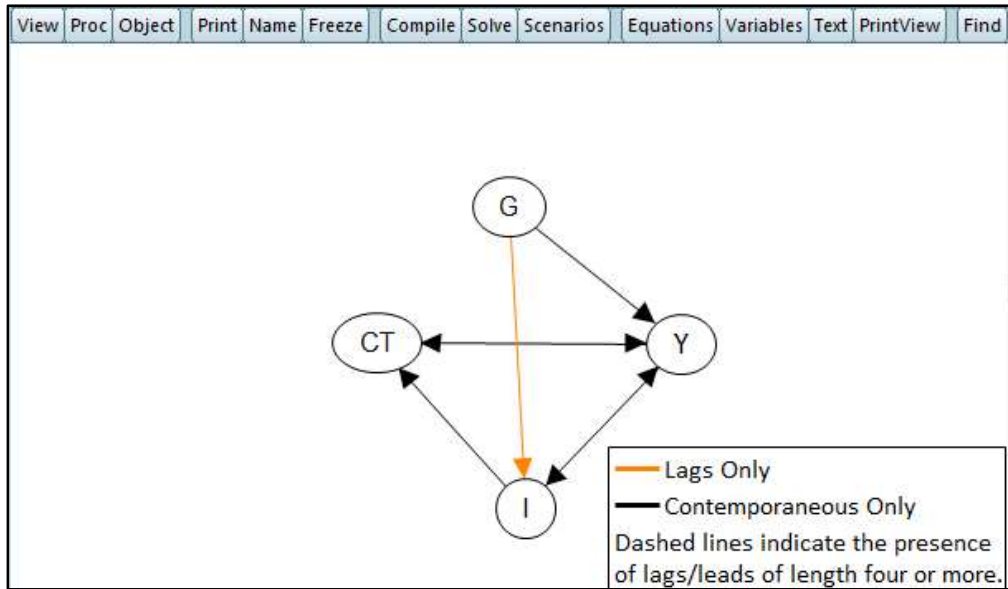


◀ عند العودة إلى ملف العمل نجد أن البرنامج قام بإنشاء متغيرات جديدة تمثل الحل الأولي أو الأساسي (Baseline) للنظام ويرمز لها بنفس اسم المتغيرات مع إضافة الرمز "_0" (أي: y_0 , i_0 , ct_0).

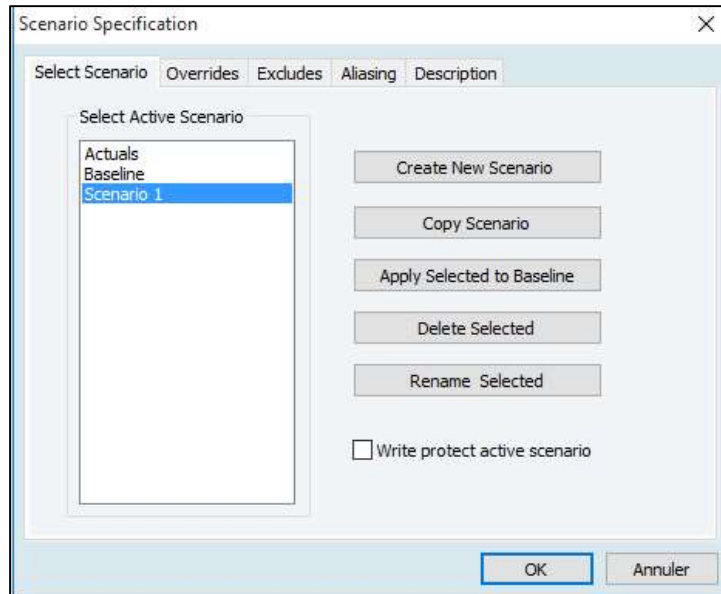


دروس في مقياس طرق التنبؤ

- ◀ بعد حل النموذج وإيجاد الحل الأولي نستطيع استخدامه في المحاكاة وبناء السيناريوهات.
- ◀ ولنأخذ مثال على ذلك، نريد دراسة أثر زيادة النفقات العامة (G) بواحد مليون دولار على المتغيرات الداخلية في الخمس سنوات الموالية (2019-2023) أي محاكاة خارج العينة (مع افتراض بقاء جميع المتغيرات على حالها، أي المتغيرات الخارجية الأخرى تبقى ثابتة وبالتالي تغييرها يكون معدوم).
- ◀ نقوم أولاً بتغيير حجم ملف العمل (التمديد إلى 2023).
- ◀ لمعرفة المتغيرات التي ستتأثر بالتغير في قيمة النفقات العامة G، نظهر شكل المسار من خلال فتح النموذج (Model1)، ثم الضغط على View ثم Dependency graph، فيظهر الشكل الموالي الذي يبين أن التغير في G يؤثر مباشرة في Y، أما G(-1) فيؤثر مباشرة في I.

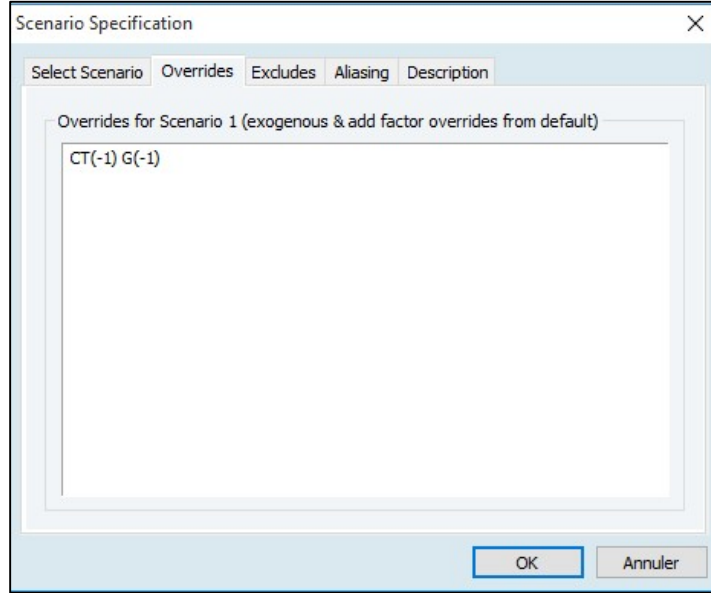


- ◀ ولتقدير حجم تأثير التغير في G على Y، نفتح النموذج (model1)، ثم نضغط على View ثم Scenario، فنظهر لنا النافذة التالية التي نختار منها السيناريو الأول (Scenario1).



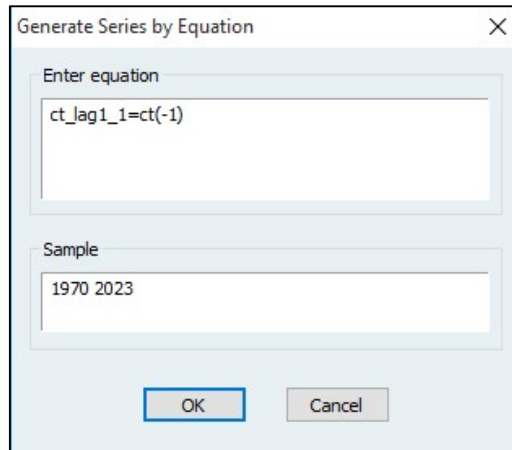
دروس في مقياس طرق التنبؤ

ثم في نفس النافذة نضغط على Overrides، لندخل المتغيرات الخارجية (الثابتة):



الآن نقوم بتثبيت المتغيرات الخارجية.

بالنسبة للمتغيرات الخارجية التي لا يوجد فيها تغيير (في مثالنا المتغير $CT(-1)$)، فنقوم بإنشاء سلسلة جديدة نضيف لها الرمز " 1_" للتعبير عن السيناريو الأول، وذلك من خلال الضغط على Quick ثم Generate Series:



ثم نفتح السلسلة الجديدة المنشأة (نرمز للسلسلة بـ CT_LAG1_1) وندخل نفس قيمة السنة الأخيرة 2019 في السنوات من 2020 إلى 2023:

View	Proc	Object	Properties	Print	Name	Freeze	Default	Sort	Edit+/-	Smpl+
		Series: CT_LAG1_1	Workfile: SEM_EX3::Untitled\							
		2018	108899026981							
		2019	111839300710							
		2020	111839300710							
		2021	111839300710							
		2022	111839300710							
		2023	111839300710							

أما بالنسبة للمتغير الخارجي الذي نبحث عن أثره عند تغيير قيمته وهو G ، فننشأ السلسلة الجديدة G_1 الخاصة بالسيناريو الأول على خطوتين:

دروس في مقياس طرق التنبؤ

- نثبت قيمة المتغير G قبل 2019 بنفس قيمه الأولية، وذلك من خلال الضغط على Quick ثم Generate Series:

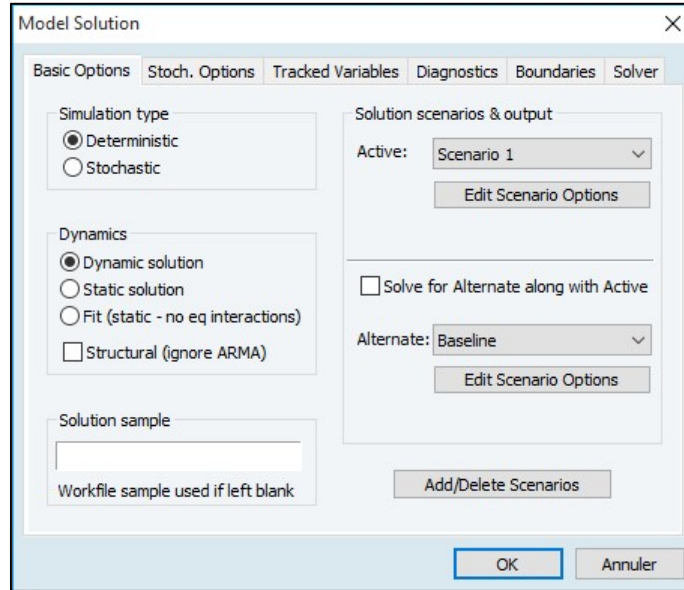
- ثم نضغط على Quick ثم Generate Series، ثم نطلب من البرنامج أن يضيف 1 مليون للقيمة الأخيرة لهذا المتغير (2018)، وهذا للسنوات 2019 إلى 2023، كما هو مبين أدناه:

◀ عند الضغط على OK، نفتح السلسلة g_1 فنجد أن قيمها من سنة 2019 إلى 2023 تكون كالتالي:


Year	Value
2016	36250920811
2017	37265946593
2018	38123063365
2019	38124063365
2020	38124063365
2021	38124063365
2022	38124063365
2023	38124063365

- ◀ بالنسبة للمتغيرات الداخلية فسيقوم البرنامج بإنشائها أوتوماتيكيا (CT_1, Y_1, I_1).
- ◀ الآن وبعد إدخال التغييرات على السلاسل، ندخل إلى النموذج (Model1)، ونضغط على Solve لحل النموذج باستخدام السيناريو الأول (نختار Scenario1) في الخانة Active:

دروس في مقياس طرق التنبؤ



فتظهر لنا النافذة التالية والتي يبين أن البرنامج قد حل النموذج باستخدام السيناريو الأول:



وبالعودة إلى ملف العمل نجد أن البرنامج قام بتوليد 3 سلاسل جديدة للمتغيرات الداخلية، وهي ct_1 ، y_1 ، i_1 :

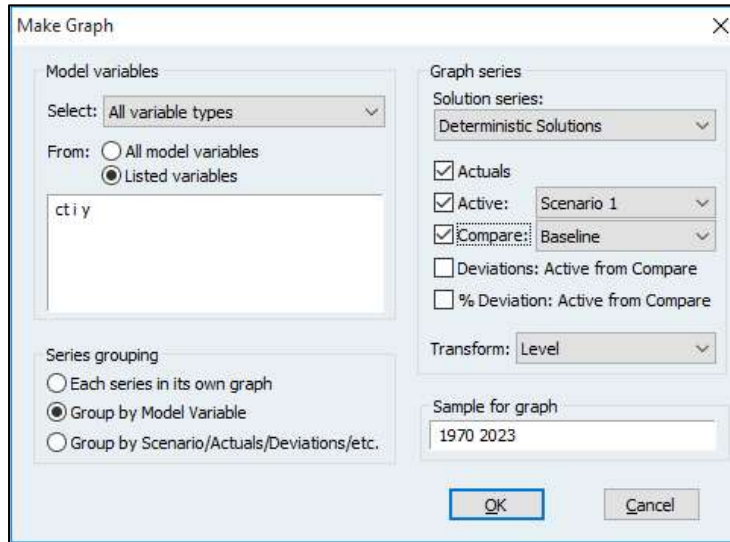


وبالعودة إلى المتغيرات الداخلية في النموذج نجد التغيرات التي يمكن أن تحدث نتيجة للتغير في قيمة المتغير الخارجي (النفقات العامة G) بواحد مليون دولار:

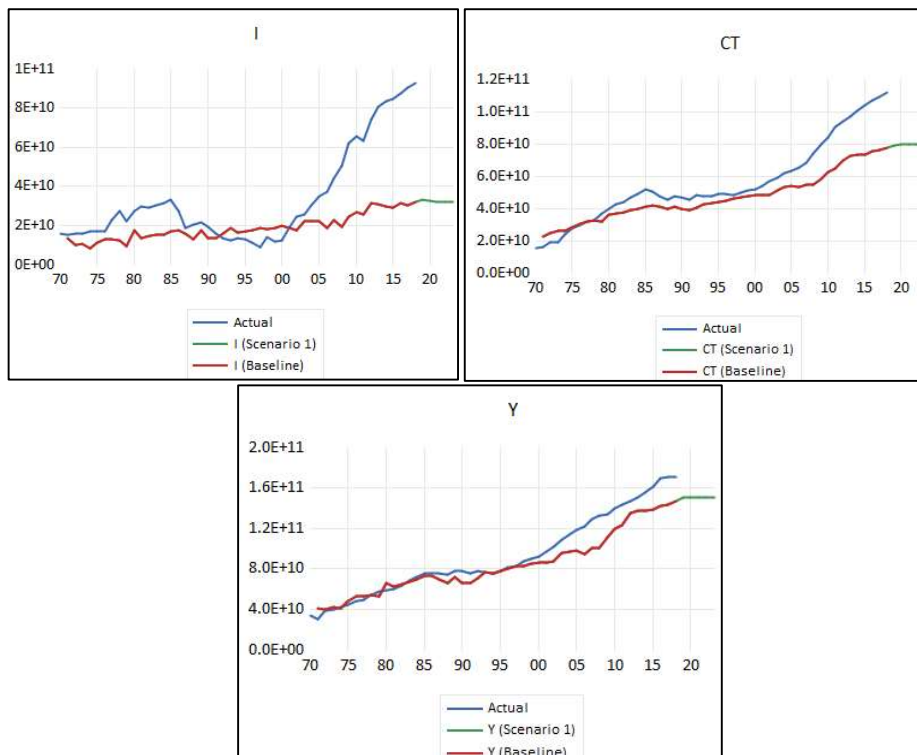
دروس في مقياس طرق التنبؤ

View	Proc	Object	Print	Name	Freeze	Default	Sort	Edit+/-	Smpl+/-	Compare+/-
		CT_1		I_1		Y_1				
		2018	77425510000	31864140000		147412700000				
		2019	79227950000	33429500000		150781500000				
		2020	79645460000	32492390000		150261900000				
		2021	79741780000	32274690000		150140500000				
		2022	79764000000	32224460000		150112500000				
		2023	79769130000	32212880000		150106100000				

بعد الحصول على قيم المحاكاة بالسيناريو الأول، يمكننا المقارنة بين القيم الأصلية والقيم المتوقعة قبل وبعد زيادة النفقات العامة (السيناريو 1)، وذلك من خلال فتح النموذج (Model1)، ثم الضغط على Proc ثم Make Graph، ثم نختار السيناريو الأول والمتغيرات الداخلية كما يلي:



عند الضغط على OK تظهر لنا التمثيلات البيانية التالية التي تقارن بين القيم الثلاثة:



دروس في مقياس طرق التنبؤ

III. المحور الثالث: منهجية بوكس-جينكينز في الأجل القصير

يشار لطريقة بوكس جينكينز (Box-Jenkins) اختصاراً باسم نماذج ARMA (ARMA Models). وهي تسمح في عدة خطوات بتحديد نموذج ARMA الذي يحتمل أن يقدم أفضل تمثيل لسلسلة زمنية، ثم التنبؤ على أساس النموذج الذي تم تحديده.

من أجل تحديد نموذج ARMA الأنسب قصد التنبؤ بسلسلة زمنية، يجب اتباع الخطوات التالية:


1. الخطوة الأولى: التحليل الأولي (Initial Analysis)

يهدف التحليل الأولي إلى كشف وجود مركبة الاتجاه العام و/أو المركبة الموسمية، ثم تحييدهما (إزالتها).

أ. كشف وإزالة الأثر الموسمي (Seasonality):

في الخطوة الأولى، يجب الكشف عن الموسمية باستخدام بعض الطرق كالرسم البياني، وشكل الارتباط، ... وفي حالة وجود سلسلة متأثرة بالمركبة الموسمية، يجب إزالتها قبل أي معالجة إحصائية، ثم نستمر الخطوات بالسلسلة المصححة من التغيرات الموسمية. ثم في الأخير نعيد المركبة الموسمية عند التنبؤ بقيم السلسلة، مع مراعاة شكل النموذج تجميعي أو جدائي. والتغيرات الموسمية S هي تغير الظاهرة المدروسة في المدى القصير (لا يزيد طولها على السنة)، فقد تكون أسبوعية أو شهرية أو فصلية، وهي تغيرات متكررة في فترات منتظمة. وتظهر المركبة الموسمية نتيجة لعدة عوامل، من بينها العوامل المرتبطة بالظروف الجوية، كالبرودة والحرارة أو الصيف والشتاء. والعوامل المرتبطة برزنامة زمنية كالأعياد والمناسبات... إلى غير ذلك.

مثال: مبيعات مكيفات الهواء (وجود موسمية: أقل القيم في شهر ديسمبر وأكبر القيم في شهر جويلية من كل سنة).



ونستطيع الكشف عن المركبة الموسمية بـ:

المنحنى البياني للسلسلة: إذا كان الشكل العام للمنحنى البياني متماثل في كل سنة (قيم حدية كبرى أو صغرى مكررة في نفس الفترة لكل سنة)، فهذا يدل على وجود تغيرات موسمية.

المنحنى البياني الموسمي: نقوم برسم منحنى بياني لكل فترة (شهر مثلاً)، ونحسب متوسط الشهر. فإذا كانت المتوسطات متقاربة فهذا يدل على عدم وجود موسمية، أما إذا كانت مختلفة بشكل ملحوظ فهذا يدل على وجود المركبة الموسمية (وهذا التمثيل البياني متوفر على برنامج إفيوز من خلال View ثم Graph ثم Seasonal Graph).

دروس في مقياس طرق التنبؤ

◀ التمثيل البياني لدالة الارتباط الذاتي: إذا كانت الحدود $p, 2p, 3p, \dots$ لدالة الارتباط الذاتي معنوية (خارج مجال الثقة)، فهذا يدل على وجود تغيرات موسمية في السلسلة. مع $p = 4$ للبيانات الفصلية أو $p = 12$ للشهرية.

◀ اختبار ANOVA: يفضل دعم التمثيل البياني الموسمي باختبار ANOVA لاختبار هل توجد فروقات ذات دلالة في المتوسطات من حيث الأشهر؟ ففي حالة وجود المركبة الموسمية تكون متوسطات الشهور غير متساوية (رفض الفرضية الصفرية: المتوسطات متساوية بين الأشهر) والعكس بالعكس (وهذا الاختبار متوفر على برنامج إفيوز من خلال View ثم Descriptives statistics and tests ثم Equality tests by classification، وللقيام بهذا الاختبار لا بد من اضافة متغير ترميزي بحيث نعطي كل شهر قيمة معينة (مثلا 1، 2، 3...)).

ب. كشف وإزالة أثر الاتجاه العام (دراسة الاستقرار - Stationarity):

بما أن منهجية بوكس جينكينز تتعامل مع العمليات العشوائية المستقرة، فقبل مرحلة تحديد النموذج المناسب يجب الإجابة على هذين السؤالين: هل السلسلة الزمنية مستقرة أم لا؟ وهل الاتجاه العام عشوائي أم محدد؟ واختبار ديكي-فولر Dicky-Fuller يجب عن هذين السؤالين.

بعد تطبيق اختبار ديكي-فولر، وحتى لو كانت السلسلة غير مستقرة نستطيع جعلها مستقرة باستخدام طرق التحويل المناسب، وذلك إما عن طريق الفروق (إذا كانت من نوع DS)، أو عن طريق الانحدار الزمني (إذا كانت من النوع TS).

والاتجاه العام T هو تغيرات أساسية طويلة المدى تعكس الاتجاه العام للظاهرة المدروسة من حيث شكل التطور (موجب أو سالب). من أهم ما يتميز به أنه يأخذ شكله بصورة تدريجية ويكون تغيره بطيئا ما بين سنة وأخرى، كما أنه يستمر في اتجاه واحد مدة طويلة من الزمن.

2. الخطوة الثانية: التعرف (التعيين - Identification)

تتمثل هذه الخطوة في العثور على عملية توليد سلسلتنا في فئة عمليات ARMA المستقرة، وهي العملية التي من المرجح أن تتكيف بشكل أفضل مع البيانات التجريبية التي تشكل السلسلة. هذا البحث يسمى التعرف (أو التعيين). ويتضمن ذلك تحديد الدرجة "p" لجزء الانحدار الذاتي AR والدرجة "q" لجزء المتوسط المحرك MA، بناءً على المقارنة بين الخصائص النظرية لدالة الارتباط الذاتي (AutoCorrelation Function) والارتباط الذاتي الجزئي (Partial AutoCorrelation Function)، والخصائص التجريبية (قيم السلسلة المدروسة) لهاتين الدالتين. أي محاولة مطابقة سلوك البيانات مع سلوك النماذج النظرية.

خصائص دالتي الارتباط الذاتي والارتباط الذاتي الجزئي للعمليات ARMA ملخصة في الجدول التالي:

العملية	دالة الارتباط الذاتي ACF	PAC دالة الارتباط الذاتي الجزئي
AR (1)	- يكون شكل الدالة أسّي متناقص أو جيبي.	- الحد الأول للدالة معنوي (خارج مجال الثقة)

دروس في مقياس طرق التنبؤ

- الحدود الأخرى الأكبر من واحد تكون معدومة (داخل مجال الثقة).		
الأولى للدالة معنوية. p - الحدود تكون p - الحدود الأخرى الأكبر من معدومة.	- يكون شكل الدالة أسّي متناقص أو جيبي بحسب إشارة المعلمات.	AR (P)
- يكون شكل الدالة أسّي متناقص أو جيبي.	- الحد الأول للدالة معنوي. - الحدود الأخرى الأكبر من واحد تكون معدومة.	MA (1)
- يكون شكل الدالة أسّي متناقص أو جيبي بحسب إشارة المعلمات.	الأولى للدالة معنوية. q - الحدود تكون q - الحدود الأخرى الأكبر تماما من معدومة.	MA (q)
- يكون شكل الدالة أسّي متناقص أو جيبي.	- يكون شكل الدالة متناقص ابتداء من الحد الأول.	ARMA(1,1)
- يكون شكل الدالة أسّي متناقص أو $p-q$ جيبي مبتور بعد الإبطاء.	- يكون شكل الدالة أسّي متناقص أو جيبي $p-q$ مبتور (تتلاشى) بعد الإبطاء.	ARMA(p,q)

في نهاية هذه المرحلة نكون قد حددنا النموذج (أو النماذج) المرشحة لتمثيل السلسلة الزمنية المدروسة.

ملاحظة: كثيرا ما تسفر مرحلة التعيين على العديد من النماذج المحتملة لتمثيل السلسلة، لذلك يمكن استخدام معايير المعلومات والمتوفرة في مخرجات برنامج افيزو لاختيار النموذج المناسب (من خلال الخاصية Automatic ARIMA Forecasting).

3. الخطوة الثالثة: التقدير (Estimation)

بعد تحديد النموذج (أو النماذج) المناسب وتحديد درجة (أو درجات) الإبطاء، يتم تقدير معلماته. ويوجد عدة طرق تستخدم في التقدير أهمها: طريقة المربعات الصغرى (LS)، طريقة الاحتمال الأعظم (MV)، وهذه الطرق متوفرة على البرامج الإحصائية الجاهزة كإفيزو، فهي تعطي مباشرة كل القيم الخاصة بتقدير هذه النماذج.

4. الخطوة الرابعة: دراسة الصلاحية (التشخيص Diagnostic Checking)

ستسمح لنا هذه الخطوة بالتحقق من صحة النموذج (أو النماذج) المقدر. ففي بداية هذه الخطوة، يكون لدينا نموذج أو العديد من نماذج ARMA القادرة على تمثيل السلسلة الزمنية المدروسة، فيجب علينا الآن التحقق من صحة هذه النماذج حتى نقصي النماذج غير الصالحة. ولهذا نقوم بتطبيق اختبارات على المعلمات واختبارات على بواقي التقدير.

دروس في مقياس طرق التنبؤ

- أ. اختبارات على المعلمات: يجب اختبار معنوية المعلمات، وذلك بالاعتماد على اختبار ستودنت (Student).
- ب. اختبارات على أخطاء (بواقفي) التقدير: من بين أهم الإختبارات التي تجرى على أخطاء التقدير: اختبار الارتباط الذاتي للأخطاء، اختبار التوزيع الطبيعي، واختبار ثبات التباين (بالنسبة لهذا الأخير سنتطرق إليه عند التطرق لنماذج ARCH).
1. اختبار الارتباط الذاتي للأخطاء: من الطرق المستخدمة لاختبار وجود ارتباط ذاتي للأخطاء:
 - شكل دالتي الارتباط الذاتي والارتباط الذاتي الجزئي للأخطاء: إذا كانت كل الحدود داخل مجال الثقة (كما تكون جميع القيم الاحتمالية prob أكبر من 0,05)، فإن سلسلة الأخطاء لا تعاني من مشكل الارتباط الذاتي. وفي الحالة العكسية، أي أن أحد حدود الدالتين خارج مجال الثقة (أو الاحتمالية prob أصغر من 0,05)، فإن سلسلة أخطاء التقدير تعاني من مشكل الارتباط الذاتي.
 - اختبار Ljung-Box (Q-Stat): يستخدم هذا الاختبار لدراسة المعنوية الكلية لمعاملات دالة الارتباط الذاتي.
 - ✓ الفرضية الصفرية: $H_0: \rho_1 = \rho_2 = \dots = \rho_m = 0$ (عدم وجود ارتباط ذاتي للأخطاء).
 - حيث: ρ_i هي دالة الارتباط الذاتي للأخطاء من الدرجة i ($i = 1, 2, \dots, m$).
 - يمكن اختيار $m: m \approx \frac{n}{3}$. حيث n هو حجم العينة.
 - ✓ قرار الاختبار: إذا كانت قيمة $Q(m)$ أصغر من القيمة الجدولية $\chi^2(m)$ عند مستوى المعنوية α (أو الاحتمالية أكبر من α)، فإننا نقبل الفرضية الصفرية (أي غياب الارتباط الذاتي للأخطاء).
 - 2. اختبار التوزيع الطبيعي للأخطاء: من بين أهم الاختبارات التي تسمح بمعرفة هل الأخطاء تتبع التوزيع الطبيعي أم لا نجد:
 - المدرج التكراري للأخطاء: يمكن للمدراج التكراري للأخطاء أن يعطينا فكرة أولية حول توزيع الأخطاء، فإذا كان شكل المدراج التكراري قريب من (يشبه) شكل التوزيع الطبيعي المعتاد (شكل الجرس)، فإن هذا يدل على أن الأخطاء تتبع التوزيع الطبيعي.
 - منحنى الرُّبَيْعَات (Q-Q plot (Quantiles): يسمح منحنى الربيعات (Q-Q plot) بالمقارنة بين القيم المشاهدة والقيم النظرية لتوزيع ما (التوزيع الطبيعي مثلا) بنفس المعلمات (نفس التوقع ونفس التباين مثلا). فإذا كانت البيانات المدروسة تتبع التوزيع النظري (الطبيعي) فستنطبق القيم على المستقيم.
 - ومنحنى الرُّبَيْعَات متوفر على برنامج SPSS وعلى برنامج EViews.
 - اختبار جاك بيرا (Jarque-Bera):
 - ✓ الفرضية الصفرية: H_0 : الأخطاء تتبع التوزيع الطبيعي.
 - ✓ قرار الاختبار: إذا كانت القيمة المحسوبة JB أصغر من القيمة الجدولية $\chi^2(2)$ عند مستوى المعنوية α (أو $P - value > \alpha$)، فإننا نقبل الفرضية الصفرية (أي الأخطاء تتبع التوزيع الطبيعي).
- بعد إجراء هذه الاختبارات، أي نموذج تكون معلماته غير معنوية و/أو يعاني من مشكل في الأخطاء، يتم التخلي عنه (يقصى) لمثل السلسلة الزمنية. وفي حالة نجاح العديد من هذه النماذج من اجتياز هذه الاختبارات، فيجب أن تتبع مرحلة التحقق من الصحة

دروس في مقياس طرق التنبؤ

بمرحلة أخرى خاصة بمقارنة خصائص هذه النماذج المقبولة لتحديد أفضلها. ومن بين أهم معايير المقارنة: معايير المعلومات لاكايبك وشوارز، معامل التحديد، مجموع مربع الأخطاء، ... إلخ. وبالاعتماد على هذه المعايير سيحدد أفضل نموذج لتمثيل السلسلة الزمنية، والذي سنعتمد عليه للقيام بعملية التنبؤ.

5. الخطوة الخامسة: التنبؤ (Forecasting)

في هذه الخطوة، من الضروري مراعاة التحويلات التي تم إجراؤها على السلسلة الزمنية في خطوة التحليل الأولى للسلسلة (الاستقرارية والتصحيح الموسمي)، من أجل الحصول على القيم المتوقعة المناسبة على السلسلة الأولية (إعادة تحويل السلسلة). عند التنبؤ في نماذج ARMA نقوم بتعويض كل القيم المستقبلية للمتغير الخاص بالظاهرة المدروسة بتنبؤاتها ($X_{t+h} = \hat{X}_{t+h}$) والقيم السابقة بالقيم المشاهدة (X_t)، بينما يتم تعويض الأخطاء المستقبلية بالصفر ($\hat{\varepsilon}_{t+h} = 0$) والأخطاء السابقة بالبواقي ($\hat{\varepsilon}_{t-h} = X_{t-h} - \hat{X}_{t-h}$).

ليكن النموذج الأمثل هو $ARMA(1, 1)$ ، ونود التنبؤ بالسلسلة في الأفق الأول $h=1$:

$$\text{لدينا: } X_t = \varphi_1 X_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1} \Rightarrow X_{t+1} = \varphi_1 X_t + \varepsilon_{t+1} - \theta_1 \varepsilon_t$$

$$\text{ومنه: } \hat{X}_{t+1} = \varphi_1 X_t + 0 - \theta_1 \hat{\varepsilon}_t = \varphi_1 X_t - \theta_1 \hat{\varepsilon}_t$$

$$\text{ولدينا: } X_{t+2} = \varphi_1 X_{t+1} + \varepsilon_{t+2} - \theta_1 \varepsilon_{t+1}$$

$$\text{ومنه: } \hat{X}_{t+2} = \varphi_1 \hat{X}_{t+1} + 0 - \theta_1 (0) = \varphi_1 \hat{X}_{t+1}$$

$$\text{وبتعميم هذه النتيجة للأفق } h: \hat{X}_{t+h} = \varphi_1 \hat{X}_{t+h-1} \quad \forall h > 1$$

ملاحظات:

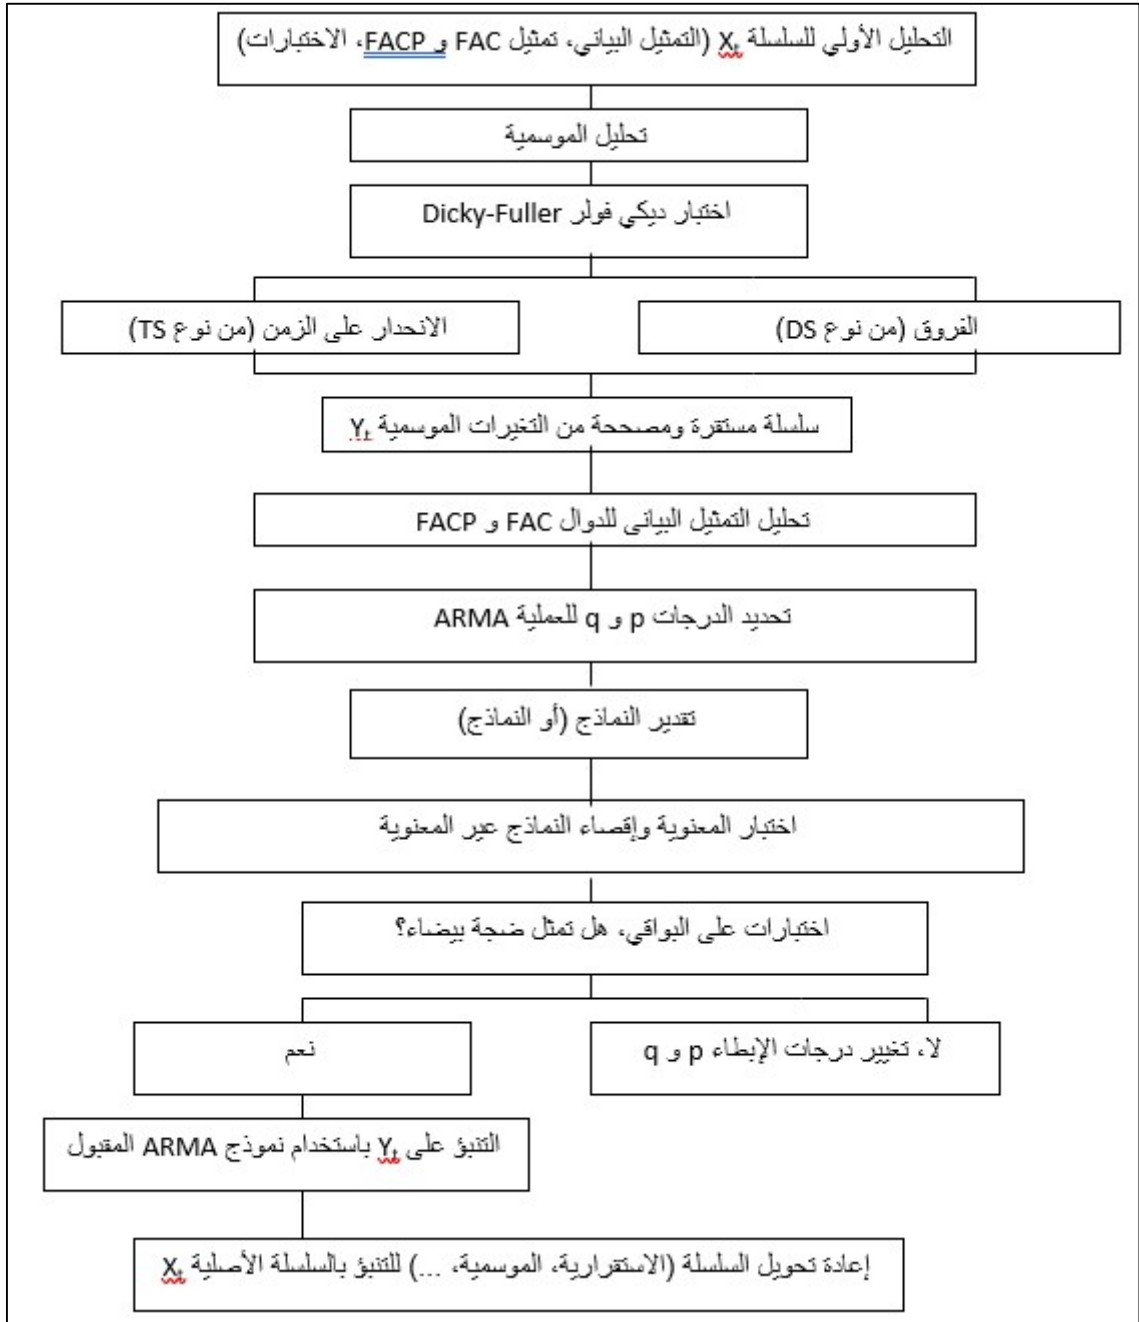
✓ يمكن التنبؤ بنموذج انحدار ذاتي $AR(p)$ إلى أي أفق مهما كان، أما نموذج المتوسط المتحرك $MA(q)$ فلا يمكن حساب التنبؤات إلا إلى الأفق $T+q$ ، ثم تصبح القيم التنبؤية ثابتة بعد ذلك.

✓ لا يكون للتنبؤ بنماذج $AR(p)$ بعد الفترة p علاقة بالقيم المشاهدة، بل سيكون مرتبط فقط بالقيم التنبؤية للفترات السابقة، لذا يجب اختيار التنبؤ الديناميكي (*Dynamic forecast*) على برنامج إيفوز ليعوض القيم المشاهدة غير المتوفرة بقيم التنبؤ المقدره لنفس الفترة.

✓ هاتان الملاحظتان السابقتان تجعلان من نماذج $ARMA$ طرق تنبؤ قصيرة الأجل (*short term forecasting*)، كالتنبؤ بالمبيعات الشهرية مثلا، وقليل ما تستخدم للتنبؤ طويل الأجل.

يمكن تلخيص المراحل المختلفة لطريقة *Box-Jenkins* في الرسم التخطيطي التالي:

دروس في مقياس طرق التنبؤ



دروس في مقياس طرق التنبؤ

6. مثال تطبيقي على برنامج إفيوز حول طريقة بوكس جينكينز:

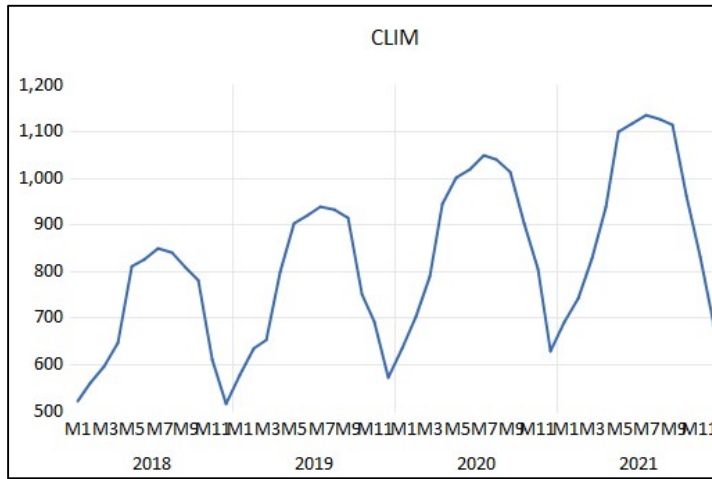
المثال يخص سلسلة زمنية لكمية المبيعات الشهرية من مكيفات الهواء لمصنع ما (clim).

أ. المرحلة الأولى: التحليل الأولي


كشوف وإزالة الأثر الموسمي:

نستطيع الكشف عن المركبة الموسمية بـ:

- المنحنى البياني للسلسلة: يظهر من التمثيل البياني للسلسلة وجود مركبة موسمية (توجد قيم حدية كبرى في أشهر الصيف وقيم حدية صغرى في أشهر الشتاء مكررة في نفس الفترة لكل سنة).




- المنحنى البياني الموسمي: نلاحظ وجود فروقات معتبرة بين المتوسطات من شهر لأخر، وهذا ما يدل على وجود موسمية.



- التمثيل البياني لدالة الارتباط الذاتي: بما أن الحد 12 لدالة الارتباط الذاتي معنوي (خارج مجال الثقة)، فهذا يوحي بوجود تغيرات موسمية في السلسلة.

دروس في مقياس طرق التنبؤ



اختبار ANOVA: بما أن $P - value < \alpha$ ، فإننا نرفض الفرضية الصفرية (إذن توجد فروق بين المتوسطات من حيث الأشهر)، وهذا يؤكد على وجود المركبة الموسمية.

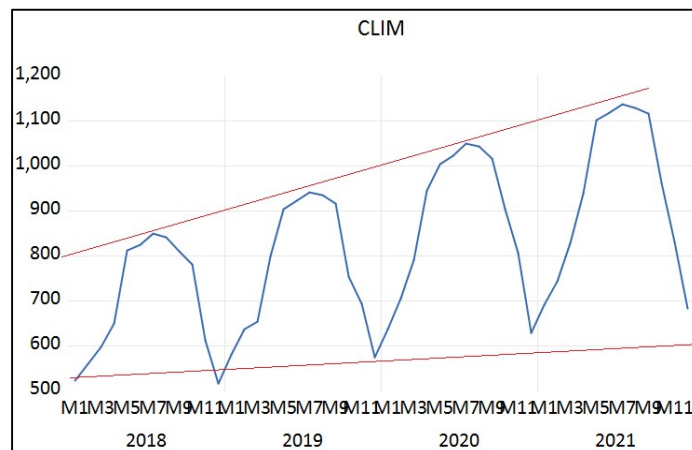
Test for Equality of Means of CLIM
Categorized by values of MONTHS
Date: 02/04/22 Time: 14:35
Sample: 2018M01 2021M12
Included observations: 48

Method	df	Value	Probability
Anova F-test	(11, 36)	7.526227	0.0000
Welch F-test*	(11, 14.1524)	6.563606	0.0007

*Test allows for unequal cell variances

بما أنه توجد المركبة الموسمية، فيجب تحديد النموذج المناسب للدمج (تحديد شكل نموذج الدمج):

الطريقة البيانية: نلاحظ بعد حصر المنحنى البياني للسلسلة الزمنية بين خطين، أحدهما غير متوازن، وهذا يدل على أن النموذج المناسب هو الجدائي.



اختبار Buys-Ballot: نقوم أولاً بحساب الانحرافات المعيارية لكل سنة (أربع سنوات 2018-2021).

دروس في مقياس طرق التنبؤ

Descriptive Statistics for CLIM Categorized by values of YEARS Date: 02/04/22 Time: 14:38 Sample: 2018M01 2021M12 Included observations: 48	
YEARS	Std. Dev.
1	133.4319
2	144.7195
3	159.3550
4	179.5147
All	177.2428

ثم نقدر معادلة الانحدار (الانحرافات المعيارية $SDCLIM$ على الزمن أو على المتوسطات السنوية) باستعمال طريقة المربعات المصغرى العادية:

Dependent Variable: SDCLIM Method: Least Squares Date: 02/04/22 Time: 14:40 Sample (adjusted): 2018M01 2018M04 Included observations: 4 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	131.3227	2.640147	49.74068	0.0004
@TREND	15.28839	1.411218	10.83347	0.0084

بما أن معلمة الاتجاه العام ($trend$) معنوية ($T_c > T_t$ و $P - value < \alpha$)، فإننا نرفض الفرضية الصفرية، فيكون النموذج المناسب هو الجدائي.

تبين أن هذه السلسلة تحتوي على المركبة الموسمية وأن النموذج المناسب هو الجدائي، فنقوم أولاً بإزالة الموسمية، وذلك بإنشاء السلسلة المصححة من التغيرات الموسمية ونرمز لها بـ $climsa$. كما نقوم بإنشاء سلسلة المعاملات الموسمية ونرمز لها بـ sa ، كما يلي:

أي نقوم بالعملية التالية: $climsa = clim/sa$

← كشف وإزالة أثر الاتجاه العام (دراسة الاستقرارية):

✓ تقدير النموذج (3): مخرجات إفيوز للنموذج (3) موضحة في الجدول التالي:

دروس في مقياس طرق التنبؤ

Augmented Dickey-Fuller Unit Root Test on CLIMSA				
Null Hypothesis: CLIMSA has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic - based on SIC, maxlag=9)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic			-5.928680	0.0001
Test critical values:				
1% level			-4.165756	
5% level			-3.508508	
10% level			-3.184230	
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(CLIMSA)				
Method: Least Squares				
Date: 02/06/22 Time: 20:40				
Sample (adjusted): 2018M02 2021M12				
Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
CLIMSA(-1)	-0.881112	0.148619	-5.928680	0.0000
C	572.7280	95.89528	5.972432	0.0000
@TREND("2018M01")	5.992662	1.031671	5.808694	0.0000

- اختبار الاتجاه العام (Trend): بما أن القيمة المحسوبة لستودنت (5,809) أكبر من القيمة الجدولية (3,18) (أي $T_c > T_t$) عند مستوى المعنوية $\alpha = 0,05$ ، فإننا نرفض الفرضية الصفرية، وهذا ما يدل على أن السلسلة تحتوي على مركبة الاتجاه العام. وبالتالي فهذا النموذج هو النموذج المناسب لاختبار الاستقرارية.
- اختبار جذر الوحدة: بما أن القيمة المحسوبة (-5,93) أصغر من القيمة الجدولية (-3,509) عند مستوى المعنوية $\alpha = 0,05$ (أي $ADF_c < ADF_t$)، فإننا نرفض الفرضية (H_0)، وهذا يعني عدم وجود جذر الوحدة. نستنتج من هذين الاختبارين أن السلسلة *climsa* غير مستقرة من نوع TS. ولجعلها مستقرة نقوم بتقدير نموذج الانحدار الخطي على الاتجاه العام ثم نزيل الاتجاه العام من السلسلة. تقدير نموذج الانحدار الخطي على الاتجاه العام موضح في الجدول التالي:

Dependent Variable: CLIMSA				
Method: Least Squares				
Date: 02/06/22 Time: 20:47				
Sample: 2018M01 2021M12				
Included observations: 48				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	650.7921	6.097698	106.7275	0.0000
@TREND	6.748632	0.223527	30.19152	0.0000

ومنه: $climsa = 650,79 + 6,7486(t)$

فتكون السلسلة الحالية من الاتجاه العام هي: $climsat = climsa - 650,79 - 6,7486(t)$
بعد إنشاء هذه السلسلة (*climsat*) نختبر استقراريتها، الجدول التالي يبين أن أثر الاتجاه العام قد زال وأنها مستقرة:

دروس في مقياس طرق التنبؤ

Augmented Dickey-Fuller Unit Root Test on CLIMSAT				
Null Hypothesis: CLIMSAT has a unit root				
Exogenous: Constant, Linear Trend				
Lag Length: 0 (Automatic - based on SIC, maxlag=9)				
			t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic				
-5.928680 0.0001				
Test critical values:				
1% level -4.165756				
5% level -3.508508				
10% level -3.184230				
*MacKinnon (1996) one-sided p-values.				
Augmented Dickey-Fuller Test Equation				
Dependent Variable: D(CLIMSAT)				
Method: Least Squares				
Date: 02/06/22 Time: 20:55				
Sample (adjusted): 2018M02 2021M12				
Included observations: 47 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
CLIMSAT(-1)	-0.881112	0.148619	-5.928680	0.0000
C	-1.494962	6.406210	-0.233361	0.8166
@TREND("2018M01")	0.046362	0.232384	0.199504	0.8428

يتبن من التحليل الأولي للسلسلة *clim* أنها تحتوي على المركبة الموسمية ولها إتجاه عام محدد (غير مستقرة من نوع TS)، وقد تم إزالة الموسمية وجعلناها مستقرة بعد إزالة الإتجاه العام، وبالتالي فنستمر في خطوات التنبؤ مع السلسلة المستقرة والمصححة من التغيرات الموسمية *climsat*. ثم بعد التنبؤ سنعيد تحويل السلسلة إلى أصلها (*clim*).

ب. المرحلة الثانية: التعرف

يمثل الشكل الموالي دوال الارتباط الذاتي والارتباط الذاتي الجزئي للسلسلة *climsat*:

Correlogram of CLIMSAT						
Date: 02/06/22 Time: 21:02						
Sample: 2018M01 2021M12						
Included observations: 48						
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.119	0.119	0.7221	0.395
		2	0.043	0.029	0.8172	0.665
		3	-0.027	-0.036	0.8564	0.836
		4	0.047	0.054	0.9762	0.913
		5	-0.223	-0.236	3.7423	0.587
		6	-0.219	-0.181	6.4875	0.371
		7	0.211	0.305	9.1021	0.245
		8	0.043	-0.023	9.2132	0.325
		9	-0.060	-0.106	9.4333	0.398
		10	-0.146	-0.153	10.783	0.375
		11	0.028	-0.056	10.834	0.457
		12	-0.295	-0.256	16.653	0.163
		13	-0.207	-0.037	19.599	0.106
		14	0.020	0.046	19.627	0.142
		15	0.028	-0.118	19.684	0.184
		16	0.027	0.014	19.739	0.232

نلاحظ أن جميع الحدود غير معنوية (داخل مجال الثقة)، وبالرغم من ذلك نلاحظ أن الحدود 5 و 6 من ACF والحدود 5 و 7 من PACF أقرب من المعنوية من بقية الحدود. ولهذا فسندرج النماذج التالية لتمثيل السلسلة الزمنية *climsat*: AR(5) و AR(7) و MA(5) و MA(6).

دروس في مقياس طرق التنبؤ

ج. الخطوة الثالثة: التقدير

في هذه الخطوة نقوم بتقدير النماذج المرشحة التالية: $AR(5)$ و $AR(7)$ و $MA(5)$ و $MA(6)$. باستخدام برنامج إفيوز:

Dependent Variable: CLIMSAT Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 02/06/22 Time: 22:00 Sample: 2018M01 2021M12 Included observations: 48 Convergence achieved after 7 iterations Coefficient covariance computed using outer product of gradients					Dependent Variable: CLIMSAT Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 02/06/22 Time: 22:00 Sample: 2018M01 2021M12 Included observations: 48 Convergence achieved after 10 iterations Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.428003	3.886392	-0.110128	0.9128	C	0.344332	2.465912	0.139637	0.8896
AR(7)	0.237555	0.182497	1.301688	0.1996	AR(5)	-0.262136	0.135060	-1.940887	0.0586
SIGMASQ	415.3207	62.71442	6.622412	0.0000	SIGMASQ	412.1892	58.86065	7.002798	0.0000
R-squared	0.058433	Mean dependent var	-2.42E-11		R-squared	0.065532	Mean dependent var	-2.42E-11	
Adjusted R-squared	0.016585	S.D. dependent var	21.22452		Adjusted R-squared	0.024000	S.D. dependent var	21.22452	
S.E. of regression	21.04777	Akaike info criterion	9.000399		S.E. of regression	20.96827	Akaike info criterion	8.991775	
Sum squared resid	19935.39	Schwarz criterion	9.117349		Sum squared resid	19785.08	Schwarz criterion	9.108725	
Log likelihood	-213.0096	Hannan-Quinn criter.	9.044595		Log likelihood	-212.8026	Hannan-Quinn criter.	9.035971	
F-statistic	1.396326	Durbin-Watson stat	1.630586		F-statistic	1.577870	Durbin-Watson stat	1.812332	
Prob(F-statistic)	0.258022				Prob(F-statistic)	0.217621			

Dependent Variable: CLIMSAT Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 02/06/22 Time: 21:58 Sample: 2018M01 2021M12 Included observations: 48 Convergence achieved after 27 iterations Coefficient covariance computed using outer product of gradients					Dependent Variable: CLIMSAT Method: ARMA Maximum Likelihood (OPG - BHHH) Date: 02/06/22 Time: 21:59 Sample: 2018M01 2021M12 Included observations: 48 Convergence achieved after 7 iterations Coefficient covariance computed using outer product of gradients				
Variable	Coefficient	Std. Error	t-Statistic	Prob.	Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.972118	1.913471	0.508039	0.6139	C	0.966571	1.498071	0.645210	0.5221
MA(6)	-0.519009	0.161781	-3.208085	0.0025	MA(5)	-0.609744	0.177939	-3.426699	0.0013
SIGMASQ	373.1318	76.07224	4.904967	0.0000	SIGMASQ	364.8377	50.66507	7.200970	0.0000
R-squared	0.154078	Mean dependent var	-2.42E-11		R-squared	0.172882	Mean dependent var	-2.42E-11	
Adjusted R-squared	0.116482	S.D. dependent var	21.22452		Adjusted R-squared	0.136121	S.D. dependent var	21.22452	
S.E. of regression	19.95012	Akaike info criterion	8.924039		S.E. of regression	19.72714	Akaike info criterion	8.910751	
Sum squared resid	17910.33	Schwarz criterion	9.040989		Sum squared resid	17512.21	Schwarz criterion	9.027701	
Log likelihood	-211.1769	Hannan-Quinn criter.	8.968235		Log likelihood	-210.8580	Hannan-Quinn criter.	8.954947	
F-statistic	4.098209	Durbin-Watson stat	1.808803		F-statistic	4.702887	Durbin-Watson stat	1.949234	
Prob(F-statistic)	0.023170				Prob(F-statistic)	0.013972			

د. الخطوة الرابعة: دراسة الصلاحية

اختبار معنوية المعلمات: يتبين من تقدير النماذج السابقة أن النموذجان اللذان جميع معلماتهم معنوية هما النموذجان: $MA(5)$ و $MA(6)$ ، لأن $T_c > T_t$ عند مستوى المعنوية $\alpha = 0,05$ و $Prob < \alpha$. أما النموذجين $AR(7)$ و $AR(5)$ فمعلماتهم غير معنوية.

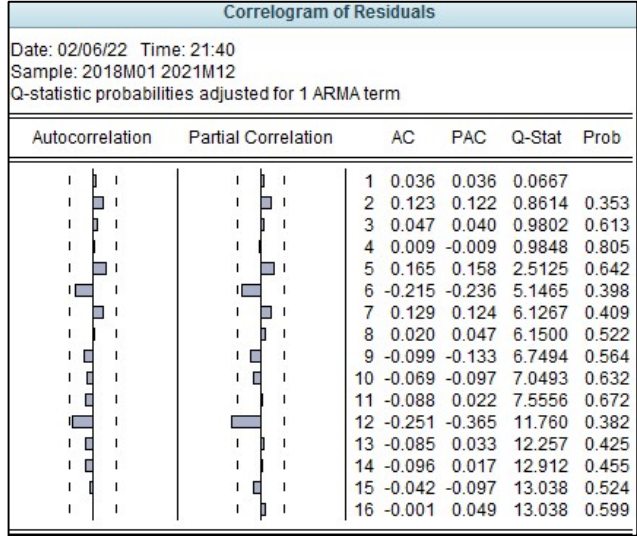
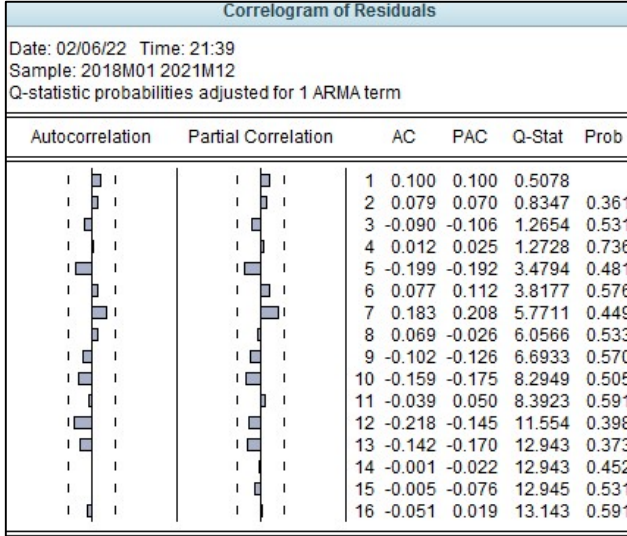
اختبارات على البواقي: سنختبر بواقي النموذجين المرشحين $MA(6)$ و $MA(5)$

✓ اختبار الارتباط الذاتي للأخطاء: سنعمد على التمثيل البياني التالي لإجراء الاختبار:

النموذج $MA(6)$

النموذج $MA(5)$


دروس في مقياس طرق التنبؤ




بما أن كل حدود ذاتي الارتباط والارتباط الذاتي الجزئي للأخطاء داخل مجال الثقة، فإن سلسلة الأخطاء لا تعاني من مشكل الارتباط الذاتي. كما أن اختبار Ljung-Box (Q-Stat) يؤكد ذلك.

✓ اختبار التوزيع الطبيعي للأخطاء: سنعمد على المدرج التكراري واختبار جاك بيرتا ومنحنى البريبيعات للبقايا التالي:

النموذج MA(6)



النموذج MA(5)

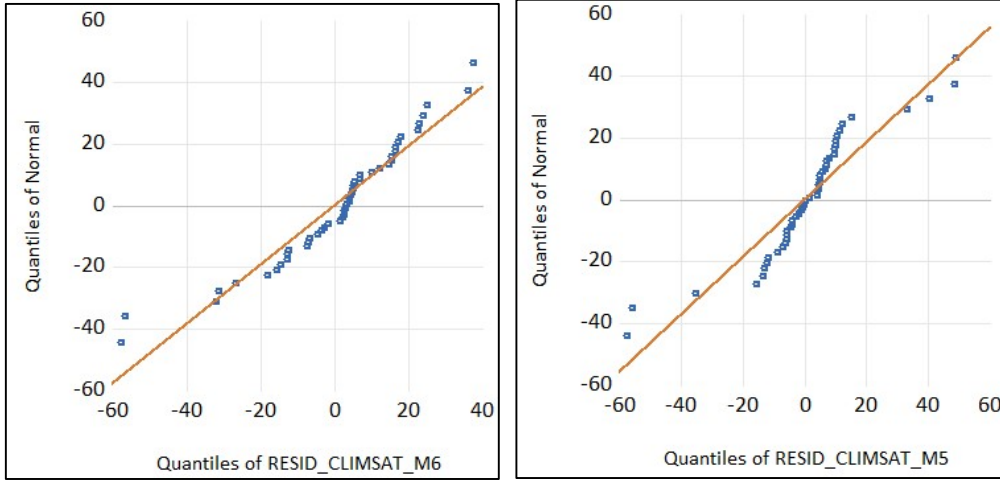


- المدرج التكراري للأخطاء: بما أن شكل المدرج التكراري قريب من شكل التوزيع الطبيعي المعتاد (شكل الجرس)، فإن هذا يدل على أن الأخطاء تتبع التوزيع الطبيعي.
- منحنى البريبيعات (Q-Q plot (Quantiles): يتبين من المنحنيين أن النموذج MA(6) أقرب للتوزيع الطبيعي من MA(5).

النموذج MA(6)

النموذج MA(5)


دروس في مقياس طرق التنبؤ



- اختبار جاك بيرا (Jarque-Bera): بما أن القيمة المحسوبة JB أكبر من القيمة الجدولية $\chi^2_{(2)} = 5,99$ عند مستوى المعنوية α (أو $P - value < \alpha$)، فإننا نرفض الفرضية الصفرية (أي الأخطاء لا تتبع التوزيع الطبيعي). يتبين من هذه الاختبارات أن البواقي أن النموذج $MA(6)$ هو المرشح لتمثيل السلسلة $climsat$. وعند تحديد أفضل نموذج للسلسلة بالاعتماد على معيار أكايك (AIC)، من خلال برنامج إفيوز، فقد تم كذلك تحديد النموذج $MA(6)$ كأفضل نموذج لتمثيل السلسلة.

Automatic ARIMA Forecasting Selected dependent variable: CLIMSAT Date: 02/06/22 Time: 21:53 Sample: 2018M01 2021M12 Included observations: 48 Forecast length: 6
Number of estimated ARMA models: 121 Number of non-converged estimations: 0 Selected ARMA model: (0,6)(0,0) AIC value: 8.95028096334

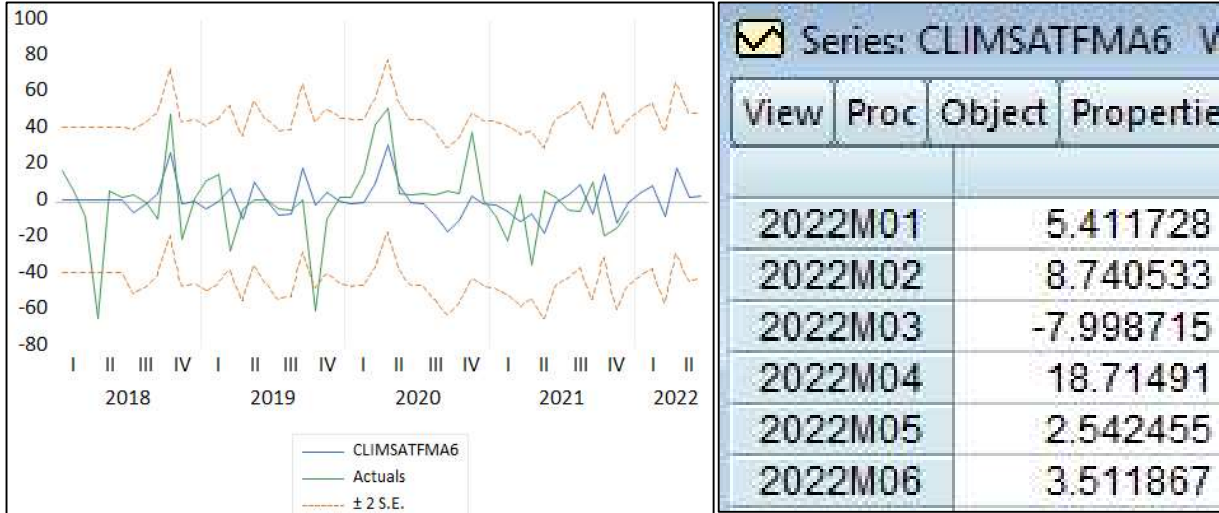
أما ترتيب أفضل النماذج من حيث أقل قيمة لمعيار المعلومات أكايك (AIC)، فهي بالترتيب التالي:



دروس في مقياس طرق التنبؤ

ح. الخطوة الخامسة: التنبؤ

لحساب القيم التنبؤية لمبيعات مكيفات الهواء للستة أشهر الأولى لسنة 2022، نفتح النموذج المقدر MA(6)، ثم نضغط على Forecast، فتظهر سلسلة جديدة خاصة بقيم التنبؤ (climsatfma6)، بالإضافة إلى التمثيل البياني للسلسلة الأصلية وسلسلة التنبؤ:



وبما أن السلسلة الأصلية clim تم إخضاعها للتحويل بإزالة الموسمية والإتجاه العام، فنستقوم الآن بالعملية العكسية للحصول على القيم التنبؤية للسلسلة الأصلية.

✓ أولاً الإتجاه العام: قمنا بالعملية التالية: $.climsat = climsa - 650,79 - 6,7486(t)$

ومنه العملية العكسية هي: $.climsa = clims + 650,79 + 6,7486(t)$

✓ ثانياً الموسمية: قمنا بالعملية التالية: $.climsa = clim/sa$

ومنه العملية العكسية هي: $.clim = climsa \times sa$

الجدول التالي يبين قيم التنبؤ للسلسلة الأصلية clim:

	CLIMSATFMA6	CLIMSAFF	SA	CLIMFF
2022M01	5.411728	980.1381	0.779790	764.3020
2022M02	8.740533	990.2156	0.844118	835.8591
2022M03	-7.998715	980.2250	0.909989	891.9942
2022M04	18.71491	1013.687	1.067649	1082.262
2022M05	2.542455	1004.263	1.187822	1192.886
2022M06	3.511867	1011.981	1.200926	1215.314

حيث: $.climsat$ القيم التنبؤية للسلسلة $.climsatfma6$

$.climsa$ القيم التنبؤية للسلسلة $.climsaff$

sa المعاملات الموسمية.

$.clim$ القيم التنبؤية للسلسلة $.climff$

دروس في مقياس طرق التنبؤ

IV. المحور الرابع: منهجية شعاع الانحدار الذاتي

واجهت نماذج المعادلات الأنية عدة انتقادات، بسبب ضعفها في مواجهة الاختلالات الاقتصادية التي حدثت في السبعينات (مثل أزمة البترول، العجز المالي، ...)، بحيث يؤدي إلى عدم صلاحية التنبؤات، الأمر الذي أدى إلى إعادة صياغة وتقدير هذه النماذج. وتم انتقادها بشكل حاد من قبل سيمس (Sims-1980)، والذي طور نماذج VAR.

1. شكل نموذج شعاع الانحدار الذاتي VAR:

نموذج VAR هو عبارة عن نظام معادلات يضم عدة متغيرات، كل متغير هو عبارة عن دالة خطية لقيمه الماضية والقيم الماضية لمتغيرات أخرى، بالإضافة إلى القيم العشوائية (حد الخطأ).

شعاع (أو متجه) الانحدار الذاتي (Vector AutoRegressive) من الدرجة p (درجة الإبطاء)، ونرمز له VAR(p)، يكتب على شكل نظام المعادلات التالي:

$$Y_t = A_0 + A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + \varepsilon_t$$

$$\text{حيث: } Y_t = \begin{pmatrix} Y_{1t} \\ Y_{2t} \\ \vdots \\ Y_{kt} \end{pmatrix} \text{ هو شعاع المتغيرات. } A_0 = \begin{pmatrix} a_1^0 \\ a_2^0 \\ \vdots \\ a_k^0 \end{pmatrix} \text{ هو شعاع الثوابت.}$$

$$A_i = \begin{pmatrix} a_{1i}^1 & a_{1i}^2 & \dots & a_{1i}^k \\ a_{2i}^1 & a_{2i}^2 & \vdots & a_{2i}^k \\ \vdots & \vdots & \dots & \vdots \\ a_{ki}^1 & a_{ki}^2 & \dots & a_{ki}^k \end{pmatrix} \text{ هي مصفوفة المعلمات (مصفوفة مربع من الدرجة k).}$$

$$\varepsilon_t = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \\ \vdots \\ \varepsilon_{kt} \end{pmatrix} \text{ الحد العشوائي (حد الخطأ)}$$

t الزمن (t = 1, 2, ..., n). عدد المشاهدات (حجم العينة). k عدد المتغيرات في النموذج.

$$\Sigma_\varepsilon = E(\varepsilon_t \varepsilon_t') \text{ هو مصفوفة التباين-التباين المشترك للأخطاء (من الدرجة k*k).}$$

يمكن تعميم نماذج VAR لتحتوي على أخطاء مترابطة ذاتية من الدرجة q، كتعميم نماذج AR إلى نماذج ARMA،

وتسمى في هذه الحالة بنماذج VARMA(p,q) أو ARMAX، وتكتب على الشكل التالي:

$$Y_t = A_0 + A_1 Y_{t-1} + \dots + A_p Y_{t-p} + B_1 \varepsilon_{t-1} + \dots + B_q \varepsilon_{t-q} + \varepsilon_t$$

ومن خصائص نموذج VAR، أنه لا يتم التمييز بين المتغيرات التابعة والمتغيرات المفسرة، كما أن التنبؤ باستخدام نماذج VAR أحسن من تلك التي يتحصل عليها من المعادلات الأنية.

دروس في مقياس طرق التنبؤ

مثال: VAR(1) بتغيرين: $Y_t = A_0 + A_1 Y_{t-1} + \varepsilon_t$.

$$\begin{pmatrix} Y_{1t} \\ Y_{2t} \end{pmatrix} = \begin{pmatrix} a_{10} \\ a_{20} \end{pmatrix} + \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} Y_{1t-1} \\ Y_{2t-1} \end{pmatrix} + \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{pmatrix}$$

أو يكتب:

$$\begin{cases} Y_{1t} = a_{10} + a_{11} Y_{1t-1} + a_{12} Y_{2t-1} + \varepsilon_{1t} \\ Y_{2t} = a_{20} + a_{21} Y_{1t-1} + a_{22} Y_{2t-1} + \varepsilon_{2t} \end{cases}$$

2. تقدير نموذج شعاع الانحدار الذاتي VAR:

لتقدير نموذج VAR، يمكن تقدير كل معادلة من معادلات النظام بطريقة المربعات الصغرى العادية (أو بطريقة المعقولة العظمى) بشكل مستقل. النموذج المقدر يكتب على الشكل التالي:

$$\hat{Y}_t = \hat{A}_0 + \hat{A}_1 Y_{t-1} + \hat{A}_2 Y_{t-2} + \dots + \hat{A}_p Y_{t-p}$$

بما أن المعادلات السابقة هي انحدارات OLS، فإن نتائج الانحدار يمكن تفسيرها بالشكل التقليدي العادي. بالطبع مع وجود العديد من قيم نفس المتغيرات في فترات زمنية متأخرة، فإن كل معامل مقدر لن يكون معنويا احصائيا، وذلك محتمل بسبب مشكلة الارتباط المتعدد. ولكن بشكل تجميحي، فإنها جميعا قد تكون معنوية معا على أساس قيمة اختبار F القياسي.

ملاحظة: لا يمكن تقدير معاملات هذا النموذج انطلاقا من سلاسل غير مستقرة. إذن يجب جعل كل السلاسل مستقرة بحساب الفروقات من الدرجة d في حالة اتجاه عام عشوائي، أو إضافة مركبة الاتجاه العام إلى صيغة النموذج VAR في حالة اتجاه عام ثابت.

3. تحديد درجة الإبطاء المثلى لنموذج VAR:

لتحديد درجة الإبطاء المثلى لنموذج VAR نستخدم معايير المعلومات، فطريقة اختيار الدرجة تكمن في تقدير كل معادلات النموذج من أجل عدة درجات (من 1 إلى p)، ويفضل أن لا تزيد p عن أربع درجات لتجنب فقدان الكثير من درجة الحرية. نستعمل مثلا المعايير الثلاثة المشهورة: Akaike، Schwarz، و Hannan-Quin. نختار التباطؤ الأمثل وذلك بتصغير المعايير الثلاثة.

4. دراسة استقرارية نموذج VAR:

يمكن كتابة النظام السابق على الشكل:

$$(I - A_1 L - A_2 L^2 - \dots - A_p L^p) Y_t = A_0 + \varepsilon_t$$

$$\Rightarrow A(L) Y_t = A_0 + \varepsilon_t$$

تكون السيروية السابقة VAR(p) مستقرة إذا كانت جميع جذور كثير الحدود المعرف انطلاقا من محدد المصفوفة $|I - A_1 L - A_2 L^2 - \dots - A_p L^p| = 0$ تقع خارج الدائرة الوحدةية (أكبر من 1 بالقيمة المطلقة) (فيكون بذلك مقلوب الجذور داخل الدائرة الوحدةية).

مثال: ليكن VAR(1) التالي:

$$\begin{pmatrix} X_t \\ Y_t \end{pmatrix} = \begin{pmatrix} 1 \\ 2 \end{pmatrix} + \begin{pmatrix} 0,2 & 0,1 \\ 0,3 & 0,2 \end{pmatrix} \begin{pmatrix} X_{t-1} \\ Y_{t-1} \end{pmatrix} + \begin{pmatrix} \hat{\varepsilon}_{1t} \\ \hat{\varepsilon}_{2t} \end{pmatrix}$$

يمكن كتابة النظام السابق على الشكل:

دروس في مقياس طرق التنبؤ

$$(I - A_1L)Y_t = A_0 + \varepsilon_t \Rightarrow A(L)Y_t = A_0 + \varepsilon_t$$

$$|I - A_1L| = \begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix} - \begin{vmatrix} 0,2L & 0,1L \\ 0,3L & 0,2L \end{vmatrix} = \begin{vmatrix} 1 - 0,2L & -0,1L \\ -0,3L & 1 - 0,2L \end{vmatrix} = 0$$

$$\Rightarrow (1 - 0,2L)^2 - (-0,3L)(-0,1L) = 1 + 0,04L^2 - 0,4L - 0,03L^2 = 0$$

$$\Rightarrow 0,01L^2 - 0,4L + 1 = 0$$

$$\Delta = (0,4)^2 - 4(0,01)(1) = 0,16 - 0,04 = 0,12$$

$$\Rightarrow \begin{cases} L_1 = \frac{0,4 - 0,346}{0,02} = 2,7 \\ L_2 = \frac{0,4 + 0,346}{0,02} = 37,3 \end{cases}$$

بما أن جميع جذور كثير الحدود المعرف انطلاقا من محدد المصفوفة $|I - A_1L| = 0$ خارج الدائرة الوحدةية (مقلوبها داخل الدائرة الوحدةية)، فإن السيورة السابقة VAR(1) مستقرة.

5. التنبؤ باستخدام نموذج VAR:

بعد اختيار أفضل درجة إبطاء للنموذج، نقوم بتقديره، ثم نعلم عليه للقيام بعملية التنبؤ.

فلتكن درجة الإبطاء 1 هي المثلى، بعد تقدير نموذج VAR(1) $(\hat{Y}_t = \hat{A}_0 + \hat{A}_1 Y_{t-1})$ ، نعلم عليه للتنبؤ.

التنبؤ في الفترة n من أجل الفترة n+1، كما يلي: $\hat{Y}_n(1) = \hat{A}_0 + \hat{A}_1 Y_n$

التنبؤ في الفترة n من أجل الفترة n+2، كما يلي: $\hat{Y}_n(2) = \hat{A}_0 + \hat{A}_1 \hat{Y}_n(1) = \hat{A}_0(I + \hat{A}_1) + \hat{A}_1^2 Y_n$

.....

التنبؤ في الفترة n من أجل الفترة n+h، كما يلي: $\hat{Y}_n(h) = \hat{A}_0(I + \hat{A}_1 + \hat{A}_1^2 + \dots + \hat{A}_1^{h-1}) + \hat{A}_1^h Y_n$

ملاحظة: عندما يؤول h إلى ما لانهاية، فإن قيمة التنبؤ تؤول إلى قيمة ثابتة (حالة مستقرة)، لأن \hat{A}_1^h يؤول إلى 0.

6. مثال تطبيقي شامل لنموذج VAR على برنامج إفيوز:

ليكن المثال التطبيقي هو دراسة أثر عنصري العمل (اليد العاملة L) ورأس المال (k) على النمو الاقتصادي (مقاس بمؤشر

الناتج المحلي الخام GDP) في الجزائر، خلال الفترة الممتدة من سنة 1970 إلى سنة 2018.

❖ تقدير نموذج VAR:

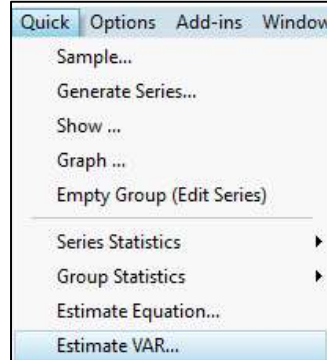
نتبع على برنامج إفيوز نفس الخطوات المطبقة على المثال التطبيقي لنموذج الانحدار الخطي المتعدد أعلاه، لفتح ملف عمل،

ولإدخال بيانات الدراسة.

لتقدير نموذج VAR:

• نضغط على Quick ثم Estimate VAR:

دروس في مقياس طرق التنبؤ



- فتظهر لنا النافذة التالية، نختار منها:
 - نوع نموذج VAR: نختار Standard VAR.
 - عينة التقدير: نحدد 1970-2018.
 - المتغيرات الداخلية: نحدد جميع المتغيرات (K, L, GDP).
 - المتغيرات الخارجية: الثابت C والاتجاه العام (@trend) (وذلك لأن للسلاسل الزمنية المدروسة إتجاه عام).
 - درجة الإبطاء: نختار مبدئيا درجة إبطاء واحدة فقط (VAR(1)). ثم نضغط على OK، فتظهر لنا مخرجات التقدير التالية (نموذج VAR(1):

Vector Autoregression Estimates			
Vector Autoregression Estimates			
Date: 12/15/22 Time: 18:29			
Sample (adjusted): 1971 2018			
Included observations: 48 after adjustments			
Standard errors in () & t-statistics in []			
	GDP	L	K
GDP(-1)	0.643949 (0.12177) [5.28818]	2.90E-07 (6.5E-08) [4.45960]	0.342758 (0.04570) [7.50034]
L(-1)	870474.6 (259378.) [3.35601]	0.374906 (0.13830) [2.71089]	230263.5 (97340.9) [2.36554]
K(-1)	-0.029075 (0.01644) [-1.76847]	-1.56E-08 (8.8E-09) [-1.77576]	1.003244 (0.00617) [162.603]
C	-1.14E+12 (3.5E+11) [-3.27005]	822292.0 (186508.) [4.40888]	-1.87E+11 (1.3E+11) [-1.42733]
@TREND	-7.10E+10 (3.1E+10) [-2.29364]	78779.54 (16502.5) [4.77379]	-6.63E+10 (1.2E+10) [-5.70837]

VAR Specification	
Basics	VAR Restrictions
VAR type	Standard VAR
Endogenous variables	gdp l k
Estimation sample	1970 2018
Lag Intervals for Endogenous:	1 1
Exogenous variables	c @trend
OK Annuler	

- الآن، نبحث عن أفضل درجة إبطاء لنموذج VAR، بالاعتماد على معايير المعلومات.
- نضغط على View ثم Lag Structure ثم Lag Length Criteria، فيطلب منا تحديد درجة الإبطاء القصوى (نختار مثلا 4):

دروس في مقياس طرق التنبؤ

- فيظهر لنا الجدول التالي، والذي يبين أن أفضل إبطاء حسب أغلب المعايير هو $p = 4$.

Lag	LogL	LR	FPE	AIC	SC	HQ
0	-3302.611	NA	1.46e+60	147.0494	147.2902	147.1392
1	-3087.693	382.0761	1.56e+56	137.8975	138.4997*	138.1220
2	-3071.055	27.35951	1.12e+56	137.5580	138.5216	137.9172
3	-3053.668	26.27423	7.84e+55	137.1852	138.5101	137.6791
4	-3039.341	19.73929*	6.40e+55*	136.9485*	138.6347	137.5771*

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

- تقدير النموذج $VAR(4)$ ، موضح في الجدول التالي:

دروس في مقياس طرق التنبؤ

Vector Autoregression Estimates			
Date: 12/15/22 Time: 18:33			
Sample (adjusted): 1974 2018			
Included observations: 45 after adjustments			
Standard errors in () & t-statistics in []			
	GDP	L	K
GDP(-1)	0.429073 (0.22380) [1.91725]	1.61E-07 (1.2E-07) [1.39606]	0.098361 (0.07545) [1.30363]
GDP(-2)	-0.319821 (0.19809) [-1.61456]	1.99E-08 (1.0E-07) [0.19420]	0.038396 (0.06678) [0.57497]
GDP(-3)	-0.351904 (0.21586) [-1.63025]	-2.80E-07 (1.1E-07) [-2.50864]	-0.000708 (0.07278) [-0.00973]
GDP(-4)	-0.246789 (0.26244) [-0.94035]	-1.09E-07 (1.4E-07) [-0.80228]	-0.086088 (0.08848) [-0.97307]
L(-1)	809419.3 (339356.) [2.38516]	0.025554 (0.17529) [0.14578]	62022.71 (114411.) [0.54210]
L(-2)	538734.3 (344941.) [1.56181]	0.139467 (0.17818) [0.78274]	141649.5 (116294.) [1.21803]
L(-3)	-426871.3 (340521.) [-1.25358]	0.087925 (0.17590) [0.49987]	176374.7 (114804.) [1.53631]
L(-4)	433773.8 (327017.) [1.32646]	0.336888 (0.16892) [1.99317]	-39077.51 (110251.) [-0.35444]
K(-1)	0.899261 (0.84316) [1.06654]	5.13E-07 (4.4E-07) [1.17858]	1.822517 (0.28426) [6.41134]
K(-2)	-1.143516 (1.50024) [-0.76222]	1.03E-08 (7.7E-07) [0.01330]	-1.242933 (0.50580) [-2.45738]
K(-3)	1.723101 (1.40596) [1.22557]	-8.38E-07 (7.3E-07) [-1.15354]	0.592126 (0.47401) [1.24919]
K(-4)	-1.555791 (0.69650) [-2.23372]	3.01E-07 (3.6E-07) [0.83678]	-0.174709 (0.23482) [-0.74401]
C	-2.13E+12 (5.9E+11) [-3.58721]	449337.7 (306920.) [1.46402]	-3.32E+11 (2.0E+11) [-1.65790]
@TREND	-1.37E+10 (7.9E+10) [-0.17466]	100964.2 (40652.7) [2.48358]	-5.34E+10 (2.7E+10) [-2.01164]
R-squared	0.990997	0.996814	0.999935
Adj. R-squared	0.987221	0.995479	0.999908
Sum sq. resid	4.15E+24	1.11E+12	4.72E+23
S.E. equation	3.66E+11	189044.4	1.23E+11
F-statistic	262.4709	746.1945	36746.31
Log likelihood	-1253.629	-802.2052	-1204.703
Akaike AIC	56.33908	27.38890	54.16458
Schwarz SC	56.90116	27.94897	54.72666
Mean dependent	4.70E+12	6177208.	1.57E+13
S.D. dependent	3.24E+12	2811435.	1.29E+13

• من خلال مخرجات إيفوز السابقة، يمكننا كتابة نموذج VAR(4) على الشكل التالي:

$$GDP = 0.43*GDP(-1) - 0.32*GDP(-2) - 0.36*GDP(-3) - 0.25*GDP(-4) + 809419*L(-1) + 538734*L(-2) - 426871*L(-3) + 433773*L(-4) + 0.90*K(-1) - 1.14*K(-2) + 1.72*K(-3) - 1.56*K(-4) - 2.13e+12 - 13746049267*@TREND$$

$$L = 1.61e-07*GDP(-1) + 1.99e-08*GDP(-2) - 2.80e-07*GDP(-3) - 1.09e-07*GDP(-4) + 0.03*L(-1) + 0.14*L(-2) + 0.09*L(-3) + 0.34*L(-4) + 5.13e-07*K(-1) + 1.03e-08*K(-2) - 8.38e-07*K(-3) + 3.01e-07*K(-4) + 449337 + 100964*@TREND$$

$$K = 0.10*GDP(-1) + 0.04*GDP(-2) - 0.0007*GDP(-3) - 0.09*GDP(-4) + 62022*L(-1) + 141649*L(-2) + 176374*L(-3) - 39077*L(-4) + 1.82*K(-1) - 1.24*K(-2) + 0.59*K(-3) - 0.17*K(-4) - 332111096692 - 53375473379*@TREND$$

$$R^2(1)=0.990997$$

$$R^2(2)=0.996814$$

$$R^2(3)=0.999935$$

$$F(1)=262.4709$$

$$F(2)=746.1945$$

$$F(3)=36746.31$$

دروس في مقياس طرق التنبؤ

- يمكن كذلك تقدير كل معادلة لوحدها بطريقة OLS، المعادلة الأولى مثلا:

Dependent Variable: GDP				
Method: Least Squares				
Date: 12/15/22 Time: 18:57				
Sample (adjusted): 1974 2018				
Included observations: 45 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
GDP(-1)	0.429073	0.223796	1.917249	0.0645
GDP(-2)	-0.319821	0.198086	-1.614558	0.1165
GDP(-3)	-0.351904	0.215859	-1.630247	0.1132
GDP(-4)	-0.246789	0.262442	-0.940353	0.3543
L(-1)	809419.3	339355.8	2.385164	0.0234
L(-2)	538734.3	344941.3	1.561815	0.1285
L(-3)	-426871.3	340521.1	-1.253582	0.2194
L(-4)	433773.8	327016.8	1.326457	0.1944
K(-1)	0.899261	0.843159	1.066539	0.2944
K(-2)	-1.143516	1.500244	-0.762220	0.4517
K(-3)	1.723101	1.405955	1.225574	0.2296
K(-4)	-1.555791	0.696502	-2.233721	0.0329
C	-2.13E+12	5.94E+11	-3.587209	0.0011
@TREND	-1.37E+10	7.87E+10	-0.174663	0.8625
R-squared	0.990997	Mean dependent var	4.70E+12	
Adjusted R-squared	0.987221	S.D. dependent var	3.24E+12	
S.E. of regression	3.66E+11	Akaike info criterion	56.33908	
Sum squared resid	4.15E+24	Schwarz criterion	56.90116	
Log likelihood	-1253.629	Hannan-Quinn criter.	56.54862	
F-statistic	262.4709	Durbin-Watson stat	1.844983	
Prob(F-statistic)	0.000000			

❖ استقرارية ومعنوية النموذج:


- المعنوية: يتبين من إحصائيات فيشر للمعادلات الثلاثة لنموذج VAR المقدر أن الانحدارات الثلاث بشكل عام معنوية ((F(1)= 262.4709, F(2)= 746.1945 , F(3)= 36746.31).
- الاستقرارية: يكون النموذج VAR(4) مستقر عندما تكون جميع جذور كثير الحدود المعرف انطلاقا من محدد المصفوفة $|I - A_1L - A_2L^2 - A_3L^3 - A_4L^4| = 0$ خارج الدائرة الوحدةية (أكبر من 1 بالقيمة المطلقة)، فيكون مقلوب الجذور داخل الدائرة الوحدةية.

– على برنامج إفيوز لدراسة استقرارية نموذج VAR المقدر، وفي نافذة التقدير، نضغط على View ثم Lag Structure، ثم AR Roots Table (و AR Roots Graph).

View	Proc	Object	Print	Name	Freeze	Estimate	Forecast	Stats	Impulse	Resids
Representations										
Estimation Output										
Simulation...										
Residuals										
Structural Residuals										
Endogenous Table										
Endogenous Graph										
Lag Structure										
Residual Tests										

– فيظهر لنا الجدول والدائرة الوحدةية التاليين:

دروس في مقياس طرق التنبؤ



— يتبين أن جميع مقلوب الجذور تقع داخل الدائرة الوحديوية، وهذا يدل على استقرار نموذج VAR(4) المقدر.

❖ التنبؤ بقيم الناتج المحلي الخام GDP والعمل L ورأس المال K:

نعمد على النموذج VAR(4)، المقدر أعلاه للتنبؤ بالمؤشرات الثلاث للسنوات 2019-2023.

مثلا القيم المتنبى بها لمتغير GDP للسنة 2019 هي (قيمة تقريبية): $\widehat{GDP}_{2019} = 10\ 406\ 055\ 277\ 014$.

	القيمة	المعلمة	الجداء
GDP(-1)	10 044 471 589 448	0,429073	4 309 811 558 299
GDP(-2)	10 031 390 598 335	-0,319821	-3 208 249 372 550
GDP(-3)	9 577 953 184 540	-0,351904	-3 370 520 037 452
GDP(-4)	9 610 136 113 524	-0,246789	-2 371 675 881 320
L(-1)	10 808 270	809419,3	8 748 422 337 611
L(-2)	10 656 083	538734,3	5 740 797 415 747
L(-3)	10 845 000	-426871,3	-4 629 419 248 500
L(-4)	10 594 000	433773,8	4 595 399 637 200
K(-1)	49 181 757 436 009	0,899261	44 227 236 373 663
K(-2)	46 518 253 097 262	-1,143516	-53 194 366 708 769
K(-3)	44 067 765 377 079	1,723101	75 933 210 589 010
K(-4)	41 285 038 534 048	-1,555791	-64 230 891 385 925
C			-2,13E+12
Trend			-1,37E+10
التنبؤ GDP للسنة 2019			10 406 055 277 014

وللتنبؤ على برنامج إفيوز، وكما أشرنا إلى ذلك أعلاه، نقوم أولاً بتغيير حجم ملف العمل على إفيوز، ثم نقدر النموذج VAR(4)، ثم نضغط على Forecast، فتظهر لنا ثلاث سلاسل جديدة في ملف العمل (GDP_F, L_F, K_F)، وعند فتحها نجد القيم المتنبى بها بالاعتماد على النموذج VAR(4)، كما هو موضح في الجدول التالي:

دروس في مقياس طرق التنبؤ

	GDP_F	L_F	K_F
2019	9744832405298	11011713	51966383304575
2020	9234336030666	11277257	54606835574869
2021	9125735391577	11112293	57032378704372
2022	9135713018863	11111237	59327323140040
2023	8807321078277	11285153	61557141005704

دروس في مقياس طرق التنبؤ

قائمة المراجع:

- 1) أموري هادي كاظم، باسم شليبه مسلم، "المقياس الاقتصادي المتقدم: النظرية والتطبيق"، مطبعة الطيف، بغداد، 2002.
- 2) برى عدنان، ماجد عبد الرحمان، "طرق التنبؤ الإحصائي"، الجزء الأول، جامعة الملك سعود، 2002.
- 3) دامودار جوجارات، "الاقتصاد القياسي"، تعريب هند عبد الغفار عودة، دار المريخ للنشر، الرياض، المملكة العربية السعودية، الجزء الثاني، 2015.
- 4) حسين علي بحيت، سحر فتح الله، "الاقتصاد القياسي"، دار اليازوري العلمية للنشر والتوزيع، عمان، الأردن، 2007.
- 5) حشمان مولود، "السلاسل الزمنية وتقنيات التنبؤ القصيرة المدى"، ديوان المطبوعات الجامعية، الطبعة الثالثة، الجزائر، 2010.
- 6) شيخي محمد، "طرق الاقتصاد القياسي: محاضرات وتطبيقات"، دار الحامد، الطبعة 1، 2011.
- 7) Christopher A. Sims, «Macroeconomics and Reality», *Econometrica*, Vol. 48, No. 1 (Jan., 1980).
- 8) Régis Bourbonnais, « Économétrie », DUNOD, 10ème édition, Paris, 2018.
- 9) J. Johnston, « Méthodes économétriques », traduit par Bernard Guerrien, Tome2, Enonomica, Paris, 1990.
- 10) موقع البنك الدولي (<https://data.albankaldawli.org/country/DZ>)