

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي
جامعة الشهيد حمه لخضر - الوادي -
كلية العلوم الاقتصادية والتجارية وعلوم التسيير
قسم العلوم الاقتصادية

محاضرات في مقياس السلاسل الزمنية
لطلبة السنة أولى ماستر إقتصاد كمي

إعداد :
د . عطاالله عمر
أستاذ محاضر صنف أ

الموسم الجامعي 2022 / 2023

الفهرس

الصفحة	العنوان
01	الفصل التمهيدي :مراجعة حول معادلات الفرق
08	الفصل الثاني :مفاهيم عامة حول السلاسل الزمنية
08	1- مفهوم السلسلة الزمنية
11	2- مركبات السلسلة الزمنية
13	3- نماذج مركبات السلسلة الزمنية
16	4- السيرورة العشوائية
34	الفصل الثالث : السيرورات الخطية للسلاسل الزمنية المستقرة
34	1- خصائص معامل التأخير
35	2- السيرورة الخطية
42	3- قابلية العكس للسيرورة $MA(q)$
51	4- سببية $AR(p)$ في ما لا نهاية لتمثيل $MA(q)$
54	5- السيرورة الخطية الموسمية
56	6- السيرورة الخطية الغير موسمية و الموسمية في نفس الوقت
58	الفصل الرابع : السيرورات الخطية للسلاسل الزمنية الغير مستقرة ARIMA
58	1- السيرورة $TS(trend stationary)$
59	2- السيرورة $DS(differency stationary)$
62	الفصل الخامس : إختبارات جذر الوحدة
62	1- إختبار ديكي فولر Dicky Fuller
66	2- إختبار ديكي فولر المطور Augmented Dicky Fuller
70	3- تحديد درجة التأخير
74	4- إختبار ديكي فليبيس بيرون Phillips Peron

77	5- إختبار KPSS 1992
79	الفصل الخامس : السيرورات المختلطة الغير مستقرة
79	1- السيرورة ARMA(p, q) غير المستقرة (نماذج ARIMA)
84	2- السيرورة ARIMA(P, D, Q) الموسمية (السيرورة ARMA(P, Q) الموسمية الغير مستقرة)
84	3- السيرورة ARIMA الموسمية والغير موسمية في نفس الوقت
86	الفصل السادس : منهجية بوكس-جينكيز .
88	1- الخطوة الأولى : التحويل
89	2- الخطوة الثانية : التعرف
92	3- الخطوة الثالثة : التقدير
95	4- الخطوة الرابعة : الفحص:
99	5- الخطوة الخامسة : التنبؤ
102	الفصل السابع : نماذج أشعة الإنحدار الذاتي للسلاسل الزمنية متعددة المتغيرات (VAR)
102	1- الصياغة العامة لنموذج VAR
105	2- طريقة التقدير نموذج VAR
106	3- طريقة تحديد رتبة نموذج VAR:

الفصل التمهيدي :مراجعة حول معادلات الفرق:

تعتبر معادلات الفرق من الأولى حيث X_t و Y_t يشيران إلى اتجاه المبيعات اليومية للمتجات الخاصة باليوم t وصدمة المبيعات الغير متوقعة في نفس اليوم على التوالي أو التسلسل.

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

حيث ε_t تمثل الصدمة.

بعد K يوم يمكن أن يصبح حجم المبيعات كالتالي :

$$Y_{t+1} = \varphi Y_t + \varepsilon_{t+1} = \varphi(\varphi Y_{t-1} + \varepsilon_t) + \varepsilon_{t+1} = \varphi^2 Y_{t-1} + \varphi \varepsilon_{t-1} + \varepsilon_{t+1}$$

$$Y_{t+2} = \varphi Y_{t+1} + \varepsilon_{t+2} = \varphi(\varphi Y_t + \varepsilon_{t+1}) + \varepsilon_{t+2}$$

$$= \varphi^2 Y_t + \varphi \varepsilon_{t+1} + \varepsilon_{t+2}$$

$$= \varphi^2(\varphi Y_{t-1} + \varepsilon_t) + \varphi \varepsilon_{t+1} + \varepsilon_{t+2}$$

$$= \varphi^3 Y_{t-1} + \varphi^2 \varepsilon_t + \varphi \varepsilon_{t+1} + \varepsilon_{t+2}$$

$$Y_{t+k} = \varphi^{k+1} Y_{t-1} + (\varphi^k \varepsilon_t + \varphi^{k-1} \varepsilon_{t-1} + \varphi^{k-2} \varepsilon_{t-2} \dots \dots \dots + \varepsilon_{t+k})$$

نعتبر الكمية التالية الخاصة بالمعادلة التالية:

$$\frac{dY_{t+k}}{d\varepsilon_t}$$

نسمي φ^k كمضاعف ديناميكي، بعبارة أخرى، أي تغيير وحدة واحدة يوميا لصدمة المبيعات يؤثر على مبيعات المتجات بعد k يوم بقدر φ^k .

نلاحظ أن حجم المبيعات φ^k لا يعتمد على تاريخ معين (محدد) والمضاعف الديناميكي يخبرنا مدى تأثير $d\varepsilon_t$ لمساهمة الإستجابة في المستقبل لـ dY_{t+k} ويسمى

$$\text{كذلك دالة الاستجابة النبضية} \quad \frac{dY_{t+k}}{d\varepsilon_t} = \varphi^k$$

إنمادا على القيم المختلفة للقاعدة φ للمضاعف الديناميكي φ^k نستنتج السلوك التالي للسلسلة المعطاة:

- يعنى السلسلة المستقرة ،تأثير الماضي البعيد على الوضع الحالي $|\varphi| < 1$.
- يكون المعامل أكثر تأثير على المستقبل ،حيث يحدث إنفجار $|\varphi| > 1$.
- يعنى أن الماضي البعيد مهم للتنبؤ بالمستقبل $|\varphi| = 1$.

$$Y_{t+k} = \varphi Y_{t-1} + \varepsilon_t + \varepsilon_{t+1} + \varepsilon_{t+2} + \dots + \varepsilon_{t+k}.$$

معادلة الفرق من الدرجة p يكون شكلها كما يلي:

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t.$$

هذه معادلة خطية بدرجة فرق p ،ويمكن كتابة هذه المعادلة على شكل شعاع Y_t

$$.Y_t = \begin{pmatrix} y_t \\ y_{t-1} \\ \vdots \\ y_{t-p+1} \end{pmatrix} \langle p \times 1 \rangle$$
 معرف بـ

أو عنصر في هذا الشعاع هو y_t أي في الفترة t وثاني عنصر هو y_{t-1} في الفترة $t-1$ وكذلك المصفوفة F ذو الدرجة $(p \times p)$ والتي هي:

$$F = \begin{bmatrix} \varphi_1 & \varphi_2 & \varphi_3 & \dots & \varphi_{p-1} & \varphi_p \\ 1 & 0 & 0 & \dots & 0 & 0 \\ 0 & 1 & 0 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & 1 & 0 \end{bmatrix}$$

على سبيل المثال $p = 4$ تشير الى مصفوفة ذو درجة (4×4)

$$F = \begin{bmatrix} \varphi_1 & \varphi_2 & \varphi_3 & \varphi_4 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

وكذلك إذا كان $p = 1$ فإن قيمة $F = \emptyset$.

كذلك نعرف الشعاع W_t ذو درجة $(p \times 1)$ كما يلي:

$$W_t = \begin{bmatrix} \varepsilon_t \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

لنعتبر معاداة الفرق لشعاع بدرجة فرق أولى :

$$Y_t = FY_{t-1} + W_t$$

$$\begin{bmatrix} y_t \\ y_{t-1} \\ y_{t-2} \\ \vdots \\ y_{t-p+1} \end{bmatrix} = \begin{bmatrix} \varphi_1 & \varphi_2 & \varphi_3 & \cdots & \varphi_{p-1} & \varphi_p \\ 1 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 1 & 0 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & 1 & 0 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ y_{t-2} \\ y_{t-3} \\ \vdots \\ y_{t-p} \end{bmatrix} = \begin{bmatrix} \varepsilon_t \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

هذا النظام يتكون من p ، وأول هذه المعاداة هي :

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \cdots + \varphi_p y_{t-p} + \varepsilon_t.$$

والمعاداة الثانية هي :

$$y_{t-1} = y_{t-1}$$

والمعاداة رقم p هي :

$$y_{t-p+1} = y_{t-p+1}$$

ولهذا يمكن كتابة Y_t بدلالة Y_{t-p} ومجموع حدود الخطأ العشوائي

$$Y_t = FY_{t-1} + W_t$$

وكذلك :

$$Y_{t-1} = FY_{t-2} + W_{t-1}$$

ومنه :

$$\begin{aligned} Y_t &= F(FY_{t-2} + W_{t-1}) + W_t \\ &= F^2 Y_{t-2} + FW_{t-1} + W_t \\ &= F^2 (FY_{t-3} + W_{t-2}) + FW_{t-1} + W_t \\ &= F^3 Y_{t-3} + F^2 W_{t-2} + FW_{t-1} + W_t = F^p Y_{t-p} + \sum_{i=0}^{p-1} F^i W_{t-i} \end{aligned}$$

معامله التأخير (lag operator):

ليكن Y_t سلسلة غير منتهية من الأحداث ونقسم المشاهدات إلى $\{y_0, y_1, \dots, y_t\}$ ونسميها سلسلة زمنية.

بالنسبة لسلسلة زمنية، يمكننا تطبيق معامل التأخير B الذي يكتب على الصيغة التالية :

$$* BY_t = Y_{t-1}.$$

$$* B(BY_t) = B^2Y_t = BY_{t-1} = BY_{t-2}.$$

$$* B^4Y_t = Y_{t-4}.$$

$$* B^kY_t = Y_{t-k}.$$

$$* B^{-2}Y_t = Y_{t+2} \quad (\text{lead operator}).$$

$$* B^0Y_t = Y_t.$$

$$* B^iB^jY_t = B^{i+j}Y_t = Y_{t-(i+j)}.$$

$$* (B^i + B^j)Y_t = B^iY_t + B^jY_t = Y_{t-i} + Y_{t-j}.$$

$$* \Delta Y_t = Y_t - Y_{t-1} = Y_t - BY_t = (1 - B)Y_t.$$

$$\begin{aligned} * \Delta Y_t &= \Delta \Delta Y_t = \Delta(\Delta Y_t) = \Delta(Y_t - Y_{t-1}) = \Delta Y_t - \Delta Y_{t-1} \\ &= Y_t - Y_{t-1} - (Y_{t-1} - Y_{t-2}) \\ &= Y_t - 2Y_{t-1} + Y_{t-2}. \end{aligned}$$

يمكن تطبيق معامل التأخير B على معادلات مختلفة :

$$.B^2Y_t = B(BY_t) = Y_{t-2}$$

$$* (a + bB)BY_t = aY_t + bB^2Y_t = aY_t + bY_{t-2}.$$

$$\begin{aligned} * (1 - aB)(1 - bB)Y_t &= (1 - aB - bB + abB^2) \\ &= Y_t - aBY_t - bBY_t + abB^2Y_t \\ &= Y_t - (a + b)Y_{t-1} + abB^2Y_t \\ &= Y_t - (a + b)Y_{t-1} + abBY_{t-2} \end{aligned}$$

حيث a و b .

إستخدام معامل التأخير B نستطيع كتابة معادلة الفرق من الدرجة الأولى :

$$Y_t = \varphi Y_{t-1} + \varepsilon_t \Rightarrow Y_t = \varphi B Y_t + \varepsilon_t$$

$$\Rightarrow Y_t - \varphi B Y_t = \varepsilon_t$$

$$\Rightarrow (1 - \varphi B) Y_t = \varepsilon_t$$

نقوم بضرب هذه المعادلة بالطرف التالي لتصبح كما يلي :

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B) Y_t = (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t) \varepsilon_t$$

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B)$$

$$= (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t) - (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t) \varphi B$$

$$= (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t) - (\varphi B + \varphi^3 B^3 + \dots + \varphi^{t+1} B^{t+1})$$

$$.= 1 - \varphi^{t+1} B^{t+1}$$

ومنه :

$$(1 - \varphi^{t+1} B^{t+1}) Y_t = (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t) \varepsilon_t$$

$$\Rightarrow Y_t = \varphi^{t+1} B^{t+1} Y_t = \varepsilon_t + \varphi B \varepsilon_t + \varphi^2 B^2 \varepsilon_t + \dots + \varphi^t B^t \varepsilon_t$$

$$\Rightarrow Y_t - \varphi^{t+1} Y_{t-(t+1)} = \varepsilon_t + \varphi B \varepsilon_t + \varphi^2 B^2 \varepsilon_t + \dots + \varphi^t B^t \varepsilon_t$$

من المعادلة السابقة لدينا :

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B) = (1 - \varphi^{t+1} B^{t+1})$$

\Leftrightarrow

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B) Y_t = (1 - \varphi^{t+1} B^{t+1}) Y_t$$

\Leftrightarrow

$$.Y_t = Y_t - \varphi^{t+1} Y_{-1}$$

إذا كان $|\varphi| < 1$ فإن $\lim_{t \rightarrow \infty} \varphi^{t+1} Y_{-1}$: ومنه :

$$.(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B) Y_t = (1 - \varphi^{t+1} B^{t+1}) Y_t \cong Y_t$$

من المعادلة السابقة لكي نتحصل على :

$$(1 - \varphi B)^{-1} = \lim_{t \rightarrow \infty} (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)$$

ولدينا خاصية

$$(1 - \varphi B)^{-1}(1 - \varphi B) = 1$$

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B)Y_t \cong Y_t$$

$$\Rightarrow (1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)(1 - \varphi B)^{-1}(1 - \varphi B)Y_t \cong Y_t(1 - \varphi B)^{-1}$$

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t)Y_t \cong Y_t(1 - \varphi B)^{-1}$$

$$(1 + \varphi B + \varphi^2 B^2 + \dots + \varphi^t B^t) = (1 - \varphi B)^{-1}$$

لدينا :

$$(1 - \varphi B)Y_t = \varepsilon_t \Rightarrow (1 - \varphi B)^{-1}(1 - \varphi B)Y_t = (1 - \varphi B)^{-1}\varepsilon_t$$

$$\Rightarrow Y_t = (1 - \varphi B)^{-1}\varepsilon_t = \frac{1}{1 - \varphi B}\varepsilon_t$$

لتكن لدينا معادلة فرق من الدرجة p ، بإستعمال معامل التأخير تصبح المعادلة كما يلي :

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$$

$$\Leftrightarrow Y_t - \varphi_1 Y_{t-1} - \varphi_2 Y_{t-2} - \dots - \varphi_p Y_{t-p} = \varepsilon_t$$

$$\Leftrightarrow Y_t - \varphi_1 B Y_t - \varphi_2 B^2 Y_t - \dots - \varphi_p B^p Y_t = \varepsilon_t$$

$$\Leftrightarrow (\varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p)Y_t = \varepsilon_t$$

مثلا لتكن معادلة الفرق من الدرجة الثانية :

$$(1 - \varphi_1 B - \varphi_2 B^2)Y_t = \varepsilon_t$$

$$(1 - \varphi_1 B - \varphi_2 B^2) = (1 - \lambda_1 B)(1 - \lambda_2 B)$$

$$= (1 - \lambda_1 B - \lambda_2 B + \lambda_1 \lambda_2 B^2)$$

$$= [1 - (\lambda_1 + \lambda_2)B + \lambda_1 \lambda_2 B^2]$$

حيث : $\lambda_1 \lambda_2 = \varphi_2$ و $\lambda_1 + \lambda_2 = \varphi_1$

ليكن المثال التالي :

$$\varphi_1 = 0.6 ; \varphi_2 = -0.08 ; \lambda_1 = 0.4 ; \lambda_2 = 0.2$$

$$(1 - 0.6B + 0.08B^2) = (1 - 0.4B)(1 - 0.6B)$$

$$(1 - \varphi_1 B - \varphi_2 B^2) = 0 \Rightarrow B_1 = \frac{\varphi_1 - \sqrt{\varphi_1^2 - 4\varphi_2}}{-2\varphi_2}$$

$$B_2 = \frac{\varphi_1 + \sqrt{\varphi_1^2 + 4\varphi_2}}{-2\varphi_2}$$

$$B_1 = \frac{0.6 - \sqrt{(0.6)^2 - 4(0.08)}}{-2(-0.08)} = 2.5$$

$$B_2 = \frac{0.6 + \sqrt{(0.6)^2 + 4(-0.08)}}{-2(-0.08)} = 2.5$$

$$\lambda_2 = \frac{1}{B_2} = 0.2 ; \lambda_1 = \frac{1}{B_1} \text{ لأن } \lambda_2 = \frac{1}{5} = 0.2 ; \lambda_1 = \frac{1}{2.5}$$

ومنه نستخلص المبرهنة لحل كثير الحدود من الدرجة p كما يلي :

$$(1 - \varphi_1 B - \varphi_2 B^2 + \dots + \varphi_p B^p) = (1 - \lambda_1 B)(1 - \lambda_2 B) \dots (1 - \lambda_p B)$$

ومنه :

$$(1 - \lambda_1 B)(1 - \lambda_2 B) \dots (1 - \lambda_p B) Y_t = \varepsilon_t$$

$$\Rightarrow Y_t = (1 - \lambda_1 B)^{-1} (1 - \lambda_2 B)^{-2} \dots (1 - \lambda_p B)^{-1} \varepsilon_t$$


الفصل الثاني: مفاهيم عامة حول السلاسل الزمنية :

1- مفهوم السلسلة الزمنية :


السلسلة الزمنية هي سلسلة لمجموعة المشاهدات المتتالية لمتغير (قد يكون متغير إقتصادي، أو متغير مالي أو نوع آخر) لفترات مختلفة t لكن هذه المشاهدات يمكن أن تكون ساعة، يوم، أسبوع، شهر سنة.... الخ، وهذه المشاهدات تحلل بهدف فهم الماضي، بهدف التنبؤ بالمستقبل لمساعدة المسيرين، والسياسات التسويقية، وسياسات إتخاذ القرارات.

السلسلة يمكن أن تكون لها مشاهدات متقطعة $t = 1, 2, 3, \dots$ أو مستمرة $t > 0$.


مثال رقم 1: بيانات فصلية ف1 1960 الى ف4 1980 لشركة أمريكية (إتجاه تصاعدي)




مثال رقم 2: الكلام المسجل لـ عبارة "aaa ... hhh".




مثال رقم 3: أرقام سنوية من 1821-1934 (دورات غير دورية حوالي 10 سنوات) .



مثال رقم 4: أرقام شهرية للخطوط الجوية للمسافرين من 1949-1960 (موسمية مع إتجاه عام).



مثال رقم 4: عوائد بورصة نيويورك من 1984/02/02 - 1991/12/31 (متوسط العائد تقريبا صفر ، ومع ذلك ، يتغير تقلب (أو تقلب) البيانات بمرور الوقت).




من المفيد أن نقوم برسم السلسلة الزمنية على معلم وتكون علي محور (Y) قيمة السلسلة الزمنية وعلى محور (X) الزمن وذلك لمعرفة سلوك وأهم مركبات السلسلة الزمنية.

2- مركبات السلسلة الزمنية :

في العموم السلاسل الزمنية تجزأ إلي أربع مركبات:


- الإتجاه العام .secular trend .
- المركبة الموسمية .seasonal variation .
- المركبة الدورية .cyclical variation .
- المركبة العشوائية .Irregular variation .

2-1 الاتجاه العام : هو النمو الطبيعي للظاهرة، حيث يعبر عن تطور متغير ما عبر الزمن، سواء أكان هذا التطور بميل موجب أو سالب، إلا أن هذا التطور لا يُلاحظ في الفترات القصيرة، بينما يكون واضحا في الفترات الطويلة ويرمز له بالرمز T_t ويعبر عنها رياضيا بـ $Y_t = f(t)$.




2-2 المركبة الموسمية : هي تعبر عن التغيرات والتذبذبات الموسمية أو الفصلية الناتجة عن التغيرات في الفصول بسبب تأثير عوامل خارجية وهي تتم غالبا بطريقة منتظمة، كما أنها تبين تغيير الظاهرة المدروسة في المدى القصير (خلال سنة) مثلا : الإستهلاك المنزلي

للكهرباء خلال 24 ساعة، الإنتاج، الإنتاج الزراعي، إستهلاك نوعا معينا من المشروبات، إنتاج الطاقة الكهربائية.... الخ، ويرمز لها بـ S_t .




2-3 المركبة الدورية : تبين هذه المركبة أثر تطورات النشاط الإقتصادي في المدى الطويل، حيث تتناسب مراحل هذه المركبة مع مراحل الدورة الإقتصادية (ركود، إنتعاش، كساد... الخ) يتراوح عادة بين ثلاث سنوات إلى عشر سنوات، ويرمز لها بالرمز C_t .



4-2 المركبة العشوائية : وهي تعبر عن التغيرات التي يصعب التحكم فيها وضبطها وهي ناتجة عن عوامل غير منتظمة، وبمعنى آخر هي تلك التغيرات الشاذة التي تنجم عن ظروف

طارئة لا يمكن التنبؤ بوقوعها أو تحديد نطاق تأثيرها ،حيث تنشأ عن أسباب عارضة لم تكن في الحسبان مثل : الزلازل ،إضرابات العمال ،ونرمز لها بالرمز ε_t .



ملاحظة : تعتبر مركبتي الإتجاه العام والمركبة الموسمية الأكثر ظهوراً في السلاسل المتعلقة بالدراسات الإقتصادية.

3- نماذج مركبات السلسلة الزمنية :

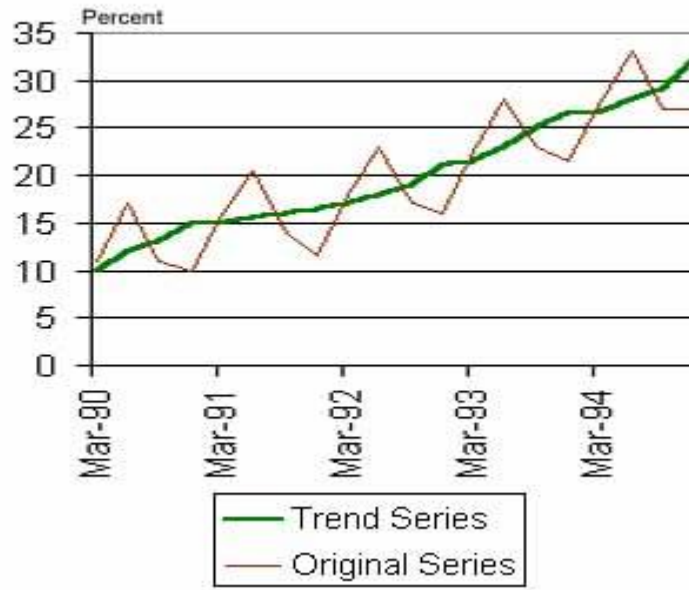
بغرض دراسة السلسلة الزمنية وتحليل مركباتها يجب أولاً بناء نموذج يحدد الصيغة الرياضية للعلاقة بين مركبات السلسلة الزمنية ،وهناك ثلاثة أنواع :

1-3 النموذج التجميعي (The additive model):

$$Y_t = T_t + S_t + C_t + \varepsilon_t.$$

وهذا يعني أن قيمة الظاهرة Y عند الزمن t هي حاصل جمع المركبات الأربع التي تتكون منها السلسلة عند نفس الزمن ،ويكون هذا النموذج مناسباً إذا كانت التذبذبات الموسمية مستقلة عن مستوى الظاهرة مقاساً بالإتجاه العام ،ومن النادر أن تجد سلسلة زمنية فعلية تتبع هذا النموذج.

Series for Which an Additive Model is Appropriate

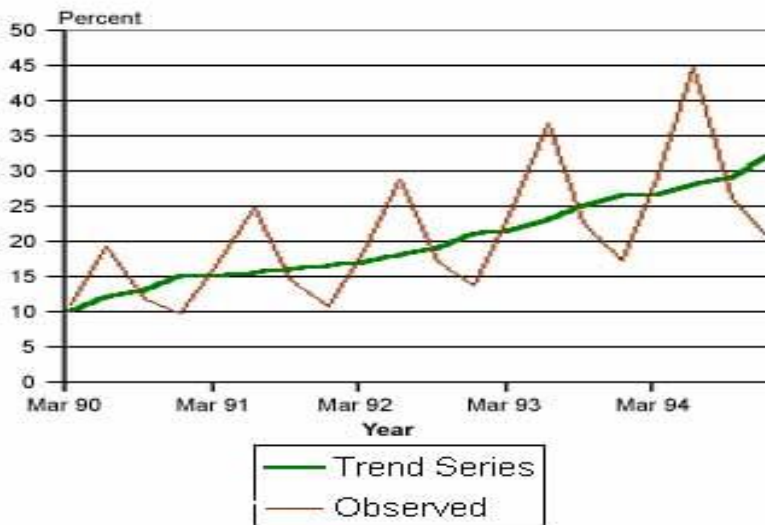


2-3 النموذج الجدائي (The multiplicative model) :

$$Y_t = T_t + S_t + C_t + \varepsilon_t.$$

يعني أن قيمة الظاهرة عند الزمن t هي حاصل ضرب المركبات الأربع التي تتكون منها السلسلة عند نفس الزمن، ويكون هذا النموذج مناسباً إذا كانت التذبذبات الموسمية تتناسب مع مستوى السلسلة مقاساً بالإتجاه، ويعتبر أكثر النماذج المستخدمة في الإقتصاد، لأن لوغاريتم هذا النموذج يؤدي النموذج التجميعي.

Series for Which a Multiplicative Model Appropriate



3-3 النموذج المختلط The mixed model:

وهذا يعني أن إذا كانت T_t و C_t مرتبطان ببعضهما، ولكن مستقلان عن S_t و ε_t فإن النموذج سيكون كما يلي :

$$Y_t = T_t \times C_t + S_t + \varepsilon_t.$$

ملاحظة : القصد من تحديد مركبات السلسلة ونوع نموذج المركبات هو معرفة مدى تأثير كل منها على قيم الظاهرة المدروسة حتى يتسنى لنا عزل هذه الآثار الخارجية وتحديد القيم الحقيقية .

* أشكال دالة الاتجاه العام :

$$T_t = a_0 + a_1 t$$

$$T_t = a_0 + a_1 t + a_2 t^2$$

$$T_t = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n$$

$$T_t = a_0 e^{a_1 t}$$

$$T_t = \frac{1}{1 + a_0 e^{a_1 t}}$$

* الصيغة الرياضية للمركبة الموسمية :

$$S_t = s_0 + s_1 D_t^1 + s_2 D_t^2 + \dots + s_p D_t^p$$

p هي الدورة الموسمية (سنوية $p = 1$ ، شهرية $p = 12$ ، سداسية $p = 2$ ، فصلية $p = 4$ ،.....).

$$D_t^j = \begin{cases} 1, & \text{periodicity } j \\ 0, & \text{otherwise} \end{cases}$$

* كتابة النموذج العام :

$$Y_t = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n + s_1 D_t^1 + s_2 D_t^2 + \dots + s_p D_t^p + \varepsilon_t$$

* النموذج المقدر :

$$\hat{Y}_t = \hat{a}_0 + \hat{a}_1 t + \hat{a}_2 t^2 + \dots + \hat{a}_n t^n + \hat{s}_1 D_t^1 + \hat{s}_2 D_t^2 + \dots + \hat{s}_p D_t^p$$

يمكن التنبؤ بالقيم المستقبلية لـ Y_t من أجل $T + h$ حيث h هو أفق التنبؤ... :

$$\hat{Y}_{T+h} = \hat{a}_0 + \hat{a}_1(T+h) + \hat{a}_2(T+h)^2 + \dots + \hat{a}_n(T+h)^n + \hat{s}_1 D_{T+h}^1 + \hat{s}_2 D_{T+h}^2 + \dots + \hat{s}_p D_{T+h}^p$$

4- السيرورة العشوائية :

السلسلة الزمنية Y_t هي سلسلة المشاهدات مشار إليها بواسطة الزمن .

في كل لحظة t قيمة الكمية المدروسة Y_t تسمى متغير عشوائي .

مجموعة القيم لـ Y_t عندما t يختلف تسمى السيرورة العشوائية ويرمز لها

بالرمز $\{Y_t, t \in Z\}$.

السلسلة الزمنية هي إذن حقيقة أو إدراك لسلسلة عشوائية.

4-1-1 السيرورة العشوائية المستقرة :

يمكن التمييز بين نوعين من السيرورات من حيث الإستقرارية، السيرورة المستقرة عند المستوى القوي والسيرورة المستقرة عند المستوى الضعيف.

4-1-1-1 السيرورة المستقرة عند المستوى القوي Strong Stationary :

نقول أن السيرورة Y مستقرة بصفة قوية إذا كان القاتون الإحتمالي لـ

$\{Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}\}$ هو نفس القانون الإحتمالي لـ $Y_{t_1+h}, Y_{t_2+h}, \dots, Y_{t_n+h}$ لكل

$\{t_1, t_2, \dots, t_n\}$ و $t_i \in \tau$ من أجل $i = 1, 2, \dots, n$ ولكل $h \in \tau$ من أجل $t_{ii+h} \in \tau$

، أيضا السيرورة العشوائية تكون مستقرة تماما إذا ظل توزيع قيمها كما هو مرور الزمن، مما

يعني أن إحتمال أن يقع Y في مجال معين هو نفس الإحتمال كما في أي وقت في الماضي أو

المستقبل.

4-1-2 السيرورة عند المستوى الضعيف Weak Stationary :

السيرورة Y_t حيث $t \in Z$ ، نقول عنها سيرورة مستقرة ذات مستوى ضعيف أو تباين مشترك

مستقر أو درجة ثانية مستقرة إذا تحقق :

- المتوسط $\mu_t = E(Y_t) = E(Y_{t+h}) = \mu$ حيث $\forall t, h \in Z$.
- التباين $var(Y_t) = \sigma_Y^2 = \gamma_0 < \infty$.
- التباين المشترك $cov(Y_t, Y_{t+h}) = \gamma(h) = E[(Y_t - \mu)(Y_{t+h} - \mu)]$ لكل $\forall t, h \in Z$ حيث γ تمثل دالة التباين المشترك لـ Y_t .
- المعادلة الأولى تعنى أن المتوسط للسيرورة يكون ثابت ومستقل عبر الزمن.
- المعادلة الثانية تعنى أن التباين محدود ومستقل عن الزمن.
- المعادلة الثالثة أن التباين المشترك لا يعتمد على الزمن، أي مستقل عن الزمن، وهذا أن التباين المشترك يعتمد على h ويعتمد على الزمن الحالي t .

ملاحظات :

* إذا كانت Y_t مستقلة ولها نفس التوزيع الإحتمالي فإن :

$$\gamma_h = \rho_h \quad \forall h \neq 0.$$

$$\gamma_h = cov(Y_t, Y_{t+h}) = 0 \quad \forall h \neq 0.$$

أي أن (Y_t, Y_{t+h}) مستقلان (أي لا يوجد بينهما إرتباط).

$$\gamma_0 = cov(Y_t, Y_t) = var(Y_t).$$

$$\rho_h = \frac{cov(Y_t, Y_{t+h})}{\sigma_{Y_t} \sigma_{Y_{t+h}}}.$$

إذا $h = 0$ فإن $\rho_h = 1$.

* إذا كانت Y_t تتبع التوزيع الطبيعي فإن السيرورة ذات المستوى الضعيف هي نفسها ذات المستوى القوي .

مثال رقم 5 :

إذا كانت $Y_t = \varepsilon_t$ حيث $\varepsilon_t \sim (0,1)$ من أجل $t \in Z$ ومنه :

$$* E(Y_t) = E(\varepsilon_t) = 0.$$

$$* var(Y_t) = var(\varepsilon_t) = \sigma^2.$$

$$* \gamma_h = E[(\varepsilon_t - E(\varepsilon_t))(\varepsilon_{t+h} - E(\varepsilon_{t+h}))]$$

$$= (\varepsilon_t, \varepsilon_{t+h}) = 0 \quad \forall h \neq 0.$$

من أجل $h = 0$ فإن $\rho_h = 1$.

من خلال هذا المثال نلاحظ أن الشروط الثلاثة عن الزمن، إذن السيرورة ذات مستوى الضعيف .

مثال رقم 6 :

$$Y_t = t + \varepsilon_t.$$

حيث $\varepsilon_t \xrightarrow{iid} (0,1)$.

$$E(Y_t) = E(t + \varepsilon_t) = E(t) + E(\varepsilon_t) = t.$$

والذي هو مرتبط بالزمن وبالتالي السيرورة ليست مستقرة.

$$var(Y_t) = E(t + \varepsilon_t - t) = E(\varepsilon_t) = \sigma^2.$$

$$\gamma_h = E[(t + \varepsilon_t - t)(t + h + \varepsilon_{t+h} - t - h)] = E(\varepsilon_t \varepsilon_{t+h}) = 0 \quad \forall h \neq 0.$$

3-1-4 سيروة التشويش الأبيض White noise process :

سيرورة التشويش الأبيض ε_t مستقرة، أي ذات مستوى ضعيف إذا تحقق مايلي:

$$* E(\varepsilon_t) = 0 \quad \forall t \in Z \quad (\text{غالباً ما يكون المتوسط مساوياً للصفر})$$

$$* var(\varepsilon_t) = \sigma^2 \quad \forall t \in Z \quad \text{التباين متجانس}$$

$$* cov(\varepsilon_t, \varepsilon_{t+h}) = 0 \quad \forall t, h \in Z \quad \text{غياب الارتباط}$$

التشويش الأبيض إذن هو سيرورة عشوائية ذو متوسط معدوم، وتباين ثابت، ولا يوجد ارتباط والذي يشار إليه كما يلي :

$$\varepsilon_t \sim WN(0, \sigma^2).$$

ملاحظات :

* إذا كان التشويش الأبيض ε_t يتبع التوزيع الطبيعي نقول أن التشويش الأبيض ذات مستوى قوي (ذو متوسط معدوم وتباين σ^2)، أو نقول عنها سيرورة مستقلة ومتماثلة التوزيع (*iid*) $\varepsilon_t \xrightarrow{iid} (0, \sigma_\varepsilon^2)$.

* إذا كان X و Y متغيران عشوائيان غير مرتبطين فإن التباين المشترك يساوي الصفر.

* إذا كان X و Y متغيران عشوائيان مستقلان فإن $P_{X,Y}(x, y) = P_X(X)P_Y(y)$

2-4 دوال المتوسط والتباين :

تعريف : دالة المتوسط لسلسلة زمنية Y_t يرمز له بالرمز $\mu_t = E(Y_t)$.

الدالة μ_t تحدد أو تعرف بخاصية الدرجة الأولى للسلاسل الزمنية .

تعريف : دالة التباين لسلسلة زمنية Y_t والذي يرمز لها بالرمز:

$$var(Y_t) = \gamma_0 = E(Y_t - \mu_t)^2$$

$$\gamma_0 = \frac{\sum_{t=1}^n (Y_t - \bar{Y})^2}{n} \quad \text{تمثل التباين و} \quad \bar{Y} = \frac{\sum_{t=1}^n Y_t}{n} \quad \text{تمثل المتوسط.}$$

3-4 دوال التباين المشترك (التغاير) والإرتباط الذاتي :

تعريف : دالة التباين المشترك لسلسلة زمنية Y_t والذي يرمز لها بالرمز:

$$\gamma_Y(t, s) = cov(Y_t, Y_s) = E(Y_t - \mu_t)(Y_s - \mu_s).$$

لكل من الفترتين من الزمن s و t حيث أن $s = t - h$ أو $s = t + h$ ، الدالة الزمنية $\gamma_h(t, s)$ تحدد أو تعرف بخاصية الدرجة الثانية لسلسلة زمنية .

تعريف : دالة الإرتباط لسلسلة زمنية Y_t والذي يرمز لها بالرمز:

$$\rho_Y(t, s) = \frac{\text{cov}(Y_t, Y_s)}{\sqrt{\text{var}(Y_t)\text{var}(Y_s)}} = \frac{\gamma_Y(t, s)}{\sqrt{\gamma_{Y_t}(0)\gamma_{Y_s}(0)}}.$$

ملاحظات :

* إذا كانت $h = t - s$ المعلمة $\gamma_Y(h)$ تسمى التباين المشترك ذو درجة h لـ Y_t وكذلك $\gamma_Y(0) = \text{var}(Y_t) = \gamma_Y(t, t)$ ومنه $\gamma_Y(t, s) = \gamma_Y(h)$ حيث $h = t - s$.

* الفرق بين لحظتين من الزمن نسميهما درجة التأخير lag .

$$\forall h \gamma_Y(h) = \text{cov}(Y_t, Y_{t+h}) = \text{cov}(Y_t, Y_{t+h}) = \gamma_Y(-h) \quad *$$

* $\gamma_Y(h) = \gamma_Y(-h)$ دالة الارتباط الذاتي من أجل كل h .

* إذا كانت a_i ثوابت، X_i و Y_i متغيرات عشوائية حيث $i = 1, 2, \dots, n$ و $j = 1, 2, \dots, m$ فإن:


$$- \text{cov}(\sum_{i=1}^n a_i X_i) = \sum_{i=1}^n a_i^2 \text{var}(X_i) + 2 \sum \sum_{i < j} a_i a_j \text{cov}(X_i, X_j).$$

$$- \text{cov}(\sum_{i=1}^n X_i \sum_{j=1}^m Y_j) = \sum_{i=1}^n \sum_{j=1}^m \text{cov}(X_i, Y_j).$$

* $\rho(0) \leq 1$ و $-1 \leq \rho(h)$ من أجل كل h .


4-4 التمثيل البياني لدالة التباين المشترك :

الشكل يوضح الرسم البياني لدالة التباين المشترك :



5-4 دالة الارتباط الذاتي :

الشكل يوضح الرسم البياني لدالة الارتباط الذاتي :



$$\rho_Y(t, s) = \frac{\text{cov}(Y_t, Y_s)}{\sqrt{\text{var}(Y_t)\text{var}(Y_s)}} = \frac{\gamma_Y(t, s)}{\sqrt{\gamma_{Y_t}(0)\gamma_{Y_s}(0)}}$$

$$= \frac{\sum_{t=1}^{n-h} (Y_t - \bar{Y})(Y_{t+h} - \bar{Y})}{\sqrt{\sum_{t=1}^{n-h} (Y_t - \bar{Y})} \sqrt{\sum_{t=1}^{n-h} (Y_{t+h} - \bar{Y})}}$$

يصعب التعامل هذه الصيغة لأنه يتطلب إعادة حساب ρ_h لكل المتوسطات والتباينات، ولهذا السبب فإن يفضل دالة الارتباط ذاتي للعينة .

6-4 دالة الارتباط الذاتي للعينة:

* إذا كانت درجة التأخير h لعينة التباين المشترك تعرف كما يلي :

$$\hat{\gamma}_Y(h) = \frac{1}{n} \sum_{t=h+1}^n (Y_t - \bar{Y})(Y_{t-h} - \bar{Y})$$

أو

$$\hat{\gamma}_Y(h) = \frac{1}{n} \sum_{t=h+1}^n (Y_t - \bar{Y})(Y_{t+h} - \bar{Y})$$

وكذلك حيث $\bar{Y} = \frac{\sum_{t=1}^n Y_t}{n}$ تسمى متوسط العينة.

* إذا كانت درجة التأخير h لعينة دالة الارتباط الذاتي فإن :

$$-1 \leq \hat{\rho}_Y(h) = \frac{\hat{\gamma}_Y(h)}{\hat{\gamma}_Y(0)} = \frac{\sum_{t=1}^{n-h} (Y_t - \bar{Y})(Y_{t+h} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \leq 1.$$

مثال رقم 7:

أوجد $\hat{\rho}_h$ حيث $h = 1, 2, 3$.

t	Z_t	Z_{t+1}	Z_{t+2}	Z_{t+3}	\dots	Z_{t-1}	Z_{t-2}
1	13	8	15	4			
2	8	15	4	4		13	
3	15	4	4	12		8	13
4	4	4	12	11		15	8
5	4	12	11	7		4	15
6	12	11	7	14		4	4
7	11	7	14	12		12	4
8	7	14	12			11	12
9	14	12				7	11
10	12					14	7

الحل :

متوسط العينة لهذه العشر قيم هو : $\bar{Z} = 10$

$$\hat{\rho}_1 = \frac{(13 - 10)(8 - 10) + (8 - 10)(15 - 10) + \dots + (7 - 10)(14 - 10) + (14 - 10)(12 - 10)}{(13 - 10)^2 + (8 - 10)^2 + \dots + (14 - 10)^2 + (12 - 10)^2}$$

$$= \frac{-27}{144} = -.188$$

$$\hat{\rho}_2 = \frac{(13 - 10)(15 - 10) + (8 - 10)(4 - 10) + \dots + (11 - 10)(14 - 10) + (7 - 10)(12 - 10)}{144}$$

$$= \frac{-29}{144} = -.201$$

$$\hat{\rho}_3 = \frac{(13 - 10)(4 - 10) + (8 - 10)(4 - 10) + \dots + (12 - 10)(14 - 10) + (11 - 10)(12 - 10)}{144}$$


$$= \frac{26}{144} = .181$$

ملاحظة :

نقول عن سلسلة أنها مستقرة ، إذا كان معامل دالة الارتباط الذاتي يساوي الصفر أو قريب منه.

لتكن دوال الارتباط الذاتي لكل سلسلة ممثلة في الأشكال التالية :

رسم بياني لأربع سلاسل



* الرسم البياني رقم 01 لقيم دالة الارتباط الذاتي لـ x_1 ، كلها قيم قريبة من الصفر وهذه هي خصائص متغير عشوائي من النوع التشويش الأبيض (white noise) .

* الرسم البياني رقم 02 لقيم دالة الارتباط الذاتي لـ x_2 تتميز بقيم كبيرة مع تناقص لهذه القيم، وهذا ما تتميز به سلسلة زمنية لهل اتجاه عام .

* الرسم البياني رقم 03 لقيم دالة الارتباط الذاتي لـ x_3 ، تكشف عن وجود مركبة موسمية .

* الرسم البياني رقم 01 لقيم دالة الارتباط الذاتي لـ x_4 ، هي مزيج للدوال الثلاث السابقة .

7-4 دالة الارتباط الذاتي الجزئي :

تعريف : يعرف معامل الارتباط الذاتي الجزئي للسيرورة الساكنة $\{Y_t\}$ عند الفجوة الزمنية h ، بأنه يقيس العلاقة بين متغيرين عشوائيين Y_t و Y_{t+h} (في مختلف الفترات h) بعد حذو تأثير المتغيرات التي تقع بينهما وهي $Y_{t+1} \dots Y_{t+h-1}$.

نرمز عادة لمعامل الارتباط الذاتي الجزئي عند الفجوة h بالرمز $\varphi_{k,k}$ ويستعمل في تحديد سيروورة $AR(p)$ (نتكلم عنها لاحقا). وبالتالي دالة الارتباط الذاتي تمثل تسلسل للإرتباطات الشرطية كما يلي :

$$\begin{aligned}\varphi_{k,k} &= \text{corr}(Y_t, Y_{t+h} | Y_{t+1} \dots Y_{t+h-1}) \quad ; h = 1, 2, \dots \\ &= \frac{\text{cov}(Y_t | Y_{t+1} \dots Y_{t+h-1}, Y_{t+h} | Y_{t+1} \dots Y_{t+h-1})}{\sqrt{\text{var}(Y_t | Y_{t+1} \dots Y_{t+h-1})} \sqrt{\text{var}(Y_{t+h} | Y_{t+1} \dots Y_{t+h-1})}} \\ &= \frac{\text{cov}(Y_t - \hat{Y}_t, Y_{t+h} - \hat{Y}_{t+h})}{\sqrt{\text{var}(Y_t - \hat{Y}_t)} \sqrt{\text{var}(Y_{t+h} - \hat{Y}_{t+h})}}\end{aligned}$$

حيث

$$\hat{Y}_t = \alpha_1 Y_{t+1} + \alpha_2 Y_{t+2} + \dots + \alpha_{n-2} Y_{t+h-1}.$$

$$\hat{Y}_{t+h} = \beta_1 Y_{t+1} + \beta_2 Y_{t+2} + \dots + \beta_{n-1} Y_{t+h-1}.$$

حيث $\alpha_i, \beta_i (1 \leq i \leq h-1)$ ، يمثلان معاملات متوسط مربعات الإنحدار الخطي المتحصل عليه من تدنئة $E(Y_t - \hat{Y}_t)^2$ و $E(Y_{t+h} - \hat{Y}_{t+h})^2$.

8-4 تقدير دالة الارتباط الذاتي الجزئي :

هناك أساليب عديدة لتقدير دالة الارتباط الذاتي الجزئي، ويعتبر أسلوب يول-ولكر (the yule-walka) من أهم الأساليب هذه التقنيات التي تساعد في الحصول على معاملات الارتباط الجزئية لدرجات التأخير $h = 1, 2, \dots$ كما يلي :

* ضبط نموذج الإنحدار حيث Y_t متغير تابع وسيروورة مستقرة وهذه بالنسبة لـ h متغيرات مستقلة $Y_{t-1}, Y_{t-2}, \dots, Y_{t-h}$ ومنه :

$$Y_t = \varphi_{h,1} Y_{t-1} + \varphi_{h,2} Y_{t-2} + \dots + \varphi_{h,h} Y_{t-h} + \varepsilon_t.$$

حيث $\varphi_{h,h}$ تشير إلى أن h يمثل عدد معاملات الإنحدار و ε_t الحد العشوائي مع متوسط مساوي للصفر، وغير مرتبط بـ Y_{t-h} لكل $h \neq 0$.

* ضرب هذه المعادلة بـ Y_{t-1} ، ثم ندخل عليها التوقع، ثم نقوم بقسمتها على التباين لـ Y_t ، نقوم بنفس العملية مع $Y_{t-2}, Y_{t-3}, \dots, Y_{t-h}$ للحصول على مجموعة من معادلات يول-ولكر .

- معادلات يوول - ولكر هي تقنية التي يمكن أن تساعد في تقدير معاملات نماذج الإنحدار $AR(h)$ التي سوف نتطرق إليها لاحقاً .

$$Y_t = \sum_{i=1}^h \varphi_i Y_{t-i} + \varepsilon_t.$$

ومنه يمكن الإعتماد على نظام يوول - ولكر لتحديد معاملات دالة الارتباط الذاتي $\varphi_{h,h}$ للفجوة الزمنية h بأنه معامل Y_{t-h} لنموذج الإنحدار الذاتي :

$$Y_t = \varphi_{h,1}Y_{t-1} + \varphi_{h,2}Y_{t-2} + \dots + \varphi_{h,h}Y_{t-h} + \varepsilon_t. \text{ حيث } h = 1, 2, \dots$$

ومن ثم تصبح دالة التباين المشترك الذاتي لهذا النموذج هي :

$$\gamma_Y(i) = cov(Y_{t-i}, Y_t) = E(Y_{t-i} - Y_t).$$

$$\gamma_Y(i) = E[Y_{t-i}(\varphi_{h,1}Y_{t-1} + \varphi_{h,2}Y_{t-2} + \dots + \varphi_{h,h}Y_{t-h} + \varepsilon_t)]; i = 1, 2 \dots h$$

بقسمة $\gamma_Y(i)$ على التباين $\gamma_Y(0)$ نصل إلى دالة الارتباط على الصورة :

$$\rho_{(1)} = \varphi_{h,1}\rho_{(i-1)} + \varphi_{h,2}\rho_{(i-2)} + \dots + \varphi_{h,h}\rho_{(i-h)} ; i = 1, 2, \dots h.$$

ويعرف هذا النظام من المعادلات بنظام يوول - ولكر ويتكون من h معادلة خطية في المجاهيل $\varphi_{h,1}, \varphi_{h,2}, \dots, \varphi_{h,h}$ ولتوضيح ذلك نكتب نظام المعادلات السابقة على الشكل التفصيلي :

$$\rho_{(1)} = \varphi_{h,1}\rho_{(0)} + \varphi_{h,2}\rho_{(1)} + \dots + \varphi_{h,h}\rho_{(h-1)}$$

$$\rho_{(2)} = \varphi_{h,1}\rho_{(1)} + \varphi_{h,2}\rho_{(0)} + \dots + \varphi_{h,h}\rho_{(h-2)}$$

$$\vdots \quad \quad \quad \vdots \quad \quad \quad \vdots \quad \quad \quad \vdots$$

$$\rho_{(h)} = \varphi_{h,1}\rho_{(h-1)} + \varphi_{h,2}\rho_{(h-2)} + \dots + \varphi_{h,h}\rho_{(0)}$$

ومنه يمكن كتابة نظام يوول - ولكر على شكل مصفوفات كما يلي : $AX = b$.

$$\begin{bmatrix} 1 & \rho(1) & \rho(2) & \cdots & \rho(h-1) \\ \rho(1) & 1 & \rho(2) & \cdots & \rho(h-2) \\ \rho(2) & \rho(1) & 1 & \cdots & \rho(h-3) \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \rho(h-1) & \rho(h-2) & \cdots & \rho(1) & 1 \end{bmatrix} \begin{bmatrix} \varphi_{h,1} \\ \varphi_{h,2} \\ \varphi_{h,3} \\ \vdots \\ \varphi_{h,h} \end{bmatrix} = \begin{bmatrix} \rho(1) \\ \rho(2) \\ \rho(3) \\ \vdots \\ \rho(h) \end{bmatrix}$$

X هو شعاع المتغيرات $(\varphi_{h,1}, \varphi_{h,2}, \dots, \varphi_{h,h})^T$ و b هو عمود شعاع $(\rho_1, \rho_2, \dots, \rho_h)^T$.

ويمكن حل هذا النظام من المصفوفات $AX = b$ باستعمال قاعدة كرامر ويمكن حل هذا النظام لاجاد $\varphi_{h,h}$ بدلالة ρ_h كما يلي :

$$\varphi_{h,h} = \frac{\det(A_h)}{\det(A)} ; h = 1, 2, 3 \dots$$

حيث $\det(A)$ يمثل المصفوفة A و $\det(A_h)$ تمثل محدد المصفوفة بعد إحلال العمود الأخير بالمتجه ρ_h أي أن :

$$\det(A_h) = \begin{vmatrix} 1 & \rho(1) & \rho(2) & \cdots & \rho(1) \\ \rho(1) & 1 & \rho(2) & \cdots & \rho(2) \\ \rho(2) & \rho(1) & 1 & \cdots & \rho(3) \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \rho(h-1) & \rho(h-2) & \cdots & \cdots & \rho(h) \end{vmatrix}$$

حل نظام يوول - ولكر للمعادلات يمثل العلاقة بين دالة الارتباط الذاتي الجزئي $\varphi_{h,h}$ ودالة الارتباط ρ_h ومن يمكن إستغلال هذه العلاقة لتقدير دالة الارتباط الذاتي الجزئي، والأمثلة التالية كيفية تقدير دالة الارتباط الذاتي الجزئي بشكل مباشر.

مثال رقم 8:

إستخدام نظام يوول - ولكر في التعبير عن $\varphi_{1,1}$ بدلالة ρ_1 .

الحل :

بوضع $h = 1$ في نظام يوول - ولكر نحصل على مايلي :

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

$$\rho_0 = 1 ; \rho_1 = \varphi_{1,1} \Rightarrow \varphi_{1,1} = \rho_1.$$

مثال رقم 9:

إستخدام نظام يوول - ولكر فى التعبير عن $\varphi_{2,2}$ بدلالة ρ_2, ρ_1 بشكل مباشر .

الحل :

$$. Y_t = \varphi_{2,1}Y_{t-1} + \varphi_{2,2}Y_{t-2} + \varepsilon_t \text{ حيث } h = 2$$

$$\rho_1 = \varphi_{2,1}\rho_0 + \varphi_{2,2}\rho_1$$

$$\rho_2 = \varphi_{2,1}\rho_1 + \varphi_{2,2}\rho_0$$

وبالتالى فإن :

$$\det |A_2| = \begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}$$

$$\det |A| = \begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}$$

ومنه :

$$\varphi_{2,2} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

مثال رقم 10:

إستخدام نظام يوول - ولكر فى التعبير عن $\varphi_{3,3}$ بدلالة ρ_3, ρ_2, ρ_1 بشكل مباشر . **الحل :**

$$. Y_t = \varphi_{3,1}Y_{t-1} + \varphi_{3,2}Y_{t-2} + \varphi_{3,3}Y_{t-3} + \varepsilon_t \text{ حيث } h = 3$$

$$\rho_1 = \varphi_{3,1}\rho_0 + \varphi_{3,2}\rho_1 + \varphi_{3,3}\rho_2$$

$$\rho_2 = \varphi_{3,1}\rho_1 + \varphi_{3,2}\rho_0 + \varphi_{3,3}\rho_1$$

$$\rho_3 = \varphi_{3,1}\rho_2 + \varphi_{3,2}\rho_1 + \varphi_{3,3}\rho_0$$

$$\det |A_3| = \begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}$$

$$\det |A| = \begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}$$

ومنه :

$$\varphi_{3,3} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} = \frac{\rho_3(1 - \rho_1^2) + \rho_1\rho_2(\rho_2 - 2) + \rho_1^3}{1 - 2\rho_1^2 + 2\rho_1^2 - \rho_2^2}$$

ومنه لما $h = h$ فإن حل نظام يوول - ولكر لهذه المعادلات يكون كمايلي :

$$\det |A_h| = \begin{vmatrix} 1 & \rho_{(1)} & \rho_2 & \cdots & \rho_{h-2} & \rho_1 \\ \rho_1 & 1 & \rho_{(2)} & \cdots & \rho_{h-3} & \rho_2 \\ \rho_2 & \rho_{(1)} & 1 & \cdots & \rho_3 & \rho_3 \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \rho_{h-1} & \rho_{h-2} & \cdots & \cdots & \rho_1 & \rho_h \end{vmatrix}$$

$$\det |A_h| = \begin{vmatrix} 1 & \rho_{(1)} & \rho_2 & \cdots & \rho_{h-2} & \rho_{h-1} \\ \rho_1 & 1 & \rho_{(2)} & \cdots & \rho_{h-3} & \rho_{h-2} \\ \rho_2 & \rho_{(1)} & 1 & \cdots & \rho_{h-3} & \rho_{h-3} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \rho_{h-1} & \rho_{h-2} & \rho_{h-3} & \cdots & \rho_1 & 1 \end{vmatrix}$$

ومنه :

$$\varphi_{h,h} = \frac{\begin{vmatrix} 1 & \rho_{(1)} & \rho_2 & \cdots & \rho_{h-2} & \rho_1 \\ \rho_1 & 1 & \rho_{(2)} & \cdots & \rho_{h-3} & \rho_2 \\ \rho_2 & \rho_{(1)} & 1 & \cdots & \rho_3 & \rho_3 \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \rho_{h-1} & \rho_{h-2} & \cdots & \cdots & \rho_1 & \rho_h \end{vmatrix}}{\begin{vmatrix} 1 & \rho_{(1)} & \rho_2 & \cdots & \rho_{h-2} & \rho_{h-1} \\ \rho_1 & 1 & \rho_{(2)} & \cdots & \rho_{h-3} & \rho_{h-2} \\ \rho_2 & \rho_{(1)} & 1 & \cdots & \rho_{h-3} & \rho_{h-3} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \rho_{h-1} & \rho_{h-2} & \rho_{h-3} & \cdots & \rho_1 & 1 \end{vmatrix}}.$$

مثال رقم 11:

أوجد معادلات دالة الارتباط الذاتي الجزئي. $\rho_3 = 0.2, \rho_2 = 0.5, \rho_1 = 0.7$.

الحل:

$$\varphi_{1,1} = \rho_1 = 0.7.$$

$$\varphi_{2,2} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & 0.7 \\ 0.7 & 0.5 \end{vmatrix}}{\begin{vmatrix} 1 & 0.7 \\ 0.7 & 1 \end{vmatrix}} = 0.0196.$$

$$\varphi_{3,3} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & 0.7 & 0.7 \\ 0.7 & 1 & 0.5 \\ 0.5 & 0.7 & 0.2 \end{vmatrix}}{\begin{vmatrix} 1 & 0.7 & 0.5 \\ 0.7 & 1 & 0.7 \\ 0.5 & 0.7 & 1 \end{vmatrix}} = -0.392.$$

ملاحظات:

* دالة الارتباط الذاتي الجزئي $\varphi_{h,h}$ حيث $-1 \leq \varphi_{h,h} \leq 1$ $\forall h > 0$.

* إذا كانت ε_t تمثل سيرورة التشويش الأبيض فإن دالة الارتباط الذاتي الجزئي $\varphi_{h,h} = 0$

لكل $h \neq 0$ و $\varphi_{0,0} = \rho_0 = 1$.

* يساعد في تحديد درجة السيرورة $AR(p)$ (نتكلم عنها لاحقاً) بمعنى أن $h > \varphi_{h,h} = 0$

p أي أن الرسم الخاص بدلالة الارتباط الذاتي الجزئي يقترب من الصفر بعد الدرجة p .

9-4 تحليل دالة الارتباط الذاتي:

عند دراسة دالة الارتباط الذاتي لسلسلة زمنية Y_t ، فإن السؤال الذي يطرح هو تحديد قيم ρ_h التي تكون معنوية تختلف عن الصفر .

في الحقيقة، إذا كان على سبيل عنصر من ρ_h يختلف معنوية عن الصفر وبالتالي فإن السلسلة الزمنية بدون ذاكرة، وهي بالتالي لا تتأثر لا باتجاه عام ولا بموسمية، كذلك سلسلة زمنية شهرية تظهر قيمة عالية أي أنها تقع خارج مجال الثقة من أجل ρ_{12} (الارتباط بين Y_t و Y_{t-12})، السلسلة الزمنية قيد الدراسة هي بالتأكيد متأثر بتغيرات أو تذبذبات موسمية .

إختبار الفرضيات من أجل المعامل ρ_h يكون كما يلي :

$$H_0 : \rho_{(h)} = 0$$

$$H_1 : \rho_{(h)} \neq 0$$

نستطيع إستعمال معامل الارتباط الذي يركز على إحصائية ستودنت، ومن جهة أخرى برهن Quenennouille(1949) من أجل حجم عينة حيث $n > 30$ ، فإن معامل الارتباط ρ_h ينتهي تقريبا الى القانون الطبيعي ذو متوسط معدوم وإنحراف معياري $\frac{1}{\sqrt{n}}$ ، ومنه يعطى مجال

الثقة للمعامل ρ_h ، ومنه يعطى مجال الثقة لـ ρ_h بـ $\rho_h = 0 \pm \frac{t_{\alpha/2}}{\sqrt{n}}$ حيث n يمثل عدد

الملاحظات . إذا كان المعامل المحسوب $\hat{\rho}_h$ خارج مجال الثقة، فهو يختلف معنوية عن الصفر عند مستوى معنوية α . (في العموم $\alpha = 0.05$ و $t_{\alpha/2} = 1.96$) معظم البرامج توفر مخطط

للرسم، ومجال للثقة، الذي يسمح بالتفسير الفوري .يجدر بنا التنبيه الى أن أحد المساوي للإختبار عند مستوى معنوية $\alpha = 0.05$ وهي، أن دالة الارتباط الذاتي المحسوبة من أجل عدد كبير لدرجات التأخير، فإننا ننتظر أحد معاملات الارتباط الذاتي أو بطريقة غير متوقعة، معنوية تختلف عن الصفر، إذا كان h عدد درجات التأخير العدد الممكن للرفض الزائف (الخاطئ أو الكاذب) هو $005 \times h$ ، من أجل مستوى معنوية $\alpha = 0.05$.

ملاحظة :

في الحالة التي لا تظهر فيها المخطط البياني (*correlogram*)، أي إنخفاض في معاملات (غياب بـ cut off)، يمكننا أن نستنتج أن السلسلة غير مستقرة في الإتجاه العام .

10-4 إختبار Box – Piere و Ling – Box :

إختبار Box-Piere يسمح بتحديد السيرورة بدون ذاكرة (متتالية من المتغيرات العشوائية مستقلة فيما بينها) لذلك نحن بحاجة لتحديد $cov(Y_t, Y_{t+h}) = 0$ أو أيضا $\rho_h = 0 ; \forall h$.
السيرورات ذات التشويش الأبيض يتضمن أن $\rho_1 = \rho_2 = \dots = \rho_h = 0$ ، أو بعبارة أخرى لإجراء إختبار مشترك لمعنوية معاملات الارتباط الذاتى كمجموعة، نستخدم إختبار *Box – Piere* ومنه الفرضية التى يجب إختبارها :

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_h = 0$$

يوجد على الأقل ρ_i معنويا يختلف عن الصفر : H_1

هذا الإختبار يسمى عند anglo – saxons بإختبار (*Test Portmanteau*) .

مثال رقم 12:

ليكن الجدول التالى يمثل التباين المشترك للعينة مع درجات التأخير $h = 0, 1, \dots, 4$ مع عدد المشاهدات السلسلة الزمنية $n = 50$.

h	0	1	2	3	4
$\hat{\gamma}(h)$	0.93673	-0.05292	-0.00140	0.06516	-0.01058

عند مستوى معنوية α ، إستخدام إختبار *Ling – Box Portmanteau* لإثبات أو عدم إثبات أن السلسلة تمثل تشويش أبيض .

الحل :

نلاحظ أن $m = 4 ; p = q = 0$ والقيمة الحرجة لـ $\alpha = 5\%$ هي

$$\cdot \chi^2_{(0.05;4)} = 0.711$$

h	0	1	2	3	4
$\hat{\gamma}(h)$	0.93673	-0.05292	-0.00140	0.06516	-0.01058
$\hat{\rho}(h)$	1.000	-0.056	-0.001	0.070	-0.011
$\hat{\rho}^2(h)$	1.000000	0.003136	0.000001	0.004900	0.000121

إختبار إحصائية : Ling-Box Portmanteau ومنه :

$$\tilde{Q}_4 = 50(52) \sum_{h=1}^4 \frac{\hat{\rho}^2(h)}{50-h} = 0.44436,$$

نلاحظ أن $\chi^2_{(0.05;4)} = 0.711 < 0.44436$ ، نرفض H_0 ونقبل H_1 ومنه السلسلة من نوع التشويش الأبيض، للقيام بهذا الإختبار، نلجأ إلى إحصائية Q (التي ترجع إلى Box-Piere) والتي يمكن أعطائها كما يلي :

$$Q_m = n \sum_{h=1}^m \hat{\rho}^2(h) \sim \chi^2_{(m-p-q)}$$

حيث n يمثل حجم العينة و $\hat{\rho}(h)$ معامل الارتباط للعينة بدرجة تأخير h _____

$m < n$ و $(p+q) < m$ هو عدد فترات التأخير التي يتم إختبارها

- إذا كان Q_m أو $\hat{Q}_m \leq \chi^2_{\alpha, (m-p-q)}$ نرفض H_1 الفرضية البديلة ونقبل فرضية العدم، وهذا يعنى أن السلسلة مستقرة (ساكنة)، حيث Q_m تتبع توزيع كاي مربع $\chi^2_{\alpha, (m-p-q)}$ وذو $(m-p-q)$ درجة حرية عند مستوى معنوية α .

كما أنه توجد إحصائية أخرى بديلة تستخدم في نفس الإختبار السابق تسمى بإحصائية Ling-Box وهي إحصائية Box-Piere المعدلة والتي تعطى بالعلاقة التالية :

$$\hat{Q}_m = n(n+2) \sum_{h=1}^m \frac{\hat{\rho}^2(h)}{n-h} \sim \chi^2_{(m-p-q)}$$

والتي تتوزع توزيع χ^2 كاي مربع بدرجة حرية $(m-p-q)$ عند مستوى معنوية α والذي لع قاعدة قرار مماثلة للسابق.

الفصل الثالث : السيرورات الخطية للسلاسل الزمنية المستقرة ARMA :

1- خصائص معامل التأخير :

تعد معاملات التأخير والتقدم والفرق طريقة ملائمة لكتابة نماذج السلاسل الخطية ووصف خصائصها .

تعريف 1 :

معامل التأخير (lag operator) يتم إستخدام مؤشر الوقت إلى الخلف ويرمز له بالرمز B أو L .

تعريف 2 :

معامل التقدم (lead operator) يتم إستخدام مؤشر الوقت إلى الأمام ويرمز له بالرمز F أو L^{-1} .

تعريف 3 :

معامل الفرق (difference operator) يعبر عن الفرق بين متغيرين عشوائيين متتاليين، ويرمز له بالرمز Δ .

$$* BY_t = Y_{t-1}$$

$$* B^2Y_t = B(BY_t) = BY_{t-1} = Y_{t-2}$$

$$* B^4Y_t = Y_{t-4}$$

$$B^hY_t = Y_{t-h} *$$

$$* FY_t = Y_{t+1}$$

$$* F^2Y_t = F(FY_t) = FY_{t+1} = Y_{t+2}$$

$$* F^4Y_t = Y_{t+4}$$

$$* F^hY_t = Y_{t+h}$$

$$* \Delta Y_t = Y_t - Y_{t-1} = Y_t - BY_t = (1 - B)Y_t$$

$$* \Delta^2Y_t = \Delta(\Delta Y_t) = \Delta Y_t - \Delta Y_{t-1} = (1 - B)\Delta Y_t$$

$$= (1 - B)^2 Y_t = (1 - 2B + B^2) Y_t = Y_t - 2BY_t + B^2 Y_t$$

$$= Y_t - 2Y_{t-1} + Y_{t-2}$$

$$* \Delta^d Y_t = (1 - B)^d Y_t$$

القيم الموجبة لـ h تعرف بدرجات التأخير إلى الخلف بينما القيم السالبة تعرف بالقيم إلى الأمام
أي :

$$* B^{-h} Y_t = F^h Y_t = Y_{t+h}$$

$$* B^{-2} Y_t = Y_{t+2}$$

$$* B^0 Y_t = F^0 Y_t = \Delta^0 Y_t = Y_t$$

$$* B^i B^j Y_t = B^{i+j} Y_t = Y_{(i+j)}$$

$$* (B^i + B^j) Y_t = B^i Y_t + B^j Y_t = Y_{t-i} + Y_{t-j}$$

إذا كان $|\phi B| < 1$ فإن :

$$(1 + \phi B + \phi^2 B + \dots) = \frac{1}{1 - \phi B}$$

2- السيرورة الخطية :

بالنسبة للسلاسل الزمنية المستقرة بدون تأثير اتجاه عام أو موسمية، إذا لزم الأمر لوجود اتجاه عام أو تأثيرات موسمية أو دورية، وقد تمت إزالتهم من السلسلة الزمنية. فقد نبني نموذج خطي للسلسلة الزمنية مع الارتباط الذاتي، ومن أهم السيرورات الخطية هم :

* نموذج الإنحدار الذاتي (Autoregressive model (AR)).

* نموذج المتوسط المتحرك (Moving Average (MA)).

* نموذج المتوسط المتحرك (ARMA).

1-2 نموذج الإنحدار الذاتي (Autoregressive model(AR):

السلسلة الزمنية Y_t مع متوسط معدوم يعنى :

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t.$$

(حيث ε_t هو التشويش الأبيض φ_i معاملات $i = 1, 2, \dots, p$ ، تسمى سيرورة الإنحدار الذاتي ذو درجة p يرمز لها بالرمز $AR(p)$.

* مع معامل التأخير B ، السيرورة $\Phi_p(B)Y_t = \varepsilon_t$ ، حيث

$$\Phi_p(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$$

* نموذج $AR(p)$; $\forall p \geq 1$ يكون مستقرا، إذا كانت مجموعة الحلول لـ

$$1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p = 0 > 1$$

* إذا كان المتوسط μ لـ Y_t لا يساوى الصفر، نعوض Y_t بـ $(Y_t - \mu)$ لتتحصل على :

$$Y_t = \varphi_1 (Y_{t-1} - \mu) + \varphi_2 (Y_{t-2} - \mu) + \dots + \varphi_p (Y_{t-p} - \mu) + \varepsilon_t$$

أو

$$Y_t = \alpha + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$$

حيث $\alpha = \mu(1 - \varphi_1 - \varphi_2 - \dots - \varphi_p)$.

مثال رقم 13:

ليكن النموذج $AR(2)$ حيث : $Y_t = 1.5 + 1.2Y_{t-1} - 0.5Y_{t-2} + \varepsilon_t$ ومنه

$$Y_t - \mu = 1.2(Y_{t-1} - \mu) - 0.5(Y_{t-2} - \mu) + \varepsilon_t$$

ومنه $1.5 = \mu(1 - 1.2 - (0.5))$ نستنتج أن $\mu = 5$ ومنه النموذج كما

$$Y_t - 5 = 1.2(Y_{t-1} - 5) - 0.5(Y_{t-2} - 5) + \varepsilon_t$$

2-2 نموذج المتوسط المتحرك (Moving Average (MA):

السلسلة الزمنية Y_t مع متوسط معدوم يعنى :

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

(حيث ε_t هو التشويش الأبيض θ_j معاملات $j = 1, 2, \dots, q$ ، تسمى سيرورة المتوسط المتحرك ذو درجة q يرمز لها بالرمز $MA(q)$.

* مع معامل التأخير أو الأبطاء B ، السيرورة $Y_t = \Theta_q(B)\varepsilon_t$ حيث

$$\Theta_q(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$$

* نموذج $MA(q)$; $\forall q \geq 1$ دائما مستقرا، بغض النظر عن قيم θ_j حيث $j = 1, 2, \dots, q$.

* إذا كانت المجموعة $1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q = 0 > 1$ السيرورة $MA(q)$ يقال عنها قابلة للعكس (invertible) وبالتالي فإنه يمكن صياغتها كنموذج $AR(\infty)$.

مثال رقم 14:

$$MA(1): Y_t = -0.8\varepsilon_{t-1} + \varepsilon_t.$$

$$MA(2): Y_t = 0.8\varepsilon_{t-1} + 0.6\varepsilon_{t-2} + \varepsilon_t.$$

3-2 النموذج المختلط (ARMA):

السلسلة الزمنية Y_t مع متوسط معدوم تسمى نماذج الإنحدار الذاتى - المتوسط المتحرك $ARMA(p, q)$ وتنتصل عليها بدمج $AR(p)$ و $MA(q)$ ، يشير مثل هذا النموذج إلى القيمة الحالية للسلسلة Y_t تعتمد خطيا على قيمها السابقة، إضافة إلى توليفة من القيم الحالية والسابقة لحد التشويش الأبيض. ويمكن صياغة النموذج كالتالى :

$$Y_t = \sum_{i=1}^p \varphi_i Y_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j}.$$

Autoregressive part

Moving Average part

حيث ε_t يمث التشويش الأبيض، حيث φ_i و θ_j من أجل $i = 1, 2, \dots, p$; $j = 0, 1, 2, \dots, q$.

يمثلان معلمات جزء الإنحدار الذاتي والمتوسط المتحرك تسلسليا حيث $\theta_0 = 1$.

* عند استعمال معامل التأخير أو الأبطاء يمكن كتابة السيرورة $ARMA(p, q)$ كمايلي :

$$\Phi_p(B)Y_t = \Theta_q(B)\varepsilon_t$$

Autoregressive part

Moving Average part

حيث $\Theta_q(B) = 1 + \sum_{j=1}^q \theta_j B^j$ و $\Phi_p(B) = 1 - \sum_{i=1}^p \varphi_i B^i$.

* إذا كان المتوسط μ لـ Y_t لا يساوى الصفر، نعوض Y_t بـ $(Y_t - \mu)$ لنحصل على :

$$\Phi_p(B)(Y_t - \mu) = \Theta_q(B)\varepsilon_t$$

يمكن أيضا كتابتها كما يلي :

$$Y_t = \alpha + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

حيث $\alpha = \mu(1 - \varphi_1 - \varphi_2 - \dots - \varphi_p)$

ملاحظة :

هناك ثلاث شروط للنموذج الخطي $ARMA(p, q)$ وهى الإستقرارية (stationarity)، قابلية العكس (invertible)، التحديد أو التعرف (identinble) :

* شرط الإستقرارية هو نفس الشرط الخاص بالسيرورة $AR(p)$ ، والذي يتمثل في أن جذر المعادلة المميزة $1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$ تقع خارج دائرة الوحدة أو أكبر تماما من العدد 1 .

* شرط قابلية العكس، هو نفس الشرط الخاص بالسيرورة $MA(q)$ ، والذي يتمثل في جذر المعادلة المميزة $1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ تقع كلها خارج دائرة الوحدة أو أكبر دائما من الواحد.

* شرط التحديد أو التعرف، يعنى أن النموذج لا يقبل التكرار والذي يتمثل في أن :

$$\Phi_p(B) = 0 \text{ و } \Theta_q(B) = 0 \text{ ليس لديهم حلول مشتركة .}$$

مثال رقم 15:

النموذج قابل للتكرار (وجود حلول مشتركة في النموذج $(ARMA(p, q))$ ، ليكن النموذج التالي $ARMA(1,2)$ ومعادلة النموذج تكون كالتالي :

$$Y_t = 0.2Y_{t-1} + \varepsilon_t - 1.1\varepsilon_{t-1} + 0.18\varepsilon_{t-2} \Leftrightarrow$$

$$Y_t - 0.2Y_{t-1} = \varepsilon_t - 1.1\varepsilon_{t-1} + 0.18\varepsilon_{t-2}$$

والذي يمكن كتابته على الشكل التالي :

$$Y_t - 0.2BY_t = \varepsilon_t - 1.1B\varepsilon_t + 0.18B^2\varepsilon_t \Leftrightarrow$$

$$(1 - 0.2B)Y_t = (1 - 1.1B + 0.18B^2)\varepsilon_t \Leftrightarrow$$

$$(1 - 0.2B)Y_t = (1 - 0.2B)(1 - 0.9B)\varepsilon_t \Leftrightarrow$$

$$Y_t = (1 - 0.9B)\varepsilon_t$$

وبالتالي السيرورة ليست في الواقع $ARMA(1,2)$ ولكن $MA(1) \equiv ARMA(1,2)$.

نعطى بعض الأمثلة عن السيرورة $ARMA(p, q)$:

- $AR(1) \equiv ARMA(1,0)$ السيرورة يمكن كتابتها كالتالي : $(1 - \varphi B)Y_t = \varepsilon_t$ أو $Y_t = \varphi Y_{t-1} + \varepsilon_t$.

- $AR(2) \equiv ARMA(2,0)$ السيرورة يمكن كتابتها كالتالي:

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varepsilon_t \text{ أو } (1 - \varphi_1 B - \varphi_2 B^2)Y_t = \varepsilon_t$$

- $MA(2) \equiv ARMA(0,2)$ السيرورة يمكن كتابتها كالتالي:

$$Y_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \varepsilon_t \text{ أو } Y_t = (1 + \theta_1 B + \theta_2 B^2)\varepsilon_t$$

- السيرورة $ARMA(1,1)$ السيرورة يمكن كتابتها كالتالي :

$$Y_t = \varphi Y_{t-1} + \varphi \varepsilon_{t-1} + \varepsilon_t \text{ أو } (1 - \varphi B)Y_t = (1 + \theta B)\varepsilon_t$$

- السيرورة $ARMA(2,1)$ السيرورة يمكن كتابتها كالتالي :

$$\text{أو } (1 - \varphi_1 B - \varphi_2 B^2)Y_t = (1 + \theta B)\varepsilon_t$$

$$. Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi \varepsilon_{t-1} + \varepsilon_t$$

- السيرورة $ARMA(1,2)$ السيرورة يمكن كتابتها كالتالي :

$$\text{أو } (1 - \varphi_1 B)Y_t = (1 + \theta B + \theta_2 B^2)\varepsilon_t$$

$$. Y_t = \varphi_1 Y_{t-1} + \varphi_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \varepsilon_t$$

- السيرورة $ARMA(2,2)$ السيرورة يمكن كتابتها كالتالي :

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \varepsilon_t$$

أو $\Phi_2(B)Y_t = \Theta_2(B)\varepsilon_t$ حيث :

$$. \Theta_2(B) = 1 + \theta_1 B + \theta_2 B^2 \text{ و } \Phi_2(B) = 1 - \varphi_1 B - \varphi_2 B^2$$

*** التباين المشترك لنماذج $MA(1)$:**

لتكن السيرورة $MA(1)$ حيث $Y_t = \varepsilon_t + \theta \varepsilon_{t-1}$ $\varepsilon_t \sim WN(0, \sigma^2)$

* المتوسط لـ Y_t الذي هو مستقل عن الزمن t $E(Y_t) = 0$

* التباين $\gamma_Y(0) = E(\varepsilon_t^2 + 2\theta \varepsilon_t \varepsilon_{t-1} + \theta^2 \varepsilon_{t-1}^2) = (1 + \theta^2)\sigma^2$

* التباين المشترك والإرتباط الذاتي مستقلان عبر الزمن بدون قيود على المعلمة θ كما هو موضح كما يلي :

$$* \gamma_y(h) = E[(Y_t - E(Y_t))(Y_{t+h} - E(Y_{t+h}))]$$

$$= E[(\varepsilon_t + \theta \varepsilon_{t-1} - 0)(\varepsilon_{t+h} + \varepsilon_{t+h-1} - 0)]$$

$$= E(\varepsilon_t \varepsilon_{t+h}) + \theta E(\varepsilon_{t-1} \varepsilon_{t+h}) + \theta E(\varepsilon_t \varepsilon_{t+h-1}) + \theta^2 E(\varepsilon_{t-1} \varepsilon_{t+h-1})$$

$$= \begin{cases} 1; & h = 0 \\ \frac{\theta}{1+\theta^2} & h = \pm 1 \\ 0 & h = \pm 2, \pm 3 \dots \end{cases}$$

من أجل السيرورة $MA(q)$ حيث $Y_t = \sum_{i=0}^q \theta_i \varepsilon_{t-i}$ و $\theta_0 = 1$ و $\varepsilon_t \sim WN(0, \sigma^2)$:

* المتوسط لـ Y_t الذي هو مستقل عن الزمن t $E(Y_t) = 0$.

* التباين $\gamma_Y(0) = (\theta_1^2 + \theta_2^2 + \dots + \theta_q^2)\sigma^2 = \sigma^2 \sum_{i=0}^q \theta_i^2$.

* التباين المشترك والإرتباط الذاتي مستقلان عبر الزمن t . بدون قيود على المعلمة θ كما هو موضح كما يلي :

$$\gamma_Y(h) = \begin{cases} \sigma^2 \sum_{i=h}^q \theta_i \theta_{i-h} & ; h = 0, \pm 1, \pm 2, \dots \pm q \\ 0, & h > q \end{cases}$$

$$\rho_Y(h) = \frac{\gamma_Y(h)}{\gamma_Y(0)} = \begin{cases} \frac{\sum_{i=h}^q \theta_i \theta_{i-h}}{\sum_{i=0}^q \theta_i^2} & ; h = 0, \pm 1, \pm 2, \dots \pm q \\ 0, & h > q \end{cases}$$

مثال رقم 16:

أوجد التوقع والتباين ثم أوجد التباين المشترك ومعاملات دالة الإرتباط الذاتي لما : $h = 1, 2, \dots$ للنموذج التالي: $Y_t = \varepsilon_t + 0.6\varepsilon_{t-1} - 0.3\varepsilon_{t-2}$ حيث:

$$\varepsilon_t \sim WN(0, \sigma^2)$$

الحل :

$$* E(Y_t) = 0.$$

$$* var(Y_t) = \gamma_Y(0) = (1 + \theta_1^2 + \theta_2^2)\sigma^2 = 1.45\sigma^2.$$

$$* cov(Y_t, Y_{t-1}) = \gamma_Y(1) = \sigma^2 \sum_{i=1}^2 \theta_i \theta_{i-1} = (\theta_1 \theta_2 + \theta_2 \theta_1)\sigma^2 = 0.42\sigma^2$$

$$* \gamma_Y(2) = \sigma^2 \sum_{h=2}^2 \theta_i \theta_{i-2} = \theta_2 \theta_0 \sigma^2 = -0.3 \sigma^2.$$

$$* \rho_Y(1) = \frac{\gamma_Y(1)}{\gamma_Y(2)} = \frac{0.42 \sigma^2}{1.45 \sigma^2} = 0.27.$$

$$* \rho_Y(2) = \frac{\gamma_Y(1)}{\gamma_Y(2)} = \frac{0.3 \sigma^2}{1.45 \sigma^2} = 0.19.$$

$$* \rho_Y(h) = 0. \quad \forall h > 2.$$

3- قابلية العكس للسيرورة $MA(q)$:

* لو عوضنا θ بـ $\frac{1}{\theta}$ ، دالة الارتباط الذاتي لـ $MA(q)$ ومنه $\rho_Y(1) = \frac{\theta}{1+\theta^2}$ ، لن تتغير في كلتا الحالتين وبالتالي يوجد سيرورتان $Y_t = \varepsilon_t + \theta \varepsilon_{t-1}$ و $Y_t = \varepsilon_t + \frac{1}{\theta} \varepsilon_{t-1}$ ، وهنا لم يتم تحديد المعامل بشكل وحيد (أي لا يوجد حل وحيد لمعامل الارتباط الذاتي).

* بالنسبة للحالة العامة للسيرورة $MA(q)$ ، كذلك لا يوجد حل وحيد لمعامل الارتباط الذاتي وهنا يكون لدينا مشكلة .

* يمكن حل هذه المشكلة بافتراض أن المعامل $1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ تكون قابلة للعكس، إذا كانت القيمة المطلقة للجنور لـ :

$$\Theta_q(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q = 0 \text{ تكون خارج دائرة الوحدة .}$$

تعريف :

السيرورة $MA(q)$ قابلة للعكس إذا كانت درجة التأخير لـ AR تؤول إلى مالانهاية

$$AR(\infty) \text{، المتوسط المتحرك } MA(q) \text{، حيث } Y_t = \Theta_q(B) \varepsilon_t$$

$$\text{و } \Theta_q(B) = 1 + \sum_{j=1}^q \theta_j B^j \text{ و } \varepsilon_t \sim WN(0, \sigma^2) \text{ في مالانهاية } AR \text{ يمثل بـ } AR(\infty) .$$

نضرب طرفي المعادلة $Y_t = \Theta_q(B) \varepsilon_t$ بـ $\Theta_q(B)^{-1}$ تصبح المعادلة كما يلي :

$$\Theta_q(B)^{-1} Y_t = \Theta_q(B)^{-1} \Theta_q(B) \varepsilon_t = \varepsilon_t$$

$$\Rightarrow \prod_{\infty}(B) Y_t = \varepsilon_t$$

حيث

تكون π_i و $\pi_0 = -1$ و $\prod_{\infty}(B) = \Theta_q(B)^{-1} = 1 - \sum_{i=1}^{\infty} \pi_i B^i = -\sum_{i=0}^{\infty} \pi_i B^i$
مقبولة $\sum_{i=0}^{\infty} |\pi_i| < \infty$.

* نلاحظ أن الشرط $(\sum_{i=0}^{\infty} |\pi_i| < \infty)$ يضمن أن $AR(\infty)$ تكون متقاربة أو بمعنى آخر أن $MA(q)$ قابلة للعكس.

مثال رقم 17:

لتكن $MA(1)$ كالتالي $Y_t = (1 + \theta B)\varepsilon_t$ حول $MA(1)$ الى تمثيل $AR(\infty)$.

الحل:

نضرب الطرفين بـ: $(1 + \theta B)^{-1}$ نتحصل على: $\varepsilon_t = \frac{1}{1 + \theta B} Y_t = \prod_{\infty}(B) Y_t$.

حيث $\prod_{\infty}(B) = (1 + \theta B)^{-1} = 1 - \sum_{i=0}^{\infty} \pi_i B^i = -\sum_{i=0}^{\infty} \pi_i B^i$ ونذكر أن
سلاسل تايلور بـ $\frac{1}{1-x}$ ، $|x| < 1$ هي الشكل الهندسي للسلسلة: $1 + X + X^2 + X^3 + \dots$
ومنه نستنتج أن:

$$\frac{1}{1 - \theta B} = \frac{1}{1 - (-\theta B)} = 1 - \theta B + \theta^2 B^2 - \theta^3 B^3 + \dots = \sum_{i=0}^{\infty} (-\theta)^i B^i$$

ومنه: $\sum_{i=0}^{\infty} (-\theta)^i B^i = -\sum_{i=0}^{\infty} \pi_i B^i$

ومنه: $\pi_i = (-1)^{i+1} (\theta)^i ; \forall i \geq 0$

ومنه السيرة $MA(1)$: $Y_t = (1 + \theta B)\varepsilon_t$ في $AR(\infty)$ نمثل كما يلي:

حيث $\pi_i = (-1)^{i+1} (\theta)^i ; i = 1, 2, \dots$ نلاحظ أن القيمة المطلقة

لحل $1 + \theta B = 0$ تسلم أن $\left| \frac{1}{\theta} \right| > 1$ أو مكافئ $|\theta| < 1$ لتأكيد أن $MA(q)$ قابلة للعكس.

مثال رقم 18:

لتكن $MA(1)$ كالتالي $Y_t = \varepsilon_t + 0.4\varepsilon_t$ قابلة للعكس.

: الحل

$$|\theta| = |0.4| < 1 \text{ أو حل جذور:}$$

$$(1 + 0.4B) = 0 \Rightarrow |B| = \left| \frac{1}{0.4} \right| = 0.25 > 1$$

السيرورة يمكن كتابتها في تمثيل $AR(\infty)$ كما يلي :

$$Y_t = \sum_{i=1}^{\infty} \pi_i Y_{t-i} + \varepsilon_t \text{ حيث } \pi_i = (-1)^{i+1} (0.4)^i ; i = 1, 2, \dots$$

$$Y_t = \varepsilon_t + 0.4Y_t - (0.4)^2 Y_{t-2} + (0.4)^3 Y_{t-3} \dots \dots$$

مثال رقم 19:

لتكن $MA(1)$ كالتالي $Y_t = \varepsilon_t + 1.8\varepsilon_t$ غير قابلة للعكس .

: الحل

لأن جذور المعادلة $(1 + 1.8B) = 0$ القيمة المطلقة $|B| = \left| \frac{1}{1.8} \right| > 1$ ومنه لا يمكن تمثيل $AR(\infty)$.

تمثل $MA(q)$ على شكل $AR(\infty)$ (أي لما AR يوول الى مالانهاية)

لدينا $\prod_{\infty}(B) = \Theta_q(B)^{-1}$ المعاملات π_i يمكن الحصول عليها عن طريق معادلة المعاملات للعلاقة :

$$\Theta_q(B) \prod_{\infty}(B) = 1.$$

$$\Theta_q(B) \prod_{\infty}(B) = (1 + \theta_1 B + \dots + \theta_q B^q)(1 - \pi_1 B - \pi_2 B^2 \dots)$$

$$= 1 - (\pi_1 - \theta_1)B - (\pi_2 + \theta_1 \pi_1 - \theta_2)B^2 - \dots$$

$$= (\pi_j + \theta_1 \pi_{j-1} + \dots + \theta_{q-1} \pi_{j-q+1} + \theta_q \pi_{j-q})B^j - \dots$$

من خلال المعاملات B^j للعلاقة $\Theta_q(B) \prod_{\infty}(B) = 1 ; j = 1, 2, \dots$ ولدينا :

$$\pi_j = -\theta_1\pi_{j-1} - \theta_2\pi_{j-2} - \dots - \theta_{q-1}\pi_{j-q+1} - \theta_q\pi_{j-q}$$

حيث $\pi_0 = -1$ و $\pi_j = 0$ من أجل $j < 0$.

مثال رقم 20:

لتكن $MA(2)$ كالتالي $Y_t = \varepsilon_t - 0.1\varepsilon_t + 0.4\varepsilon_{t-1}$ قابلة للعكس.

الحل:

الجدور بالقيمة المطلقة:

$$(1 - 0.1B + 0.4B^2) = (1 \pm 0.7B)(1 + 0.6B) = 0$$

والآن $B_1 = \frac{1}{0.7} = 1.43 > 1$ و $B_2 = \left| \frac{1}{-0.6} \right| = 1.67 > 1$ ومنه السيروورة قابلة للعكس.

الآن السيروورة تمثل $AR(\infty)$ تكتب كما يلي: $Y_t = \sum_{i=1}^{\infty} \pi_i Y_{t-i} + \varepsilon_t$

$$\pi_j = -\theta_1\pi_{j-1} - \theta_2\pi_{j-2} - \dots - \theta_{q-1}\pi_{j-q+1} - \theta_q\pi_{j-q}; q = 2$$

حيث $\theta_1 = -0.1$ و $\theta_2 = 0.42$ و $\forall j > q$ فإن $\theta_j = 0$ و $\pi_0 = -1$ و $\forall j < 0$ فإن $\pi_j = 0$.

$$\pi_1 = -\theta_1\pi_0 - 0 \dots = -(-0.1)(-1) = -0.1$$

$$\pi_2 = -\theta_1\pi_1 - \theta_2\pi_0 \dots = -(-0.1)(-1) - (0.42)(-1) = 0.41$$

$$\pi_3 = -\theta_1\pi_2 - \theta_2\pi_1 - 0 \dots = -(-0.1)(0.41) - (0.42)(0.1) = 0.083$$

$$\pi_4 = -(-0.1)(0.083) - (0.42)(0.1) - 0 = -0.1639$$

التمثيل لـ $MA(2)$ لـ $AR(\infty)$ يكون كما يلي:

$$Y_t = \varepsilon_t - 0.1Y_{t-1} + 0.41Y_{t-2} + 0.083Y_{t-3} - 0.1639Y_{t-4} \dots$$

مثال رقم 20:

لتكن السيروورة $MA(2)$ كالتالي $Y_t = \varepsilon_t - \varepsilon_t + 0.5\varepsilon_{t-1}$.

: الحل

لتكن المعادلة $aX^2 + bX + c = 0$ حلو المعادلة هو $X = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$.

حلول المعادلة بالقيمة المطلقة $1 - B + 0.5B^2$ يكون كما يلي :

$$|B| = \left| \frac{-(-1) \pm \sqrt{(-1)^2 - 4(0.5)}}{2(0.5)} \right| = |1 \pm i|$$

حيث $i = \sqrt{-1}$

نتذكر القيمة المطلقة للأعداد المركبة حيث :

$$|a + ib| = \sqrt{a^2 + b^2} = \sqrt{1^2 + 1^2} = \sqrt{2} \cong 1.41 > 1$$

التمثيل لـ $AR(\infty)$ حيث $Y_t = \sum_{i=1}^{\infty} \pi_i Y_{t-i} + \varepsilon_t$ و $\pi_j = -\theta_1 \pi_{j-1} - \theta_2 \pi_{j-2}$ و $\theta_1 = -1$ و $\theta_2 = 0.5$ و $\pi_0 = -1$ و $\pi_1 = 0$ ومنه :

$$\pi_1 = -\theta_1 \pi_0 = -(-1)(-1) = -1$$

$$\pi_2 = -\theta_1 \pi_1 - \theta_2 \pi_0 = -(-1)(-1) - (0.5)(-1) = -0.5$$

$$\pi_3 = -\theta_1 \pi_2 - \theta_2 \pi_1 = -(-1)(0.5) - (0.5)(-1) = 0$$

$$\pi_4 = -\theta_1 \pi_3 - \theta_2 \pi_2 = -(-1)(0) - (0.5)(-0.5) = 0.25$$

ومنه التمثيل هو :

$$Y_t = \varepsilon_t - Y_{t-1} - 0.5Y_{t-2} + 0.25Y_{t-4} \dots$$

تمثيل $AR(1)$ على شكل $MA(\infty)$:

لتكن السلسلة Y_t الممثلة بـ $RA(1)$ سيروية حيث $\varepsilon_t \sim WN(0, \sigma^2)$ ومنه :

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

$$= \varphi(\varphi Y_{t-2} + \varepsilon_{t-1}) + \varepsilon_t$$

$$= \varepsilon_t + \varphi \varepsilon_{t-1} + \varphi^2 Y_{t-2}$$

$$= \varepsilon_t + \varphi \varepsilon_{t-1} + \varphi^2 (\varphi Y_{t-3} + \varepsilon_{t-2})$$

$$= \varepsilon_t + \varphi \varepsilon_{t-1} + \varphi^2 \varepsilon_{t-2} + \varphi^3 Y_{t-3}$$

∴ ...

$$Y_t = \sum_{j=0}^{\infty} \varphi^j \varepsilon_{t-j}$$

الذي هو تمثيل $MA(\infty)$ ، نلاحظ أن الجزء (ε_{t-i}) قد ينظر الى هذا التمثيل على أنه سلسلة هندسية، والتي تكون متقاربة إذا فقط إذا كان $|\varphi| < 1$.

- السيروورة $RA(1)$ مع معامل التأثير B يمكن أن تكتب كما يلي : $(1 - \varphi B)Y_t = \varepsilon_t$ حيث $\varepsilon_t \sim WN(0, \sigma^2)$ ومنه $Y_t = \frac{\varepsilon_t}{1 - \varphi B}$. إذا كانت $|\varphi B| < 1$ فإن سلسلة تايلور لـ

$$\frac{1}{1 - \varphi B} = 1 + \varphi B + \varphi^2 B^2 + \dots$$

$$\Rightarrow Y_t = (1 + \varphi B + \varphi^2 B^2 + \varphi^3 B^3 + \dots) \varepsilon_t = \sum_{j=0}^{\infty} \varphi^j \varepsilon_{t-j}$$

والذي هو تمثيل $MA(\infty)$.

*- خصائص التباين المشترك لـ AR :

لدينا التمثيل للسيروورة $RA(1)$ في $MA(\infty)$ هو : $Y_t = \sum_{j=0}^{\infty} \varphi^j \varepsilon_{t-j}$.

* المتوسط لـ Y_t ، (مستقل عبر الزمن) $E(Y_t) = E(\sum_{j=0}^{\infty} \varphi^j \varepsilon_{t-j}) = 0$.

* التباين $\gamma_Y(0) = E(\sum_{i=0}^{\infty} \varphi^{2i} \varepsilon_{t-i}^2) = \sigma^2 \sum_{i=0}^{\infty} \varphi^{2i} = \frac{\sigma^2}{1 - \varphi^2}$.

* التباين المشترك مستقل عبر الزمن كما يلي :

$$\gamma_Y(h) = E(Y_t Y_{t+h}) = \sum_{i=0}^{\infty} \sum_{j=h}^{\infty} \varphi^i \varphi^j E(\varepsilon_{t-i} \varepsilon_{t+h-j}) = \sigma^2 \sum_{i=0}^{\infty} \varphi^i \varphi^j$$

$$= \varphi^h \sigma^2 \sum_{i=0}^{\infty} \varphi^{2i} = \sigma^2 \frac{\varphi^h}{1-\varphi^2} .$$

$$. \rho_Y(h) = \frac{\gamma_Y(h)}{\gamma_Y(0)} = \varphi^h \text{ (مستقل عبر الزمن) : معامل الارتباط الذاتي} *$$

مثال رقم 21:

معامل دالة الارتباط الذاتي للسيرورة المستقرة $AR(1)$ $\varepsilon_t \sim WN(0,4)$ و $Y_t = 0.6Y_{t-1} + \varepsilon_t$

الحل :

$$\rho_Y(h) = \varphi^h = 0.6^h \quad \forall h > 0 .$$

$$\rho_Y(0) = 1 ; \rho_Y(1) = 0.6 ; \rho_Y(2) = 0.6^2 = 0.36 .$$

ليكن النموذج $AR(p)$: $Y_t = \sum_{i=1}^p \varphi_i Y_{t-i} + \varepsilon_t$ حيث $\varepsilon_t \sim WN(0, \sigma^2)$.

$$E(Y_t) = 0 \quad * \text{ التوقع الرياضي لـ } Y_t :$$

$$\text{var}(Y_t) = \gamma_Y(0) = \sum_{i=1}^p \varphi_i^2 \gamma_Y(i) + \sigma^2 \quad * \text{ التباين لـ } Y_t \text{ يكون:}$$

$$\gamma_Y(i) = \text{cov}(Y_t, Y_{t-i}) \text{ حيث}$$

نلاحظ أن التباين لـ Y_t يتم الحصول عليه بضرب طرفي المعادلة أعلاه بـ Y_t وأخذ التوقع

حيث : $E(Y_t \varepsilon_t) = \sigma^2$ ، بضرب طرفي المعادلة: $Y_t = \sum_{i=1}^p \varphi_i Y_{t-i} + \varepsilon_t$ بـ Y_{t-h}

وبعد أخذ التوقع نتحصل على ما يلي :

$$\gamma_Y(h) = \sum_{i=1}^p \varphi_i \gamma_Y(h-i) \quad \forall h > 0$$

نقسم طرفي المعادلة على $\gamma_Y(0)$ نتحصل على معاملات دالة الارتباط الذاتي :

$$\rho_Y(h) = \sum_{i=1}^p \varphi_i \rho_Y(i-h) .$$

وهذه معادلات يؤول ولكر التي تكلمنا عليها سابقا .

تعريف :

الشرط بالنسبة للإنحدار الذاتي للسيرورة $AR(1)$ ، $Y_t = \varphi Y_{t-1} + \varepsilon_t$ لكي تكون مستقرة، يجب أن تكون القيمة المطلقة لجذور الوحدة $(1 - \varphi B) = 0$ خارج دائرة الوحدة، هذا يعني أن $AR(1)$ مستقرة إذا كان $|B| = \left| \frac{1}{\varphi} \right| > 1$ أو $|\varphi| < 1$.

$$* (1 - 0.4B)Y_t = \varepsilon_t \text{ مستقرة لأن القيمة المطلقة للجذر :}$$

$$(1 - 0.4B) = 0 \Rightarrow |B| = \left| \frac{1}{0.4} \right| = 2.5 > 1$$

$$* (1 + 1.8B)Y_t = \varepsilon_t \text{ ليست مستقرة لأن القيمة المطلقة للجذر :}$$

$$(1 + 1.8B) = 0 \Rightarrow |B| = \left| \frac{1}{-1.8} \right| = 0.56 < 1$$

$$* Y_t = 0.5Y_{t-1} + \varepsilon_t \text{ مستقرة لأن } |0.5| < 1.$$

نظرية :

بالنسبة لنماذج $AR(2)$ ، الشروط الضرورية والكافية للإستقرار هي :

$$* |\varphi_2| < 1$$

$$* \varphi_1 + \varphi_2 < 1$$

$$* \varphi_2 - \varphi_1 < 1$$

مثال رقم 22:

$$* Y_t = 1.1Y_{t-1} - 0.4Y_{t-2} + \varepsilon_t \text{ مستقرة .}$$

$$* Y_t = 0.6Y_{t-1} - 1.3Y_{t-2} + \varepsilon_t \text{ ليست مستقرة لأن } (|\varphi_2| \not< 1).$$

$$* Y_t = 0.6Y_{t-1} + 0.8Y_{t-2} + \varepsilon_t \text{ ليست مستقرة لأن } (|\varphi_1 + \varphi_2| \not< 1).$$

$$* Y_t = -0.4Y_{t-1} + 0.7Y_{t-2} + \varepsilon_t \text{ ليست مستقرة لأن } (\varphi_2 - \varphi_1 \not< 1).$$

تعريف :

الشرط بالنسبة للانحدار الذاتي للسيرورة $AR(p)$ من الدرجة p ،

الشرط بالنسبة للانحدار الذاتي للسيرورة $AR(p)$ من الدرجة p ،
 $Y_t = \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$ لكي تكون مستقرة، يجب أن تكون القيمة المطلقة
 لجذور الوحدة $(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p) = 0$ خارج دائرة الوحدة .

مثال رقم 23:

* $Y_t = -0.4Y_{t-1} + 0.2Y_{t-2} + \varepsilon_t$ سيرورة مستقرة لأن القيمة المطلقة الجذور :

$$(1 + 0.4B - 0.21B^2) = (1 - 0.3B)(1 + 0.7B) = 0$$

الحلول هي : $|B_1| = \left| \frac{1}{0.3} \right| = 3.3 > 1$ و $|B_2| = \left| \frac{1}{-0.7} \right| = 1.4 > 1$

* $Y_t = 1.7Y_{t-1} - 0.42Y_{t-2} + \varepsilon_t$ السيرورة ليست مستقرة لأن القيمة المطلقة الجذور :

$$(1 - 1.74B + 0.42B^2) = (1 - 0.3B)(1 - 1.4B) = 0$$

لأن $|B_2| = \left| \frac{1}{1.14} \right| = 0.71 < 1$

* $Y_t = -0.25Y_{t-2} + \varepsilon_t$ السيرورة ليست مستقرة لأن القيمة المطلقة الجذور :

$$1 + 0.25B^2 = 0$$

لأن $|B| = |\sqrt{-2}| = 2 > 1$ حيث $i = -1$.

4- سببية $AR(p)$ في ما لا نهاية لتمثيل $MA(q)$:

* **السببية :** تشير السببية لسلسلة زمنية مستقرة إلى أن السلاسل تعتمد أن السلاسل الزمنية
 تعتمد على قيم الماضي بشكل أساسي .

* السيرورة $AR(p)$ و $\Phi_p(B)Y_t = \varepsilon_t$ حيث $\Phi_p(B) = 1 - \sum_{i=1}^p \varphi_i B^i$ و $\varepsilon_t \sim WN(0, \sigma^2)$ ، سيرورة سببية، إذا كان يمكن كتابتها بدلالة ما لا نهاية لتمثيل

$MA(\infty)$ كما يلي :

$$\Phi_p(B)^{-1}\Phi_p(B)Y_t = \Phi_p(B)^{-1}\varepsilon_t$$

$$\Rightarrow Y_t = \Phi_p(B)^{-1}\varepsilon_t = \Psi_\infty(B)\varepsilon_t = \sum_{i=0}^{\infty} \psi_i \varepsilon_{t-i}$$

حيث : $\Psi_\infty(B) = 1 + \sum_{i=1}^{\infty} \psi_i B^i$ و $\Psi_\infty(B) = \Phi_p(B)^{-1}$

حيث : $\Psi_\infty(B) = 1 + \sum_{i=1}^{\infty} \psi_i B^i$ و $\Psi_\infty(B) = \Phi_p(B)^{-1}$

$\Psi_\infty(B) = \Phi_p(B)^{-1}$ لأن $\psi_0 = 1$ و $\sum_{i=0}^{\infty} |\psi_i| < \infty$ إذا كانت ψ_i تكون مقبولة إذا كانت معاملات ψ_i يمكن الحصول عليها من خلال العلاقة :

$$\Phi_p(B)\Psi_\infty(B) = 1$$

$$\Phi_p(B)\Psi_\infty(B) = (1 - \varphi_1 B - \dots - \varphi_p B^p)(1 + \psi_1 B + \psi_2 B^2 + \dots)$$

$$= 1 + (\psi_1 - \varphi_1)B + (\psi_2 - \psi_1\varphi_1 - \varphi_2)B^2 + \dots$$

$$+ (\psi_i - \varphi_1\psi_{i-1} - \dots - \varphi_p\psi_{i-p})B^i + \dots$$

من خلال المعاملات B^i للعلاقة :

$$\cdot i = 1, 2, \dots \text{ من أجل } \Phi_p(B)\Psi_\infty(B) = 1$$

$$\psi_i = \varphi_1\psi_{i-1} + \varphi_2\psi_{i-2} + \dots + \varphi_{p-1}\psi_{i-p+1} + \varphi_p\psi_{i-p}$$

حيث $\psi_0 = 1$ و $\psi_i = 0$ من أجل $i < 0$

مثال رقم 24:

لتكن السيرورة AR(2) التالية :

$$Y_t = 0.1Y_{t-1} - 0.42Y_{t-2} + \varepsilon_t$$

حيث $p = 2$ و $\varphi_1 = 0.1$ و $\varphi_2 = -0.42$ من أجل $\varphi_i = 0 \quad \forall i > p$

الحل :

جذر كثير الحدود $(1 - 0.1B + 0.42B^2)$ ومنه $(1 - 0.7B)(1 + 0.6B)$ ومنه الحلول هي: $|B_1| \left| \frac{1}{0.7} \right| = 1.43 > 1$ و $|B_2| \left| \frac{1}{-0.6} \right| = 1.67 > 1$ ومنه السيروورة مستقرة - سببية.

الآن السيروورة لـ $MA(\infty)$ يمكن تمثيلها كما يلي: $Y_t = \sum_{i=0}^{\infty} \psi_i \varepsilon_{t-i}$.

حيث $\psi_0 = 1$ وكذلك $\psi_i = \varphi_1 \psi_{i-1} + \varphi_2 \psi_2 + \dots + \varphi_{p-1} \psi_{i-p+1} + \varphi_p \psi_{i-p}$ و $\psi_i = 0$ من أجل $i < 0$ و $\varphi_i = 0$ من أجل $i > p$.

$$\psi_1 = \varphi_1 \psi_0 = (0.1)(1) = 0.1$$

$$\psi_2 = \varphi_1 \psi_1 - \varphi_2 \psi_0 = (0.1)(0.1) + (-0.42)(1) = -0.41$$

$$\psi_3 = \varphi_1 \psi_2 - \varphi_2 \psi_1 = (0.1)(-0.41) + (-0.42)(0.1) = 0 - 0.083$$

$$\psi_4 = \varphi_1 \psi_3 - \varphi_2 \psi_2 = (0.1)(0.083) + (-0.42)(-0.41) = 0.1639$$

السيروورة $AR(2)$ في $MA(\infty)$ كما يلي:

$$Y_t = \varepsilon_t + 0.1\varepsilon_{t-1} - 0.41\varepsilon_{t-2} - 0.083\varepsilon_{t-3} + 0.1639\varepsilon_{t-4} \dots$$

نتذكر أن نماذج $ARMA(p, q)$ يمكن أن تمثل كما يلي :

$$\Phi_p(B)Y_t = \Theta_q(B)\varepsilon_t .$$

$$\Phi_p(B) = 1 - \sum_{i=1}^p \varphi_i B^i .$$

$$\Theta_q(B) = 1 + \sum_{j=1}^q \theta_j B^j .$$

تحت شروط الإستقرارية لدينا صيغة $MA(\infty)$:

$$Y_t = \Psi_{\infty}(B)\varepsilon_t .$$

حيث $\Psi_{\infty}(B) = \Phi_p(B)^{-1}\Theta_q(B) = \sum_{i=0}^{\infty} \psi_i B^i$.

علي غرار حالة نموذج AR، معاملات ψ_i يمكن أن تشتق من معاملات العلاقة :

$$\Phi_p(B)\Psi_\infty(B) = \Theta_q(B) .$$

ψ_i مقبولة كانت :

$$\psi_i = \varphi_1\psi_{i-1} + \varphi_2\psi_{i-2} + \dots + \varphi_{p-1}\psi_{i-p+1} + \varphi_p\psi_{i-p} + \theta_i \quad ; i = 1, 2, \dots$$

حيث $\psi_0 = 1$ و $\psi_i = 0$ من أجل $i < 0$ و $\theta_i = 0$ من أجل $i > q$.

تحت شروط الإنعكاسية، لدينا صيغة $AR(\infty)$:

$$\Psi_\infty(B)Y_t = \varepsilon_t .$$

$$\Psi_\infty(B) = \Phi_p(B)^{-1}\Theta_q(B) = 1 - \sum_{i=1}^{\infty} \psi_i B^i$$

علي غرار حالة نموذج MA، معاملات π_i يمكن أن تحدد من معاملات العلاقة :

$$\Theta_q(B)\Psi_\infty(B) = \Phi_p(B) .$$

π_i مقبولة إذا كانت :

$$\pi_i = -\theta_1\pi_{i-1} - \theta_2\pi_{i-2} - \dots - \theta_{q-1}\pi_{i-q+1} - \theta_q\pi_{i-q} + \varphi_i \quad ; i = 1, 2, \dots$$

حيث $\pi_0 = -1$ و $\pi_i = 0$ من أجل $i < 0$ و $\varphi_i = 0$ من أجل $i < 0$.

5- السيرورة الخطية الموسمية :

1-5 السيرورة AR الموسمية :

سيرورة الإنحدار الذاتي الموسمية يرمز لها بالرمز $AR(P)_S$ حيث S تمثل الخطوة في الزمن ثابتة ومختلفة عن الواحد. نعطي لها إسم الفترة للسيرورة AR المستقرة من أجل S و P هو درجة السيرورة AR الموسمية.

$$\text{لدينا : } \Phi_p(B) = 1 - \sum_{i=1}^p \varphi_i B^i \text{ و } \Theta_q(B) = 1 + \sum_{i=1}^q \theta_i B^i .$$

$$\text{و } \Phi_P(B^S) = 1 - \sum_{i=1}^P \varphi_{is} B^{is} \text{ و } \Theta_Q(B^S) = 1 + \sum_{i=1}^Q \theta_{is} B^{is} .$$

والشكل العام للسيرورة AR الموسمية :

$$Y_t = \varphi_{1s}Y_{t-s} + \varphi_{2s}Y_{t-2s} \cdots + \varphi_{ps}Y_{t-ps} + \varepsilon_t$$

وتسمى $SAR(p)_s$. حيث :

$$* (12 \text{ مشاهدة في السنة}) \text{ مشاهدات شهرية } S = 12$$

$$* (4 \text{ مشاهدات في السنة}) \text{ مشاهدات فصلية } S = 4$$

$$* (365 \text{ مشاهدة في السنة}) \text{ مشاهدات يومية } S = 365$$

$$* (52 \text{ مشاهدة في السنة}) \text{ مشاهدات أسبوعية } S = 52$$

2-5 السيرورة MA الموسمية :

سيرورة المتوسط المتحرك، يرمز لها بالرمز $MA(Q)_s$ حيث S تمثل الخطوة في الزمن ثابتة. ومختلف عن الواحد Q . هو درجة السيرورة MA الموسمية. والشكل العام للسيرورة MA الموسمية :

$$Y_t = \theta_s\varepsilon_{t-s} + \theta_{2s}\varepsilon_{t-2s} + \cdots + \theta_{Qs}\varepsilon_{t-Qs} + \varepsilon_t$$

وتسمى كذلك $SMA(Q)_s$.

3-5 السيرورة $ARMA$ الموسمية :

السيرورة المختلطة الموسمية، يرمز لها بالرمز $ARMA(P, Q)_{s,s}$ حيث S, S' حيث الخطوة في الزمن ثابتة ومختلفة عن الواحد. والتي تأخذ الشكل التالي :

$$Y_t = \varphi_{1s}Y_{t-s} + \varphi_{2s}Y_{t-2s} \cdots + \varphi_{ps}Y_{t-ps} + \theta_s\varepsilon_{t-s} + \theta_{2s}\varepsilon_{t-2s} \\ + \cdots + \theta_{Qs}\varepsilon_{t-Qs} + \varepsilon_t$$

مثال رقم 25:

السيرورة $ARMA(1,2)_{12,6}$ تكتب كما يلي :

$$Y_t = \varphi_{12}Y_{t-12} + \theta_6\varepsilon_{t-6} + \varphi_{12}\varepsilon_{t-12} + \varepsilon_t$$

على شكل كثير حدود معاملات التأخير السيرورة ARMA الموسمية يمكن كتابتها كما يلي :

$$Y_t - \varphi_{1s}Y_{t-s} - \varphi_{2s}Y_{t-2s} \cdots - \varphi_{ps}Y_{t-ps} \\ = \theta_s \varepsilon_{t-s} + \theta_{2s} \varepsilon_{t-2s} + \cdots + \theta_{Qs} \varepsilon_{t-Qs} + \varepsilon_t$$

$$Y_t - \varphi_{1s}B^s Y_t - \varphi_{2s}B^{2s} Y_t \cdots - \varphi_{ps}B^{Ps} Y_t \\ = \theta_s B^s \varepsilon_t + \theta_{2s} B^{2s} \varepsilon_t + \cdots + \theta_{Qs} B^{Qs} \varepsilon_t + \varepsilon_t$$

$$(1 - \varphi_s B^s - \cdots - \varphi_{ps} B^{Ps}) Y_t = (1 + \theta_s B^s + \cdots + \theta_{Qs} B^{Qs}) \varepsilon_t \Leftrightarrow$$

$$\Phi_p(B^s) Y_t = \Theta_Q(B^s) \varepsilon_t$$

يمكن إضافة ثابت للسيرورة $ARMA(P, Q)_{s,s}$ في هذه الحالة السيرورة يمكن كتابتها كما يلي : $\Phi_p(B^s) Y_t = \mu + \Theta_Q(B^s) \varepsilon_t$.

إن شروط إستقرارية وقابلية العكس للسيرورة ARMA الموسمية مماثلة لشروط إستقرارية وقابلية العكس للسيرورة ARMA الغير موسمية .

ملاحظة :

إن السيرورة ARMA الموسمية تسمى عند بعض الكتاب والباحثين بالسيرورة SARMA .

6- السيرورة الخطية الغير موسمية و الموسمية في نفس الوقت:

1-6 السيرورة AR التجميعية:

وتكتب كما يلي : $AR(p) + AR(P)_s = (\Phi_p(B) + \Phi_p(B^s) + 1) Y_t = \varepsilon_t$ و

2-6 السيرورة MA التجميعية:

وتكتب كما يلي : $MA(q) + MA(Q)_s = (\Theta_q(B) + \Theta_Q(B^s) - 1) \varepsilon_t$ و

3-6 السيرورة ARMA التجميعية:

وتكتب كما يلي : $ARMA(p, q) + ARMA(P, Q)_{s, \acute{s}}$ و :

$$\cdot (\Phi_p(B) + \Phi_p(B^s) + 1)Y_t = (\Theta_q(B) + \Theta_q(B^{\acute{s}}) - 1)\varepsilon_t .$$

4-6 السيرورة AR التضاعفية:

وتكتب كما يلي : $AR(p) \times AR(P)_s$ و $\Phi_p(B)\Phi_p(B^s)Y_t = \varepsilon_t$ حيث $p < S$ وهو مكافئ للسيرورة $AR(p + PS)$

5-6 السيرورة MA التضاعفية:

وتكتب كما يلي : $MA(q) \times MA(Q)_{\acute{s}}$ و $Y_t = \Theta_q(B)\Theta_q(B^{\acute{s}})\varepsilon_t$ حيث $q < \acute{s}$ وهو مكافئ للسيرورة $MA(q + Q\acute{s})$.

6-6 السيرورة ARMA التضاعفية:

وتكتب كما يلي : $ARMA(p, q) \times ARMA(P, Q)_{s, \acute{s}}$ و :

$\Phi_p(B)\Phi_p(B^s)Y_t = \Theta_q(B)\Theta_q(B^{\acute{s}})\varepsilon_t$ حيث $p < s$ و $q < \acute{s}$ وهو مكافئ للسيرورة $ARMA(p + PS, q + Q\acute{s})$ ومنه :

$$(1 - \varphi_1 B - \dots - \varphi_p B^p)(1 - \varphi_s B^s - \dots - \varphi_{Ps} B^{Ps})Y_t = (1 + \theta_1 B + \dots + \theta_q B^q)(1 + \theta_{\acute{s}} B^{\acute{s}} + \dots + \theta_{Q\acute{s}} B^{Q\acute{s}})\varepsilon_t$$

هذه السيرورة ARMA الغير موسمية والموسمية في نفس الوقت لها شروط تواجد دائما مماثلة للسيرورة ARMA الغير موسمية ،ويمكن أن تتواجد مع ثابت في الطرف الثاني من المعادلة.

مثال رقم 26:

أكتب هذه السيرورة علي شكل كثير حدود بدلالة معامل التأخير :

$$ARMA(1,2) \times ARMA(1,1)_{6,12}$$

الحل :

$$(1 - \phi_1 B)(1 - \phi_6 B^6)Y_t = (1 + \theta_1 B + \theta_2 B^2)(1 + \theta_{12} B^{12})\varepsilon_t \Leftrightarrow$$

$$(1 - \phi_1 B - \phi_6 B^6 + \phi_1 \phi_6 B^7)Y_t \\ = (1 + \theta_1 B + \theta_2 B^2 + \theta_{12} B^{12} + \theta_1 \theta_{12} B^{13} + \theta_2 \theta_{12} B^{14})\varepsilon_t$$

ملاحظة :

السيروورة $ARMA(1,2) + ARMA(1,1)_{6,12}$ نكتب كما يلي:

$$[(1 - \phi_1 B) + (1 - \phi_6 B^6) + 1]Y_t \\ = [(1 + \theta_1 B + \theta_2 B^2) + (1 + \theta_{12} B^{12}) - 1]\varepsilon_t \Leftrightarrow$$

$$[1 - \phi_1 B - \phi_6 B^6]Y_t = [1 + \theta_1 B + \theta_2 B^2 + \theta_{12} B^{12}]\varepsilon_t$$

الفصل الرابع : السيروورات الخطية للسلاسل الزمنية الغير مستقرة ARIMA :

في حقيقة الأمر أن معظم السلاسل الزمنية الفعلية التي تنشأ في الإقتصاد ومجال الأعمال والبيئة وغيرها غالبا ما تكون غير مستقرة في المتوسط ولكنها تتميز بخاصية تعرف بالتجانس، وبقصد بهذه الخاصية أنه بالرغم من أن المتوسط الحسابي لمثل هذه العمليات قد يتغير مع الزمن، إلا أن أجزاء من السلسلة تسلك سلوكا متشابها إلى حد كبير يمكن معه تحويل هذه السلاسل إلى سلاسل مستقرة، ومن ناحية أخرى، ويغض النظر عن إستقرار المتوسط من عدمه. فإن كثير من السلاسل الفعلية التي تنشأ في فروع المعرفة المختلفة خاصة في الإقتصاد والبيئة يتغير تباينها بتغير الزمن (غالبا ما يتزايد) وهذا التغير عادة ما يأخذ نمط معين. مثل

هذه السيرورات (السلاسل) أيضا يمكن تحويلها إلى سلاسل مستقرة باستخدام بعض التحويلات الرياضية البسيطة .

وتجدر الإشارة بالقول بأن التحويلات الرياضية التي تستخدم في إستقرار السلاسل لا يقتصر استخدامها مع النماذج العشوائية DS(differencing stationary)، ليشمل النماذج المحددة (غير العشوائية) TS(trend stationary)، ولهذا يوجد نوعين من السلاسل الغير مستقرة.

1- السيرورة TS(trend statinary) :

هذه النماذج غير مستقرة وتبرر عدم إستقرارية تحديدية أي بمعنى وجود إتجاه عام تحديدي deterministic trend ويأخذ الشكل $Y_t = f(t) + \varepsilon_t$ هي دالة كثير حدود للزمن قد تكون خطية غير خطية. و ε_t تمثل خطأ التشويش الأبيض. وأكثر هذه النماذج إنتشارا هو كثير الحدود من الدرجة الأولى والذي يكتب على الشكل التالي: $Y_t = a_0 + a_1t + \varepsilon_t$ وخصائص هذه السيرورة هي :

$$* E(Y_t) = E[a_0 + a_1t + \varepsilon_t] = a_0 + a_1t.$$

$$* \text{var}(Y_t) = E[a_0 + a_1t + \varepsilon_t - (a_0 + a_1t)]^2 = E[0 + \varepsilon_t]^2 = E(\varepsilon_t^2) = \sigma_\varepsilon^2.$$

$$* \text{cov}(Y_t, Y_{t'}) = 0 ; \forall t \neq t'.$$

هذا النموذج غير مستقر لأن توقعه الرياضي $E(Y_t)$ مرتبط بالزمن لكننا نجعله مستقرا بتقدير المعلمات \hat{a}_0 و \hat{a}_1 بطريقة المربعات الصغرى (OLS) وطرح المقدار $\hat{a}_0 + \hat{a}_1t$ من Y_t أي $\hat{Y}_t - \hat{a}_0 + \hat{a}_1t$. في هذا النوع من النمذجة، يكون التأثير ناتج عن صدمة ما (أو صدمات عشوائية) في اللحظة t .

2- السيرورة DS(differency stationary) :

هذه النماذج أيضا غير مستقرة، ولها خاصية عدم إستقرارية عشوائية أي وجود إتجاه عام عشوائي stochastic trend، ويأخذ شكل نموذج $Y_t = Y_{t-1} + a + \varepsilon_t$ حيث ε_t يمثل التويش الأبيض، a عدد ثابت حقيقي، يمكننا جعلها بأخذ الفروقات لها :

الدرجة الأولى $d = 1$ وتكتب على الشكل التالي: $\Delta Y_t = (1 - B)Y_t = a + \varepsilon_t$. تأخذ هذه النماذج شكل :

* إذا كان $a = 0$ يسمى نموذج DS بدون مشتقة ويسمى كذلك بنموذج السير العشوائي (random walk model) ويكتب على شكل: $Y_t = Y_{t-1} + \varepsilon_t$ ، كثيرا ما يستخدم لتحليل كفاءة الأسواق المالية. لدراسة خصائص هذا النموذج نحاول كتابة في شكله الموسع :

$$Y_1 = Y_0 + \varepsilon_1$$

$$Y_2 = Y_1 + \varepsilon_{t-1} = Y_0 + \varepsilon_1 + \varepsilon_2$$

∴ ...

$$Y_t = Y_0 + \sum_{i=1}^t \varepsilon_i$$

خصائص هذه السيرورة (بافتراض أن Y_0 معلومة) :

$$* E(Y_t) = Y_0.$$

$$* \text{var}(Y_t) = \text{var}(\sum_{i=1}^t \varepsilon_i) = t\sigma_\varepsilon^2.$$

$$* \text{cov}(Y_t, Y_{t'}) = \text{Min}(t, t')\sigma_\varepsilon^2 \quad \forall t \neq t'.$$

مثال رقم 27:

$$\text{cov}(Y_4, Y_2) = E[(Y_0 + \varepsilon_1 + \varepsilon_2 + \varepsilon_3 + \varepsilon_4 - Y_0)(Y_0 + \varepsilon_1 + \varepsilon_2 - Y_0)]$$

$$= E(\varepsilon_1\varepsilon_1) + E(\varepsilon_2\varepsilon_2) = 2\sigma_\varepsilon^2$$

في الواقع نعلم أن كل جداء $t \neq t'$ فإن $E(\varepsilon_t\varepsilon_{t'}) = 0$ هذه السيرورة غير مستقرة في التباين لأنه مرتبط بالزمن. نعتبر هذه السيرورة عشوائية، ولهذا علينا تطبيق الفرق من الدرجة

$$\text{الأولى: } Y_t = Y_{t-1} + \varepsilon_t \Leftrightarrow (1 - B)Y_t = \varepsilon_t .$$

* إذا كان $a \neq 0$ يسمى نموذج DS مع المشتقة والتي تكتب كما يلي :

$$Y_t = Y_{t-1} + a + \varepsilon_t .$$

كما أنه في السابق يمكن إيجاد شكل مكافئ موسع :

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

$$Y_{t-1} = Y_{t-2} + a + \varepsilon_{t-1} \Rightarrow Y_t = Y_{t-2} + 2a + \varepsilon_{t-1} + \varepsilon_t$$

$$Y_{t-2} = Y_{t-3} + a + \varepsilon_{t-2} \Rightarrow Y_t = Y_{t-3} + 3a + \varepsilon_{t-2} + \varepsilon_{t-1} + \varepsilon_t$$

لو فرضنا أن قيمة Y_0 معروفة ومحددة إذن الشكل يصبح كمايلي :

$$.Y_t = Y_0 + at + \sum_{i=1}^t \varepsilon_i$$

نستطيع تحليل خصائص هذه السيرورة :

$$* E(Y_t) = Y_0 + at .$$

$$* \text{var}(Y_t) = \text{var}(\sum_{i=1}^t \varepsilon_i) = t\sigma_\varepsilon^2 .$$

$$* \text{cov}(Y_t, Y_t) = \text{Min}(t, t)\sigma_\varepsilon^2 \quad \forall t \neq t .$$

السيرورة غير مستقرة بالنسبة لتوقعها وتباينها .

من خلال التوقع ، هذا الشكل هو نفسه نموذج TS ، حيث يمكن أن ندرك بأن هذه السيرورة غير مستقرة تحديدية وعشوائية في نفس الوقت .

يتم إستقرار هذه السيرورة بإستخدام معامل الفرق من الدرجة الأولى .

$$.Y_t = Y_{t-1} + a + \varepsilon_t \Leftrightarrow (1 - B)Y_t = a + \varepsilon_t$$

لنستخدم النموذج الموسع :

$$Y_t = Y_0 + at + \sum_{i=1}^t \varepsilon_i$$

$$Y_{t-1} = Y_0 + a(t - 1) + \sum_{i=1}^{t-1} \varepsilon_i$$

ومنه :

$$Y_t - Y_{t-1} = (1 - B)Y_t = a + \varepsilon_t$$

في السيرورات من نوع DS ، الصدمة في لحظة معينة ، يكون لها انعكاس غير محدود على القيم المستقبلية للسلسلة ، وبالتالي تأثير الصدمة يكون دائم ويقل عبر الزمن .

نلخص ، لجعل السيرورة TS مستقرة ، أحسن طريقة هي طريقة المربعات الصغرى ، بالنسبة للسيرورة DS يجب استخدام معاملات الفرق .

* الفرق TD و DS :

TDP	TSP
1- ليست مستقرة .	1- ليست مستقرة .
2- مستقرة بعد أخذ الفرق .	2- مستقرة بإزالة الاتجاه .
3- الاتجاه في المتوسط ، اتجاه محدد أو لا يوجد اتجاه محدد في المتوسط أي بدون اتجاه محدد .	3- الاتجاه في المتوسط اتجاه محدد .
4- اتجاه على مستوى التباين أو التباين المشترك ، اتجاه عشوائي ، يتضمن الاتجاه العشوائي جميع الصدمات العشوائية $(\varepsilon_1 \dots \varepsilon_t)$ التي لها تأثير دائم على مستوى Y_t .	4- لا يوجد اتجاه في التباين أو التباين المشترك .
5- تأثير الصدمة دائم يستمر لمدة طويلة .	5- تأثير الصدمة مؤقت ، تأثير قصير .

الفصل الخامس : إختبارات جذر الوحدة :

إن السلاسل الزمنية مستقرة ، لكن في العموم السلاسل غير مستقرة ، وجذر الوحدة يعني خصائص الجذور التي تساوي واحد ، وكذلك وجود جذر وحدة ، هذا يستلزم أن السلسلة غير مستقرة ، ويوجد عدة طرق للكشف عن إستقرار السلسلة من عدمها من بينها رسم البيانات وكذلك رسم دالة الارتباط الذاتي الجزئي . ولكن رسم ACF ضعيف في الكشف عن جذر الوحدة يوجد الكثير من الإختبارات الإحصائية للكشف عن وجود جذر وحدة .

1- إختبار ديكي فولر :

يعمل إختبار ديكي فولر Dicky Fuller 1979 على البحث عن إستقرارية السلسلة أو عدمها. وذلك بمعرفة مركبة الإتجاه العام للسلسلة سواء كانت تحديدية deterministic أو عشوائية stochastic، ولهذا إختبار ديكي فولر يتمثل في النموذج $AR(1)$ كالتالي :

$$.Y_t = \varphi_1 Y_{t-1} + \varepsilon_t \dots (1)$$

$$.Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varepsilon_t \dots (2)$$

$$.Y_t = \varphi_0 + \varphi_1 Y_{t-1} + bt + \varepsilon_t \dots (3)$$

قبل القيام بإجراء ،نحتاج إلى تقدير النموذج بطريقة المربعات الصغرى،بالنسبة للنموذج $AR(1)$ وجود جذر وحدة يعني أن $|\varphi_1| = 1$.

لذلك يوجد فرضيات للإختبار بعد التقدير :

$$.H_0: |\varphi_1| = 1$$

$$.H_1: |\varphi_1| < 1$$

قبول الفرضية H_0 يعني وجود إتجاه عام. أو النموذج نموذج سير عشوائي ،وقبول الفرضية H_1 يعني أن السلسلة مستقرة ،وهذا بالنسبة للمعادلة للمعادلة (1) و (2) .

أما بالنسبة للمعادلة (3) الفرضيات تكون كما يلي :

$$.H_0: |\varphi_1| = 1 ; b = 0$$

$$.H_1: |\varphi_1| < 1 \quad b \neq 0$$

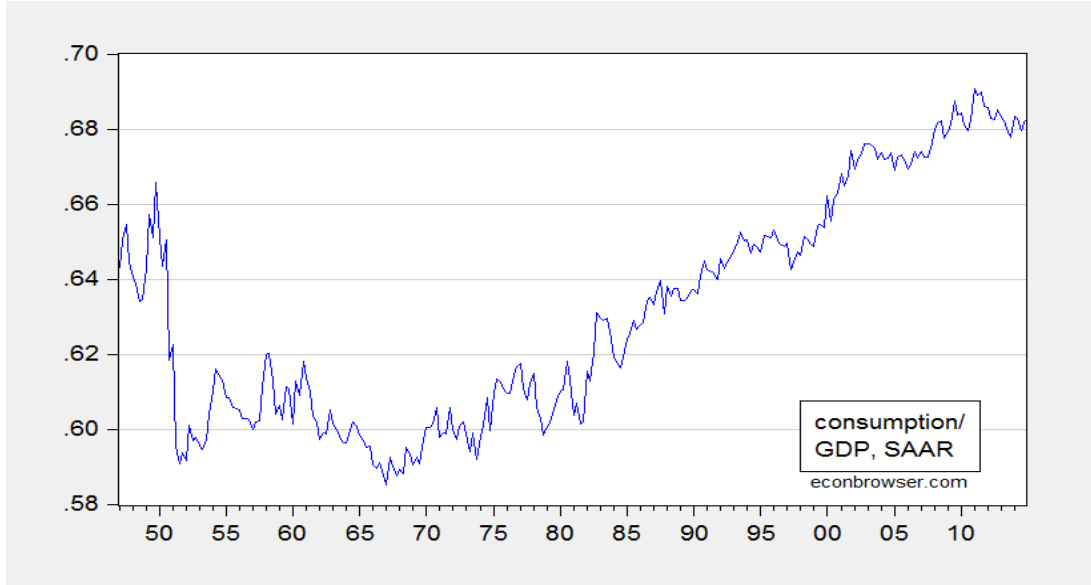
قبول H_0 يعني أن السيرورة من نوع DSP وقبول H_1 يعني أن السيرورة من نوع TSP يعد تحديد النموذج أمرا بالغ الأهمية لإختبار جذر الوحدة. إذا كانت مشاهدات السلسلة لا تظهر إتجاها متزايدا او متناقصا. إذن النموذج المناسب، إما النموذج (1) أو (2) .

الأشكال التالية توضح المسار الزمني لسلسلة ذات إتجاه .

* الحالة الأولى : سلسلة بدون جذر وحدة .



* الحالة الثانية : السلسلة تحتوي جذر وحدة .



يرتكز إختبار ديكي فولر Dicky Fuller على النماذج الثلاثة التالية :

* النموذج الأول : إختبار جذر الوحدة بدون ثابت (drift) وبدون إتجاه .

$$\Delta Y_t = \lambda Y_t + \varepsilon_t \dots (4)$$

* النموذج الثاني : إختبار جذر الوحدة بثابت (with drift).

$$\Delta Y_t = \varphi_0 + \lambda Y_t + \varepsilon_t \dots (5)$$

* النموذج الثالث : إختبار جذر الوحدة بثابت (with drift) وإتجاه تحديدي .

$$\Delta Y_t = \varphi_0 + bt + \lambda Y_t + \varepsilon_t \dots (6)$$

يمكن تقدير هذه النماذج وإختبار جذر الوحدة وفق الفرضيات التالية :

* الفرضيات بالنسبة للنموذج (4) و (5) هي :

$$.H_0: |\lambda| = 0$$

$$.H_1: |\lambda| < 0$$

* الفرضيات بالنسبة للنموذج (6) هي :

$$.H_0: |\lambda| = 0 ; b = 0$$

$$.H_1: |\lambda| < 0 \quad b \neq 0$$

ملاحظة :

إختبار جذر الوحدة يكون من الطرف الأيسر على طرف واحد .

بعد تقدير $\hat{\varphi}_1$ بطريقة OLS المربعات الصغرى فإن :

$$\hat{\varphi}_1 = \frac{\sum_{t=1}^n Y_{t-1} Y_t}{\sum_{t=1}^n Y_{t-1}^2} \quad \text{أو} \quad \hat{\varphi}_1 = \varphi_1 + \frac{\sum_{t=1}^n Y_{t-1} \varepsilon_t}{\sum_{t=1}^n Y_{t-1}^2}$$

وكذلك لدينا التوقع لـ $\hat{\varphi}_1$ هو $E(\hat{\varphi}_1) = \varphi_1$ مقدر غير متحيز. وكذلك التباين هو :

$$\text{var}(\hat{\varphi}_1) = \frac{\sigma^2}{\sum_{t=1}^n Y_{t-1}^2} = \frac{\sigma^2}{\frac{n \sum_{t=1}^n Y_{t-1}^2}{n}} = \frac{\sigma^2}{\frac{n \sigma^2}{1 - \varphi_1^2}} = \frac{1 - \varphi_1^2}{n} .$$

لدينا $\varepsilon_t \sim WN(0, \sigma^2)$ ، وتحت قبول الفرضية H_1 أي Y_t مستقرة بمعنى $|\varphi_1| < 1$ فإن :

$$.\hat{\varphi}_1 \sim N\left(\varphi_1, \frac{1 - \varphi_1^2}{n}\right)$$

نعلم أن القيمة الإحصائية تحت الفرضية H_0 هي :

$$t_{\hat{\varphi}_1} = \frac{\hat{\varphi}_1 - 1}{\sigma_{\hat{\varphi}_1}} = \frac{\hat{\lambda}}{\sigma_{\hat{\lambda}}} \sim N(0,1)$$

ومنه تحت الفرضية H_0 ومن النتيجة أعلاه لـ $\hat{\varphi}_1$ التي تتبع التوزيع الطبيعي فإن :

$$\hat{\varphi}_1 \sim N(0,1) . \text{ والذي من الواضح لا معنى له .}$$

في سنة 1987 أظهر Philips وديكي فولر Ducky Fuller أن لحظات العينة من Y_t تتقارب من الدالة العشوائية Brownian motion .

بعد التقدير بطريقة المربعات الصغرى OLS :

$$\hat{\varphi}_1 = \frac{\sum_{t=1}^n Y_{t-1} Y_t}{\sum_{t=1}^n Y_{t-1}^2}$$

عندما تكون القيمة الصحيحة لـ $\varphi = 1$ فإن :

$$.n(\hat{\varphi}_1 - 1) = \frac{n^{-1} \sum_{t=1}^n Y_{t-1} Y_t}{n^{-2} \sum_{t=1}^n Y_{t-1}^2}$$

$$. n(\hat{\varphi}_1 - 1) = \frac{\int_0^1 W(r)dW(r)}{\int_0^1 W(r)^2 dt} \quad \text{ومنه :}$$

$\hat{\varphi}_1$ لا تتبع التوزيع الطبيعي ، وبالتالي تم حساب القيم الحرجة للاختبار عن طريق المحاكاة ووضعوه في جدول يسمى جدول ديكي فولر ، ونقوم بحساب القيمة المحسوبة بعد تقدير المعلمة $\hat{\varphi}_1$ كما يلي : $n(\hat{\varphi}_1 - 1)$.

* إذا كانت $n(\hat{\varphi}_1 - 1)$ أكبر من القيمة المجدولة ، نقبل H_0 فرضية العدم ، إذن يوجد جذر وحدة ، ونرفض H_1 الفرضية البديلة .

مثال رقم 28:

ليكن النموذج التالي : $\hat{Y}_t = 0.946Y_{t-1}$ حيث $n = 34$ و $\alpha = 5\%$.

الحل :

نقوم بحساب القيمة الإحصائية :

$$n(\hat{\varphi}_1 - 1) = 34(0.964 - 1) = -1.836$$

تحت مستوى معنوية $\alpha = 5\%$ فإن القيمة المجدولة لما $n = 34$ هي $t_t = -1.95$ بما أن $-1.95 < -1.836$ نقبل H_0 ونرفض H_1 أي السلسلة Y_t غير مستقرة أي وجود جذر وحده، ولهذا نحتاج لأخذ الفروق حتى تكون هذه السلسلة مستقرة .

2- إختبار ديكي فولر المطور Augmented Dicky Fuller :

سايد وديكي فولر في سنة 1984 قام بتطوير إختبار ديكي فولر البسيط وهو إمتداد لإختبار جذر الوحدة للإندجار الذاتي، هذا الإختبار يشير إلى إختبار ديكي فوبر المطور .

* إختبار ديكي فولر إذا تحققت فرضية العدم H_0 نقول أن سلسلة الفروقات من الدرجة الأولى مستقرة أي إن السلسلة الأصلية Y_t متكاملة من الدرجة الأولى $I(1)$ ، أما إذا كانت السلسلة مستقرة بعد الحصول على الفروقات من الدرجة الثانية، فإن السلسلة الأصلية متكاملة من الدرجة الثانية $I(2)$ ، أما إذا تحققت الفرضية البديلة H_1 فإن السلسلة الأصلية Y_t مستقرة ومتكاملة من الدرجة صفر $I(0)$.

* إذا كانت السلسلة من نوع سيرورة من إندجار ذاتي بدرجات أعلى من واحد، فإننا نحتاج إلى دمج الحدود المطورة لتحويلها إلى إندجار ذاتي من الدرجة الأولى $AR(1)$ ، لنعبر Y_t من نوع سيرورة $AR(2)$:

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varepsilon_t \dots (1)$$

نستطيع تغيير النموذج كالتالي :

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varepsilon_t + \varphi_2 Y_{t-2} - \varphi_2 Y_{t-2} .$$

ومنه :

$$Y_t = \varphi_0 + (\varphi_1 + \varphi_2) Y_{t-1} - \varphi_2 (Y_{t-1} - Y_{t-2}) + \varepsilon_t$$

أو :

$$Y_t - Y_{t-1} = \varphi_0 + (\varphi_1 + \varphi_2) Y_t - \varphi_2 (Y_{t-1} - Y_{t-2}) + \varepsilon_t - Y_{t-1} \Leftrightarrow$$

$$\Delta Y_t = \varphi_0 + (\varphi_1 + \varphi_2 - 1) Y_{t-1} - \varphi_2 (Y_{t-1} - Y_{t-2}) + \varepsilon_t$$

أو

$$\Delta Y_t = \varphi_0 + \lambda Y_{t-1} + \alpha_1 \Delta Y_{t-1} + \varepsilon_t \dots (2)$$

حيث $\lambda = \varphi_1 + \varphi_2$ و $\alpha_1 = -\varphi_2$.

المعادلة (1) هي تكون نموذج إنحدار ذاتي من الدرجة الأولى $AR(1)$ مع حد مطور $\alpha_1 \Delta Y_{t-1}$ والنموذج هو نموذج ديكي فولر المطور، أي أنه إذا كانت Y_t من نوع $AR(2)$ ، نحتاج إلى حد مطور واحد لتحويلها إلى $AR(1)$ ، كذلك النموذج $AR(2)$ هو نموذج ديكي فولر المطور من الرتبة الأولى، النموذج $AR(1)$ هو نموذج ديكي فولر من الرتبة صفر، أما بالنسبة للنموذج $AR(3)$ تكتب على الشكل :

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_3 Y_{t-3} + \varepsilon_t \dots (3)$$

$$\Leftrightarrow$$

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \varphi_3 Y_{t-3} + \varepsilon_t + \varphi_2 Y_{t-1} + \varphi_3 Y_{t-1} + \varphi_3 Y_{t-1} + \varphi_3 Y_{t-2} - \varphi_2 Y_{t-1} - \varphi_3 Y_{t-1} - \varphi_3 Y_{t-2}$$

$$\Leftrightarrow$$

$$Y_t = \varphi_0 + (\varphi_1 + \varphi_2 + \varphi_3) Y_{t-1} - (\varphi_2 + \varphi_3) (Y_{t-1} - Y_{t-3}) - \varphi_3 (Y_{t-2} - Y_{t-3}) + \varepsilon_t$$

$$\Leftrightarrow$$

$$Y_t - Y_{t-1} = \varphi_0 + (\varphi_1 + \varphi_2 + \varphi_3) Y_{t-1} - (\varphi_2 + \varphi_3) (Y_{t-1} - Y_{t-3}) - \varphi_3 (Y_{t-2} - Y_{t-3}) + \varepsilon_t - Y_{t-1}$$

$$\Leftrightarrow$$

$$\Delta Y_t = \varphi_0 + (\varphi_1 + \varphi_2 + \varphi_3 - 1) Y_{t-1} - (\varphi_2 + \varphi_3) (Y_{t-1} - Y_{t-3}) - \varphi_3 (Y_{t-2} - Y_{t-3}) + \varepsilon_t$$

$$\Leftrightarrow$$

$$\Delta Y_t = \varphi_0 + \lambda Y_{t-1} + \alpha_1 \Delta Y_{t-1} + \alpha_3 \Delta Y_{t-2} + \varepsilon_t$$

حيث $\lambda = \varphi_1 + \varphi_2 + \varphi_3 - 1$ و $\alpha_1 = -(\varphi_2 + \varphi_3)$ و $\alpha_2 = \varphi_3$.

هذا النموذج نموذج $AR(1)$ مع حدين مطورين، وهكذا إذا كان لدينا سيروورة من نوع $AR(p)$ ، يجب علينا دمج $(p - 1)$ حد مطور داخل النموذج المنشأ $AR(1)$.

$$\Delta Y_t = \varphi_0 + \lambda Y_{t-1} + \sum_{i=1}^{p-1} \alpha_i \Delta Y_{t-i} + \varepsilon_t$$

لو أدرجنا مركبة الإتجاه العام المحدد في محتوى النموذج $AR(p)$ ، صيغة ديكي فولر المطور من الرتبة $(p - 1)$.

أما بالنسبة لدرجة الفرق من الدرجة الثانية Δ^2 يكون كما يلي :

$$\Delta^2 Y_t = \tilde{\varphi}_0 + \tilde{\lambda} Y_{t-1} + \sum_{i=1}^{p-1} \tilde{\alpha}_i \Delta^2 Y_{t-i} + \varepsilon_t$$

$$.H_0: Y_t \sim I(1)$$

$$.H_1: Y_t \sim I(0)$$

$$H_0: Y_t \text{ مرفوض} \sim I(0)$$

$$H_1: \text{مقبول} \Rightarrow$$

$$H_0: Y_t \sim I(2)$$

$$\text{أو } H_0: \Delta Y_t \sim I(1)$$

$$H_1: Y_t \sim I(1)$$

$$H_0: Y_t \text{ مرفوض} \sim I(1)$$

$$H_1: \text{مقبول} \Rightarrow$$

$$H_0: Y_t \sim I(3)$$

$$\text{أو } H_0: \Delta^2 Y_t \sim I(1)$$

$$H_1: Y_t \sim I(2)$$

$$H_0: Y_t \sim I(2) \text{ مرفوض}$$

يوجد مشكل : مرفوض H_0

خلاصة :

خلاصة إختبار ديكي فولر ، أننا نقوم بتقدير الإنحدار ثم نقوم بحساب القيمة المحسوبة .

$$* t_{\hat{\varphi}_1} = n(\hat{\varphi}_1 - 1) \text{ لها توزيع ولها جدول خاص بها وهو جدول ديكي فولر .}$$

$$* t_{\hat{\varphi}_1} = \frac{n(\hat{\varphi}_1 - 1)}{\hat{\sigma}_{\hat{\varphi}_1}} \text{ لها توزيع ولها جدول خاص بها وهو جدول ديكي فولر .}$$

يجب مقارنة هذه القيم بـ t_{DF} القيمة المجدولة لديكي فولر لكل جدول ، إذا كانت

$|t_{\hat{\varphi}_1}| > t_{DF}$ ومن هنا نقبل H_0 فرضية العدم ، ومنه نقول أن السلسلة لها جذر وحده ، أي السلسلة غير مستقره ونقبل H_1 الفرضية البديلة إذا كان العكس .

مثال رقم 29:

عندما يكون الحد الثابت موجود على مستوى تقدير الإنحدار الذاتى بالنسبة لبيانات معدل الفائدة والمثال التالي نتيجة كالتالي بعد التقدير :

$$i_t = 0.211 + 0.9669i_{t-1}$$

$$(0.112) \quad (0.019133)$$

حيث $n = 168$ و القيم التي بين قوسين تمثل الإنحرافات المعيارية .

الحل :

إختبار ديكي فولر يرتكز على القيمة المقدره لـ φ_0 ومنه :

$$* \text{ الحالة الأولى : } t_{\hat{\varphi}_1} = n(\hat{\varphi}_1 - 1) = 168(0.96691 - 1) = -5.56$$

من جدول ديكي فولر الخاص بهذه الحالة عند مستوى معنوية $\alpha = 5\%$ نجد أن القيمة الحرجة هي $t_{DF} = -13.8$ نلاحظ أن $-13.8 > -5.56$ ومنه نقبل H_0 أي أن $\hat{\varphi}_1 = 1$ أي يوجد جذر أحادي للسلسلة غير مستقرة .

$$* \text{ الحالة الأولى : } t_{\hat{\varphi}_1} = t_{\hat{\varphi}_1} = \frac{n(\hat{\varphi}_1 - 1)}{\hat{\sigma}_{\hat{\varphi}_1}} = \frac{(0.96691 - 1)}{0.019133} = -1.73$$

من جدول ديكي فولر الخاص بهذه الحالة عند مستوى معنوية $\alpha = 5\%$ نجد أن القيمة الحرجة هي $t_{DF} = -2.89$ نلاحظ أن $-2.89 > -1.73$ ومنه نقبل H_0 أي أن $\hat{\varphi}_1 = 1$ أي يوجد جذر أحادي للسلسلة غير مستقرة .

3- تحديد درجة التأخير :

من المهم تحديد درجة التأخير (scherert 1989) و (Harris 1992) و (Agiakloglou and Newbold 1993) عرض من قبل (Ng and Person) إذا تم إختبار p على أساس معيار المعلومات *information criteria (IC)*، طريقة تحديد معامل التأخير على أساس معيار المعلومات (*IC*) والتي تعنى المفاضلة بين تشوهات الحجم وهذا لإدراج عدد قليل من فترات معامل التأخير وفقدانه للمصدقية لإدراجه عدد كبير من فترات معامل التأخير، بهذه الطريقة (*IC*) معامل التأخير الأفضل (p^*) نتحصل عليه بالطريقة التالية :

$$.p^* = \operatorname{argmin}(p_{\min} \leq p \leq p_{\max} IC(p))$$

$$.IC(p) = \ln \hat{\sigma}_p^2 + p \frac{C_t}{T}$$

حيث $\hat{\sigma}_p$ هي مقدار البواقي بطريقة المربعات الصغرى OLS لـ p درجة الإنحدار لديكي فولر المطور . و C_t هي دالة جزائية محددة بأشكال حسب معيار المعلومات الذي سيستخدم . معيار المعلومات الأكثر استخداما هم :

* Akaike information criterion(AIC) المقترحة من طرف Akaike سنة 1979 .

* Bayesian information criterion(BIC) المقترحة من طرف Schwartz سنة

. 1978

* Hannan and Quinn information criterion(HQIC) .

ومنه في معيار (AIC) قيمة $C_t = 2$. وفي معيار (BIC) قيمة $C_t = \ln T$ وفي معيار (HQIC) قيمة $C_t = \ln(\ln T)$. والتي تعطي كلها المعادلات التالية :

$$* AIC(P) = T \ln \hat{\sigma}_p^2 + 2P .$$

$$* BIC(P) = T \ln \hat{\sigma}_p^2 + P \ln(T) .$$

$$* HQIC(P) = T \ln \hat{\sigma}_p^2 + P \ln(\ln(T)) .$$

في هذا الأجراء يجب أن نضع حد أعلى P_{max} لـ p ، وتقدير نموذج إنحدار ديكي فولر مع $p = P_{max}$ ، إذا كانت معاملات فروق التأخير غير معنوية إحصائياً نحن بحاجة إلى تقليل طول التأخير الفرق الواحد تلو الآخر وإعادة العملية . يوجد قاعدة مفيدة مشهورة لتحديد P_{max} المقترحة من طرف Schwartz(1989) هي :

$$.P_{max} = \text{int} \left[12 \left(\frac{T}{100} \right)^{\frac{1}{4}} \right]$$

مثال رقم 29:

دعنا نقدر (AIC) و (BIC) حيث $\hat{\sigma}_p^2$ تستخدم كما هي موضحة في الجدول التالي ، و T تمثل حجم العينة .

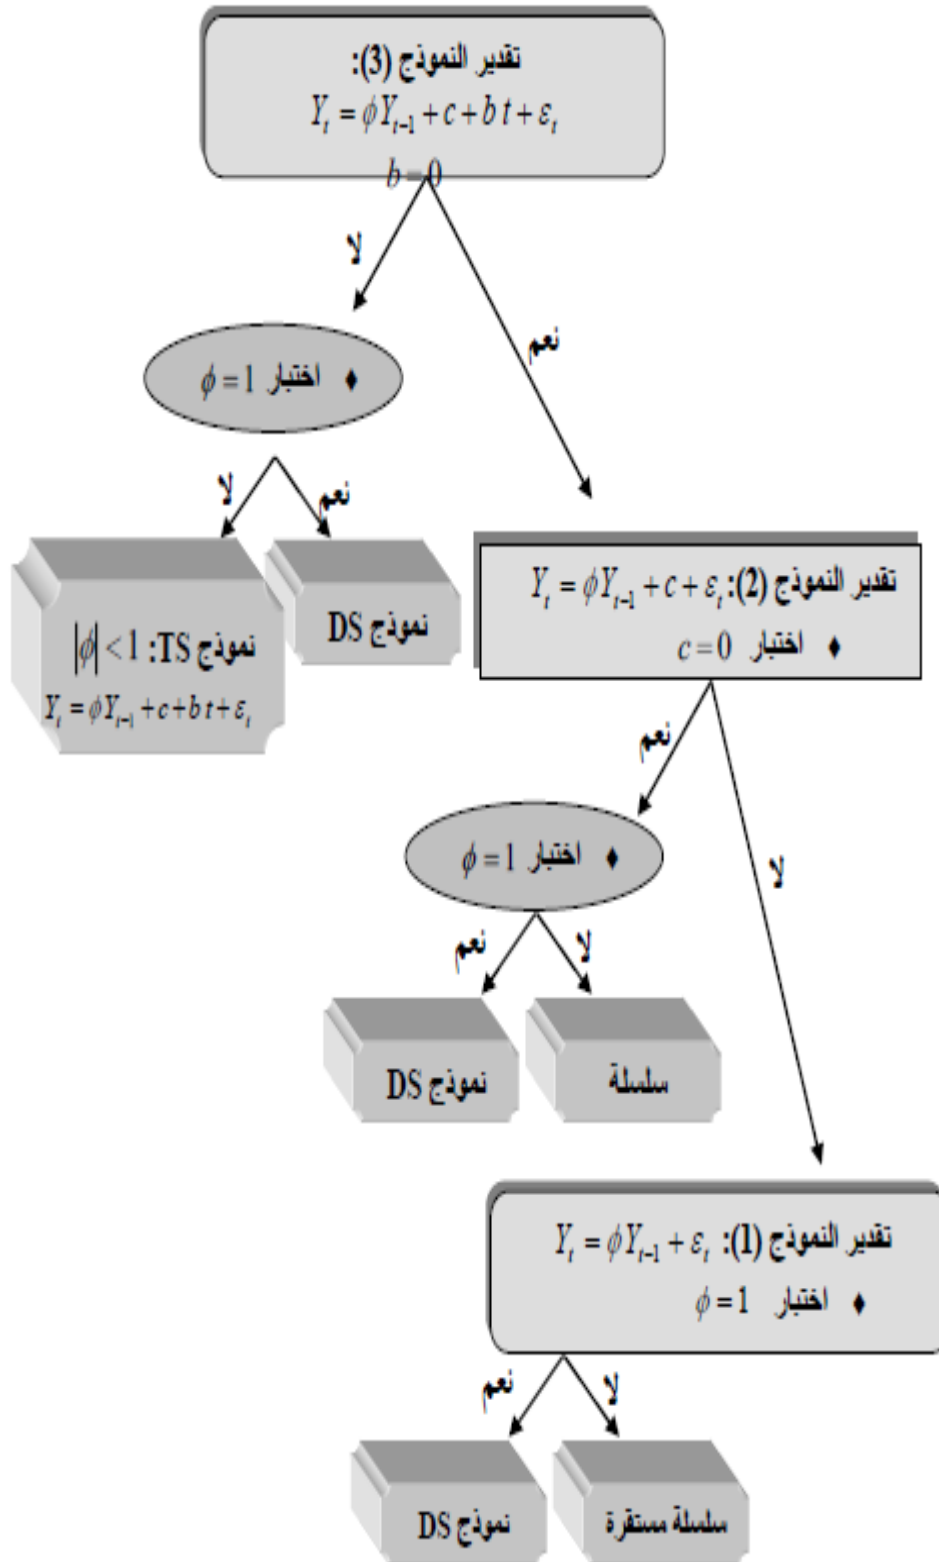
	P=0	P=1	p=2
$\hat{\sigma}_p^2$	2256	2017	1944
$T \ln \hat{\sigma}_p^2$	200.4	200.29	200.25
$P \ln(T)$	30.03	30.05	30.08
$2P$	29.01	29.02	29.03
BIC	230.43	230.34	230.33
AIC	229.41	229.31	229.28

كما يرى في الجدول أعلاه بعد الحساب. نلاحظ أن أقل قيمة عند BIC لما $p = 2$ ، وكذلك أقل قيمة عند AIC لما $p = 2$ ومنه العدد المحدد هو $p = 2$.

السلسلة مستقرة .

فيما يلي صورة مبسطة لمنهجية إختبارات الجذر الأحادي *ADF*.

الشكل يوضح منهجية مبسطة لإختبارات جذر الوحدة .



المصدر : محمد شيخي طرق الإقتصاد القياسي .

4- اختبار ديكي فليبيس بيرون Phillips Peron :

سنة 1988 طور نظرية أكثر شمولية للسلاسل الغير مستقرة ،أي التي لها جذر وحدة ،الإختبار مشابه لإختبار ADF ،إختبار جذر الوحدة لفليبس وبيرون يختلف عن إختبار ADF أساسا في كيفية التعامل مع الارتباط التسلسلي والأخطاء ε_t ،وعدم تجانس الأخطاء على وجه الخصوص ،حيث إختبار ADF يستخدم إنحدار ذاتي معلمي ،والتي تقترب من بنية نموذج $ARMA$ للأخطاء في إنحدار الإختبار،بينما إختبارات فليبس وبيرون تتجاهل الارتباط التسلسلي في إختبار الإنحدار .الإختبار عادة يعطى نفس النتائج وحساب قيم إحصائية معقدة .

لنعتبر النموذج : $Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varepsilon_t$

.DF: $\varepsilon_t \sim iid$ (مستقلة ومتماثلة التوزيع)

.PP: $\varepsilon_t \sim$ (serially correlated) (ارتباط متسلسل)

إضافة المعامل المصحح المسمى التباين على المدى الطويل لإحصائية إختبار DF ديكي فولر البسيط (ADF) هو يكون مضافا إليه معامل التأخير الفرق (ΔY_t) .

* فرضيات إختبار فليبس وبيرون :

.H₀: $|\lambda| = 0$

.H₁: $|\lambda| < 0$

إحصائية إختبار فليبس وبيرون هي إحصائية ستودنت المصححة بطريقة غير معلمية ،والتي تعتمد على المعامل المصحح ،الذي يسمح بتقدير تباين الأخطاء ε_t على المستوى الطويل (تحسب بواسطة الكثافة الطيفية للخطأ العشوائي ε_t بتردد صفري f_0) هذا الذي يسمح بأن يكون إختبار فليبس وبيرون قوي في وجود ارتباط ذاتي للأخطاء وكذلك وجود عدم تجانس الأخطاء ε_t ،يوجد من مقدرات الطيف بتردد صفر f_0 بالنسبة للأخطاء العشوائية ε_t .

* مقدرات قاعدة البيانات (Kernel – based estimator) أو مقدر النواة .

* مقدرات الكثافة الطيفية للإنحدار الذاتي .

يعتمد إختبار فليبس وبيرون على نفس التوزيعات الإحصائية المرفقة لإختباري DF و ADF ويجرى هذا الإختبار في عدة مراحل :

- التقدير بواسطة OLS النماذج الثلاثة القاعدية لإختبار ديكي فولر Dicky Fuller مع حساب الإحصائيات المرافقة .

- مقدر المجموع المرجح للتباين المشترك للبواقي : $\hat{\gamma}_j = \sum_{t=j+1}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-j}$.

- تقدير التباين قصير المدى و $\hat{\varepsilon}_t$ تمثل البواقي $\gamma_0 = \frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{n}$.

- تقدير التباين على المدى الطويل لـ $\hat{\varepsilon}_t$ أو تقدير المعامل المصحح \hat{W}^2 :

$$\hat{W}^2 = \hat{\gamma}_0 + 2 \sum_{j=1}^q \left(1 - \frac{j}{q+1}\right) \hat{\gamma}_j$$

وهذا المقدار يشار إليه كذلك بمقدار Newy – west estimator هذا المقدر يتطلب إختيار حجم النافذة ويسمى (Bartlet window) نافذة بارتلت ، والتي $\left(1 - \frac{j}{q+1}\right)$. يوجد العدد من النوافذ منها Bartlet window و Parzen window و Quadratic spectrale window ، وكذلك من أجل تقدير هذا التباين من الضروري

إيجاد عدد التأخيرات لـ q المقدر بعدد المشاهدات n على النحو التالي : $q = 12 \left(\frac{n}{100}\right)^{\frac{1}{4}}$.

- S^2 هو تباين البواقي لـ $\hat{\varepsilon}_t$ بطريقة المربعات الصغرى OLS حيث : $S^2 = \frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{n-2}$.

- حساب إحصائية فليبس وبيرون كما يلي :

$$Z_{\hat{\alpha}} = n(\hat{\varphi}_1 - 1) - \frac{1}{2} \left(\frac{n^2 \hat{\sigma}_{\hat{\varphi}_1}^2}{S^2} \right) (\hat{W}^2 - \hat{\gamma}_0)$$

$$Z_t = \sqrt{\frac{\hat{\gamma}_0}{\hat{W}^2}} \left(\frac{\hat{\varphi}_1 - 1}{\hat{\sigma}_{\hat{\varphi}_1}} \right) - \frac{1}{2} \left(\frac{\hat{W}^2 - \hat{\gamma}_0 \left(n \frac{\hat{\sigma}_{\hat{\varphi}_1}}{s} \right)}{\hat{w}} \right)$$

مميزات إختبار PP على إختبارات ADF :

* قوي بالنسبة للصيغ العامة لعدم تجانس حد الخطأ العشوائي ε_t .

* لا يحتاج لتحديد طويل معامل التأخير كما رينا في إختبار ADF .

مثال رقم 30:

ليكن $\hat{\varepsilon}_t$ يشير إلى مقدار البواقي بطريقة المربعات OLS وهذا بالنسبة للإندجار معدل الفائدة كما يلي :

$$\hat{\varepsilon}_t = i_t - 0.211 - 0.96691i_{t-1} \quad , t = 1, 2, \dots, 168$$

$$(0.112) \quad (0.019133)$$

حيث $q = 4$.

مقدرات التباين المشترك للبواقي :

$$\hat{\gamma}_0 = \frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{n} = 0.630 \quad ; \hat{\gamma}_1 = \frac{\sum_{t=2}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-1}}{n} = 0.114 ;$$

$$\hat{\gamma}_2 = \frac{\sum_{t=3}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-2}}{n} = -0.162 \quad ; \hat{\gamma}_3 = \frac{\sum_{t=4}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-3}}{n} = 0.064$$

$$\hat{\gamma}_4 = \frac{\sum_{t=5}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-4}}{n} = 0.047 \quad ; S^2 = \frac{\sum_{t=1}^n \hat{\varepsilon}_t^2}{n-2} = 0.63760$$

الحل :

$$\hat{W}^2 = 0.630 + 2 \left(\frac{4}{5}\right) (0.114) + 2 \left(\frac{3}{5}\right) (-0.162) + 2 \left(\frac{2}{5}\right) (0.064) +$$

$$2 \left(\frac{1}{5}\right) (0.047) = 0.688$$

$$Z_{\hat{\alpha}} = n(\hat{\varphi}_1 - 1) - \frac{1}{2} \left(\frac{n^2 \hat{\sigma}_{\hat{\varphi}_1}^2}{S^2} \right) (\hat{W}^2 - \hat{\gamma}_0)$$

$$Z_{\hat{\alpha}} = 168(0.96691 - 1) - \frac{1}{2} \frac{[(168)(0.019133)]^2}{0.63760} (0.688 - 0.630) = -0.603$$

$$.Z_{\hat{\alpha}} = -0.603$$

حسب حالة النموذج رقم 2 عند مستوى معنوية 5% فإن القيمة الحرجة هي 13.8- نلاحظ أن $-13.8 > -6.03$ ومنه نقبل الفرضية H_0 وهذا يعني أن السلسلة الخاصة بمعدل الفائدة تحتوي على جذر الوحدة .

$$Z_t = \sqrt{\frac{\hat{\gamma}_0}{\hat{W}^2}} \left(\frac{\hat{\varphi}_1 - 1}{\hat{\sigma}_{\hat{\varphi}_1}} \right) - \frac{1}{2} \left(\frac{\hat{W}^2 - \hat{\gamma}_0 \left(n \frac{\hat{\sigma}_{\hat{\varphi}_1}}{s} \right)}{\hat{w}} \right)$$

$$= \left[\sqrt{\frac{(0.630)}{0.688}} \cdot \left(\frac{0.96691 - 1}{0.019133} \right) - \left[\frac{\frac{1}{2}(0.688 - 0.630) \left(\frac{168(0.019133)}{\sqrt{0.63760}} \right)}{\sqrt{0.688}} \right] \right] = -1.80$$

من خلال الجدول عند مستوى معنوية $\alpha = 5\%$ فإن القيمة الحرجة تساوي 2.89- . ومنه $-1.80 > -2.89$ نقبل H_0 ومنه يوجد جذر وحدة .

5- إختبار KPSS 1992 :

إختبار KPSS يقترح تصحيح غير معلمي للإرتباط الذي مماثل لإختبار فليبس وبيرون ،إختبار KPSS يعالج مشكلة إحتماية وجود إرتباط ذاتي للأخطاء ε_t ،ويستخدم معامل التصحيح الذي يقدر التباين الطويل المدى للأخطاء ε_t (الذي يحسب بواسطة الكثافة الطيفية للأخطاء لـ ε_t بتردد صفري f_0) .

الفرضية الصفرية H_0 لإختبار ADF و PP تمثل وجود جذر وحدة أي $H \sim I(1)$ أما بالنسبة لإختبار KPSS فإن الفرضية الصفرية H_0 تمثل غياب جذر الوحدة أي $H \sim I(0)$ أي أن السلسلة تكون مستقرة ،والذي يعتمد على النموذجين التاليين :

$$.Y_t = a + \varphi_1 Y_{t-1} + \varepsilon_t ; t = 1, 2, \dots, n$$

$$.Y_t = a + bt + \varphi_1 Y_{t-1} + \varepsilon_t ; t = 1, 2, \dots, n$$

نحن نهتم بفرضية العدم ومنه :

$$.H_0: |\varphi_1| < 1 ; \text{غياب جذر الوحدة}$$

$H_1: |\varphi_1| = 1$ وجود جذر الوحدة

إقتراح Kwiatkowski , Phillips , Schmidt and Schur استخدام مضاعف لاغرانج لإختبار فرضية الإستقرارية H_0 لتطبيق إختبار KPSS نتبع الخطوات التالية :

* فبعد تقدير النموذجين أعلاه ، نحسب المجموع الجزئي للبواقي $S_t = \sum_{t=1}^n \hat{\varepsilon}_t$.

* تقدير التباين طويل المدى \hat{w}^2 بنفس طريقة إختبار فليبس وببيرون كما يلي :

$$\hat{w}^2 = \hat{\gamma}_0 + 2 \sum_{j=1}^q \left(1 - \frac{j}{q+1}\right) \hat{\gamma}_j .$$

* تحسب إحصائية إختبار KPSS من العلاقة التالية :

$$LM_{KPSS} = \frac{1}{\hat{w}^2} \cdot \frac{\sum_{t=1}^n S_t^2}{n^2}$$

- إذا كانت قيمة LM_{KPSS} أكبر من القيمة الحرجة المستخرجة من الجدول المعد من طرف Phillips Kwiatkowski ، إذن نقبل H_0 إذن السلسلة مستقرة .

- إذا كانت قيمة LM_{KPSS} أكبر من قيمة الحرجة المستخرجة من الجدول ، إذن نرفض H_0 إذن وجود جذر وحدة .

ما هو إختبار جذر الوحدة المستخدم ؟.

ADF * PP * KPSS *

- إختبار فليبس وببيرون أقوى في عدم التجانس مقارنة بإختبار ADF .

- إختبار KPSS لديه فرضية صفرية عكس إختبار ADF و PP لذلك فهي إختبارات تكميلية وليست إلزامية ، التي تستخدم يمكن أن تعطى نتائج قوية .

الفصل الخامس : السيرورات المختلطة الغير مستقرة :

إختبارات ديكي فولر المطورة ، كما درسنا أنه يسمح بتحديد إذا كانت السلسلة مستقرة وكذلك الحالة الغير مستقرة مع تحديدها لنوعها : TS و DS ، إذا كانت السلسلة المدروسة من

نوع TS يجب أن تكون مستقرة عن طريق الإنحدار خلال الزمن بإستخلاص بواقي معادلة الإتجاه العام، ثم يتم مواصلة التقدير بواسطة منهجية بوكس جنكينز Box – jenkins هذا يسمح بتحديد رتبة p و q من جزء AR و MA للأخطاء، النموذج دائما يكون في هذه الحالة $ARMA(p, q)$.

إذا كانت السلسلة المدروسة من نوع DS ، يجب أن تكون مستقرة عند إستخدام درجات الفروق حسب درجة التكامل $I = d$ (بمعنى عدد مرات التي يجب أن تكون حتى تكون السلسلة مستقرة)، كذلك السلسلة المستقرة بواسطة إستخدام الفروق تتم مواصلة دراستها بواسطة منهجية بوكس-جينكز Box – jenkins التي تسمح كذلك بتحديد رتبة AR و MA نرمز لهذا النوع من النموذج بـ $ARIMA(p, q)$.

1- السيرورة $ARMA(p, q)$ غير المستقرة (نماذج $ARIMA$):

السلسلة Y_t غير مستقرة فيقال عنها أنها متكاملة أو غير مستقرة Integrated or Nonstationary، وإذا تعين الحصول على فروقات السلسلة d مرة حتى تصبح مستقرة، يقال عندئذ أن السلسلة Y_t متكاملة من الدرجة d $I(d)$.

وبعبارة أخرى نقول أن Y_t هي سلسلة متجانسة وغير مستقرة متكاملة من الدرجة d إذا وجدت $W_t = \Delta^d Y_t$ سلسلة مستقرة جديدة، ومنه يمكن أن نمذج السلسلة الجديدة W_t كأنها $ARMA(p, q)$ في هذه الحالة ينتج أن Y_t هي سيرورة $ARIMA(p, d, q)$ ، ويسمى كذلك بنموذج الإنحدار الذاتي والمتوسط المتحرك المتكامل، هذا الأخير بالإضافة إلى الدرجتين p و q فإنه يتميز بدرجة ثلاثة d .

مثال رقم 31:

ليكن Y_t هي سيرورة من $ARIMA(p, 1, q)$ كما يلي: $W_t = Y_t - Y_{t-1} = \Delta Y_t$ ، ومن ثم W_t سيرورة من نوع $ARMA(p, q)$ ومنه يفترض أن:

$$W_t = \varphi_1 W_{t-1} + \varphi_2 W_{t-2} \dots + \varphi_p W_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

ومنه Y_t مقبولة:

$$Y_t - Y_{t-1} = \varphi_1(Y_{t-1} - Y_{t-2}) + \varphi_2(Y_{t-2} - Y_{t-3}) + \dots + \varphi_p(Y_{t-p} - Y_{t-p+1}) + \varepsilon_t + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q}$$

وكذلك نتحصل على صيغة معادلة الفرق لـ Y_t :

$$\Delta Y_t = \varphi_1\Delta Y_{t-1} + \varphi_2\Delta Y_{t-2} + \dots + \varphi_p\Delta Y_{t-p} + \varepsilon_t + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q}$$

والتي هي سيرة من نوع: $ARIMA(p, 1, q) = ARMA(p + 1, q)$.

كثير الحدود الخاص بالإنحدار الذاتي AR لـ Y_t والممثل بواسطة معامل التأخير B يكون $(1 - \varphi_1 B - \varphi_2 B^2 + \dots + \varphi_p B^p)(1 - B)$ التي لها جذر وحدة، إذن السيرة $ARMA(p + 1, q)$ غير مستقرة.

في العموم إذا كانت السلسلة Y_t من نوع $ARIMA(p, d, q)$ و $W_t = \Delta^d Y_t$ فإن الشكل العام يكون كما يلي :

$$W_t = \varphi_1 W_{t-1} + \varphi_2 W_{t-2} \dots + \varphi_p W_{t-p} + \varepsilon_t + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q}$$

وكذلك نتحصل على معادلة الفرق والتي شكلها كما يلي :

$$\Delta^d Y_t = \varphi_1\Delta^d Y_{t-1} + \varphi_2\Delta^d Y_{t-2} + \dots + \varphi_p\Delta^d Y_{t-p} + \varepsilon_t + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q}$$

حيث $\Delta^d Y_t$ لها كثير الحدود الخاص بالإنحدار الذاتي AR والممثل بواسطة معامل التأخير B يكون $\Phi_p(B)$ ثم Y_t لها كثير الحدود الخاص بالإنحدار AR والذي هو $\Phi_p(B)(1 - B)^d$ يمكننا استخدام هذا لتحديد نوع نماذج $ARIMA$.

إذا كانت السيرة الصادرة $ARMA(p, q)$ ، إذن السيرة المدخلة Y_t هي $ARIMA(p, d, q)$ ، السيرة $ARIMA(p, d, q)$ يمكن كتابتها بدلالة معامل التأخير B كما يلي:

$$\Phi_p(B)(1 - B)^d Y_t = \Theta_q(B)\varepsilon_t$$

$$[ARIMA(p, d, q) = ARMA(p + d, q) \text{ غير مستقرة}]$$

ملاحظة :

يتم تطبيق نماذج ARIMA في بعض الحالات التي يظهر فيها البيانات تأكيد على عدم الإستقرارية، حيث خطوة الفرق الأولية يمكن تطبيقها مرة أو أكثر من مرة وهذا لجعل السلسلة مستقرة .

$$.AR(p) \equiv ARIMA(p, 0, 0)$$

$$.MA(q) \equiv ARIMA(0, 0, q)$$

$$.ARMA(p, q) \equiv ARIMA(p, 0, q)$$

$$.WN \equiv ARIMA(0, 0, 0)$$

مثال رقم 32:

$$* ARIMA(1, 1, 1)$$

يمكن كتابتها كما يلي :

$$(1 - \varphi_1 B)(1 - B)Y_t = (1 + \theta_1 B)\varepsilon_t \quad \equiv$$

$$(1 - \varphi_1 B)\Delta Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad \equiv$$

$$\Delta Y_t - \varphi_1 \Delta Y_{t-1} = \varepsilon_t + \theta_1 B \varepsilon_t \quad \equiv$$

$$.\Delta Y_t = \varphi_1 \Delta Y_{t-1} + \varepsilon_t + \theta_1 B \varepsilon_t$$

$$* ARIMA(2, 1, 1)$$

يمكن كتابتها كما يلي :

$$(1 - \varphi_1 B - \varphi_2 B^2)(1 - B)Y_t = (1 + \theta_1 B)\varepsilon_t \quad \equiv$$

$$(1 - \varphi_1 B - \varphi_2 B^2)\Delta Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad \equiv$$

$$\Delta Y_t - \varphi_1 \Delta Y_{t-1} - \varphi_2 \Delta Y_{t-2} = \varepsilon_t + \theta_1 B \varepsilon_t \quad \equiv$$

$$\Delta Y_t = \varphi_1 \Delta Y_{t-1} - \varphi_2 \Delta Y_{t-2} + \varepsilon_t + \theta_1 B \varepsilon_t$$

* ARIMA(1,2,2)

يمكن كتابتها كما يلي :

$$(1 - \varphi_1 B)(1 - B)^2 Y_t = (1 + \theta_1 B + \theta_2 B^2) \varepsilon_t \quad \equiv$$

$$(1 - \varphi_1 B) \Delta^2 Y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} \quad \equiv$$

$$\Delta^2 Y_t - \varphi_1 \Delta^2 Y_{t-1} = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} \quad \equiv$$

$$\Delta^2 Y_t = \varphi_1 \Delta^2 Y_{t-1} \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}$$

*** الحد الثابت في نماذج ARIMA :**

إذا كانت Y_t من نوع ARIMA(p, d, q) و $W_t = \Delta^d Y_t$ من نوع ARMA(p, q) عندما W_t يكون لديها متوسط ثابت حيث $\mu \neq 0$ يمكن أن تتمذج على الشكل التالي :

$$W_t - \mu = \alpha + \sum_{i=1}^p \varphi_i (W_{t-i} - \mu) + \varepsilon_t + \sum_{j=1}^q \vartheta_j \varepsilon_{t-j}$$

بأخذ القيمة المتوقعة يمكن الحصول على ما يلي :

$$\alpha = \mu(1 - \varphi_0 - \varphi_1 - \varphi_2 - \dots - \varphi_p)$$

هناك عائلتان خاصتان بالسيرورات الغير مستقرة ، وهما :

* $IMA(d, q) = ARIMA(0, d, q)$ السيرورة لا تحتوى عنصر الإنحدار الذاتي .

* $IRA(p, d) = ARIMA(p, d, 0)$ السيرورة لا تحتوى عنصر المتوسط المتحرك .

مثال رقم 33:

* $IMA(1,1) = ARIMA(0,1,1)$

$$\Delta Y_t = (1 - B)Y_t = (1 + \theta_1 B)\varepsilon_t \quad \equiv$$

$$Y_t - Y_{t-1} = \varepsilon_t + \theta_1 \varepsilon_t \quad \equiv$$

$$Y_t = Y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_t$$

$$* \text{IMA}(2,2) = \text{ARIMA}(0,2,2)$$

$$\Delta^2 Y_t = (1 - B)^2 Y_t = (1 + \theta_1 B + \theta_2 B^2) \varepsilon_t \quad \equiv$$

$$\Delta(\Delta Y_t) = \varepsilon_t + \theta_1 \varepsilon_t + \theta_2 \varepsilon_{t-2} \quad \equiv$$

$$\Delta(Y_t - Y_{t-1}) = \varepsilon_t + \theta_1 \varepsilon_t + \theta_2 \varepsilon_{t-2} \quad \equiv$$

$$\Delta Y_t - \Delta Y_{t-1} = \varepsilon_t + \theta_1 \varepsilon_t + \theta_2 \varepsilon_{t-2} \quad \equiv$$

$$Y_t - Y_{t-1} - Y_{t-1} - Y_{t-2} = \varepsilon_t + \theta_1 \varepsilon_t + \theta_2 \varepsilon_{t-2} \quad \equiv$$

$$Y_t = 2Y_{t-1} + Y_{t-2} + \varepsilon_t + \theta_1 \varepsilon_t + \theta_2 \varepsilon_{t-2}$$

$$* \text{ARIMA}(1,1,1)$$

$$(1 - \phi_1 B)(1 - B)Y_t = \varepsilon_t \quad \equiv$$

$$(1 - \phi_1 B)\Delta Y_t = \varepsilon_t \quad \equiv$$

$$\Delta Y_t - \phi_1 \Delta Y_{t-1} = \varepsilon_t \quad \equiv$$

$$Y_t - Y_{t-1} = \phi_1 (Y_{t-1} - Y_{t-2}) + \varepsilon_t \quad \equiv$$

$$Y_t = Y_{t-1} + \phi_1 (Y_{t-1} - Y_{t-2}) + \varepsilon_t \quad \equiv$$

$$Y_t = (1 + B)Y_{t-1} - \phi_1 Y_{t-2} + \varepsilon_t$$

2- السيرورة ARIMA(P, D, Q) الموسمية (السيرورة ARMA(P, Q) الموسمية الغير مستقرة) :

نعتبر سلسلة Y_t ممثلة بالسيرورة DS الموسمية من الرتبة D وبالفترة الموسمية S ، يمكن إرجاع هذه السلسلة مستقرة بإستعمال المرشح الذي يدمج الفروقات الموسمية من الرتبة D أي:

$$.Y_t = \Delta_s Y_t = Y_t - Y_{t-s} = (1 - B^s)Y_t$$

تحتوي السلسلة Y_t على D جذر أحادي حقيقي أو مركب، بمعنى آخر نقول عنها أنها متكاملة من الدرجة D ونكتب $Y \sim I_s(D)$ حيث D هي درجة التكامل و s تمثل الفترة الموسمية .

خلاصة :

نفترض أن السيرورة المتحصل عليها من المرشح هي W_t وهي من نوع $SARIMA_{s,s}(P, Q)$ غير مستقرة، وكذلك $SARIMA(P, D, Q)$ هي سيرورة $SARMA(P, Q)$ مستقرة .

3- السيرورة $ARIMA$ الموسمية والغير موسمية في نفس الوقت :

من خلال نماذج $ARIMA$ الغير موسمية ونماذج $ARIMA$ الموسمية يمكن بناء نماذج تضاعفية أو جدائية بين نماذج $ARIMA$ الغير موسمية ونماذج $ARIMA$ الموسمية، إنه النموذج الأكثر شيوعا وإستعمالا الموجود في منهجية بوكس و جينكينز .

$$.W_t = (1 - B)^d(1 - B^s)^D Y_t$$

تحتوي هذه السيرورة على $d + D$ جذر أحادي أو مركب بمعنى آخر يعتبر متكاملًا من الرتبة $d + D$ ونكتب $Y_t \sim I_s(d + D)$.

خلاصة :

إذا كانت السيرورة المتحصل عليها من المرشح هي W_t وهي من نوع :

$$.ARMA(p, q) \times SARMA_{s,s}(P, Q)$$

إذن السيرورة المدخلة Y_t هي من نوع : $ARIMA(p, d, q) \times SARIMA_{s,s}(P, D, Q)$

والتي تكتب كما يلي :

$$\Phi_p(B)\Phi_p(B^s)(1 - B^s)^D(1 - B)^d Y_t = \theta_q(B)\theta_q(B^s)\varepsilon_t$$

حيث $\Phi_p(B)$ و $\theta_q(B)$ هي على التوالي كثيرات حدود المميزة للانحدار الذاتي AR، والمتوسط المتحرك MA، وكذلك $\Phi_p(B^s)$ و $\theta_q(B^s)$ هي على التوالي كثيرات حدود المميزة المميزة للانحدار الذاتي SAR، والمتوسط المتحرك SMA.

ملاحظة :

السيروورة $ARIMA(p, d, q) \times SARIMA_{s,s}(P, D, Q)$ هي سيروورة من نوع :
 $ARMA(p + d + Ps + Ds, q + Qs)$ غير مستقرة .

الفصل السادس : منهجية بوكس- جينكينز (*Box and Jenkins*) :

إهتم 1976 بوكس وجينكينز بجمع التقنيات المستعملة في السلاسل الزمنية للمساعدة على تحديد النموذج وتقدير معلماته، ثم إقترحا بعض الطرق للتأكد من صلاحيته النموذج لأخذ شكله النهائي، ويرى بوكس و جينكينز أن النماذج الدينامكية الخطية المقدره والتحليلات النظرية المرافقة لها لا تعطينا شكل النموذج فقط بل تمكننا أيضا من الحصول على المعلمات المقدره وإختبار جودتها الإحصائية والتنبؤ الذي يعتبر الهدف الأساسي من هذه العملية .

المخطط التالي يوضح أهم الخطوات العملية حسب منهجية بوكس و جينكينز لبناء نموذج عشوائي لسلسلة زمنية واحدة، وأهم هذه خطوات هذه المنهجية هي :

* تحويل السلسلة .

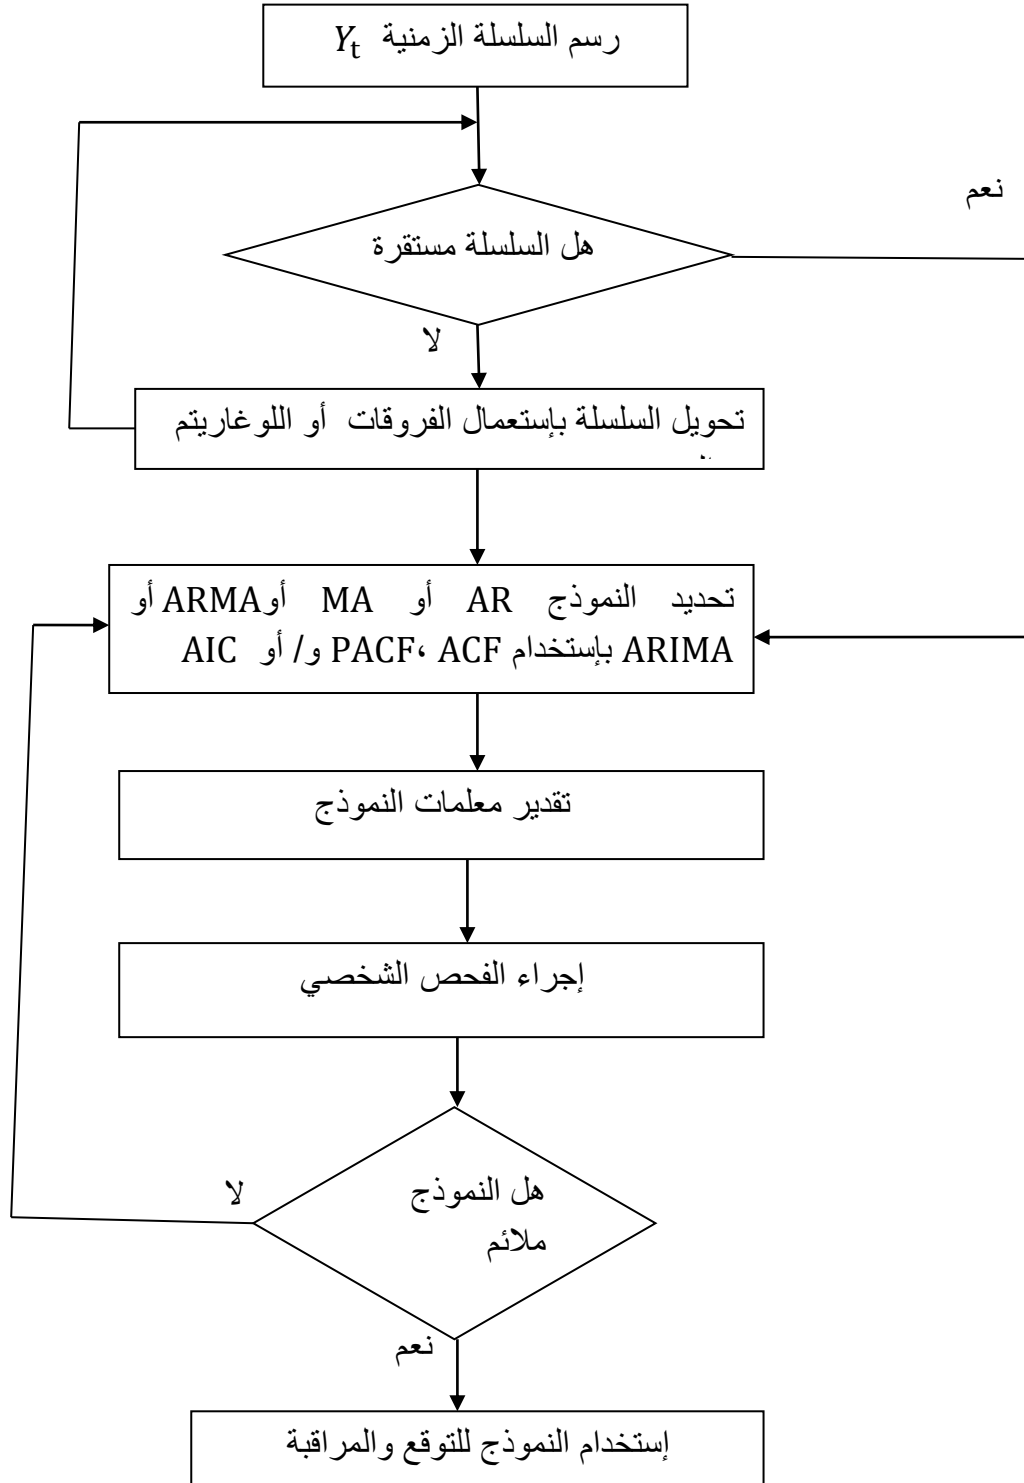
* التعرف .

* التقدير .

* مرحلة الفحص .

* مرحلة التنبؤ .

مخطط يوضح خطوات منهجية بوكس و جينكينز لمتغير واحد



حسب منهجية بوكس - جينكينز أن هذه المنهجية هي عبارة عن خوارزمية تكرارية ممثلة في خمس خطوات يمكن توضيح كل خطوة من هذه الخطوات كما يلي :

1- الخطوة الأولى : التحويل (Transformation) :

يمكن استخدام منهجية بوكس - جينكينز للسيرورات المستقرة والغير مستقرة، الخطية والغير خطية، إلا أنه إذا كانت السيرورة غير مستقرة أو غير خطية وجب تحويلها إلى سيرورة مستقرة وخطية لتقريب خصائص هذه السلسلة الزمنية من السيرورة ARMA النظرية وذلك للتعرف الجيد على السيرورة المولدة لهذه السلسلة .

في الحقيقة ، أن السلاسل الزمنية الاقتصادية نادرا ما تكون مستقرة ولهذا السبب خلال معالجة هذه السلسلة بالإعتماد على منهجية بوكس - جينكينز ،تعد مرحلة تحويل السلسلة الزمنية قيد الدراسة إلى سلسلة زمنية مستقرة ،لهذا إذا كانت Y_t السلسلة الأصلية و \hat{Y}_t هي السلسلة المستقرة لـ Y_t يتم تعريفها كما يلي :

$$* \hat{Y}_t = Y_t \text{ إذا كانت } Y_t \text{ مستقرة } \hat{Y}_t = Y_t$$

$$* \hat{Y}_t = \ln(Y_t) \text{ إذا كانت } Y_t \text{ غير مستقرة و } \ln(Y_t) \text{ مستقرة.}$$

$$* \hat{Y}_t = (1 - B)Y_t \text{ إذا كانت } Y_t \text{ غير مستقرة و متكاملة من الدرجة 1.}$$

$$* \hat{Y}_t = (1 - B)^2 Y_t \text{ إذا كانت } Y_t \text{ غير مستقرة و متكاملة من الدرجة 2.}$$

$$* \hat{Y}_t = (1 - B)\ln(Y_t) \text{ إذا كانت } Y_t \text{ غير مستقرة و } \ln(Y_t) \text{ متكاملة من الدرجة 1.}$$

$$* \hat{Y}_t = (1 - B)^2 \ln(Y_t) \text{ إذا كانت } Y_t \text{ غير مستقرة و } \ln(Y_t) \text{ متكاملة من الدرجة 2.}$$

* $\hat{Y}_t = Y_t - \hat{a} - \hat{b}t$ إذا كانت Y_t غير مستقرة وتحتوى إتجاه عام (خطي) ،طبعا في هذه الحالة الأخيرة ،يجب تقدير a و b بطريقة المربعات الصغرى OLS للنموذج :

$$Y_t = a + bt + \varepsilon_t$$

عندما تعرض سلسلة شهرية أو ربع سنوية ،تغيرات موسمية يكون التحول أكثر تعقيدا إذا

كانت Y_t سلسلة موسمية فإن شكلها يكون كما يلي :

$$* \text{ إذا كانت } \hat{Y}_t = (1 - B^S)^2 Y_t \text{ إذا كانت } Y_t \text{ غير مستقرة و متكاملة من الدرجة 2 (حيث } S$$

هي دورة السلسلة الزمنية ... $S = 4, 12$).

$$* \text{ إذا } \hat{Y}_t = (1 - B^S)^2 \ln(Y_t) \text{ إذا كانت } Y_t \text{ غير مستقرة و } \ln(Y_t) \text{ متكاملة من الدرجة 2}$$

أما إذا كانت السلسلة Y_t سلسلة موسمية و غير موسمية في نفس الوقت فإن :

$$\hat{Y}_t = \hat{Y}_t = (1 - B)^d(1 - B^s)^D Y_t$$

$$\hat{Y}_t = \hat{Y}_t = (1 - B)^d(1 - B)^2 \ln(Y_t)$$

حيث d هي درجة الفرق و D هي درجة الفرق الموسمية و S هي دورية السلسلة .

2- الخطوة الثانية : التعرف (Identification) :

هي مرحلة التعرف على النموذج المبدئي الملائم لبيانات السلسلة الزمنية المرصودة ،ويقصد بالتعرف على النموذج هو تحديد إختيار أو تحديد رتب النموذج الثلاث (p, d, q) ،حيث يشير الرمز d إلى درجة الفرق الضرورية ويشير الرمز p إلى عدد حدود عدد حدود المشاهدات السابقة التي يجب إدراجها في النموذج المبدئي الملائم ،بينما يشير الرمز q إلى عدد متغيرات التشويش الأبيض التي يجب أن يشملها النموذج الملائم ،وتعد مرحلة التعرف من أصعب مراحل التحليل وأهمها ،ليس في مجال السلاسل الزمنية فحسب بل في مجال الإحصاء بصفة عامة ،بصفة خاصة حيث تتطلب هذه المرحلة ،بالإضافة إلى الأسس النظرية ،مهارة وخبرة وممارسة عملية وقدر من الحكم الشخصي للباحث .

بعد تحديد رتبة الفروق الضرورية لإستقرار السلسلة ،يجب تحديد رتبة الجزء الخاص بالإنحدار الذاتي p ورتبة الجزء الخاص بالمتوسطات المتحركة q ،وتعتبر كل من دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي أحد المفاتيح السحرية والفعالة في التمييز بين النماذج $AR(p)$ والنماذج $MA(q)$ والنماذج المختلطة $ARMA(p, q)$ وقد يكون من الضروري إستدعاء الخصائص الضرورية لهاتين الدالتين ونمط كل منهما لأهم النماذج التي تنتمي إلى هذه العائلات الثلاث وتلخيصها في جدول .

جدول خصائص دالتي الارتباط الذاتي والذاتي الجزئي لنماذج ARMA

النموذج	$\rho(h)$	$\phi_{h,h}$
---------	-----------	--------------

التشويش الأبيض ε_t	كلها قيم صفرية	كلها قيم صفرية
AR(1)	تنعدم تدريجيا من الصفر بشكل أسي أو شكل متردد في الإشارة .	تنعدم تماما بعد الدرجة 1 .
AR(2)	تنعدم تدريجيا من الصفر بشكل أسي أو شكل متردد في الإشارة .	تنعدم تماما بعد الدرجة 2 .
AR(p)	تنعدم تدريجيا من الصفر بشكل أسي أو شكل متردد في الإشارة أو موجات جيبيية .	تنعدم تماما بعد الدرجة p .
MA(1)	تنعدم تماما بعد الدرجة 1 .	تقترب تدريجيا من الصفر بصورة تدريجية .
MA(2)	تنعدم تماما بعد الدرجة 2 .	تقترب تدريجيا من الصفر بصورة تدريجية أو موجات تحاكي دالة جيبيية .
MA(q)	تنعدم تماما بعد الدرجة q .	تقترب تدريجيا من الصفر بصورة تدريجية أو موجات تحاكي دالة جيبيية .
ARMA(p, q)	تقترب تدريجيا من الصفر بعد (q - p) من الدرجات بشكل أسي أو موجات تحاكي دالة جيبيية .	تقترب تدريجيا من الصفر بعد (p - q) من الدرجات بشكل أسي أو موجات تحاكي دالة جيبيية .
سيرورة السير العشوائي	تفترب من 1 ولا تؤول الى الصفر .	كل القيم صفرية بعد 1 .

هناك فكرة اساسية في منهجية بوكس - جينكينز وهي مبدأ البخل أو الشح بإدراج معلمات إضافية يزيد من القدرة التفسيرية للنموذج (مثلا قيمة R^2 تزيد) في مقابل فقدان درجة حرية في النموذج .

يبين ويوضح بوكس - جينكينز من خلال هذه المنهجية بأن نموذج تشحيح (أقل معلمات) ينتج عادة تنبؤات أفضل من نموذج قيمة معلمات زائدة ،بعبارة أخرى ،نموذج شحيح يناسب ويوافق عادة وبشكل جيد السلسلة الزمنية قيد الدراسة من دون إدراج أي معلمات لا داعي لها. من ناحية أخرى ،خلال إختيار النموذج المناسب يحتاج الإقتصادي أن يدرك أن العديد من النماذج المختلفة قد يكون لها نفس الخواص المماثلة للنموذج المختار ،فمثلا ،نموذج إنحدار ذاتي من الدرجة الأولى $AR(1)$:

$$Y_t = 0.5Y_{t-1} + \varepsilon_t$$

يكافئ في الحقيقة نموذج متوسط متحرك ذو درجة غير منتهية $MA(\infty)$ ويمكن توضيح ذلك كما يلي :

$$Y_t = 0.5Y_{t-1} + \varepsilon_t$$

$$Y_t = 0.5(0.5Y_{t-1} + \varepsilon_{t-1}) + \varepsilon_t$$

$$Y_t = 0.25Y_{t-2} + 0.5\varepsilon_{t-1} + \varepsilon_t$$

$$Y_t = 0.25(0.5Y_{t-3} + \varepsilon_{t-2}) + 0.5\varepsilon_{t-1} + \varepsilon_t$$

$$Y_t = 0.125Y_{t-3} + 0.25\varepsilon_{t-2} + 0.5\varepsilon_{t-1} + \varepsilon_t$$

⋮

$$Y_t = \varepsilon_t + 0.5\varepsilon_{t-1} + 0.25\varepsilon_{t-2} + 0.125\varepsilon_{t-3} + \dots$$

في أغلب العينات (السلاسل الزمنية) تقريبا هذا المتوسط المتحرك الغير محدود $MA(\infty)$ لـ $MA(2)$ أو $MA(3)$ سيتمكن من الحصول على نموذج ذو جودة عالية ،ومع ذلك ،يعتبر $AR(1)$ النموذج الأكثر شحا والمفضل في هذه الحالة ،من ناحية أخرى ،يمكن أن نلاحظ بأن هذا النموذج الأخير $AR(1)$ لدينا تمثيل مماثل ومكافئ لـ :

$$Y_t = 0.5Y_{t-1} + \varepsilon_t$$

$$Y_t = 0.5(0.5Y_t + \varepsilon_{t-1}) + \varepsilon_t$$

$$Y_t = 0.25Y_{t-2} + 0.5\varepsilon_{t-1} + \varepsilon_t$$

وهو موافق في الحقيقة للسيرورة ARMA(2,1) .

تعتبر هذه الخطوة أصعب مراحل تطبيق منهجية بوكس - جينكينز وهي صعوبة لا ننكرها بل نؤكد عليها ، ونعتبرها أحد العيوب الأساسية لهذه المنهجية وأحد أسباب توجيهات الأبحاث الحديثة لإيجاد أسلوب أسهل وأكثر موضوعية للتعرف على النموذج المبدئي للبيانات .

3- الخطوة الثالثة : التقدير (Estimation) :

بعد الإنتهاء من مرحلة التعرف على النموذج المبدئي للبيانات المتاحة ، يجب تقدير معالم النموذج باستخدام إحدى الطرق المعروفة في نظرية الإحصاء ، والمتمثلة في مرحلة تقدير معالم النموذج .

1-2 تقدير معالم نموذج الإنحدار الذاتي AR :

1-1-2 طريقة معادلات نظام يوول وولكر :

تعتمد هذه الطريقة على معادلات يوول وولكر التي تحدثنا عنها سابقا من خلال معاملات الارتباط الذاتي لتقدير معالم النموذج $\varphi_1, \varphi_2, \dots, \varphi_p$ ففي حالة AR(p) إذن تكون لدينا p معادلة .

$$\rho_1 = \varphi_1\rho_0 + \varphi_2\rho_1 + \dots + \varphi_p\rho_{p-1}$$

$$\rho_2 = \varphi_1\rho_1 + \varphi_2\rho_2 + \dots + \varphi_p\rho_{p-2}$$

⋮

$$\rho_n = \varphi_1\rho_{p-1} + \varphi_2\rho_{p-2} + \dots + \varphi_p\rho_0$$

حيث $\rho_0 = 1$ ، ومنه يمكن كتابة المعادلات على الشكل المصفوفي التالي كما يلي :

2-1-2 الطريقة الإنحدارية :

تمثل هذه النماذج إنحدار المتغير Y_t على المتغيرات المفسرة (المستقلة)

تتشبه الى حد كبير نماذج الإنحدار العام التقليدية حيث يلعب دور Y_t دور المتغير التابع وتلعب المتغيرات $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ دور المتغيرات المفسرة، بينما يلعب دور الأخطاء الحقيقية، ومن ثم يمكن تطبيق طريقة المربعات الصغرى، ليكون لدينا النموذج التالي AR(p) :

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$$

وبكتابتها على الشكل التالي :

$$\begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ \vdots \\ Y_T \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ 1 & Y_1 & 0 & \dots & \vdots \\ 1 & \dots & \dots & \dots & \vdots \\ \dots & \dots & \dots & \dots & \dots \\ 1 & Y_{t-1} & Y_{t-2} & \dots & Y_{t-p} \end{bmatrix} \times \begin{bmatrix} \varphi_0 \\ \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \vdots \\ \varepsilon_T \end{bmatrix}$$

نحصل على الكتابة المختصرة : $Y = X \Phi + \varepsilon$.

حيث $X(T, p + 1)$ مصفوفة المتغيرات المستقلة $Y(T, 1)$ المتغير التابع، $\Phi(p + 1, 1)$ شعاع المعلمات الواجب تقديرها، $\varepsilon(T, 1)$ شعاع الأخطاء نذكر أننا سنفقد p مشاهدة يتم تعويض تلك القيم المفقودة بالصفر، وتحت فرضيات معينة معروفة يمكن تقدير شعاع المقدرات بطريقة المربعات الصغرى OLS كما يلي :

$$\hat{\Phi} = (\hat{X}X)^{-1} \hat{X}Y$$

أما مصفوفة التباينات والتباينات المشتركة للمقدرات تعرف كما يلي :

$$\hat{\sigma}_\varepsilon = \frac{\sum_{t=1}^T \hat{\varepsilon}_t^2}{T-p-1} ; \Omega_{\hat{\Phi}} = \hat{\sigma}_\varepsilon^2 (\hat{X}X)^{-1}$$

حيث $\sum_{t=1}^T \hat{\varepsilon}_t^2$ هي مجموع مربعات البواقي RSS و $\hat{\varepsilon}_t = Y_t - \hat{Y}_t$.

2-2 تقدير معلمات نموذج المتوسط المتحرك والمختلطة:

تعتبر النماذج $MA(q)$ و $ARMA(p, q)$ أعقد بكثير من حيث التقدير للنماذج الإندارية كونها غير خطية في المعلمات من جهة وعدم مشاهدة الأخطاء العشوائية من جهة أخرى، فهذه التقدير إذن هو تحديد قيم معلمات قسم الإندار الذاتي وقسم المتوسط المتحرك لـ $ARMA(p, q)$ معا، في الحالة العامة لدينا :

$$\Phi_p(B)Y_t = \theta_q(B)\varepsilon_t$$

فإفترض إمكانية قلب دالة تصبح كما يلي :

$$\varepsilon_t = \theta_q(B)^{-1}\Phi_p(B)Y_t$$

لتقدير معلمات النموذج، يجب تصغير مجموع مربعات البواقي أي

$$. \text{Min} \sum \hat{\varepsilon}_t^2 = S(\hat{\varphi}, \hat{\theta})$$

لقد رأينا إمكانية وسهولة تقدير معالم العلاقة في حالة غياب الطرق $MA(q)$ بينما في حالة وجودها لوحدها أو مع مركبة الإندار الذاتي $AR(p)$ فإن هذه العلاقة تصبح غير خطية المعالم. ومنه يوجد عدة طرق من بين هذه الطرق :

1-2-2 طريقة البحث التشابكي :

وهي أحد طرق نماذج $ARMA(p, q)$.

2-2-2 طريقة المعقولية العظمى (MLE) Maximum likelihood :

ليكم لدينا السيرورة $ARMA$ التالية :

$$.Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

حيث $\varepsilon_t \sim^{iid} N(0, \sigma^2)$ ، في العموم نحتاج لتقدير ما يلي : $\hat{b} =$

$(\hat{\varphi}_1, \dots, \hat{\varphi}_p, \hat{\theta}_1, \dots, \hat{\theta}_q)$ و $\hat{\sigma}^2$ ، السيرورة $ARMA$ يمكن كتابتها كما يلي :

$$\varepsilon_t = Y_t - \varphi_1 Y_{t-1} - \varphi_2 Y_{t-2} - \dots - \varphi_p Y_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

نفرض أن الأخطاء تتوزع توزيعاً طبيعياً حيث $t = 1, 2, \dots, n$ و $\varepsilon_t \sim^{iid} N(0, \sigma^2)$ فإن دالة الكثافة للمعقولية العظمى تكتب على الشكل التالي :

$$L(b, \sigma^2 / \varepsilon) = \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} e^{\left(-\frac{1}{2\sigma^2} \sum_{t=1}^n \varepsilon_t^2\right)}$$

حيث $b = (\varphi_1, \dots, \varphi_p, \theta_1, \dots, \theta_q)^T$ و $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)$. لنأخذ اللوغاريتم لدالة المعقولية العظمى :

$$\ln(b, \sigma^2 / \varepsilon) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{t=1}^n \varepsilon_t^2$$

يتم تقدير معالم النموذج وتباين الأخطاء بتعظيم دالة المعقولية حيث :

$$\max_{b, \sigma^2} \left\{ \ln(b, \sigma^2 / \varepsilon) \right\} = \max_{b, \sigma^2} \left\{ -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{t=1}^n \varepsilon_t^2 \right\}$$

الشروط الضرورية لكي يكون لوغاريتم الدالة عند قيمتها العظمى هي :

$$\frac{\partial \ln(L)}{\partial b} = 0 \Rightarrow b = \hat{b} = (\hat{\varphi}_1, \dots, \hat{\varphi}_p, \hat{\theta}_1, \dots, \hat{\theta}_q)$$

$$\frac{\partial \ln(L)}{\partial \sigma^2} = 0$$

مقدر المعقولية العظمى MLE لـ σ^2 هو $\hat{\sigma}^2 = \frac{\sum_{t=1}^n \varepsilon_t^2}{n}$. تعظيم اللوغاريتم لدالة العظمى، هو

$$S(b) = \sum_{t=1}^n \varepsilon_t^2$$

يعادل أقل ما يمكن مجموع مربعات الأخرى

4- الخطوة الرابعة : الفحص:

بعد تحديد وتقدير معالم النموذج ، فإن الخطوة الثالثة هي التحقق من مدى ملائمة النموذج المناسب يمكن إستخدام عدة طرق للفحص التشخيصي :

1-4 معايير المفاضلة بين النماذج الملائمة :

قد يحدث أحيانا أن يكون هناك مجموعة من النماذج ونريد المفاضلة بينهم .ولهذا يوجد عدة معايير :

1-1-4 معيار *Akaike information criterion 1971 AIC* :

يحسب بالعلاقة التالية :

$$* AIC(p, q) = n \ln \hat{\sigma}_\varepsilon^2 + 2(p + q) .$$

$$. \hat{\sigma}_\varepsilon^2 = \frac{\sum_{t=1}^T \hat{\varepsilon}_t^2}{n} \text{ حيث } \hat{\sigma}_\varepsilon^2 \text{ هو التباين المقدر لبواقي النموذج .}$$

2-1-4 معيار *Baysian information criterion BIC* :

يسمى كذلك بمعيار *Schwarz* . ويحسب بالعلاقة التالية :

$$* BIC(p, q) = n \ln \hat{\sigma}_\varepsilon^2 + (p + q) \ln(n) .$$

3-1-4 معيار *Hannan – Quin 1979 HQ* :

يحسب بالعلاقة التالية :

$$* HQIC(P) = n \ln \hat{\sigma}_\varepsilon^2 + p \ln(\ln(n)) .$$

وتعتبر هذه المعايير هي الأكثر إستعمالا في حالة نماذج السلاسل الزمنية ، والنموذج الأفضل هو يمنحنا أقل القيم الممكنة للمعايير السابقة ، وكذلك يمكننا إستعمال معيار لوغار يتم المعقولة العظمى $\ln(L)$ والنموذج الأفضل هو الذي يمنحنا أقل قيمة .

2-4 إختبار معنوية المعلمات وامعنوية الكلية للنموذج :

إذا إعتبرنا أن مقدرات نموذج $ARMA(p, q)$ تتوزع طبيعيا فإن :

$$\frac{\hat{\varphi}_i}{\hat{\sigma}_{\varphi_i}} \sim N(0,1) \quad i = 1, 2 \dots p$$

$$\frac{\hat{\theta}_j}{\hat{\sigma}_{\theta_j}} \sim N(0,1) \quad j = 1, 2 \dots q$$

وعليه نختبر مدى معنوية المعلمات φ_i و θ_j وفق الفرضيتين :

$$.H_0: \theta_1 = \dots = \theta_j ; H_0: \varphi_i = 0 \quad ; \quad i = 1, 2, \dots, p$$

$$.H_1: \theta_j \neq 0 \quad ; \quad H_0: \varphi_i \neq 0 \quad ; \quad j = 1, 2, \dots, q$$

نطبق الطريقة الكلاسيكية ،نستخدم توزيع t ستيودنت ،يمكن الوصول عادة إلى أن معلمة أو العديد من معاملات ليس معنويا يختلف عن الصفر ،ففي هذه الحالة نرجع إلى مرحلة التقدير بحذف المتغير الذي له معلمة غير معنوية .

لإختبار المعنوية الكلية للنموذج $ARMA(p, q)$ (غير متضمنة ثابت) نستخدم إحصائية Fisher ،حيث نختبر الفرضية التالية :

$$.H_0: \theta_1 = \dots = \theta_j = \dots = \theta_q = \varphi_1 = \dots = \varphi_i = \dots = \varphi_p = 0$$

تعرف إحصائية كما يلي :

$$.F_c = \frac{\sum_{t=1}^n (\hat{Y}_t - \bar{Y}) / (p+q)}{\sum_{t=1}^n \hat{\varepsilon}_t^2 / (n-p-1)} = \frac{R^2 / (p+q)}{(1-R^2) / (n-p-1)} \sim F((p+q), n-p-1)$$

إذا تجاوزت الإحصائية F_c قيمة F المجدولة عند مستوى معنوية α بدرجتي حرية $p - q$ و $n - p - q$ ،فإننا نقبل الفرضية H_1 القائلة بأن معاملات النموذج ليست جميعها مساوية للصفر وأن R^2 يخنف معنويا عن الصفر وفي هذه الحالة يمكن القول أنه ذو دلالة إحصائية .

ملاحظة :

n عدد المشاهدات المستخدمة في النموذج وليست بالضرورة عدد المشاهدات السلسلة الزمنية Y_t ،في الحقيقة :

* إذ تم تقدير $ARMA(p, q)$ فإننا سنفقد p ملاحظة .

* إذا تم تطبيق فروقات بسيطة أو موسمية على السلسلة الزمنية ،فإننا نفقد $(d + s\Delta)$ ملاحظة في الحالة العامة لسيرورة موسمية وغير موسمية في نفس الوقت .

3-4 تحليل البواقي :

إذا كانت البواقي تمثل فعلا تشويش أبيض، فإنه عند وجود إرتباط ذاتي في السلسلة والبواقي يجب أن تكون متجانسة، والإختبارات التالية يمكن أن تستخدم للتحقق من ذلك :

* إختبار Box – Piere 1979 (تكلنا عنه سابقا)، أثبت أن التوزيع المقارب لدوال الإرتباط الذاتي للبواقي $\rho_\varepsilon(h)$ حيث $h = 1, 2, 3, \dots$ يمكن أن تستخدم للتحقق من فرضيات التشويش الأبيض في ظل وجود نماذج $ARMA(p, q)$.

* تحت الفرضية الصفرية السيرورة هي تشويش أبيض بدلا من إختيار العشوائية في كل فترة تأخير مميزة، Box – Piere 1979 قدما إختبار Portmanteau لدوال الإرتباط الذاتي للبواقي، مع فترة تأخير m .

* Ljing و Box (الذي تكلنا عنه سابقا) حسنا من إختبار من Box – Piere 1979 بتقديم إختبار Portmanteau جديد.

* إختبار pena و Rodriguez إقتراحا إختبار Portmanteau للتباين المعمم، والذي أوضح أن إختبارهم الإحصائي أقوى من إختبار Ljing و Box.

* إختبار ARCH – LM : يستعمل إختبار ARCH لإختبار التباين الشرطي للأخطاء، أي إختبار ما إذا كان التذبذب الشرطي الذي يعبر في الغالب عن المخاطرة ثابتا، يعتمد هذا الإختبار على إحصائية مضاعف لاغرانج LM، نتبع الخطوات التالية :

- تقدير النموذج العام $\Phi_p(B)Y_t = \Theta_q(B)\varepsilon_t$. بطريقة المعقولة العظمى أو أي طريقة أخرى، ثم نقوم بحساب مربعات البواقي $\hat{\varepsilon}_t^2$.

- تقدير المعادلة التالية $\hat{\varepsilon}_t = \theta_0 + \theta_1\hat{\varepsilon}_{t-1}^2 + \dots + \theta_q\hat{\varepsilon}_{t-q}^2 + \hat{v}_t$ ثم حساب معامل التحديد الخاص بهذه المعادلة R^2 نفقد في هذه الحالة q مشاهدة.

- فرضيات ثبات التباين الشرطي للأخطاء H_0 التي ينبغي إختيارها هي :

$$.H_0: \theta_0 = \theta_1 = \dots = \theta_q = 0$$

تخضع إحصائية مضاعف لاغرانج $LM = (n - q) \times R^2$ لتوزيع χ^2 بدرجة حرية q عند مستوى معنوية α . فإننا نقبل فرضية تجانس التباين الشرطي للأخطاء H_0 ، أي إذا كانت كل معاملات معادلة ARCH تساوي معنويا الصفر في آن واحد .

5- الخطوة الخامسة : التنبؤ :The forecasting

لنعتبر السلسلة الزمنية Y_t ، حيث قيم Y_t عبر الزمن $t = n$ التنبؤ بقيم Y_t في الزمن $t = n + 1$ تكون ليست لها قيمة، وتكتب كما يلي : $\hat{Y}_{n+1/n}$.

* $Y_{n+k/n}$ أو تسمى التنبؤ في الفترة بخطوة واحدة إلى الأمام لـ Y_{n+1} أو تسمى التنبؤ في الفترة الأولى، ثم نأخذ القيمة المتوقعة الشرطية $\hat{Y}_{n+1} = E(Y_{t+1}/Y_1 \dots Y_n)$ نظرا لأن التنبؤ يسبق البيانات المتاحة بخطوة واحدة $\dots Y_n, Y_{n-1}$.

* في العموم، التنبؤ بـ k خطوة إلى الأمام هي $Y_{n+k/n}$ ويمكن أن نعبر عنها كمجموعة خطية كما يلي :

$$\hat{Y}_{n+k/n} = a_0 + a_1 Y_n + a_2 Y_{n-1} \dots$$

* هدفنا هو إنتاج تنبؤا مثل الحد لمتوسط مربع الأخطاء (MSE (Mean Square Error حيث MSE تعرف كما يلي : $MSE = E(Y_{n+k} - \hat{Y}_{n+k/n})^2$.

* نلاحظ أن التنبؤ لـ k خطوة إلى الأمام يمكن أن يكتب بعدة طرق مثل $\hat{Y}_{n+k/n}$ أو $\hat{Y}_{n/n-k}$ أو $\hat{Y}_{n-2/n-k-2}$... الخ .

لنعتبر نموذج $AR(p)$:

$$.Y_t = \phi_1 Y_{n-1} + \phi_2 Y_{n-2} + \dots + \phi_p Y_{n-p} + \varepsilon_t$$

حيث $\varepsilon_t \sim WN(0, \sigma_\varepsilon^2)$ ، نفترض أن التنبؤ بخطوة واحدة إلى الأمام $\hat{Y}_{n+1/n}$ هو المطلوب. إذا كانت المعلمات حول السلسلة الزمنية كمايلي في الفترة n :

$$.Y_{n+1} = \phi_1 Y_n + \phi_2 Y_{n-1} + \dots + \phi_p Y_{n-p+1} + \varepsilon_{n+1}$$

$$Y_{n+1/n} = \varphi_1 Y_{n/n} + \varphi_2 Y_{n-1/n} + \dots + \varphi_p Y_{n-p-1/n} + \varepsilon_{n+1/n}$$

$$\hat{Y}_{n+1/n} = \hat{\varphi}_1 \hat{Y}_{n/n} + \hat{\varphi}_2 \hat{Y}_{n-1/n} + \dots + \hat{\varphi}_p \hat{Y}_{n-p-1/n} + \hat{\varepsilon}_{n+1/n}$$

الآن، لأن المعلومات في الزمن t قيم $\hat{Y}_{n/n}, \hat{Y}_{n-1/n}, \dots, \hat{Y}_{n-p-1/n}$ معرفة قيمتها بالضبط، هم القيم لـ Y في الزمن t $n, n-1, \dots, n-p+1$ تسلسليا بمعنى

لـ $\hat{\varepsilon}_{n+1/n}$ ، يمكن أن تعوض بمتوسطها التي هي صفر .
 بالنسبة للقيمة الغير المعروفة $(\hat{Y}_{n/n} = Y_n, \hat{Y}_{n-1/n} = Y_{n-1}, \hat{Y}_{n-p-1/n} = Y_{n-p+1})$

* التنبؤ بخطوة واحدة إلى الأمام يعطي كمايلي :

$$\hat{Y}_{n+1/n} = \hat{\varphi}_1 Y_{n/n} + \hat{\varphi}_2 Y_{n-1/n} + \dots + \hat{\varphi}_p Y_{n-p-1/n}$$

الخطأ في عمل التنبؤ هو $\varepsilon_{n+1} = Y_{n+1} - Y_{n+1/n}$.

* في العموم، التنبؤات بـ k خطوة إلى الأمام يمكن أن يكتب كمايلي :

$$\hat{Y}_{n+k/n} = \hat{\varphi}_1 \hat{Y}_{n+k-1/n} + \hat{\varphi}_2 \hat{Y}_{n+k-2/n} + \dots + \hat{\varphi}_p \hat{Y}_{n+k-p/n} + \hat{\varepsilon}_{n+k/n}$$

كما من قبل، قيمة $\hat{\varepsilon}_{n+k/n}$ تعوض بقيمة متوسطها صفر تصبح كما يلي :

$$\hat{Y}_{n+k/n} = \hat{\varphi}_1 \hat{Y}_{n+k-1/n} + \hat{\varphi}_2 \hat{Y}_{n+k-2/n} + \dots + \hat{\varphi}_p \hat{Y}_{n+k-p/n}$$

مثال رقم 34:

لنعتبر النموذج $AR(1)$ $Y_t = 0.6Y_{t-1} + \varepsilon_t$ حيث لدينا Y_{100} أوجد التنبؤ لـ Y_{101} و Y_{102} و Y_{103} و Y_{104} .

الحل :

$$\hat{Y}_{101/100} = 0.6Y_{100} = 0.6 \times 0.9 = 0.54$$

$$\hat{Y}_{102/100} = 0.6Y_{101/100} = 0.6 \times 0.54 = 0.324$$

$$\hat{Y}_{103/100} = 0.6Y_{102/100} = 0.6 \times 0.324 = 0.1944$$

$$\hat{Y}_{104/100} = 0.6Y_{103/100} = 0.6 \times 0.1944 = 0.11664$$

الصيغة العامة للتنبؤ بـ k خطوة إلى الأمام بالنسبة للنموذج $AR(1)$ هي :

$$\hat{Y}_{t+k/t} = \hat{\varphi}^k \quad ; k \geq 1$$

الفصل السابع : نماذج أشعة الإنحدار الذاتي للسلاسل الزمنية متعددة المتغيرات (VAR) :

في الواقع الإقتصادي ، هناك نماذج فيها بعض المتغيرات ليست فقط متغيرات مفسرة لمتغير تابع ولكنها أيضا تفسر بالمتغيرات التي كانت تفسرها ، في هذه الحالة نحصل على نموذج معادلات أنية فيها متغيرات داخلية (مفسرة) وأخرى خارجية إلا أن نماذج المعادلات الأنية عرفت العديد من الإنتقادات ولاسيما ضعف التنبؤات الناتجة عنها في ظل بيئة إقتصادية معكرة ، إضافة إلى ذلك إنتقد Sim 1980 في مقاله الضهير *Macroeconomic and Reality* ، قرؤ التمييز بين المتغيرات ، حيث إذا كان هناك أنية بين المتغيرات بنفس الطريقة أي يجب أن لا يكون هناك تمييز بين المتغيرات الداخلية والخارجية ، جاءت نماذج VAR كبديل لهذا النوع من التنبؤية فلقد أثبتت الإختلالات الإقتصادية (الأزمة الإقتصادية العالمية ... الخ) عدم صلاحيتها بسبب أنية العلاقات التي تربط بين المتغيرات الإقتصادية وعدم أخذه بعين الإعتبار حركية نظام المعادلات القياسية . في نماذج VAR ، تعالج كل المتغيرات بصفة مماثلة وبدون شروط إقصاء مع إدخال عامل التأخير أو الإبطاء لكل المتغيرات في المعادلات ليعطي للنظام الطبيعة الحركية . هذه النماذج عبارة عن تعميم لنماذج الإنحدار الذاتي إذ يتكون من نظام لجملة معادلات بحيث كل متغير هو عبارة عن توليفة خطية لقيمها الماضية والقيم الماضية لمتغيرات أخرى ، بالإضافة إلى الأخطاء العشوائية .

1- الصياغة العامة لنموذج VAR :

يكتب النموذج $VAR - K$ متغير و p درجة تأخير على الشكل المصفوفي التالي :

$$\begin{aligned}
 Y_t = & \begin{bmatrix} a_{01} \\ a_{02} \\ a_{03} \\ \vdots \\ a_{0k} \end{bmatrix} + \begin{bmatrix} a_{1,1}^1 & a_{1,2}^1 & a_{1,3}^1 & \cdots & a_{1,k}^1 \\ a_{2,1}^1 & a_{2,2}^1 & a_{2,3}^1 & \cdots & a_{2,k}^1 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ a_{k,1}^1 & a_{k,2}^1 & a_{k,3}^1 & \cdots & a_{k,k}^1 \end{bmatrix} \times \begin{bmatrix} Y_{1,t-1} \\ Y_{2,t-1} \\ Y_{3,t-1} \\ \vdots \\ Y_{k,t-1} \end{bmatrix} \\
 & + \begin{bmatrix} a_{1,1}^2 & a_{1,2}^2 & a_{1,3}^2 & \cdots & a_{1,k}^2 \\ a_{2,1}^2 & a_{2,2}^2 & a_{2,3}^2 & \cdots & a_{2,k}^2 \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ a_{k,1}^2 & a_{k,2}^2 & a_{k,3}^2 & \cdots & a_{k,k}^2 \end{bmatrix} \times \begin{bmatrix} Y_{1,t-2} \\ Y_{2,t-2} \\ Y_{3,t-2} \\ \vdots \\ Y_{k,t-2} \end{bmatrix} + \cdots + \\
 & \cdot \begin{bmatrix} a_{1,1}^p & a_{1,2}^p & a_{1,3}^p & \cdots & a_{1,k}^p \\ a_{2,1}^p & a_{2,2}^p & a_{2,3}^p & \cdots & a_{2,k}^p \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ a_{k,1}^p & a_{k,2}^p & a_{k,3}^p & \cdots & a_{k,k}^p \end{bmatrix} \times \begin{bmatrix} Y_{1,t-2} \\ Y_{2,t-2} \\ Y_{3,t-2} \\ \vdots \\ Y_{k,t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1,t} \\ \varepsilon_{2,t} \\ \varepsilon_{3,t} \\ \vdots \\ \varepsilon_{k,t} \end{bmatrix}
 \end{aligned}$$

الصيغة العامة لنموذج ARMAX أو VARMAX نماذج ARMAX هي تعميم لسيرورات $VAR(p)$. تماما مثل سيرورات $ARMA(p, q)$ هي تعميم لسيرورات $AR(p)$ والتي هي :

$$Y_t = A_0 + A_1 Y_{t-1} + \cdots + A_p Y_{t-p} + \theta_1 \varepsilon_{t-1} + \cdots + \theta_{t-q} + \varepsilon_t$$

حيث θ, A هما مصفوفتان ذات البعد $(k \times k)$ للمتغيرات ومن الممكن أن تتصف بالسيرورة VMA (تم الحصول عليها عندما $p = 0$) بالمتوسطات المتحركة المتعددة المتغيرات، وهو نموذج $ARMA(p, q)$ متعدد المتغيرات أو $VARMA(p, q)$ الذي يصطلح تسميته أيضا بـ $ARMAX(p, q)$.

* تكون السيرورات VAR قابلة للقلب دائما، ومستقرة إذا كانت جذور كثير الحدود المميزة لها تقع خارج دائرة الوحدة .

* تتوقف شروط القلب والإستقرارية لسيرورات $ARMA$ على أجزاء السيرورات VAR و VMA .

* قد يتضمن نموذج VAR متغيرات مستقلة ويسمى بنموذج SVAR الذي بأخذ الشكل التالي :

$$Y_t = A_0 + A_1 Y_{t-1} + \dots + A_p Y_{t-p} + \alpha_1 X_{t-1} + \dots + \alpha_m X_{t-m} + \varepsilon_t$$

حيث:

Y_t شعاع نموذج الإنحدار الذاتي VAR و A_0 شعاع الثوابت و $A_1 \dots A_p$ مصفوفة المعاملات و ε_t شعاع الأخطاء (التشويش الأبيض).

مصفوفة التباين-التباين المشترك للأخطاء $\Sigma = E(\varepsilon_t \varepsilon_t')$ هنا غير معروفة، يمكن أيضا كتابة النموذج بدلالة معامل التأخير حيث :

$$(I_k - A_1 B + A_1 B^2 + \dots + A_p B^p) Y_t = A_0 + \varepsilon_t$$

$$A(B) Y_t = A_0 + \varepsilon_t$$

حيث A هي مصفوفة كثير الحدود ذات البعد $(k \times k)$ للمتغيرات $Y_t^1, Y_t^2, \dots, Y_t^k$ كسلاسل زمنية مستقرة و $\varepsilon_t^1, \varepsilon_t^2, \dots, \varepsilon_t^k$ ذات تشويش أبيض ولها تباينات ثابتة $\sigma_{\varepsilon^1}^2, \sigma_{\varepsilon^2}^2, \dots, \sigma_{\varepsilon^k}^2$ يكون المسار VAR إذا تحققت الفرضيات التالية :

- المتوسط $\mu_t = E(Y_t) = \mu$ حيث $\forall t \in Z$.

- التباين $var(Y_t) = \sigma_Y^2 = \gamma_0 < \infty$.

- التباين المشترك $cov(Y_t, Y_{t+h}) = \gamma(h) = E[(Y_t - \mu)(Y_{t+h} - \mu)]$ لكل $\forall t, h \in Z$ حيث γ تمثل دالة التباين المشترك لـ Y_t .

بصفة عامة، تكون السيرورة VAR مستقرة إذا كان كثير الحدود المعرف إنطلاقاً من محدد المصفوفة $|I_k - A_1B + A_1B^2 + \dots + A_pB^p| = 0$ تحتوى على جذور خارج دائرة الوحدة .

متغيرات داخلية $Y_{1,t}, \dots, Y_{k,t}$ و متغيرات خارجية ويطلق عليه بإسم النظام الخطي، كما يسمى بنموذج المعادلات الآنية الحركية (الدينامكية) بإستعمال معامل التأخير B في النموذج حيث يكون الشكل المختصر كما يلي :

$$A(B)Y_t = \alpha(B)Y_t + \varepsilon_t$$

وبضرب الشكل المختصر بـ : $A^{-1}(B)$

$$Y_t = A^{-1}(B)\alpha(B)Y_t + A^{-1}(B)\varepsilon_t$$

حيث $\alpha(B)$ يسمى بالشكل النهائي للنظام ويكون هذا الشكل موجوداً في حالة ما إذا كانت المصفوفة $A(B)$ قابلة للقلب تحت الشرط التالي :

$$\det(A(B)) \neq 0$$

2- طريقة التقدير نموذج VAR:

في حالة نموذج VAR يمكن تقدير كل معادلة من معادلات هذا النموذج بطريقة المربعات الصغرى أو المعقولة العظمى، يكتب نموذج $VAR(p)$ المقدر وفق الشكل التالي :

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

حيث ε هو شعاع ذو البعد $(k \times 1)$ للبواقي المقدر $(\hat{\varepsilon}_{1t}, \hat{\varepsilon}_{2t}, \dots, \hat{\varepsilon}_{kt})$ ، ونسمى \sum_{ε} مصفوفة التباين-التباين المشترك لبواقي التقدير.

يجب تقدير معاملات هذا النموذج إنطلاقاً من سلاسل مستقرة عن طريق حساب الفروقات من الدرجة d في حالة إتجاه عام عشوائي أو إضافة مركبة إتجاه عام إلى صيغة نموذج VAR في حالة إتجاه عام ثابت، أيضاً يمكن إضافة متغيرات صورية لتصحيح التغيرات الموسمية .

3- طريقة تحديد رتبة نموذج VAR:

لتحديد درجة نموذج VAR(p)، نستخدم معايير المعلومات، فطريقة إختيار الدرجة تكمن في تقدير كل معاملات النموذج من أجل أي درجة من 0 الى p^* (p^* هو العدد الأصي المقبول للتأخير المسموح من قبل النظرية الإقتصادية أو البيانات المتاحة)، نستعمل مثلا ثلاثة معايير Akaike و Schwarz و Hannan – Quin المعرفة كما يلي :

$$* AIC(p) = \ln(\det|\sum_{\hat{\epsilon}}|) + \frac{2k^2p}{n} .$$

$$* SC(p) = \ln(\det|\sum_{\hat{\epsilon}}|) + \frac{k^2 \ln(n)}{n} .$$

$$* AIC(p) = \ln(\det|\sum_{\hat{\epsilon}}|) + \frac{2k^2p \times \ln(n)}{n} .$$

قائمة المراجع

قائمة المراجع باللغة العربية :

- * محمد شيخي ، طرق القياس الاقتصادي محاضرات وتطبيقات، الحامد ، الطبعة الاولى، 2011.
- * سمير مصطفى الشعراوي، مقدمة في التحليل الحديث للسلاسل الزمنية مركز النشر العلمي، الطبعة الأولى، جده، المملكة العربية، 2005.
- * عبد القادر محمد عبد القادر عطية، "الاقتصاد القياسي بين النظرية والتطبيق"، ط (2)، الإسكندرية: الدار الجامعية، 200.
- * مولود حشمان، نماذج وتقنيات التنبؤ على المدى القصير ،ديوان المطبوعات الجامعية ،الجزائر؛ 1998.
- * مولود حشمان، "نماذج وتقنيات التنبؤ القصير المدى"، ديوان المطبوعات الجامعية ،الجزائر، 2010 .
- * هاري كلجيان، والاس أوتس ؛ ترجمة المرسي السيد حجازي، عبد القادر محمد عطية ،مقدمة في الاقتصاد القياسي: المبادئ والتطبيقات،النشر العلمي والمطابع، المملكة العربية السعودية 2001.
- * صالح تومي ،مدخل لنظرية القياس الاقتصادي (الجزء الأول) ،ديوان المطبوعات الجامعة ،الجزائر 1999.

قائمة المراجع باللغة الأجنبية :

- * Régis Bourbonnais Michel Terraza, Analyse des séries temporelles Applications à l'économie et à la gestion, 3e édition, Dunod, Paris, 2010.
- * Esam Mahdi, Time Series Analysis - Part 1, Islamic University of Gaza - Department of Mathematics, 19April, 2017.
- * Esam Mahdi, Time Series Analysis - Part 2, Islamic University of Gaza Department of Mathematics, 26April, 2017.
- * James D. Hamilton, Time Series Analysis, published by Princeton University Press, 41 William St., Princeton, New Jersey 08540, 1994.
- * Badi H. Baltagi, Econometrics, Springer Heidelberg Dordrecht London New York, Fifth Edition, 2011.
- * Éric DOR, Économétrie, Pearson Education France, 2009.
- * Darnodar Gujarati, Econometrics by Example, First published 2011 by PALGRAVE MACMILLAN.
- * John D. Levendis, Time Series Econometrics, Springer Nature Switzerland AG, 2018.