

طرق التنبؤ الإحصائي

(الجزء الأول)

تأليفه د. عدنان ماجد عبدالرحمن بري
أستاذ الإحصاء وبيوتي العمليات المشارك

بسم الله الرحمن الرحيم

الحمد لله رب العالمين والصلوة والسلام على اشرف خلق الله سيدنا ونبينا محمد
وعلى آله وصحبه وسلم.
أما بعد.

هذه هي المسودة الأولى لكتاب طرق التنبؤ الإحصائي لطلاب مرحلة البكالوريوس.
هذا الكتاب سيظل مسودة إلى ماشاء الله لأنني وبإذن الله تعالى سوف أقوم بتطويره
وتتجديده وتحسينه بشكل مستمر وسيظل بشكله الإلكتروني هذا لأنني أعتقد أن العلوم
والتقنية تتطور يوميا وبشكل متسارع بحيث إن وضعها في كتاب جامد ستاتيكي
لايتنااسب مع ديناميكية الموضوع وخاصة في عصر ثورة المعلومات والإنترنت.

يعطي الجزء الأول من الكتاب الأساسية الأولية للموضوع ويتطرق إلى موضوع
التنبؤ الإحصائي بإستخدام نماذج ARIMA والتي كانت أول معالجة رياضية جادة
ومحكمة للتنبؤ الإحصائي بإستخدام المتسلسلات الزمنية Time Series كما تطرقت
في آخر الكتاب إلى بعض الطرق التقليدية الهرستيكية للتنبؤ الإحصائي وفي جميع
أجزاء الكتاب قمت بتوسيع الأمثلة والحالات الدراسية بإستخدام الحزمة الإحصائية
Minitab وهي برامج حاسب طورت خاصة لتعليم علم الإحصاء بجميع فروعه
وهذه الحزمة متوفرة للطلاب بالمجان.

الجزء الثاني من الكتاب وموجه لطلاب الدراسات العليا سوف يتطرق بإذن الله
لمواضيع مثل تحليل التدخل Intervention Analysis ونماذج دالة التحويل
Transfer Function Models ونماذج المتسلسلات الزمنية الموجهة
Multivariate Time Series Models ونماذج المتسلسلات الزمنية الموجهة
Vector Time Series Models ونماذج فضاء الحالة ومرشح كالمن State
Threshold Time Space Models and Kalman Filtering ونماذج ARCH GARCH وتطبيقاتها في التنبؤ
Series Models والمالي Finantial Time Series Forecasting كما ستنتطرق إلى الشبكات
العصبية Neural Networks وإستخدامها في التنبؤ الإحصائي.

هذا وارجوا من الله ان يوفقني في إنجاز هذا العمل لوجهه الكريم ولإثراء المكتبة
العربية الفقيرة إلى مثل هذا الكتاب.

سيكون هذا الكتاب مجاني لأي طالب علم وهو سيكون متواجد على شبكة الإنترنت
في الموقع <http://www.abarry.ws/books/statisticalForecast.pdf>
والله الموفق.

المؤلف

د. عدنان ماجد عبد الرحمن بري

جامعة الملك سعود

ذو القعدة 1422 هـ

يناير 2002 م

المحتويات

مقدمة

9	1- الفصل الأول: مقدمة وتعريف
9	1-1 أمثلة على المتسلسلات الزمنية
9	2-1 الغرض من دراسة وتحليل المتسلسلات الزمنية
9	3-1 الخطوات المتخذة لبناء نموذج تنبؤ
9	3-1-1 تعريف النموذج
10	2-3-1 تطبيق النموذج
10	3-3-1 تشخيص وإختبار النموذج
10	4-3-1 توليد التنبؤات
10	5-3-1 استخدام التنبؤات ووضع القرارات
10	4-1 تعريف ومبادئ أولية
10	4-1-1 تعريف ماضي أو تاريخ الظاهرة
10	4-1-2 تعريف الحاضر أو الآن
10	4-1-3 تعريف أخطاء التطبيق
11	4-1-4 تعريف أخطاء التنبؤ
11	4-1-5 تعريف الاستقرار
11	4-1-6 تعريف الضجة البيضاء
11	4-1-7 مثال 1 : المشي العشوائي
12	4-1-8 تعريف دالة التغایر الذاتی
12	4-1-9 تعريف دالة الترابط الذاتی
12	4-1-10 مثال 2 : دالة الترابط الذاتی للضجة البيضاء
13	4-1-11 تعريف دالة الترابط الذاتی الجزئی
14	4-1-12 مثال 3: دالة الترابط الذاتی الجزئی للضجة البيضاء
15	4-1-13 تعريف دالة الترابط الذاتی للعينة
16	4-1-14 تعريف دالة الترابط الذاتی الجزئی للعينة

2- الفصل الثاني: نماذج الإنحدار الذاتي-المتوسط المتحرك ARMA	2
25 3- وإستخداماتها في التنبؤ	25
25 1-2 تعريف نماذج الإنحدار الذاتي-المتوسط المتحرك من الدرجة (p,q)	25
25 2-2 تعريف عامل الإزاحة الخلفي	25
25 3-2 تعريف عامل الإزاحة الأمامي	25
25 4-2 تعريف عامل التفريق	25
25 5-2 تعريف عامل التجميع	25
26 6-2 أمثلة	26
26 7-2 خصائص نماذج الإنحدار الذاتي-المتوسط المتحرك	26
26 1-7-2 نموذج ARMA(0,0)	31
31 2-7-2 نموذج AR(1)	31
31 3-7-2 نموذج AR(2)	36
36 4-7-2 نموذج MA(1)	39
39 5-7-2 نموذج MA(2)	40
40 6-7-2 نموذج ARMA(1,1)	47
47 7-7-2 خواص نماذج ARMA(p,q)	58
58 3- الفصل الثالث: نماذج المتسلسلات الزمنية غير المستقرة	58
58 1-3 عدم الاستقرار في المتوسط	59
59 2-3 عدم الاستقرار في التباين	62
62 3-3 نماذج الإنحدار الذاتي-التكاملية-المتوسط المتحرك من الدرجة (p,d,q)	62
62 1-3-3 نموذج ARIMA(1,1,0)	62
62 2-3-3 نموذج ARIMA(0,1,1)	63
63 3-3-3 نموذج المشي العشوائي بإنجراف	63
63 4-3 دالة الأوزان (B^ψ) وتمثيل نماذج ARMA(p,q)	64
64 5-3 أمثلة لدالة الأوزان لبعض النماذج	64
64 1-5-3 دالة الأوزان لنموذج AR(1)	65
65 2-5-3 دالة الأوزان لنموذج MA(1)	

65	3-5-3 دالة الأوزان لنموذج AR(2)
66	4-5-3 دالة الأوزان لنموذج MA(2)
66	5-5-3 دالة الأوزان لنموذج ARMA(1,1)
67	6-5-3 دالة الأوزان لنموذج ARI(1)
68	7-5-3 دالة الأوزان لنموذج المشي العشوائي ARIMA(1,0,1)
69	6-3 بعض خواص دالة الأوزان $\psi(B)$
71	4- الفصل الرابع: التنبؤات ذات متوسط مربع الخطأ الأدنى لنماذج ARMA(p,q)
71	4-1 نظرية 2: أخطاء التنبؤ
72	4-2 مجموعة المعلومات Information Sets
72	4-3 نظرية 3: المتتبى ذا متوسط مربع الخطأ الأدنى
72	4-4 قاعدة 2
73	5-4 تعريف دالة التنبؤ
73	6-4 دوال التنبؤ لنماذج ARIMA(p,d,q)
73	1-6-4 دالة التنبؤ لنموذج AR(1)
73	2-6-4 شرط الإستمرار
74	3-6-4 دالة التنبؤ لنموذج AR(2)
74	4-6-4 دالة التنبؤ لنموذج ARIMA(0,1,1)
75	5-6-4 دالة التنبؤ لنموذج MA(1)
75	6-6-4 دالة التنبؤ لنموذج MA(2)
76	7-6-4 دالة التنبؤ لنموذج ARMA(1,1)
80	7-4 حدود التنبؤ
80	1-7-4 تعريف فترة تنبؤ للقيمة المستقبلية
81	2-7-4 مثال
82	5- الفصل الخامس: تصميم وبناء نظام تنبؤ إحصائي
82	1-5 تعيين أو تحديد النموذج
83	1-1-5 تثبيت التباين
83	2-1-5 اختيار درجة التقرير d
84	3-1-5 تحديد p,q
84	4-1-5 إضافة معلم إنجراف

85	تقدير النموذج.....	2-5
85	طريقة العزوم.....	1-2-5
86	تقدير العزوم لبعض النماذج.....	2-2-5
86	1 لنموذج (AR(1)).....	1-2-2-5
86	2 لنموذج (MA(1)).....	2-2-2-5
87	3 لنموذج (AR(2)).....	3-2-2-5
87	4 لنموذج (MA(2)).....	4-2-2-5
87	5 لنموذج (ARMA(1,1)).....	5-2-2-5
89	3 طريقة المربعات الدنيا الشرطية.....	3-2-5
89	4 تقديرات المربعات الدنيا الشرطية لبعض النماذج.....	4-2-5
89	1 لنماذج (AR(1)).....	1-4-2-5
90	2 لنماذج (MA(1)).....	2-4-2-5
94	3-5 تشخيص وإختبار النموذج.....	
94	1-3-5 فحص البوافي.....	
94	1-1-3-5 إختبار المتوسط للبوافي.....	
95	2-1-3-5 إختبار العشوائية للبوافي.....	
95	3-1-3-5 إختبار الترابط أو الإستقلال للبوافي.....	
96	4-1-3-5 إختبار طبيعة البوافي.....	
96	2-3-5 بعض المعايير الأخرى لإختيار نموذج مناسب.....	
96	1-2-3-5 إحصائية كيو للجنة وبكس.....	
96	2-2-3-5 معيار الإعلام الذاتي AIC.....	
96	3-3-5 أمثلة وحالات دراسة.....	
143	6- الفصل السادس: نماذج الإنحدار الذاتي-التكاملـي-المتوسط المتحرك الموسمية.....	
143	1-6 دوال الترابط الذاتي والترابط الذاتي الجزيئي لبعض النماذج الموسمية.....	
144	1-1-6 1 لنـموذج SARMA(0,1)(1,1)12.....	
145	2-6 دوال الترابط الذاتي لبعض النماذج الموسمية.....	
145	1-2-6 SARIMA(0,d,0)(0,D,1)s.....	
145	2-2-6 SARIMA(0,d,0)(1,D,1)s.....	
145	3-2-6 SARIMA(0,d,1)(0,D,1)s.....	

146	SARIMA(0,d,0)(1,D,1)s	4-2-6
146	SARIMA(0,d,1)(1,D,0)s	5-2-6
146	SARIMA(0,d,2)(0,D,1)s	6-2-6
147	3-6 دالة الترابط الذاتي الجزئي للنموذج الموسمي التضاعفي	
147	4-6 أمثلة على المتسلسلات الزمنية الموسمية	
148	5-6 إشتقاق دوال تنبؤ لبعض نماذج المتسلسلات الموسمية التضاعفية	
148	5-6-1 دالة التنبؤ للنموذج SARIMA(0,0,0)(0,1,1)12	
148	5-6-2 دالة التنبؤ للنموذج SARIMA(0,1,1)(0,1,1)12	
149	6-6 أمثلة وحالات دراسة للمتسلسلات الزمنية الموسمية	
الجزء العملي:		
7- الفصل السابع: ورقة تدريب عملي على التنبؤ بواسطة نماذج الانحدار		
178	الذاتي-المتوسط المتحرك	
193	8- الفصل الثامن: مثال تحليل الباقي ومعيير اختيار نموذج مناسب	
202	9- الفصل التاسع: تحليل أو تفكك المتسلسلة الزمنية إلى مركبات	
225	10- التمهيد والتنبؤ بواسطة المتوسط المتحرك	
225	1-10 الوسيط الجاري	
232	11- الفصل الحادي عشر: التمهيد والتنبؤ بواسطة التمهيد الأسني البسيط	
239	12- الفصل الثاني عشر: التمهيد والتنبؤ بواسطة التمهيد الأسني المزدوج	
239	1-12 طريقة براون	
240	2-12 طريقة هولت	
242	3-12 أمثلة	
250	13- الفصل الثالث عشر: التمهيد الأسني الثلاثي والتنبؤ بواسطة طريقة وتنز للمتسلسلات الموسمية المنجرفة	
250	1-13 النموذج الإضافي	
242	2-13 النموذج التضاعفي	
259	3-13 مثال لبناء نموذج تنبؤ	
267	4-13 مثال آخر لبناء نموذج تنبؤ	
275	ملحق (1) أسئلة وإجابات الإختبارات السابقة	
358	المراجع	

الفصل الأول

مقدمة وتعريف

تعريف 1:

المتسلسلة الزمنية Time Series هي متتابعة من القيم المشاهدة لظاهرة عشوائية مرتبة مع الزمن (او مرتبة على المكان)

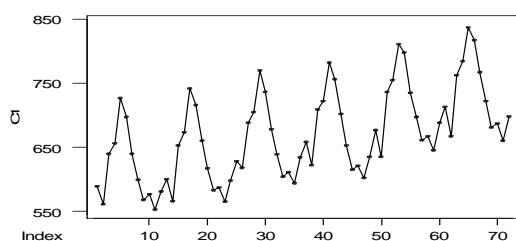
امثلة على المتسلسلات الزمنية:

- 1- سعر افقال سهم بنك الرياض يوميا.
- 2- عدد الوحدات المطلوبة اسبوعيا من انتاج سلعة معينة.
- 3- حجم المبيعات شهريا من سلعة ما.
- 4- حجم الإنتاج اليومي للنفط الخام بالمملكة.

والغرض من دراسة وتحليل المتسلسلات الزمنية هو:

- 1- فهم ونمذجة عشوائية الظاهرة المشاهدة.
- 2- التنبؤ عن القيم المستقبلية للظاهرة العشوائية.
- 3- التحكم بالظاهرة العشوائية إذا أمكن ذلك.

الشكل التالي لمتسلسلة زمنية مشاهدة وهي عبارة عن الإنتاج اليومي للحليب بالرطل لبقرة ما



الخطوات المتخذة لبناء نموذج تنبؤ:

إن إيجاد نموذج مناسب تتطبق عليه متسلسلة زمنية مشاهدة يعتبر من المهام الصعبة والتي تحتاج إلى الكثير من البحث والخبرة. سوف نستعرض بعض الخطوات العريضة لبناء نموذج رياضي للتنبؤ عن متسلسلة زمنية ما:

- 1- تعيين النموذج أو تحديد النموذج :Model Identification

وهذا يتم برسم المتسلسلة الزمنية فيما يسمى Time Plot حيث يكون الإحداثي الأفقي هو الزمن والرأسي حجم الظاهرة المشاهدة ومن ثم اختيار نموذج رياضي معتمدين على بعض المقاييس الإحصائية التي تميز نموذج عن آخر وعلى الخبرة المستمدة من الدراسات والابحاث.

- 2- تطبيق النموذج :Model Fitting

بعد ترشيح نموذج او أكثر كنموذج مناسب لوصف المتسلسلة المشاهدة نقوم بتقدير معالم هذا النموذج من البيانات المشاهدة باستخدام طرق التقدير الإحصائي الخاصة بالمتسلسلات الزمنية وهذا النموذج المرشح يؤخذ كنموذج أولي قابل للتعديل لاحقا.

- 3- تشخيص وإختبار النموذج :Model Diagnostics

إجراء إختبارات تفحصية على أخطاء التطبيق Fitting Errors لمعرفة مدى تطابق المشاهدات مع القيم المحسوبة من النموذج المرشح ومدى صحة فرضيات النموذج. في حالة إجتياز النموذج المرشح لهذه الإختبارات نقوم بإعتماده على انه النموذج النهائي ويستخدم لتوليد تنبؤات للقيم المستقبلية وإلا نعود للخطوة الاولى لتعيين نموذج جديد.

- 4- توليد التنبؤات :Forecast Generation

يستخدم النموذج النهائي لتوليد تنبؤات عن القيم المستقبلية ومن ثم حساب أخطاء التنبؤ Forecast Errors كلما استجدة قيم جديدة مشاهدة من المتسلسلة الزمنية ومراقبة هذه الأخطاء في ما يسمى بمخططات المراقبة Control Charts والتي توضع للقبول بنسبة خطأ معين إذا تجاوزته أخطاء التنبؤ يعاد النظر في النموذج وتعاد الدورة من جديد بتحديد نموذج مرشح آخر.

- 5- استخدام التنبؤات ووضع القرارات :Implementation and Decision

making: تقدم التنبؤات في تقرير لصانعي القرار للنظر في استخدامها بالشكل المناسب.

تعاريف ومبادئ اولية:

سوف نرمز للظاهرة العشوائية أو العملية العشوائية التي تولد المتسلسلة الزمنية بالرمز $\{Z_t, t \in \{\dots, -1, 0, 1, 2, \dots\}\}$ او اختصارا $\{Z_{-1}, Z_0, Z_1, Z_2, \dots\}$ او ببساطة $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ وللمتسلسلة الزمنية المشاهدة بالرمز $\{z_1, z_2, \dots, z_{n-1}, z_n\}$

تعريف 2:

القيم $z_1, z_2, \dots, z_{n-1}, z_n$ تسمى بالماضي او تاريخ الظاهرة History

والتاريخ مهم جدا في عملية النمذجة

تعريف 3 :

القيمة z_n تسمى الحاضر او الان

وهي المشاهدة الأخيرة .

تعريف 4:

أخطاء التطبيق تعطى بالعلاقة $e_t = z_t - \hat{z}_t, \quad t = 1, 2, \dots, n$ حيث \hat{z}_t هي القيم المطبقة)

القيم التي نتحصل عليها من النموذج) وتسمى أيضا الرواسب Residuals

ويلاحظ ان اخطاء التطبيق نحصل عليها دفعه واحدة بعد تقدير النموذج.

ملاحظة: سوف نرمز للمشاهدات المستقبلية بالرموز $z_{n+1}, z_{n+2}, \dots, z_{n+3}$ او بشكل عام

$z_{n+\ell}, \ell \geq 0$ ونرمز لتنبؤاتها بالرمز $z_n(1), z_n(2), z_n(3), \dots$ او بشكل عام

$z_n(\ell), \ell \geq 0$

تعريف 5:

$$e_n(\ell) = z_{n+\ell} - z_n(\ell), \quad \ell \geq 0$$

أخطاء التنبؤ تعطى بالعلاقة

وأخطاء التنبؤ تنتج الواحدة تلو الأخرى كلما تقدم الزمن وشوهدت القيم الحقيقية

تعريف 6:

يقال ان المتسلسلة الزمنية المشاهدة $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ مستقرة Stationary إذا حققت الشروط التالية:

$$1) \quad E(z_t) = \text{constant} = \mu, \quad \forall t$$

$$2) \quad \text{cov}(z_t, z_s) = \begin{cases} \text{constant} = \gamma_0, \forall t, \forall s, t = s \\ f(|s-t|), \forall t, \forall s, t \neq s \end{cases}$$

الآن سوف نعرف متسلسلة زمنية مهمة جداً لكونها حجرة او طوب البناء Building Blocks لجميع النماذج التي سوف ندرسها

تعريف 7:

متسلسلة الضجة البيضاء White Noise Series او عملية الضجة البيضاء White Noise Process هي عبارة عن متتابعة من المشاهدات العشوائية غير المترابطة () واحياناً نفترض أنها متتابعة من المتغيرات العشوائية التي تكون مستقلة ولها توزيعات متطابقة (Independent, Identically Distributed) (IID) بمتوسط صفر وتبالين ثابت σ^2 أي:

$$1) \quad E(a_t) = 0, \forall t$$

$$2) \quad \text{cov}(a_t, a_s) = \begin{cases} \sigma^2, & \forall t, \forall s, t = s \\ 0, & \forall t, \forall s, t \neq s \end{cases}$$

ويرمز لها بالرمز $a_t \sim WN(0, \sigma^2)$

مثال 1:

متسلسلة المشى العشوائى Random Walk

سوف نبني عملية عشوائية $\{Z_t\}$ كالتالي:

$$Z_1 = a_1$$

$$Z_2 = a_1 + a_2$$

⋮

$$Z_t = a_1 + a_2 + \dots + a_t$$

أو

$$Z_t = Z_{t-1} + a_t$$

أي لو اعتبرنا أن a_j هو حجم الخطوة التي تؤخذ الي الامام او الخلف عند الزمن j فان

هي موقع مashi عشوائي عند الزمن t

ملاحظة: هذه العملية او المتسلسلة من النماذج الهامة جدا التي تصف اسواق المال العالمية

تمرين: اوجد $E(Z_t)$ و $\text{cov}(Z_t, Z_s)$ لجميع قيم t, s وهل العملية مستقرة؟

تعريف 8:

دالة التغير الذاتي Autocovariance Function وتعرف كالتالي:

$$\gamma_{t,s} = \text{cov}(Z_t, Z_s), \forall t, \forall s$$

$$= E[(Z_t - \mu)(Z_s - \mu)], \forall t, \forall s$$

وإذا عرفنا التخلف k على انه الفترة الزمنية التي تفصل بين Z_t وبين Z_{t-k} او Z_{t+k} فإن

دالة التغير الذاتي تعطى بالعلاقة:

$$\gamma_k = \text{cov}(Z_t, Z_{t-k}), \quad k = 0, \pm 1, \pm 2, \dots$$

$$= E[(Z_t - \mu)(Z_{t-k} - \mu)], \quad k = 0, \pm 1, \pm 2, \dots$$

ملاحظة: سوف نستخدم التعريف الثاني دائما

تعريف 9:

دالة الترابط الذاتي Autocorrelation Function (ACF) وتعرف كالتالي:

$$\rho_k = \frac{\gamma_k}{\gamma_0}, \quad k = 0, \pm 1, \pm 2, \dots$$

ولها الخواص التالية:

1. $\rho_0 = 1$
2. $\rho_{-k} = \rho_k$
3. $|\rho_k| \leq 1$

مثال 2:

سوف نست酉 الآن دالة الترابط الذاتي لعملية الضجة البيضاء

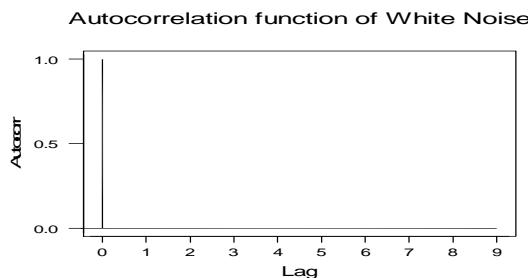
دالة التغير الذاتي لعملية الضجة البيضاء هي:

$$\gamma_k = \text{cov}(a_t, a_{t-k}) = \begin{cases} \sigma^2, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

وذلك من التعريف 7 ومنها نجد دالة الترابط الذاتي:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

ولها الشكل التالي:



تعريف 10:

دالة الترابط الذاتي الجزئي (PACF) وتعطي مقدار الترابط بين Z_t و Z_{t-k} بعد إزالت تأثير الترابط الناتج من المتغيرات الواقعية بينهما ويرمز لها عند التخلف k بالرمز ϕ_{kk} وأحد طرق حسابها تقوم على حساب معامل الإنحدار الجزئي ϕ_{kk} في التمثيل:

$$Z_t = \phi_{k1}Z_{t-1} + \phi_{k2}Z_{t-2} + \dots + \phi_{kk}Z_{t-k} + a_t$$

حساب ϕ_{11} :

$$Z_t = \phi_{11}Z_{t-1} + a_t$$

بضرب طرفي العلاقة بـ Z_{t-1} وأخذ التوقع نجد

$$E(Z_{t-1}Z_t) = \phi_{11}E(Z_{t-1}Z_{t-1}) + E(Z_{t-1}a_t)$$

أي

$$\gamma_1 = \phi_{11}\gamma_0$$

حيث $E(Z_{t-k}a_t) = 0, k = 1, 2, \dots$ (بشكل عام كما سنبين لاحقا)

وبالقسمة على γ_0 نجد

$$\phi_{11} = \rho_1$$

تعريف 11:

بشكل عام تعرف دالة الترابط الذاتي الجزئي كالتالي:

$$\phi_{kk} = \begin{cases} 1, & k=0 \\ \rho_1, & k=1 \\ \left| \begin{array}{ccccc} 1 & \rho_1 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_1 & \rho_k \end{array} \right|, & k=2,3,\dots \\ \left| \begin{array}{ccccc} 1 & \rho_1 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_1 & 1 \end{array} \right| \end{cases}$$

حيث | ترمز الي محددة مصفوفة

التعريف السابق صعب الإستخدام لقيم k الكبيرة ولهذا سوف نعطي تعريف آخر لحساب دالة الترابط الذاتي الجزئي تكراريا:

تعريف 11 ب:

تحسب ϕ_{kk} تكراريا من العلاقات

$$\phi_{00} = 1, \text{ by definition}$$

$$\phi_{11} = \rho_1$$

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}, \quad k=2,3,\dots$$

حيث

$$\phi_{kj} = \phi_{k-1,j} - \phi_{kk} \phi_{k-1,k-1}, \quad j=1,2,\dots,k-1$$

حساب ϕ_{22} :

من تعريف 11 ب:

$$\phi_{22} = \frac{\rho_2 - \phi_{11}\rho_1}{1 - \phi_{11}\rho_1} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

وذلك لأن $\phi_{11} = \rho_1$.

مثال 3:

سوف نشتق الآن دالة الترابط الذاتي الجزئي لعملية الضجة البيضاء:

من تعريف 11 ب

$$\phi_{00} = 1, \text{ by definition}$$

$$\phi_{11} = \rho_1 = 0$$

وذلك من مثال 1 السابق

وبالتعويض في تعريف 11 ب عن ϕ_{kk} نجد

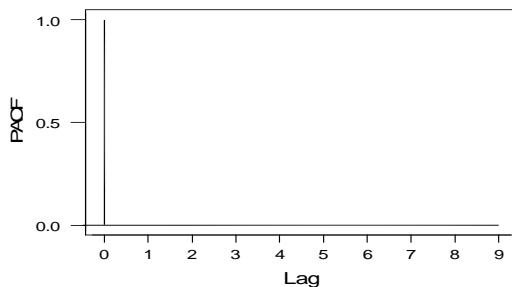
$$\phi_{22} = \phi_{33} = \dots = 0$$

وهكذا:

$$\phi_{kk} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

ولها الشكل التالي:

Partial Autocorrelation function of White Noise



ملاحظة: لاحظ أن كل من دالتي الترابط الذاتي والترابط الذاتي الجزئي لعملية الضجة البيضاء تساوي الصفر من التخلف الأول. وهذه خاصية جميع المتغيرات العشوائية غير المترابطة أو المستقلة. لاختبار عدم الترابط بين قيم مشاهدة لمتغير عشوائي تستخدم دالة الترابط الذاتي لذلك.

تعريف 12 :

دالة الترابط الذاتي للعينة Sample Autocorrelation Function SACF لسلسلة

زمنية مشاهدة $z_1, z_2, \dots, z_{n-1}, z_n$ ويرمز لها بالرمز r_k وتعطى بالعلاقة:

$$r_k = \frac{\sum_{t=1}^{n-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=1}^n (z_t - \bar{z})^2}, \quad k = 0, 1, 2, \dots$$

$$\bar{z} = \frac{1}{n} \sum_{t=1}^n z_t \quad \text{حيث}$$

وهي مقدّر Estimator لدالة الترابط الذاتي أي $\hat{\rho}_k = r_k, \quad k = 0, 1, 2, \dots$ وبما أنها مقدّر فهي إذا تتغير عشوائياً من عينة لآخر ولهذا فإن لها الخواص العينية التالية:

1- إذا كانت $\rho_k = 0, \quad k > q$ فإن

$$V(r_k) \approx \frac{1}{n} \left(1 + 2 \sum_{k=1}^q \rho_k^2 \right), \quad k > q$$

وفي الحالة الخاصة عندما $k > 0$ فإن $\rho_k = 0$, $k > 0$

2- لقيم n الكبيرة و $\rho_k = 0$ فإن r_k يكون لها توزيع طبيعي وبالتالي نستطيع القيام بالاختبار التالي:

$$H_0 : \rho_k = 0$$

$$H_1 : \rho_k \neq 0$$

وذلك باستخدام الإحصاء.

$$\frac{|r_k|}{n^{\frac{1}{2}}} = \sqrt{n} |r_k|$$

وذلك عند مستوى معنوية $\alpha = 0.05$ إذا كانت H_0 وترفض H_0 إذا كانت $\sqrt{n} |r_k| > 1.96$

3- تحت الفرضية $corr(r_k, r_{k-s}) \approx 0, s \neq 0$ فإن $H_0 : \rho_k = 0, \forall k$

4- تقدّر التباينات لدالة الترابط الذاتي للعينة كالتالي:

$$\hat{V}(r_k) \approx \frac{1}{n} \left(1 + 2 \sum_{k=1}^q r_k^2 \right), \quad k > q$$

تعريف 13:

دالة الترابط الذاتي الجزئي للعينة **Sample Partial Autocorrelation Function** لسلسلة زمانية مشاهدة $z_1, z_2, \dots, z_{n-1}, z_n$ ويرمز لها بالرمز **SPACF**

r_{kk} تعطى بالعلاقة:

$$r_{kk} = \begin{cases} 1, & k=0 \\ r_1, & k=1 \\ \begin{vmatrix} 1 & r_1 & \cdots & r_{k-2} & r_1 \\ r_1 & 1 & \cdots & r_{k-3} & r_2 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ r_{k-1} & r_{k-2} & \cdots & r_1 & r_k \end{vmatrix}, & k=2,3,\dots \\ \begin{vmatrix} 1 & r_1 & \cdots & r_{k-2} & r_{k-1} \\ r_1 & 1 & \cdots & r_{k-3} & r_{k-2} \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ r_{k-1} & r_{k-2} & \cdots & r_1 & 1 \end{vmatrix} \end{cases}$$

و لحساب دالة الترابط الذاتي الجزئي للعينة تكراريا:

تعريف 13 ب:

تحسب r_{kk} تكراريا من العلاقات

$$r_{00} = 1, \text{ by definition}$$

$$r_{11} = r_1$$

$$r_{kk} = \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j}, \quad k=2,3,\dots$$

حيث

$$r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-1}, \quad j=1,2,\dots,k-1$$

وهي ايضا مقدار Estimator لدالة الترابط الذاتي الجزئي للعينة اي $\hat{\phi}_{kk} = r_{kk}$, $k=0,1,2,\dots$ وبما انها مقدار فهي إذا تتغير عشوائيا من عينة لآخر ولهذا فإن لها الخواص العينية التالية:

$$V(r_{kk}) \equiv \frac{1}{n}, \quad k > 0$$

2- لقيم n الكبيرة فإن r_{kk} يكون لها تقريراً توزيع طبيعي وبالتالي نستطيع القيام بالاختبار التالي:

$$H_0 : \phi_{kk} = 0$$

$$H_1 : \phi_{kk} \neq 0$$

وذلك باستخدام الإحصاء.

$$\frac{|r_{kk}|}{n^{-\frac{1}{2}}} = \sqrt{n} |r_{kk}|$$

وذلك عند مستوى معنوية $\alpha = 0.05$ إذا كانت H_0 وترفض H_0 إذا كانت H_1 .

3- تحت الفرضية $\text{corr}(\phi_{kk}, \phi_{k-s, k-s}) \equiv 0, s \neq 0$ فإن $H_0 : \phi_{kk} = 0, \forall k$

4- تقدّر البيانات دالة الترابط الذاتي للعينة كالتالي:

$$\hat{V}(r_{kk}) \equiv \frac{1}{n}, \quad k > 0$$

مثال 4:

البيانات التالية تمثل الطلب على منتج معين يومياً:

158 222 248 216 226 239 206 178 169

أحسب الترابط الذاتي والترابط الذاتي الجزئي للعينة وارسمهما:

$$\bar{z} = \frac{1}{n} \sum_{t=1}^n z_t = \frac{1}{9} (158 + 222 + \dots + 169) = 206.89$$

ثانياً: أحسب الترابط الذاتي من العلاقة

$$r_k = \frac{\sum_{t=1}^{n-k} (z_t - \bar{z})(z_{t+k} - \bar{z})}{\sum_{t=1}^n (z_t - \bar{z})^2}, \quad k = 0, 1, 2, \dots$$

$$r_1 = \frac{(158 \times 222 + 222 \times 248 + \dots + 178 \times 169)}{(158 \times 158 + 222 \times 222 + \dots + 169 \times 169)} = 0.265116$$

$$r_2 = \frac{(158 \times 248 + 222 \times 216 + \dots + 206 \times 169)}{(158 \times 158 + 222 \times 222 + \dots + 169 \times 169)} = -0.212$$

$$r_3 = \frac{(158 \times 216 + 222 \times 226 + \dots + 239 \times 169)}{(158 \times 158 + 222 \times 222 + \dots + 169 \times 169)} = -0.076$$

وهكذا $r_8 = 0.230, r_7 = 0.104, r_6 = -0.242, r_5 = -0.387, r_4 = -0.183$

ثالثاً: نحسب التباينات من

$$\hat{V}(r_k) \cong \frac{1}{n} \left(1 + 2 \sum_{k=1}^q r_k^2 \right), \quad k > q$$

$$\hat{V}(r_1) \cong \frac{1}{9}$$

$$\hat{V}(r_2) \cong \frac{1}{n} (1 + 2r_1^2) = \frac{1}{9} (1 + 2(0.265)^2) = 0.1267$$

$$\hat{V}(r_3) \cong \frac{1}{n} (1 + 2(r_1^2 + r_2^2)) = \frac{1}{9} (1 + 2((0.265)^2 + (-0.212)^2)) = 0.1367$$

$$\hat{V}(r_4) \cong 0.138 \quad \hat{V}(r_5) \cong 0.1454 \quad \hat{V}(r_6) \cong 0.1787$$

الخ...

رابعاً: نحسب الترابط الذاتي الجزئي للعينة:

$$r_{00} = 1, \quad \text{by definition}$$

$$r_{11} = r_1 = 0.265$$

ثم نحسب باقي الترابطات من العلاقات التكرارية

$$r_{kk} = \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j}, \quad k = 2, 3, \dots$$

حيث

$$r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-1}, \quad j = 1, 2, \dots, k-1$$

$$r_{22} = \frac{r_2 - \sum_{j=1}^1 r_{1,j} r_{2-j}}{1 - \sum_{j=1}^1 r_{1,j} r_j} = \frac{r_2 - r_{11} r_1}{1 - r_{11} r_1} = \frac{(-0.212) - (0.265)(0.265)}{1 - (0.265)(0.265)} = \frac{-0.282225}{0.929775}$$

$$= -0.30354$$

لحساب r_{33} نحتاج الى r_{21} وتحسب من

$$r_{21} = r_{11} - r_{22} r_{11} = 0.265 - (-0.303)(0.265) = 0.345295$$

$$r_{33} = \frac{r_3 - \sum_{j=1}^2 r_{2,j} r_{3-j}}{1 - \sum_{j=1}^k r_{2,j} r_j} = \frac{r_3 - (r_{21} r_2 + r_{22} r_1)}{1 - (r_{21} r_1 + r_{22} r_2)}$$

$$= \frac{(-0.076) - ((0.345)(-0.212) + (-0.303)(0.265))}{1 - ((0.345)(0.265) + (-0.303)(-0.212))}$$

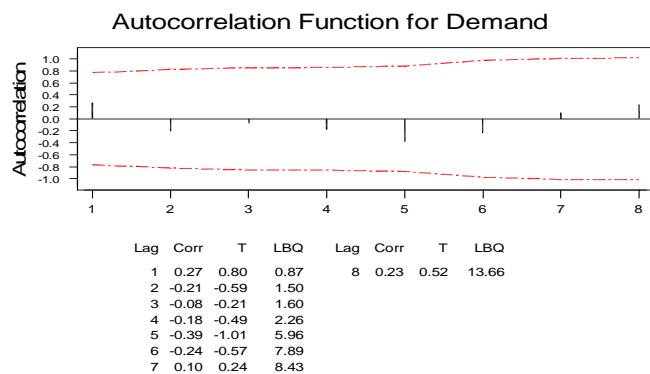
$$= 0.092$$

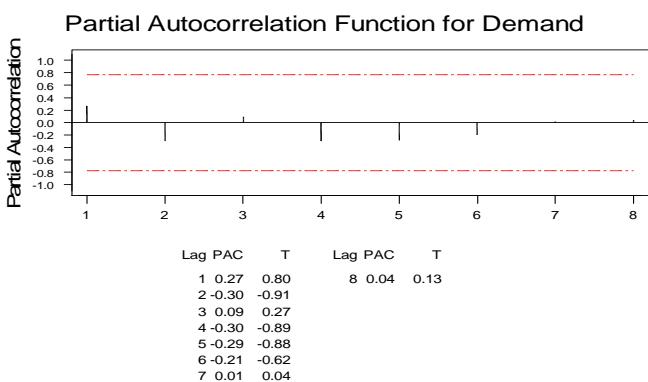
وهكذا نحسب باقي الترابطات الجزئية للعينة

$$r_{88} = 0.042, r_{77} = 0.013, r_{66} = -0.207, r_{55} = -0.294, r_{44} = -0.298$$

ولها جميعاً التباينات تساوي تقريباً $\frac{1}{9} = 0.1111$

خامساً: رسم دوال الترابط الذاتي والترابط الذاتي الجزئي للعينة





الفصل الثاني

نماذج الانحدار الذاتي المتوسط المتحرك Autoregressive-Moving Average و استخداماتها في التنبؤ Models:

هناك عائلة كبيرة من النماذج التي يطلق عليها نماذج الانحدار الذاتي_المتوسط المتحرك Autoregressive-Moving Average Models والتي اثبتت الأبحاث الكثيرة في مختلف الميادين التطبيقية على تفوقها الهائل علي الطرق التقليدية في التنبؤ.

تعريف 14:

نموذج الانحدار الذاتي_المتوسط المتحرك من الدرجة (p,q) ويرمز له $ARMA(p,q)$ لمسلسلة زمانية مشاهدة $\{z_t\}$ يكتب علي الشكل:

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

حيث $a_t \sim WN(0, \sigma^2)$ معلم ثابت يمثل المستوى و $\phi_1, \phi_2, \dots, \phi_p$ هي معالم الانحدار الذاتي Autoregressive Parameters و $\theta_1, \theta_2, \dots, \theta_q$ هي معالم المتوسط المتحرك Moving Average Operators

سوف نستعين بجبر العمال Operators Algebra لتبسيط هذه النماذج لكي يسهل التعامل معها

تعريف 15: عامل الإزاحة الخلفي Backshift Operator ويرمز له B وله الخواص التالية:

$$1 - B z_t = z_{t-1}$$

$$2 - B^m z_t = B^{m-1} (B z_t) = B^{m-2} (B (B z_t)) = \dots = z_{t-m}$$

$$3 - Bc = c, \quad c \text{ is a constant}$$

بالإضافة الي عامل الإزاحة الخلفي توجد عمال اخري نحتاج اليها لاحقا هي:

تعريف 15 ب:

1- عامل الإزاحة الأمامي **Forwardshift Operator** ويرمز له F ويعرف كالتالي:

$$F = B^{-1}$$

2- عامل التفريق **Difference Operator** ويرمز له ∇ ويعرف كالتالي:

$$\nabla = (1 - B)$$

4- عامل التجميع **Sum Operator** ويرمز له S ويعرف كالتالي:

$$S = \nabla^{-1} = (1 - B)^{-1}$$

الآن نعود إلى نموذج الإنحدار الذاتي المتوسط المتحرك من الدرجة (p, q) ونكتبه على الشكل:

$$z_t - \phi_1 z_{t-1} - \phi_2 z_{t-2} - \cdots - \phi_p z_{t-p} = \delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q}$$

$$z_t - \phi_1 B z_t - \phi_2 B^2 z_t - \cdots - \phi_p B^p z_t = \delta + a_t - \theta_1 B a_t - \theta_2 B^2 a_t - \cdots - \theta_q B^q a_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p) z_t = \delta + (1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q) a_t$$

أو

$$\phi_p(B) z_t = \delta + \theta_q(B) a_t$$

حيث $\phi_p(B)$ هو عامل الإنحدار الذاتي و $\theta_q(B)$ هو عامل المتوسط المتحرك

$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \cdots - \theta_q B^q$ و $\theta_q(B)$ هو عامل المتوسط المتحرك

Moving Average Operator

أمثلة:

1- نموذج المتوسط الثابت Constant Mean Model ويرمز له $ARMA(0,0)$ ويكتب

على الشكل:

$$\phi_0(B) z_t = \delta + \theta_0(B) a_t$$

أو

$$(1) z_t = \delta + (1) a_t$$

$$z_t = \delta + a_t, \quad a_t \sim WN(0, \sigma^2)$$

2- نموذج الإنحدار الذاتي من الدرجة الاولى $ARMA(1,0) \equiv AR(1)$ وهو على الشكل:

$$\phi_1(B)z_t = \delta + \theta_0(B)a_t$$

$$(1 - \phi_1 B)z_t = \delta + a_t$$

$$z_t = \delta + \phi_1 z_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

3- نموذج المتوسط المتحرك من الدرجة الاولى $ARMA(0,1) \equiv MA(1)$ وهو على الشكل:

$$\phi_0(B)z_t = \delta + \theta_1(B)a_t$$

$$z_t = \delta + (1 - \theta_1 B)a_t$$

$$z_t = \delta + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2)$$

4- نموذج الإنحدار الذاتي من الدرجة الثانية $ARMA(2,0) \equiv AR(2)$ وهو على الشكل:

$$\phi_2(B)z_t = \delta + \theta_0(B)a_t$$

$$(1 - \phi_1 B - \phi_2 B^2)z_t = \delta + a_t$$

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

5- نموذج الإنحدار الذاتي_المتوسط المتحرك من الدرجة (1,1) $ARMA(1,1)$ ونكتبه على

الشكل:

$$\phi_1(B)z_t = \delta + \theta_1(B)a_t$$

$$(1 - \phi_1 B)z_t = \delta + (1 - \theta_1 B)a_t$$

$$z_t = \delta + \phi_1 z_{t-1} + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2)$$

خصائص نماذج الإنحدار الذاتي المتوسط المتحرك:

سوف ندرس الخصائص الإحصائية التي تميز نماذج الإنحدار الذاتي_المتوسط المتحرك ومعرفة كيفية التعرف على احد هذه النماذج من عينة مشاهدة وذلك لتعيين او تحديد نموذج مناسب يصف المشاهدات.

أولاً: نموذج المتوسط الثابت ARMA(0,0)

ويكتب على الشكل

$$\phi_0(B)z_t = \delta + \theta_0(B)a_t$$

او

$$z_t = \delta + a_t, \quad a_t \sim WN(0, \sigma^2)$$

سوف نستخرج الخواص الإحصائية لهذا النموذج وذلك بإيجاد التوقع (المتوسط) ودالتي الترابط الذاتي والترابط الذاتي الجزئي كالتالي:

$$\begin{aligned} E(z_t) &= \delta + E(a_t) \\ &= \delta \end{aligned}$$

وذلك لأن $a_t \sim WN(0, \sigma^2)$

سوف نرمز لمتوسط المتسلسلة $E(z_t)$ بالرمز μ أي $\mu = E(z_t)$ وبالتالي يكون $\mu = \delta$ ويكتب النموذج:

$$z_t - \mu = a_t$$

لإستخراج دالتي الترابط الذاتي والترابط الذاتي الجزئي نضرب طرفي المعادلة السابقة في $z_{t-k} - \mu$ ونأخذ التوقع أي

$$E[(z_{t-k} - \mu)(z_t - \mu)] = E[(z_{t-k} - \mu)a_t]$$

ولكن $E[(z_{t-k} - \mu)(z_t - \mu)] = \gamma_k$ من تعريف 8 إذا

$$\gamma_k = E[(z_{t-k} - \mu)a_t], \quad k = 0, \pm 1, \pm 2, \dots$$

ونحل هذه العلاقة تكراريا:

$$k = 0: \quad \gamma_0 = E[(z_t - \mu)a_t]$$

لإيجاد الطرف الأيمن نضرب طرفي $a_t - \mu = z_t$ في a_t ونأخذ التوقع أي

$$E[(z_t - \mu)a_t] = E(a_t a_t) = \sigma^2$$

وذلك لأن $a_t \sim WN(0, \sigma^2)$ إذا

$$k=0: \quad \gamma_0 = E[(z_t - \mu)a_t] = \sigma^2$$

$$k=1: \quad \gamma_1 = E[(z_{t-1} - \mu)a_t] = 0$$

وذلك لأن

$$z_{t-1} - \mu = a_{t-1}$$

$$E[(z_{t-1} - \mu)a_t] = E(a_{t-1}a_t) = 0$$

في الحقيقة فإن

$$z_{t-k} - \mu = a_{t-k}, \quad k=1, 2, \dots$$

$$E[(z_{t-k} - \mu)a_t] = E(a_{t-k}a_t) = 0, \quad k=1, 2, \dots$$

أي

قاعدة 1:

$$E[(z_{t-k} - \mu)a_t] = E(a_{t-k}a_t) = \begin{cases} \sigma^2, & k=0 \\ 0, & k=1, 2, \dots \end{cases}$$

أي

$$\gamma_0 = \sigma^2$$

$$\gamma_k = 0, \quad k = \pm 1, \pm 2, \dots$$

وتوضع على شكل دالي:

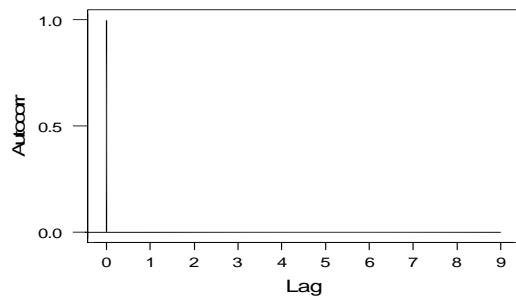
$$\gamma_k = \begin{cases} \sigma^2, & k=0 \\ 0, & k \neq 0 \end{cases}$$

وبالقسمة على σ^2 نجد

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \begin{cases} 1, & k=0 \\ 0, & k \neq 0 \end{cases}$$

ولها الشكل التالي:

Autocorrelation function of Constant Mean Model



نشتق الآن دالة الترابط الذاتي الجزئي من التعريف 11 نجد

$$\phi_{00} = 1, \text{ by definition}$$

$$\phi_{11} = \rho_1, \text{ by definition}$$

$$\phi_{11} = 0$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & 0 \\ 0 & 0 \end{vmatrix}}{\begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix}} = 0$$

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{vmatrix}}{\begin{vmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{vmatrix}} = 0$$

⋮

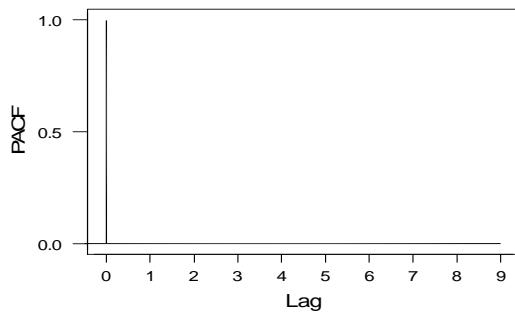
$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_2 \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{vmatrix}}{\begin{vmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{vmatrix}} = \frac{0}{1} = 0, \quad k = 2, 3, \dots$$

وتوضع على شكل دالي:

$$\phi_{kk} = \begin{cases} 1, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

ولها الشكل التالي:

Partial Autocorrelation function of Constant Mean Model



ملاحظة: نموذج المتوسط الثابت لا يفترق عن نموذج الضجة البيضاء الا في ان له متوسط غير صفرى

ثانياً: نموذج الإنحدار الذاتي من الدرجة الأولى (AR(1))

وهو على الشكل:

$$\phi_1(B)z_t = \delta + \theta_0(B)a_t$$

$$(1 - \phi_1 B)z_t = \delta + a_t$$

$$z_t = \delta + \phi_1 z_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

كالنموذج السابق سوف نجد التوقع (المتوسط) ودالتي الترابط الذاتي والترابط الذاتي الجزئي:

$$(1 - \phi_1 B)z_t = \delta + a_t$$

$$z_t = \frac{\delta}{(1 - \phi_1)} + (1 - \phi_1 B)^{-1} a_t$$

$$E(z_t) = \frac{\delta}{(1 - \phi_1)} + E[(1 - \phi_1 B)^{-1} a_t]$$

الحد الثاني في الطرف الأيمن هو

$$E[(1 - \phi_1 B)^{-1} a_t] = E\left[\left(\sum_{j=0}^{\infty} \phi_1^j B^j\right) a_t\right]$$

لإدخال التوقع على المجموع اللانهائي يجب أن تكون المتسلسلة اللانهائية $\sum_{j=0}^{\infty} \phi_1^j B^j$ متسقة.

مقاربة وذلك يتحقق إذا كانت $|\phi_1| < 1$ وذلك إذا اعتبرنا العامل B الآن يلعب دور متغير

مركباً له الشكل $B = a + ib$ وله القياس $|B| = 1$ في الحقيقة لابد أن

نطلب أن تكون جزور او اصفار $(1 - \phi_1 B)$ خارج دائرة الوحدة أي $|B| > 1$

$$1 - \phi_1 B = 0$$

$$B = \frac{1}{\phi_1}$$

$$|B| > 1 \Rightarrow \left| \frac{1}{\phi_1} \right| > 1 \Rightarrow |\phi_1| < 1$$

وهذا هو شرط الاستقرار. نعود إلى العلاقة

$$\begin{aligned}
E[(1-\phi_1 B)^{-1} a_t] &= E\left[\left(\sum_{j=0}^{\infty} \phi_1^j B^j\right) a_t\right] \\
&= \left[\left(\sum_{j=0}^{\infty} \phi_1^j B^j\right) E(a_t)\right] \\
&= 0, \quad \forall t
\end{aligned}$$

ويكون

$$E(z_t) = \frac{\delta}{(1-\phi_1)}$$

او

$$\begin{aligned}
\mu &= \frac{\delta}{(1-\phi_1)} \\
\therefore \delta &= \mu(1-\phi_1)
\end{aligned}$$

وبالتعويض عن δ في صيغة النموذج نجد

$$\begin{aligned}
z_t &= \delta + \phi_1 z_{t-1} + a_t \\
&= \mu(1-\phi_1) + \phi_1 z_{t-1} + a_t \\
&= \mu + \phi_1(z_{t-1} - \mu) + a_t \\
(z_t - \mu) - \phi_1(z_{t-1} - \mu) &= a_t
\end{aligned}$$

نضرب طرفي المعادلة السابقة في $\mu - z_{t-k}$ ونأخذ التوقع أي

$$E[(z_{t-k} - \mu)(z_t - \mu)] - \phi_1 E[(z_{t-k} - \mu)(z_{t-1} - \mu)] = E[(z_{t-k} - \mu)a_t], \quad k = 0, \pm 1, \pm 2, \dots$$

أي

$$\gamma_k - \phi_1 \gamma_{k-1} = E[(z_{t-k} - \mu)a_t], \quad k = 0, \pm 1, \pm 2, \dots$$

وذلك من تعريف 8 وتحل هذه العلاقة تكراريا كما يلي:

$$k=0: \quad \gamma_0 - \phi_1 \gamma_1 = E[(z_t - \mu)a_t]$$

لإيجاد الطرف الأيمن نقوم بالتالي:

$$E[a_t(z_t - \mu)] - \phi_1 E[a_{t-1}(z_{t-1} - \mu)] = E(a_t a_t)$$

$$E[a_t(z_t - \mu)] - \phi_1 \times (0) = \sigma^2$$

$$\therefore E[a_t(z_t - \mu)] = \sigma^2$$

إذا

$$\gamma_0 - \phi_1 \gamma_1 = \sigma^2$$

$$k=1: \quad \gamma_1 - \phi_1 \gamma_0 = E[(z_{t-1} - \mu)a_t] = 0$$

في الحقيقة

$$\gamma_k - \phi_1 \gamma_{k-1} = 0, \quad k=1,2,\dots$$

بقسمة المعادلة الأخيرة على γ_0 نجد

$$\rho_k - \phi_1 \rho_{k-1} = 0, \quad k=1,2,\dots$$

أو

$$\rho_k = \phi_1 \rho_{k-1}, \quad k=1,2,\dots$$

وبما ان $\rho_0 = 1$ فإن:

$$\rho_1 = \phi_1 \rho_0 = \phi_1$$

$$\rho_2 = \phi_1 \rho_1 = \phi_1^2$$

\vdots

$$\rho_k = \phi_1^k$$

أو بشكل دالة

$$\rho_k = \phi_1^{|k|}, \quad k=0, \pm 1, \pm 2, \dots$$

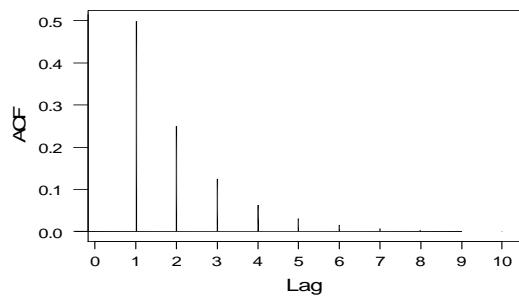
وذلك لأن $\rho_{-k} = \rho_k$, $\forall k$ أي

$$\rho_k = \phi_1^k, \quad k=0,1,2,\dots$$

هذه الدالة لها الشكل التالي:

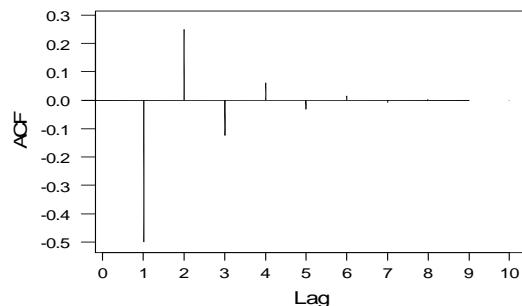
- عندما تكون $\phi_1 > 0$

Autocorrelation function of AR(1) Model



- $\phi_1 < 0$ عندما تكون

Autocorrelation function of AR(1) Model



نشق الآن دالة الترابط الذاتي الجزئي

من تعريف 11 نجد

$\phi_{00} = 1$, by definition

$\phi_{11} = \rho_1 = \phi_1$, by definition

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & \phi_1 \\ \phi_1 & \phi_1^2 \end{vmatrix}}{\begin{vmatrix} 1 & \phi_1 \\ \phi_1 & 1 \end{vmatrix}} = \frac{0}{1 - \phi_1^2} = 0$$

⋮

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_2 \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & \phi_1 & \cdots & \phi_1 \\ \phi_1 & 1 & \cdots & \phi_1^2 \\ \vdots & \vdots & \cdots & \vdots \\ \phi_1^{k-1} & \phi_1^{k-2} & \cdots & \phi_1^k \end{vmatrix}}{\begin{vmatrix} 1 & \phi_1 & \cdots & \phi_1^k \\ \phi_1 & 1 & \cdots & \phi_1^{k-1} \\ \vdots & \vdots & \cdots & \vdots \\ \phi_1^{k-1} & \phi_1^{k-2} & \cdots & 1 \end{vmatrix}} = \frac{0}{| | > 0}$$

محددة البسط تساوي صفرًا لأن العامود الأخير يساوي العامود الأول مضروبا في ϕ_1 ونكتب

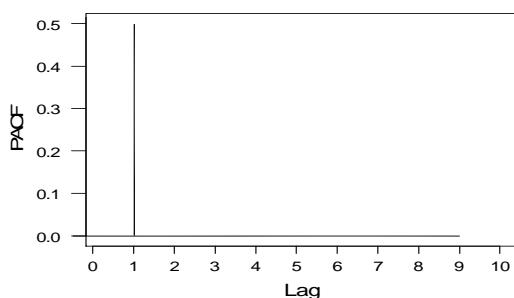
دالة الترابط الذاتي الجزئي على الشكل التالي:

$$\phi_{kk} = \begin{cases} 1, & k=0 \\ \phi_1, & k=1 \\ 0, & k \geq 2 \end{cases}$$

ولها الشكل التالي:

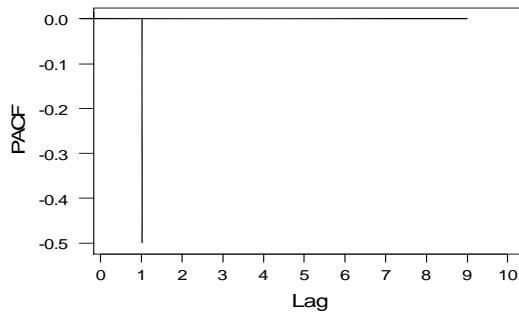
-1 عندما تكون $\phi_1 > 0$

Partial Autocorrelation function of AR(1) Model



-2- عندما تكون $\phi_1 < 0$

Partial Autocorrelation function of AR(1) Model



ملاحظة: دائما لا ترسم أي من $\rho_{00} = 1$ أو $\phi_1 = 1$ في الأشكال البيانية.

مناقشة النموذج:

- 1- عندما تكون $|\phi| > 1$ (شرط الاستقرار) فإن $E(z_t) = \delta / (1 - \phi)$ وهو ثابت لجميع قيم t
- 2- دالة الترابط الذاتي دالة للتخلف k فقط ولا تعتمد على الزمن t
- 3- دالة الترابط الذاتي تتداخل اسيا في إتجاه واحد إبتداء من $\rho_1 > 0$ عندما تكون $|\phi| < 1$ وتتداخل اسيا متعددة بين القيم الموجبة والسلبية عندما تكون $|\phi| < 0$
- 4- دالة الترابط الذاتي الجزئي لها قيمة واحدة غير صفرية (مع عدم النظر إلى ρ_{00}) ويكون إتجاهها حسب إشارة ϕ ومقدارها يساوي $|\phi|$

ثالثاً: نموذج الإنحدار الذاتي من الدرجة الثانية (ARMA(2,0) = AR(2))

ويكتب على الشكل:

$$\phi_2(B)z_t = \delta + \theta_0(B)a_t$$

$$(1 - \phi_1 B + \phi_2 B^2)z_t = \delta + a_t$$

$$z_t = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

كالسابق نوجد المتوسط ودالتي الترابط الذاتي والترابط الذاتي الجزئي:

$$(1 - \phi_1 B - \phi_2 B^2) z_t = \delta + a_t$$

$$z_t = \frac{\delta}{(1 - \phi_1 - \phi_2)} + (1 - \phi_1 B - \phi_2 B^2)^{-1} a_t$$

$$E(z_t) = \frac{\delta}{(1 - \phi_1 - \phi_2)} + E\left[(1 - \phi_1 B - \phi_2 B^2)^{-1} a_t\right]$$

الحد الثاني في الطرف الأيمن مجموع لانهائي على الشكل $E\left(\sum_{j=0}^{\infty} \psi_j a_{t-j}\right)$ ولكي ندخل التوقع

داخل التجميع اللانهائي لابد ان تكون $\sum_{j=0}^{\infty} \psi_j a_{t-j}$ متقاربة في المتوسط المربع وهذا يتحقق إذا

و فقط إذا كان $\sum_{j=0}^{\infty} \psi_j^2 < \infty$ وهذا يتحقق إذا حققت معالم الإنحدار الذاتي الشروط التالية:

$$\phi_2 - \phi_1 < 1$$

$$\phi_2 + \phi_1 < 1$$

$$-1 < \phi_2 < 1$$

والتي تسمى شروط الاستقرار (هذه الشروط تنتج ايضا من كون جذور او أصفار

$$(1 - \phi_1 B - \phi_2 B^2) = 0$$

$$E\left[(1 - \phi_1 B - \phi_2 B^2)^{-1} a_t\right] = \left[(1 - \phi_1 B - \phi_2 B^2)^{-1} E(a_t)\right] = 0, \forall t$$

ويكون

$$\mu = E(z_t) = \frac{\delta}{(1 - \phi_1 - \phi_2)}$$

$$\delta = (1 - \phi_1 - \phi_2) \mu$$

و بالتعويض عن δ في صيغة النموذج نجد

$$\begin{aligned} z_t &= (1 - \phi_1 - \phi_2) \mu + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t \\ &= \mu + \phi_1 (z_{t-1} - \mu) + \phi_2 (z_{t-2} - \mu) + a_t \\ (z_t - \mu) - \phi_1 (z_{t-1} - \mu) - \phi_2 (z_{t-2} - \mu) &= a_t \end{aligned}$$

نضرب المعادلة السابقة في $\mu - z_{t-k}$ ونأخذ التوقع نجد:

$$E[(z_t - \mu)(z_{t-k} - \mu) - \phi_1(z_{t-1} - \mu)(z_{t-k} - \mu) - \phi_2(z_{t-2} - \mu)(z_{t-k} - \mu)] \\ = E[a_t(z_{t-k} - \mu)], k = 0, \pm 1, \pm 2, \dots$$

أي

$$E[(z_t - \mu)(z_{t-k} - \mu)] - \phi_1 E[(z_{t-1} - \mu)(z_{t-k} - \mu)] - \phi_2 E[(z_{t-2} - \mu)(z_{t-k} - \mu)] \\ = E[a_t(z_{t-k} - \mu)], k = 0, \pm 1, \pm 2, \dots$$

أو

$$\gamma_k - \phi_1 \gamma_{k-1} - \phi_2 \gamma_{k-2} = E[a_t(z_{t-k} - \mu)], k = 0, \pm 1, \pm 2, \dots$$

وذلك من تعريف 8 الآن نحل هذه العلاقة تكراريا كما يلي:

$$k=0: \gamma_0 - \phi_1 \gamma_{-1} - \phi_2 \gamma_{-2} = E[a_t(z_t - \mu)] = \sigma^2 \Rightarrow \gamma_0 = \phi_1 \gamma_1 - \phi_2 \gamma_2 + \sigma^2$$

وذلك من قاعدة 1

$$k=1: \gamma_1 - \phi_1 \gamma_0 - \phi_2 \gamma_1 = 0 \Rightarrow \gamma_1 = \phi_1 \gamma_0 - \phi_2 \gamma_1$$

$$k=2: \gamma_2 - \phi_1 \gamma_1 - \phi_2 \gamma_0 = 0 \Rightarrow \gamma_2 = \phi_1 \gamma_1 - \phi_2 \gamma_0$$

وبشكل عام

$$k \geq 1: \gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2}$$

بقسمة الطرفين على γ_0 نجد

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2}, \quad k = 1, 2, \dots$$

(ملاحظة: بوضع المعادلة السابقة على الشكل $\rho_k - \phi_1 \rho_{k-1} - \phi_2 \rho_{k-2} = 0, \quad k = 1, 2, \dots$

نجد أنها معادلة فروقية من الدرجة الثانية والتي يمكن حلها بشكل مغلق بإستخدام طرق حل

المعادلات الفروقية ولكن هذا خارج نطاق المقرر الحالي)

سوف نحل العلاقة السابقة بالطريقة التكرارية والتي تحتاج إلى قيمتين أوليتين:

$$1 - \rho_0 = 1$$

$$2 - \rho_1 = \phi_1 \rho_0 + \phi_2 \rho_{-1} \Rightarrow \rho_1 = \frac{\phi_1}{1 - \phi_2}$$

ومنها نجد

$$\rho_2 = \phi_1 \rho_1 + \phi_2 \rho_0 \Rightarrow \rho_2 = \frac{\phi_1^2}{1-\phi_2} + \phi_2$$

وهكذا الخ ...

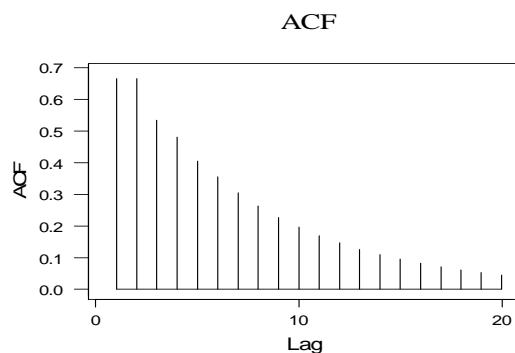
الأشكال التالية هي لدوال الترابط الذاتي لعملية $AR(2)$

- الشكل (1) $\phi_1 = 0.4, \phi_2 = 0.4$

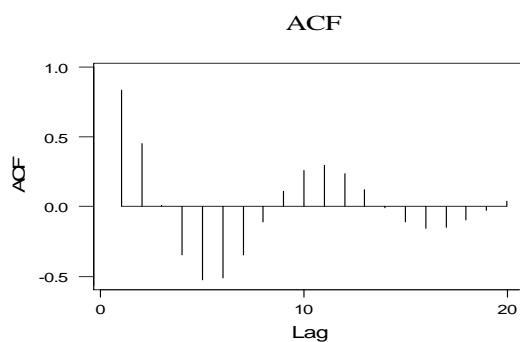
- الشكل (2) $\phi_1 = 1.5, \phi_2 = -0.8$

- الشكل (3) $\phi_1 = 0.5, \phi_2 = -0.6$

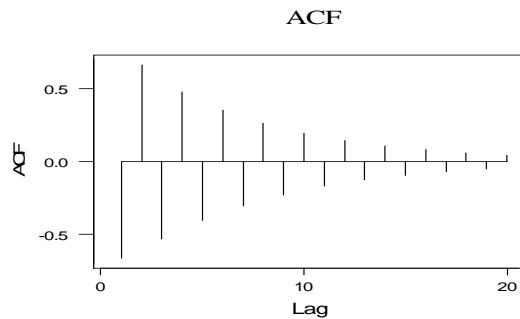
شكل (1)



شكل (2)



شكل (3)



الآن نستقر دالة الترابط الذاتي الجزئي لعملية $AR(2)$ كالتالي:

$$\phi_{00} = 1, \text{ by definition}$$

$$\phi_{11} = \rho_1, \text{ by definition}$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \neq 0$$

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} = \frac{\phi_1 + \phi_2 \rho_1}{|\rho_1|} = \frac{\phi_1 \rho_2 + \phi_2 \rho_1}{|\rho_1|} = 0$$

وذلك لأن العمود الأخير في محدد البسط هو تركيب خطى من العمودين الأول والثانى، كذلك

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_2 \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{vmatrix}} = \frac{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_1 \\ \rho_1 & 1 & \cdots & \rho_2 \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_k = \phi_1\rho_0 + \phi_2\rho_1 \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_1 = \phi_1\rho_1 + \phi_2\rho_0 \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & \rho_{k-2} = \phi_1\rho_{k-1} + \phi_2\rho_{k-2} \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \cdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \cdots & 1 \end{vmatrix}} = 0, k = 3, 4, \dots$$

وذلك ايضا لنفس السبب السابق. إذا

$$\phi_{kk} = \begin{cases} 1, & k=0 \\ \rho_1, & k=1 \\ \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}, & k=2 \\ 0, & k \geq 3 \end{cases}$$

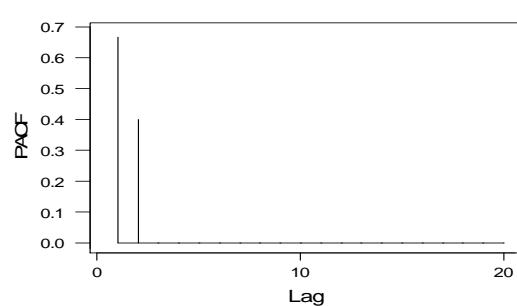
الأشكال التالية هي لدوال الترابط الذاتي الجزئي لعملية $AR(2)$

- الشكل (4) $\phi_1 = 0.4, \phi_2 = 0.4$

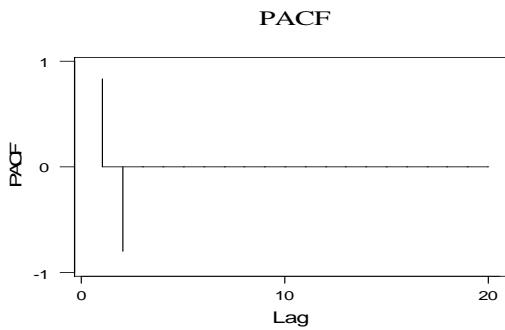
- الشكل (5) $\phi_1 = 1.5, \phi_2 = -0.8$

- الشكل (6) $\phi_1 = 0.5, \phi_2 = -0.6$

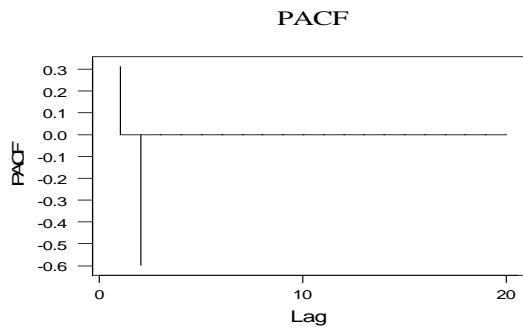
شكل (4)



شكل (5)



شكل (6)



رابعاً: نموذج المتوسط المتحرك من الدرجة الأولى $\text{ARMA}(0,1) = \text{MA}(1)$

وتكتب علي الشكل:

$$\begin{aligned}\phi_0(B)z_t &= \delta + \theta_1(B)a_t \\ z_t &= \delta + (1 - \theta_1 B)a_t \\ z_t &= \delta + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2)\end{aligned}$$

الآن نوجد المتوسط ودالتي الترابط الذاتي والترابط الذاتي الجزئي:

$$\begin{aligned}E(z_t) &= E(\delta + a_t - \theta_1 a_{t-1}) = \delta \\ \therefore \mu &= \delta\end{aligned}$$

ونكتب النموذج

$$z_t - \mu = a_t - \theta_1 a_{t-1}$$

بضرب هذه المعادلة في $z_{t-k} - \mu$ وأخذ التوقع نجد

$$E[(z_t - \mu)(z_{t-k} - \mu)] = E[(z_{t-k} - \mu)a_t] - \theta_1 E[(z_{t-k} - \mu)a_{t-1}], k = 0, \pm 1, \pm 2, \dots$$

او

$$\gamma_k = E[(z_{t-k} - \mu)a_t] - \theta_1 E[(z_{t-k} - \mu)a_{t-1}], k = 0, \pm 1, \pm 2, \dots$$

وبحلها تكراريا

$$k=0: \quad \gamma_0 = E[(z_t - \mu)a_t] - \theta_1 E[(z_t - \mu)a_{t-1}]$$

نوجد كل من $E[(z_t - \mu)a_{t-1}]$ و $E[(z_t - \mu)a_t]$ كالتالي:

$$E[(z_t - \mu)a_t] = E(a_t a_t) - \theta_1 E(a_{t-1} a_t) = \sigma^2$$

$$E[(z_t - \mu)a_{t-1}] = E(a_t a_{t-1}) - \theta_1 E(a_{t-1} a_{t-1}) = -\theta_1 \sigma^2$$

$$\therefore \gamma_0 = \sigma^2 - \theta_1(-\theta_1 \sigma^2) = \sigma^2(1 + \theta_1^2)$$

$$k=1: \quad \gamma_1 = E[(z_{t-1} - \mu)a_t] - \theta_1 E[(z_{t-1} - \mu)a_{t-1}]$$

$$\therefore \gamma_1 = -\theta_1 \sigma^2 \Rightarrow \rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{-\theta_1}{1 + \theta_1^2}$$

وذلك باستخدام القاعدة 1

$$k=2: \quad \gamma_2 = E[(z_{t-2} - \mu)a_t] - \theta_1 E[(z_{t-2} - \mu)a_{t-1}]$$

$$\therefore \gamma_2 = 0 \Rightarrow \rho_2 = 0$$

أيضا من قاعدة 1 وبشكل عام فإن

$$k \geq 2: \quad \gamma_k = 0 \Rightarrow \rho_k = 0$$

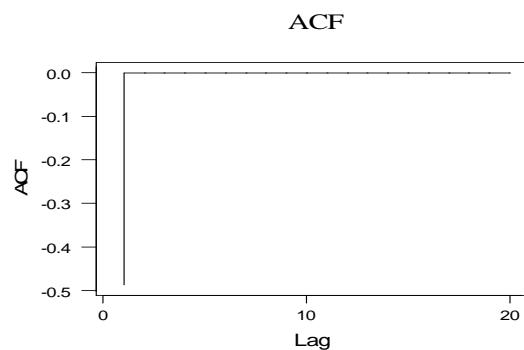
وهكذا فإن دالة الترابط الذاتي لنموذج المتوسط المتحرك من الدرجة الأولى $MA(1)$ هي على

الشكل:

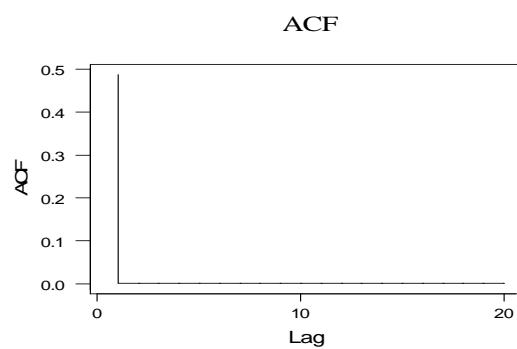
$$\rho_k = \begin{cases} 1, & k=0 \\ \frac{-\theta_1}{1+\theta_1^2}, & k=1 \\ 0 & k \geq 2 \end{cases}$$

ولها الشكل التالي:

- 1 - عندما $\theta_1 = 0.8$



- 2 - عندما $\theta_1 = -0.8$



الآن نستخرج دالة الترابط الجزئي لنموذج المتوسط المتحرك من الدرجة الأولى $MA(1)$

$$\phi_{00} = 1, \text{ by definition}$$

$$\phi_{11} = \rho_1, \text{ by definition}$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \\ \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \\ \end{vmatrix}} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 0 \\ \end{vmatrix}}{1 - \rho_1^2} = \frac{-\rho_1^2}{1 - \rho_1^2} = \frac{-\theta_1^2}{1 + \theta_1^2 + \theta_1^4} = \frac{-\theta_1^2 (1 - \theta_1^2)}{1 - \theta_1^6}$$

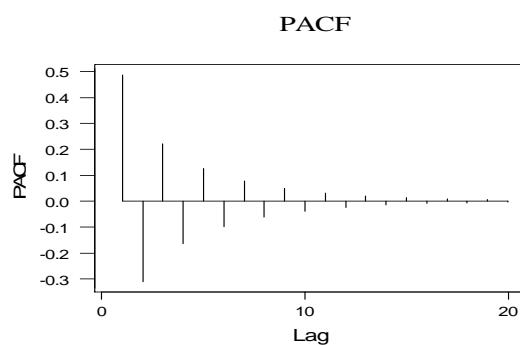
$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \\ \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \\ \end{vmatrix}} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & 0 \\ 0 & \rho_1 & 0 \\ \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & 0 \\ 1 & \rho_1 & 0 \\ \rho_1 & 1 & \rho_1 \\ \end{vmatrix}} = \frac{\rho_1^3}{1 - 2\rho_1^2} = \frac{-\theta_1^3 (1 - \theta_1^2)}{1 - \theta_1^8}$$

وبشكل عام

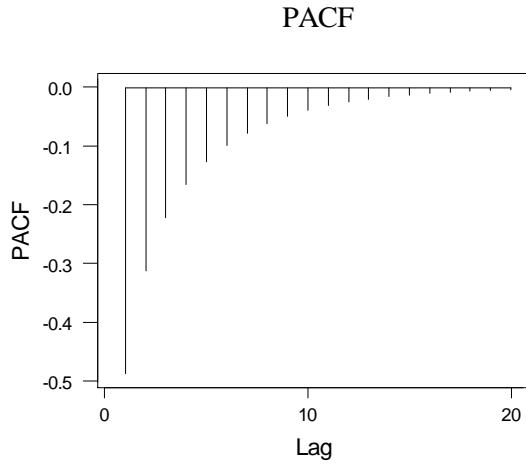
$$\phi_{kk} = \frac{-\theta_1^k (1 - \theta_1^2)}{1 - \theta_1^{2(k+1)}}, \quad k > 0$$

ولها الشكل التالي:

- 1 - عندما $\theta_1 = -0.8$



-2 عندما $\theta_1 = 0.8$



خامساً: نموذج المتوسط المتحرك من الدرجة الثانية (ARMA(0,2) = MA(2))

وتكتب على الشكل:

$$\begin{aligned}\phi_0(B)z_t &= \delta + \theta_2(B)a_t \\ z_t &= \delta + (1 - \theta_1 B - \theta_2 B^2)a_t \\ z_t &= \delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}, \quad a_t \sim WN(0, \sigma^2)\end{aligned}$$

الآن نوجد المتوسط والباقي الترابط الذاتي والترابط الذاتي الجزئي:

$$\begin{aligned}E(z_t) &= E(\delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}) = \delta \\ \therefore \mu &= \delta\end{aligned}$$

ونكتب النموذج

$$z_t - \mu = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

بضرب هذه المعادلة في $\mu - z_{t-k}$ وأخذ التوقع نجد

$$\begin{aligned}E[(z_t - \mu)(z_{t-k} - \mu)] &= E[(z_{t-k} - \mu)a_t] - \theta_1 E[(z_{t-k} - \mu)a_{t-1}] \\ &\quad - \theta_2 E[(z_{t-k} - \mu)a_{t-2}], \quad k = 0, \pm 1, \pm 2, \dots\end{aligned}$$

او

$$\gamma_k = E[(z_{t-k} - \mu)a_t] - \theta_1 E[(z_{t-k} - \mu)a_{t-1}] - \theta_2 E[(z_{t-k} - \mu)a_{t-2}], \quad k=0, \pm 1, \pm 2, \dots$$

وبحلها تكراريا نجد

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2) \sigma^2$$

$$\gamma_1 = (-\theta_1 + \theta_1 \theta_2) \sigma^2$$

$$\gamma_2 = -\theta_2 \sigma^2$$

$$\gamma_k = 0, \quad k > 2$$

وبالقسمة على γ_0 نجد

$$\rho_1 = \frac{-\theta_1 + \theta_1 \theta_2}{1 + \theta_1^2 + \theta_2^2}$$

$$\rho_2 = \frac{-\theta_2}{1 + \theta_1^2 + \theta_2^2}$$

$$\rho_k = 0, \quad k > 2$$

وتكتب على شكل دالة

$$\rho_k = \begin{cases} 1, & k = 0 \\ \frac{-\theta_1 + \theta_1 \theta_2}{1 + \theta_1^2 + \theta_2^2}, & k = 1 \\ \frac{-\theta_2}{1 + \theta_1^2 + \theta_2^2}, & k = 2 \\ 0, & k > 2 \end{cases}$$

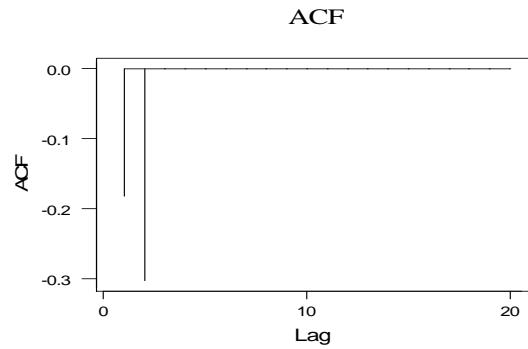
الأشكال التالية هي لدوال الترابط الذاتي لعملية $MA(2)$

- الشكل (7) $\theta_1 = 0.4, \theta_2 = 0.4$

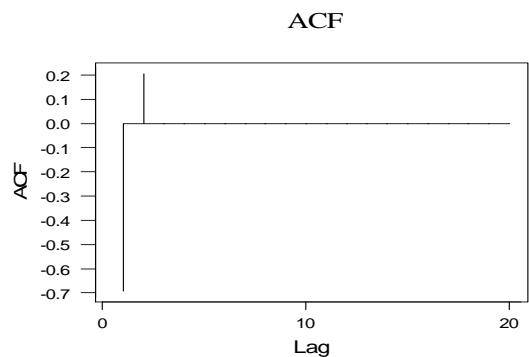
- الشكل (8) $\theta_1 = 1.5, \theta_2 = -0.8$

- الشكل (9) $\theta_1 = 0.5, \theta_2 = -0.6$

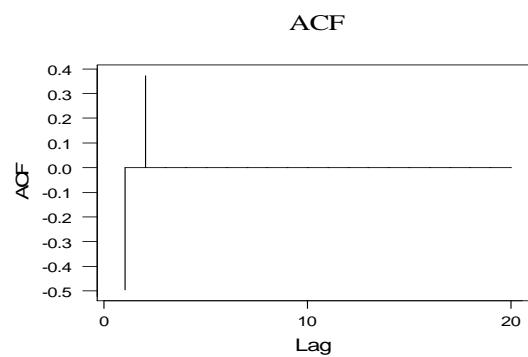
شكل (7)



شكل (8)



شكل (9)



من الصعب جدا إيجاد شكل مغلق لدالة الترابط الذاتي الجزئي لنموذج المتوسط المتحرك من الدرجة الثانية $MA(2)$ ولهذا سوف نستخدم تعريف 11 ب لحسابها ورسمها تكراريا لقيم

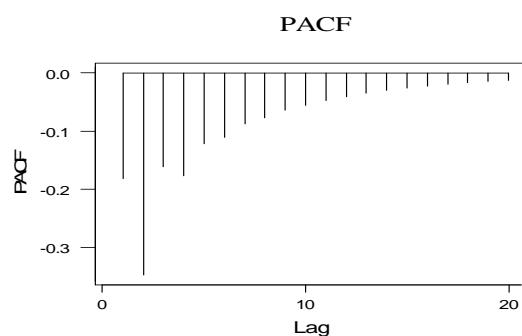
المعالم التالية:

$$\theta_1 = 0.4, \theta_2 = 0.4 \quad \text{الشكل (10)} \quad -10$$

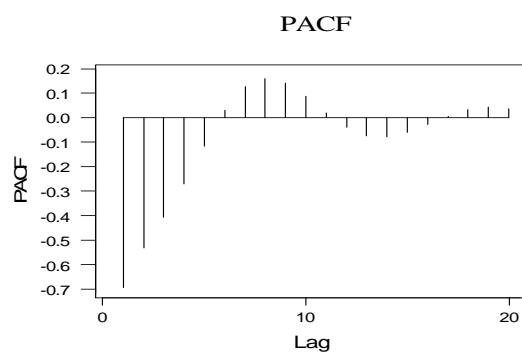
$$\theta_1 = 1.5, \theta_2 = -0.8 \quad \text{الشكل (11)} \quad -11$$

$$\theta_1 = 0.5, \theta_2 = -0.6 \quad \text{الشكل (12)} \quad -12$$

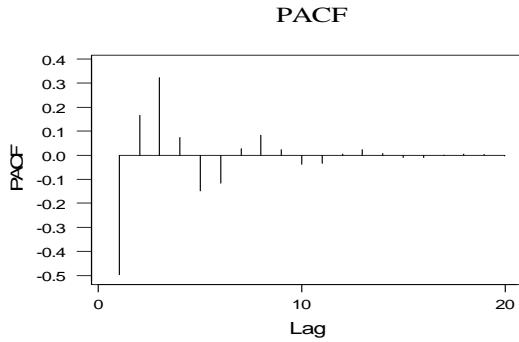
شكل (10)



شكل (11)



شكل (12)



سادساً: نموذج المتوسط المتحرك-الإنحدار الذاتي من الدرجة $\text{ARMA}(1,1)$:

ويكتب على الشكل:

$$\begin{aligned}\phi_1(B)z_t &= \delta + \theta_1(B)a_t \\ (1-\phi_1B)z_t &= \delta + (1-\theta_1B)a_t \\ z_t - \phi_1z_{t-1} &= \delta + a_t - \theta_1a_{t-1} \\ z_t &= \delta + \phi_1z_{t-1} + a_t - \theta_1a_{t-1}, a_t \sim WN(0, \sigma^2), \phi_1 \neq \theta_1\end{aligned}$$

شرط الاستقرار $|\phi_1| < 1$ وشرط الإنقلاب $|\theta_1| < 1$ وهناك شرط آخر يسمى شرط إمتساخ

وهو $\phi_1 \neq \theta_1$ وهذا الشرط يضمن عدم إمتساخ النموذج إلى نموذج Degeneracy Condition

أقل درجة ففي حالة كون $\phi_1 = \theta_1$ فمن العلاقة $(1-\phi_1B)z_t = \delta + (1-\theta_1B)a_t$ وبالقسمة على

$$ARMA(0,0) \text{ نجد أن النموذج يصبح } z_t = \delta' + a_t \text{ حيث } \delta' = \frac{\delta}{1-\phi_1} \text{ وهو } (1-\phi_1B)$$

نوجد المتوسط كالتالي:

$$(1-\phi_1B)z_t = \delta + (1-\theta_1B)a_t$$

$$z_t = \frac{\delta}{1-\phi_1} + \frac{(1-\theta_1B)}{(1-\phi_1B)}a_t$$

$$E(z_t) = \frac{\delta}{1-\phi_1} + \frac{(1-\theta_1B)}{(1-\phi_1B)}E(a_t)$$

وذلك لأن $|\phi_1| < 1$ وهذا

$$E(z_t) = \frac{\delta}{1-\phi_1}$$

أي $\delta = \mu(1 - \phi_1)$ أو $E(z_t) = \mu = \frac{\delta}{1 - \phi_1}$ وبالتعويض عن δ نجد

$$\begin{aligned} z_t &= \mu(1 - \phi_1) + \phi_1 z_{t-1} + a_t - \theta_1 a_{t-1} \\ (z_t - \mu) - \phi_1(z_{t-1} - \mu) &= a_t - \theta_1 a_{t-1} \end{aligned}$$

وبضرب طرفي المعادلة بالحد ... $(z_{t-k} - \mu), k = 0, \pm 1, \pm 2, \dots$ وأخذ التوقع للطرفين نجد

$$E[(z_{t-k} - \mu)(z_t - \mu)] - \phi_1 E[(z_{t-k} - \mu)(z_{t-1} - \mu)] = E[(z_{t-k} - \mu)a_t] - \theta_1 E[(z_{t-k} - \mu)a_{t-1}],$$

$$k = 0, \pm 1, \pm 2, \dots$$

ومنها

$$\gamma_k - \phi_1 \gamma_{k-1} = E[(z_{t-k} - \mu)a_t] - \theta_1 E[(z_{t-k} - \mu)a_{t-1}], k = 0, \pm 1, \pm 2, \dots$$

وبحلها تكرارياً نجد

$$k = 0 \quad \gamma_0 - \phi_1 \gamma_1 = E[(z_t - \mu)a_t] - \theta_1 E[(z_t - \mu)a_{t-1}]$$

نوجد الآن كل من $E[(z_t - \mu)a_{t-1}]$ و $E[(z_t - \mu)a_t]$ بضرب العلاقة

$$(z_t - \mu) - \phi_1(z_{t-1} - \mu) = a_t - \theta_1 a_{t-1}$$

في كل من a_t و a_{t-1} وأخذ التوقع

$$E[(z_t - \mu)a_t] - \phi_1 E[(z_{t-1} - \mu)a_t] = E[a_t a_t] - \theta_1 E[a_{t-1} a_t]$$

ومن القاعدة 1 نجد

$$E[(z_t - \mu)a_t] - \phi_1(0) = \sigma^2 - \theta_1(0)$$

$$E[(z_t - \mu)a_t] = \sigma^2$$

و

$$E[(z_t - \mu)a_{t-1}] - \phi_1 E[(z_{t-1} - \mu)a_{t-1}] = E[a_t a_{t-1}] - \theta_1 E[a_{t-1} a_{t-1}]$$

$$E[(z_t - \mu)a_{t-1}] - \phi_1 \sigma^2 = 0 - \theta_1 \sigma^2$$

$$\therefore E[(z_t - \mu)a_{t-1}] = \sigma^2(\phi_1 - \theta_1)$$

وبالتعويض في الصيغة السابقة نجد

$$k = 0 \quad \gamma_0 - \phi_1 \gamma_1 = \sigma^2 - \theta_1 \sigma^2 (\phi_1 - \theta_1)$$

$$\therefore \gamma_0 - \phi_1 \gamma_1 = \sigma^2 [1 - \theta_1 (\phi_1 - \theta_1)]$$

و

$$k=1 \quad \gamma_1 - \phi_1 \gamma_0 = E[(z_{t-1} - \mu) a_t] - \theta_1 E[(z_{t-1} - \mu) a_{t-1}] \\ \therefore \gamma_1 - \phi_1 \gamma_0 = -\theta_1 \sigma^2$$

و

$$k=2 \quad \gamma_2 - \phi_1 \gamma_1 = E[(z_{t-2} - \mu) a_t] - \theta_1 E[(z_{t-2} - \mu) a_{t-1}] = 0 \\ \therefore k \geq 2 \quad \gamma_k - \phi_1 \gamma_{k-1} = 0$$

ومن المعادلات

$$\gamma_0 - \phi_1 \gamma_1 = \sigma^2 [1 - \theta_1 (\phi_1 - \theta_1)]$$

و

$$\gamma_1 - \phi_1 \gamma_0 = -\theta_1 \sigma^2$$

نجد

$$\gamma_0 = \frac{1 + \theta_1^2 - 2\phi_1\theta_1}{1 - \phi_1^2} \sigma^2 \\ \gamma_1 = \frac{(1 - \phi_1\theta_1)(\phi_1 - \theta_1)}{1 - \phi_1^2} \sigma^2$$

ومن العلاقة بين γ_0 و γ_1

$$\rho_1 = \frac{\gamma_1}{\gamma_0} = \frac{(1 - \phi_1\theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1\theta_1}$$

ومن العلاقة

$$\gamma_k - \phi_1 \gamma_{k-1} = 0, \quad k \geq 2$$

وبالقسمة على γ_0 نجد

$$\rho_k - \phi_1 \rho_{k-1} = 0, \quad k \geq 2$$

ويتمكن حل هذه المعادلة تكراريا لجميع قيم $k \geq 2$ باستخدام القيم الأولية $\rho_0 = 1$ و

$$\rho_1 = \frac{(1 - \phi_1\theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1\theta_1} \text{ فمثلا}$$

$$\rho_2 = \phi_1 \rho_1$$

$$\rho_2 = \phi_1 \frac{(1 - \phi_1\theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1\theta_1}$$

$$\rho_3 = \phi_1 \rho_2$$

$$\rho_3 = \phi_1^2 \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1 \theta_1}$$

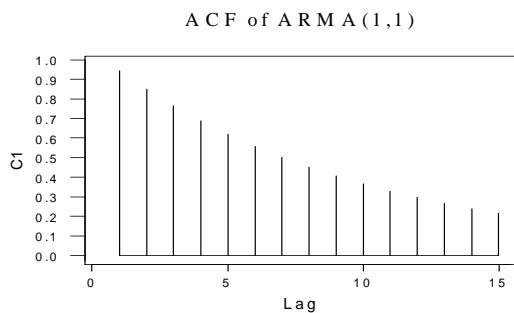
وهكذا.

نكتب دالة الترابط الذاتي لنموذج $ARMA(1,1)$ على الشكل

$$\rho_k = \begin{cases} 1, & k = 0 \\ \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1 \theta_1}, & k = 1 \\ \phi_1 \rho_{k-1}, & k \geq 2 \end{cases}$$

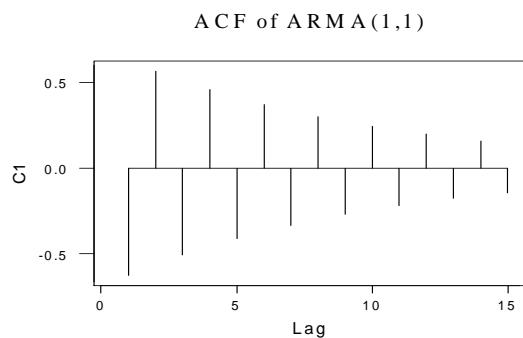
شكل 13 يعطي دالة الترابط الذاتي لقيم $\phi_1 = 0.9, \theta_1 = -0.5$

شكل(13)



شكل 14 يعطي دالة الترابط الذاتي لقيم $\phi_1 = -0.9, \theta_1 = -0.5$

شكل(14)



نلاحظ ان دالة الترابط الذاتي لنموذج $ARMA(1,1)$ تتخامد اسيا في إتجاه واحد أو متعدد بين القيم الموجبة والسلبية وهي في هذا تشبه تماما دالة الترابط الذاتي لنموذج $AR(1)$ ماعدى ان

$$\text{التخامد يبدأ من } \rho_1 \text{ (برهن أن } \rho_k = \phi_1^{k-1} \rho_1, k \geq 2)$$

دالة الترابط الذاتي الجزئي ϕ_{kk} تحسب من تعريف 11 أو 11ب كالتالي:

من تعريف 11ب نوجد ϕ_{kk} تكراريا

$\phi_{00} = 1$, by definition

$$\phi_{11} = \rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1 \theta_1}$$

$$\phi_{22} = \frac{\rho_2 - \phi_{11}\rho_1}{1 - \phi_{11}\rho_1}$$

$$\phi_{33} = \frac{\rho_3 - \phi_{21}\rho_2 - \phi_{22}\rho_1}{1 - \phi_{21}\rho_1 - \phi_{22}\rho_2}, \quad \phi_{21} = \phi_{11} - \phi_{22}\phi_{11}$$

وهكذا تحسب بقية القيم تكراريا.

فمثلا لقيم $\phi_1 = 0.9, \theta_1 = -0.5$ نجد

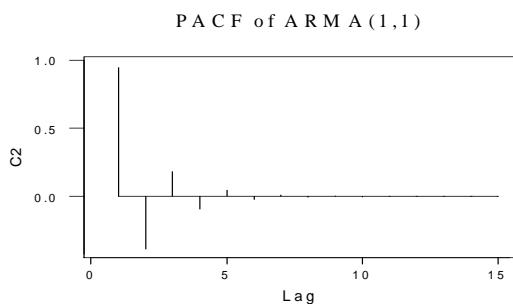
$$\phi_{11} = 0.944186 \quad \phi_{22} = -0.384471 \quad \phi_{33} = 0.183710$$

$$\phi_{44} = -0.908462 \quad \phi_{55} = 0.452979 \quad \phi_{66} = -0.226337$$

$$\phi_{77} = 0.113154 \quad \phi_{88} = -0.565702 \quad \phi_{99} = 0.282834$$

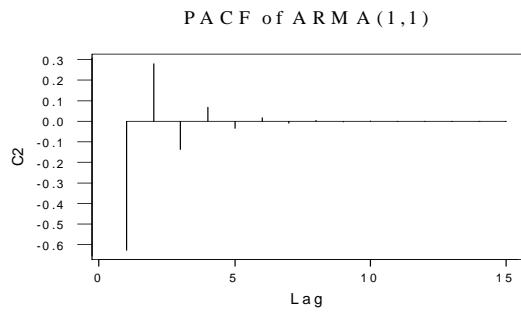
ونرسم هذه القيم في شكل 15

شكل 15



شكل 16 يبين دالة الترابط الذاتي الجزئي لقيم $\phi_1 = -0.9, \theta_1 = -0.5$

شكل 16



نلاحظ ان دالة الترابط الذاتي الجزئي لنموذج $ARMA(1,1)$ تتحامد اسيا في إتجاه واحد أو متعدد بين القيم الموجبة والسلبية وهي في هذا تشبه تماما دالة الترابط الذاتي الجزئي لنموذج $MA(1)$
ماعدى ان التحامد يبدأ بعد القيمة الأولية ρ_1 .

ملخص خواص نماذج ARMA(p,q) :

أولاً: نموذج AR(p)

ويتميز بالتالي:

- 1- دالة ترابط ذاتي تمتد لانهائيا و تتكون من خليط من التخامدات الاسية والتخامدات الجيبية.
- 2- دالة ترابط ذاتي جزئي تتكون من أصفار لقيم التخلفات $p > k$ أي

$$\phi_{11} = \phi_{22} = \phi_{33} = \dots = \phi_{pp} \neq 0$$

$$\phi_{p+1,p+1} = \phi_{p+2,p+2} = \dots = 0$$

ويسمى هذا قطعا في دالة الترابط الذاتي الجزئي بعد التخلف $p > k$.

ثانياً: نموذج MA(q)

ويتميز بالتالي:

- 1- دالة ترابط ذاتي تتكون من أصفار لقيم التخلفات $q > k$ أي

$$\rho_1 = \rho_2 = \rho_3 = \dots = \rho_q \neq 0$$

$$\rho_{q+1,q+1} = \rho_{q+2,q+2} = \dots = 0$$

ويسمى هذا قطعا في دالة الترابط الذاتي بعد التخلف $q > k$.

2- دالة ترابط ذاتي جزئي تمتد لانهائيا و تتكون من خليط من التخامدات الاسية والتخامدات الجيبية.

لاحظ الإزدواجية Duality بين نموذجي AR و MA.

ثالثاً: النموذج المختلط ARMA(p,q)

ويتميز بالتالي:

دوال الترابط الذاتي والترابط الذاتي الجزئي للنموذج المختلط تمتد لانهائيا و تتكون من خليط من التخامدات الاسية والتخامدات الجيبية التي تنتهي إلى الصفر كلما زاد التخلف k . عندما تكون $k > q - p$ فإن دالة الترابط الذاتي تتحدد من جزء الإنحدار الذاتي للنموذج و عندما تكون $k > p - q$ فإن دالة الترابط الذاتي الجزئي تتحدد من جزء المتوسط المتحرك للنموذج.

الفصل الثالث

نماذج المتسلسلات الزمنية غير المستقرة Nonstationar Time Series Models

اولاً: عدم الاستقرار في المتوسط:

من تعريف 6 لاستقرار متسلسلة زمنية نرى ان الشرط الأول للإستقرار يتطلب أن يكون متوسط المتسلسلة ثابت على طول الزمن، فمثلاً $E(z_t) = \mu = \text{constant} \quad \forall t$

لنموذج الإنجراف الخطى

$$z_t = b_0 + b_1 t + a_t, \quad a_t \sim WN(0, \sigma^2), \quad b_0, b_1 \in (-\infty, \infty)$$

نجد ان المتوسط هو

$$E(z_t) = b_0 + b_1 t$$

وهو غير ثابت بالنسبة للزمن، اي ان شرط الاستقرار الأول غير متحقق في هذه الحالة.

لناحول التحويل ∇z_t وذلك بتطبيق عامل التفريق على النموذج نجد

$$\begin{aligned} w_t &= \nabla z_t = z_t - z_{t-1} = b_0 + b_1 t + a_t - b_0 - b_1(t-1) - a_{t-1} \\ &= b_1 + a_t - a_{t-1} = b_1 + c_t \\ \therefore w_t &= b_1 + c_t, \quad c_t \sim WN(0, \nu^2) \end{aligned}$$

(تمرين: أوجد العلاقة بين ν^2 و σ^2)

الآن نجد متوسط المتسلسلة الجديدة w_t

$$E(w_t) = b_1 = \text{constant} \quad \forall t$$

أي ان تطبيق التحويل $\nabla = B - 1$ على المتسلسلة غير المستقرة (أي أخذ التفريق الأول

للمتسلسلة) حولها إلى متسلسلة مستقرة.

كمثال آخر نموذج الإنجراف التربيعي

$$z_t = b_0 + b_1 t + b_2 t^2 + a_t, \quad a_t \sim WN(0, \sigma^2), \quad b_0, b_1, b_2 \in (-\infty, \infty)$$

بإيجاد المتوسط

$$E(z_t) = b_0 + b_1 t + b_2 t^2$$

وهو يعتمد على الزمن، أي ان النموذج غير مستقر. بأخذ التحويل $\nabla^2 z_t$ (أخذ التفريق الثاني)

نجد

$$\begin{aligned}
\nabla^2 z_t &= \nabla^2 (b_0 + b_1 t + b_2 t^2 + a_t) \\
(1 - 2B + B^2) z_t &= (1 - 2B + B^2)(b_0 + b_1 t + b_2 t^2 + a_t) \\
w_t &= \{b_0 - 2b_0 + b_0\} + \{b_1 t - 2b_1(t-1) + b_1(t-2)\} + \\
&\quad \{b_2 t^2 - 2b_2(t-1)^2 + b_2(t-2)^2\} + \\
&\quad \{a_t - 2a_{t-1} + a_{t-2}\} \\
&= 2b_2 + \{a_t - 2a_{t-1} + a_{t-2}\} \\
&= b' + h_t, \quad h_t \sim WN(0, \tau^2)
\end{aligned}$$

وهكذا

$$w_t = \nabla^2 z_t = b' + h_t, \quad h_t \sim WN(0, \tau^2)$$

$$E(w_t) = b' = \text{constant} \quad \forall t$$

أي ان تطبيق التحويل ∇^2 (أي اخذ التفريق الثاني) على المتسلسلة غير المستقرة حولها الى مستقرة.

(تمرين: أوجد العلاقة بين τ^2 و σ^2).

بشكل عام إذا كان النموذج غير المستقر على الشكل

$$z_t = b_0 + b_1 t + \dots + b_d t^d + a_t, \quad a_t \sim WN(0, \sigma^2), \quad b_0, b_1, \dots, b_d \in (-\infty, \infty)$$

فإن التحويل $\nabla^d z_t$ يحوله إلى نموذج مستقر، أي ان $w_t = \nabla^d z_t$ هو نموذج مستقر.

تعريف 16:

للمتسلسلة غير المستقرة في المتوسط

$$z_t = b_0 + b_1 t + \dots + b_d t^d + a_t, \quad a_t \sim WN(0, \sigma^2), \quad b_0, b_1, \dots, b_d \in (-\infty, \infty)$$

التحويل $\nabla^d z_t$ وهو التفريق للدرجة d للمتسلسلة يحولها إلى متسلسلة مستقرة.

ثانياً: عدم الاستقرار في التباين:

من تعريف 6 للاستقرار متسلسلة زمنية، الشرط الثاني

$$V(z_t) = \gamma_0 = \text{constant} \quad \forall t$$

يتطلب أن يكون التباين ثابت لجميع قيم t .

فمثلا لنموذج المشي العشوائي

$$z_t = z_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

نجد من التعويض المتكرر

$$z_t = a_1 + a_2 + \cdots + a_t$$

وبأخذ التوقع والتبابين

$$E(z_t) = 0 = \text{constant} \quad \forall t$$

$$V(z_t) = t\sigma^2$$

ونلاحظ أن التبabin يعتمد على الزمن t .

بأخذ التفريق الأول

$$w_t = \nabla z_t = z_t - z_{t-1} = a_t$$

وبأخذ التوقع والتبابين

$$E(w_t) = 0 = \text{constant} \quad \forall t$$

$$V(w_t) = \sigma^2 = \text{constant} \quad \forall t$$

إذا التفريق الأول حول المتسلسلة غير المستقرة في التبabin إلى متسلسلة مستقرة.

بشكل عام لو كان التبabin دالة لمستوى (متوسط) متغير على الشكل

$$V(z_t) = cf(\mu_t)$$

حيث $c > 0$ ثابت و f دالة معروفة تعطى قيمة غير سالبة و μ_t مستوى أو متوسط يتغير

مع الزمن و بالتالي فإن التبabin يعتمد على الزمن وهنا نحاول إيجاد تحويل $(z_t) \rightarrow T$ أي إيجاد دالة

T لإستقرار التبabin.

التحويل

$$y_t = T(z_t) = \frac{z_t^\lambda - 1}{\lambda}$$

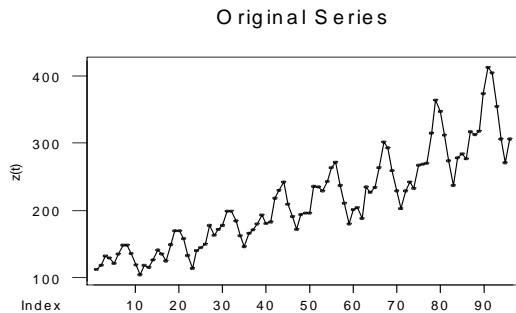
يعطي متسلسلة مستقرة في التبabin حيث $\lambda \in (-\infty, \infty)$ هو معلم التحويل. الجدول التالي يعطي

القيم الأكثر استخداماً للمعلم λ مع التحويلات المقابلة لها:

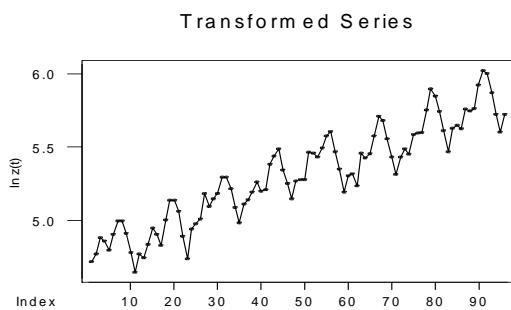
λ	-0.1	-0.5	0.0	0.5	1.0
y_t	$\frac{1}{z_t}$	$\frac{1}{\sqrt{z_t}}$	$\ln z_t$	$\sqrt{z_t}$	z_t

مثال:

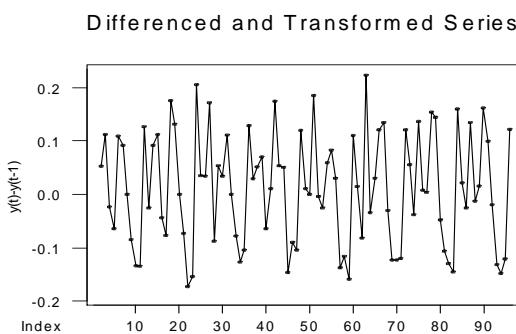
الشكل(ا) لمتسلسلة غير مستقرة في المتوسط والتباين z_t



الشكل(ب) المتسلسلة بعد تثبيت التباين بإجراء التحويل $y_t = \ln z_t$



الشكل(ج) المتسلسلة المحولة y_t بعد إجراء التفريغ الأول $\nabla y_t = y_t - y_{t-1}$



لاحظ كيف أصبحت المتسلسلة مستقرة في كل من المتوسط والتباين.

نماذج الإنحدار الذاتي-التكاملى-المتوسط المتحرك من الدرجة (p,d,q)

Integrated-Moving Average Models ARIMA(p,d,q)

يمكن نمذجة المتسلسلة المستقرة $z_t = \nabla^d w_t$ على شكل نموذج أنحدار ذاتي-متوسط متحرك من الدرجة (p,q) كالتالي:

$$\phi_p(B)w_t = \phi_p(B)\nabla^d z_t = \delta + \theta_q(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

أو

$$\phi_p(B)(1-B)^d z_t = \delta + \theta_q(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

وهذا النموذج يسمى نموذج الإنحدار الذاتي-التكاملى-المتوسط المتحرك من الدرجة (p,d,q) حيث $\delta \in (-\infty, \infty)$ معلم الإنجراف.

أمثلة على نماذج الإنحدار الذاتي-التكاملى-المتوسط المتحرك من الدرجة (p,d,q) :

أولاً: نموذج الإنحدار الذاتي-التكاملى من الدرجة (1,1) أو (1,1,1) ويكتب على الشكل

$$\phi_1(B)(1-B)z_t = \delta + \theta_0(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1 - \phi_1 B)(1 - B)z_t = \delta + a_t$$

$$\{1 - (\phi_1 + 1)B + \phi_1 B^2\}z_t = \delta + a_t$$

أي

$$z_t = \delta + (\phi_1 + 1)z_{t-1} - \phi_1 z_{t-2} + a_t, \quad a_t \sim WN(0, \sigma^2), \quad |\phi_1| < 1$$

ثانياً: نموذج التكاملى-المتوسط المتحرك من الدرجة (1,1)

أو (1,1,0) = IMA(1,1)

ويكتب على الشكل

$$\phi_0(B)(1-B)z_t = \delta + \theta_1(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1 - B)z_t = \delta + (1 - \theta_1 B)a_t, \quad a_t \sim WN(0, \sigma^2), \quad |\theta_1| < 1$$

$$z_t - z_{t-1} = \delta + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2), \quad |\theta_1| < 1$$

أي

$$z_t = \delta + z_{t-1} + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2), \quad |\theta_1| < 1$$

ثالثاً: نموذج المشي العشوائي بإنحراف Random Walk with Trend Model

: ARIMA(0,1,0)

ويكتب على الشكل

$$\phi_0(B)(1-B)z_t = \delta + \theta_0(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1-B)z_t = \delta + a_t, \quad a_t \sim WN(0, \sigma^2)$$

أي

$$z_t = \delta + z_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

دالة الأوزان (B) وتمثيل نماذج ARMA(p,q)

سبق أن كتبنا نماذج $ARMA(p, q)$ على الشكل

$$\phi_p(B)z_t = \delta + \theta_q(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

أو بشكل الإنحراف عن المتوسط

$$\phi_p(B)(z_t - \mu) = \theta_q(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

في كلتا الحالتين بالنسبة على عامل الإنحدار الذاتي $(B)^{\phi_p}$ نجد

$$z_t = \frac{\delta}{\phi_p(1)} + \frac{\theta_q(B)}{\phi_p(B)}a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$z_t - \mu = \frac{\theta_q(B)}{\phi_p(B)}a_t, \quad a_t \sim WN(0, \sigma^2)$$

لاحظ ان للنماذج المستقرة النسبة $\frac{\theta_q(B)}{\phi_p(B)}$ تشكل مسلسلة متقاربة وذلك لأن جذور $0 = \phi_p(B)$

تقع خارج دائرة الوحدة ايضا $\mu = \frac{\delta}{\phi_p(1)}$ ولهذا سوف نكتفي بشكل الإنحراف عن المتوسط في

مناقشة التالية

$$z_t - \mu = \frac{\theta_q(B)}{\phi_p(B)}a_t, \quad a_t \sim WN(0, \sigma^2)$$

المسلسلة المتقاربة

$$\psi(B) = \frac{\theta_q(B)}{\phi_p(B)}$$

والتي تكتب على الشكل

$$\psi(B) = \frac{\theta_q(B)}{\phi_p(B)} = \psi_0 B^0 + \psi_1 B^1 + \psi_2 B^2 + \psi_3 B^3 + \dots, \quad \psi_0 = 1$$

تسمى دالة الأوزان.

تعريف 17:

دالة الأوزان لنموذج ARMA(p, q) المستقر تعطى بالعلاقة

$$\psi(B) = \frac{\theta_q(B)}{\phi_p(B)} = \psi_0 B^0 + \psi_1 B^1 + \psi_2 B^2 + \psi_3 B^3 + \dots, \quad \psi_0 = 1$$

$$\psi(B) = \frac{\theta_q(B)}{\phi_p(B)} = \sum_{j=0}^{\infty} \psi_j B^j, \quad \psi_0 = 1$$

حيث الأوزان هي $\psi_0, \psi_1, \psi_2, \psi_3, \dots$

ملاحظة: النموذج الذي على الشكل يسمى تمثيل

المتوسط المتحرك اللانهائي لنماذج ARMA(p, q).

أمثلة لدالة الأوزان لبعض النماذج:

دالة الأوزان لنموذج AR(1):

نموذج AR(1) يكتب على الشكل

$$\phi_1(B)(z_t - \mu) = \theta_0(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1 - \phi_1 B)(z_t - \mu) = a_t$$

$$z_t - \mu = \frac{1}{(1 - \phi_1 B)} a_t$$

$$z_t - \mu = \psi(B)a_t$$

حيث

$$\psi(B) = \frac{1}{(1 - \phi_1 B)}$$

سوف نجد الأوزان $\psi_1, \psi_2, \psi_3, \dots$ بالطريقة التالية

$$\psi(B) = \frac{1}{(1 - \phi_1 B)}$$

$$\psi(B)(1 - \phi_1 B) \equiv 1$$

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - \phi_1 B) \equiv 1$$

لاحظ أن العلاقة الأخيرة هي علاقة تكافؤ أي ان معاملات B^j على طرفي العلاقة متساوية.

وبمساواة معاملات B^j على طرفي العلاقة نجد

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - \phi_1 B) \equiv 1, \quad |\phi_1| < 1$$

$$B^0 : (1)(1) \equiv 1$$

$$B^1 : \psi_1 - \phi_1 \equiv 0 \Rightarrow \psi_1 = \phi_1$$

$$B^2 : \psi_2 - \psi_1 \phi_1 \equiv 0 \Rightarrow \psi_2 = \psi_1 \phi_1 = \phi_1^2$$

$$B^3 : \psi_3 - \psi_2 \phi_1 \equiv 0 \Rightarrow \psi_3 = \psi_2 \phi_1 = \phi_1^3$$

\vdots

$$B^j : \psi_j - \psi_{j-1} \phi_1 \equiv 0 \Rightarrow \psi_j = \psi_{j-1} \phi_1 = \phi_1^j$$

أي ان الأوزان لنموذج AR(1) هي

$$\psi_j = \phi_1^j, \quad |\phi_1| < 1$$

دالة الأوزان لنموذج MA(1)

نموذج MA(1) يكتب على الشكل

$$\phi_0(B)(z_t - \mu) = \theta_1(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(z_t - \mu) = (1 - \theta_1 B)a_t$$

$$z_t - \mu = \psi(B)a_t$$

حيث

$$\psi(B) = (1 - \theta_1 B)$$

بمساواة معاملات B^j على طرفي العلاقة نجد

$$\psi_1 = -\theta_1, \quad \psi_2 = \psi_3 = \dots = 0$$

أي

$$\psi_j = \begin{cases} 1, & j = 0 \\ -\theta_1, & j = 1 \\ 0, & j \geq 2 \end{cases}$$

دالة الأوزان لنموذج AR(2)

نماذج AR(2) يكتب على الشكل

$$\phi_2(B)(z_t - \mu) = \theta_0(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1 - \phi_1 B - \phi_2 B^2)(z_t - \mu) = a_t$$

$$z_t - \mu = \frac{1}{(1 - \phi_1 B - \phi_2 B^2)} a_t$$

$$z_t - \mu = \psi(B)a_t$$

حيث

$$\psi(B) = \frac{1}{(1 - \phi_1 B - \phi_2 B^2)}$$

و نجد الأوزان $\psi_1, \psi_2, \psi_3, \dots$ بالطريقة السابقة

$$\psi(B)(1 - \phi_1 B - \phi_2 B^2) \equiv 1$$

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - \phi_1 B - \phi_2 B^2) \equiv 1$$

$$B^1 : \psi_1 - \phi_1 = 0 \Rightarrow \psi_1 = \phi_1$$

$$B^2 : \psi_2 - \phi_1 \psi_1 - \phi_2 = 0 \Rightarrow \psi_2 = \phi_1 \psi_1 + \phi_2 = \phi_1^2 + \phi_2$$

$$B^3 : \psi_3 - \phi_1 \psi_2 - \phi_2 \psi_1 = 0 \Rightarrow \psi_3 = \phi_1 \psi_2 + \phi_2 \psi_1$$

⋮

$$B^j : \psi_j - \phi_1 \psi_{j-1} - \phi_2 \psi_{j-2} = 0 \Rightarrow \psi_j = \phi_1 \psi_{j-1} + \phi_2 \psi_{j-2}$$

أي ان الأوزان لنماذج AR(2) هي

$$\psi_j = \begin{cases} 1, & j = 0 \\ \phi_1, & j = 1 \\ \phi_1^2 + \phi_2, & j = 2 \\ \phi_1 \psi_{j-1} + \phi_2 \psi_{j-2}, & j \geq 3 \end{cases}$$

دالة الأوزان لنماذج MA(2)

نماذج MA(2) يكتب على الشكل

$$\phi_0(B)(z_t - \mu) = \theta_2(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(z_t - \mu) = (1 - \theta_1 B - \theta_2 B^2)a_t$$

$$z_t - \mu = \psi(B)a_t$$

حيث

$$\psi(B) = (1 - \theta_1 B - \theta_2 B^2)$$

بمساواة معاملات B^j على طرفي العلاقة نجد

$$\psi_1 = -\theta_1, \quad \psi_2 = -\theta_2, \quad \psi_3 = \psi_4 = \psi_5 = \dots = 0$$

أي

$$\psi_j = \begin{cases} 1, & j=0 \\ -\theta_1, & j=1 \\ -\theta_2, & j=2 \\ 0, & j \geq 2 \end{cases}$$

دالة الأوزان لنموذج ARMA(1,1)

نموذج ARMA(1,1) يكتب على الشكل

$$\phi_1(B)(z_t - \mu) = \theta_1(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1 - \phi_1 B)(z_t - \mu) = (1 - \theta_1 B)a_t$$

$$z_t - \mu = \frac{(1 - \theta_1 B)}{(1 - \phi_1 B)} a_t$$

$$z_t - \mu = \psi(B)a_t$$

حيث

$$\psi(B) = \frac{(1 - \theta_1 B)}{(1 - \phi_1 B)}$$

و نوجد الأوزان $\psi_1, \psi_2, \psi_3, \dots$ بالطريقة السابقة

$$\psi(B)(1 - \phi_1 B) \equiv (1 - \theta_1 B)$$

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - \phi_1 B) \equiv (1 - \theta_1 B)$$

$$B^1 : \psi_1 - \phi_1 = -\theta_1 \Rightarrow \psi_1 = \phi_1 - \theta_1$$

$$B^2 : \psi_2 - \phi_1 \psi_1 = 0 \Rightarrow \psi_2 = \phi_1 \psi_1 = \phi_1(\phi_1 - \theta_1)$$

$$B^3 : \psi_3 - \phi_1 \psi_2 = 0 \Rightarrow \psi_3 = \phi_1 \psi_2 = \phi_1^2(\phi_1 - \theta_1)$$

⋮

$$B^j : \psi_j - \phi_1 \psi_{j-1} = 0 \Rightarrow \psi_j = \phi_1 \psi_{j-1} = \phi_1^{j-1}(\phi_1 - \theta_1)$$

أي ان الأوزان لنموذج ARMA(1,1) هي

$$\psi_j = \phi_1 \psi_{j-1} = \phi_1^{j-1}(\phi_1 - \theta_1), \quad j \geq 1, \quad |\phi_1| < 1, \quad \phi_1 \neq \theta_1$$

دالة الأوزان لنموذج ARI(1)

نموذج ARI(1) يكتب على الشكل

$$\phi_1(B)(1-B)(z_t - \mu) = a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$z_t - \mu = \frac{1}{(1-\phi_1 B)(1-B)} a_t$$

$$z_t - \mu = \psi(B) a_t$$

حيث

$$\psi(B) = \frac{1}{(1-\phi_1 B)(1-B)}$$

و نجد الأوزان $\psi_1, \psi_2, \psi_3, \dots$ بالطريقة السابقة

$$\psi(B)(1-\phi_1 B)(1-B) \equiv 1$$

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - \phi_1 B)(1 - B) \equiv 1$$

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - (\phi_1 + 1)B + \phi_1 B^2) \equiv 1$$

$$B^1 : \psi_1 - (\phi_1 + 1) = 0 \Rightarrow \psi_1 = \phi_1 + 1$$

$$B^2 : \psi_2 - (\phi_1 + 1)\psi_1 + \phi_1 = 0 \Rightarrow \psi_2 = (\phi_1 + 1)\psi_1 + \phi_1 = (\phi_1 + 1)^2 + \phi_1$$

$$B^3 : \psi_3 - (\phi_1 + 1)\psi_2 + \phi_1\psi_1 = 0 \Rightarrow \psi_3 = (\phi_1 + 1)\psi_2 - \phi_1\psi_1$$

⋮

$$B^j : \psi_j - (\phi_1 + 1)\psi_{j-1} + \phi_1\psi_{j-2} = 0 \Rightarrow \psi_j = (\phi_1 + 1)\psi_{j-1} - \phi_1\psi_{j-2}$$

أي ان الأوزان لنموذج ARI(1) هي

$$\psi_j = \begin{cases} 1, & j=0 \\ \phi_1 + 1, & j=1 \\ (\phi_1 + 1)^2 + \phi_1, & j=2 \\ (\phi_1 + 1)\psi_{j-1} - \phi_1\psi_{j-2}, & j \geq 3 \end{cases}$$

وأخيرا نجد

دالة الأوزان لنموذج المشى العشوائى ARIMA(1,0,1) أو Random Walk Model

ويكتب على الشكل

$$z_t = z_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

أي

$$z_t - z_{t-1} = a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$(1-B)z_t = a_t$$

$$z_t = \frac{1}{(1-B)} a_t$$

حيث

$$\psi(B) = \frac{1}{(1-B)}$$

و نوجد الأوزان $\psi_1, \psi_2, \psi_3, \dots$ بالطريقة السابقة

$$\psi(B)(1-B) \equiv 1$$

$$(1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1-B) \equiv 1$$

$$B^1 : \psi_1 - 1 = 0 \Rightarrow \psi_1 = 1$$

$$B^2 : \psi_2 - \psi_1 = 0 \Rightarrow \psi_2 = \psi_1 = 1$$

$$B^3 : \psi_3 - \psi_2 = 0 \Rightarrow \psi_3 = \psi_2 = 1$$

\vdots

$$B^j : \psi_j - \psi_{j-1} = 0 \Rightarrow \psi_j = \psi_{j-1} = 1$$

أي ان الأوزان لنموذج المشي العشوائي $ARIMA(0,1,0)$ هي

$$\psi_j = 1, \quad j \geq 1$$

بعض خواص دالة الأوزان $\underline{\psi(B)}$

سبق أن كتبنا نموذج الإنحدار الذاتي-المتوسط المتحرك من الدرجة ARMA(p,q) على الشكل

$$z_t - \mu = \psi(B)a_t, \quad a_t \sim WN(0, \sigma^2)$$

وبكتابة هذه العلاقة على الشكل

$$z_t - \mu = a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \psi_3 a_{t-3} + \dots$$

$$= \sum_{j=0}^{\infty} \psi_j a_{t-j}, \quad \psi_0 = 1$$

وإذا افترضنا ان الأوزان تتقرب اي $\sum_{j=0}^{\infty} \psi_j^2 < \infty$ فإنه يمكن إثبات النظرية التالية:

نظريّة 1:

لنموذج الانحدار الذاتي-المتوسط المتحرك من الدرجة ARMA(p,q) المستقر والذي يكتب على الشكل

$$z_t - \mu = \sum_{j=0}^{\infty} \psi_j a_{t-j}, \quad a_t \sim WN(0, \sigma^2), \psi_0 = 1, \sum_{j=0}^{\infty} \psi_j^2 < \infty$$

1- المتوسط هو

$$E(z_t) = \mu, \quad \forall t$$

2- دالة الترابط الذاتي تعطى بالعلاقة

$$\rho_k = \frac{\sum_{j=0}^{\infty} \psi_j \psi_{j+k}}{\sum_{j=0}^{\infty} \psi_j^2}, \quad k = 0, 1, 2, \dots$$

مثال: لنموذج الانحدار الذاتي من الدرجة AR(1) وجدنا سابقا دالة الأوزان

$$\psi_j = \phi_1^j, \quad |\phi_1| < 1$$

دالة الترابط الذاتي

$$\rho_k = \frac{\sum_{j=0}^{\infty} \psi_j \psi_{j+k}}{\sum_{j=0}^{\infty} \psi_j^2} = \frac{\sum_{j=0}^{\infty} \phi_1^j \phi_1^{j+k}}{\sum_{j=0}^{\infty} \phi_1^{2j}} = \frac{\frac{\phi_1^k}{1-\phi_1^2}}{\frac{1}{1-\phi_1^2}} = \phi_1^k, \quad k = 0, 1, 2, \dots$$

وهي نفس النتيجة السابقة

تمرين: باستخدام نظرية 2 (2) أوجد دوال الترابط الذاتي للنماذج التالية

AR(2), MA(1), MA(2), ARMA(1,1), ARMA(2,1), ARMA(1,2)

الفصل الرابع

التنبؤات ذات متوسط مربع الخطأ الأدنى لنماذج ARMA(p,q)

Minimum Mean Square Error Forecasts for ARMA(p,q) Models

في الفقرة السابقة كتبنا نموذج الإنحدار الذاتي-المتوسط المتحرك من الدرجة (ARMA(p,q)) المستقر على الشكل

$$z_t - \mu = \sum_{j=0}^{\infty} \psi_j a_{t-j}, \quad a_t \sim WN(0, \sigma^2), \quad \psi_0 = 1, \quad \sum_{j=0}^{\infty} \psi_j^2 < \infty$$

أو

$$\begin{aligned} z_t - \mu &= a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \psi_3 a_{t-3} + \dots \\ &= \sum_{j=0}^{\infty} \psi_j a_{t-j}, \quad \psi_0 = 1 \end{aligned}$$

ملاحظة: هذا ينطبق أيضاً على نماذج ARIMA(p,d,q) بشكل عام.

للمتسلسلة زمنية مشاهدة $\{z_1, z_2, \dots, z_n\}$ التنبؤات $z_n(\ell)$, $\ell \geq 1$ للقيم المستقبلية

يمكن ان تكتب على الشكل $z_{n+\ell}$, $\ell \geq 1$

$$z_n(\ell) = \xi_0 a_n + \xi_1 a_{n-1} + \xi_2 a_{n-2} + \dots, \quad \ell \geq 1$$

القيم المستقبلية $z_{n+\ell}$, $\ell \geq 1$ تكتب بدلالة النموذج كالتالي

$$z_{n+\ell} - \mu = a_{n+\ell} + \psi_1 a_{n+\ell-1} + \dots + \psi_{\ell-1} a_{n+1} + \psi_\ell a_n + \psi_{\ell+1} a_{n-1} + \dots, \quad \ell \geq 1$$

متوسط مربع الخطأ يعطى بالعلاقة (انظر تعريف 5)

$$\begin{aligned} E[z_{n+\ell} - z_n(\ell)]^2 &= E[a_{n+\ell} + \psi_1 a_{n+\ell-1} + \dots + \psi_{\ell-1} a_{n+1} + (\psi_\ell - \xi_0) a_n + (\psi_{\ell+1} - \xi_1) a_{n-1} + \dots]^2 \\ &= (1 + \psi_1^2 + \dots + \psi_{\ell-1}^2) \sigma^2 + \sum_{j=0}^{\infty} (\psi_{\ell+j} - \xi_j)^2 \sigma^2 \end{aligned}$$

متوسط مربع الخطأ الأدنى ينتج من تصغير العلاقة السابقة بالنسبة للأوزان ξ_j لجميع قيم j

وهذا يمكن إذا وفقط إذا حققت الأوزان ξ_j العلاقة التالية

$$\xi_j = \psi_{\ell+j}, \quad j = 0, 1, 2, \dots, \ell \geq 1$$

وعليه فإن التنبؤات ذات متوسط مربع الخطأ الأدنى MMSE Forecasts تعطى بالعلاقة

$$z_n(\ell) = \psi_\ell a_n + \psi_{\ell+1} a_{n-1} + \psi_{\ell+2} a_{n-2} + \dots, \quad \ell \geq 1$$

نظريّة 2:

أخطاء التنبؤ تعطى بالعلاقة:

$$e_n(\ell) = z_{n+\ell} - z_n(\ell) = a_{n+\ell} + \psi_1 a_{n+\ell-1} + \psi_2 a_{n+\ell-2} + \cdots + \psi_{\ell-1} a_{n+1}, \ell \geq 1$$

وتبين أخطاء التنبؤ تعطى بالعلاقة:

$$V[e_n(\ell)] = \sigma^2 (1 + \psi_1^2 + \psi_2^2 + \cdots + \psi_{\ell-1}^2), \ell \geq 1$$

الصيغة $z_n(\ell) = \psi_\ell a_n + \psi_{\ell+1} a_{n-1} + \psi_{\ell+2} a_{n-2} + \cdots, \ell \geq 1$ غير عملية لإيجاد التنبؤات القيمة

المستقبلية $\{a_1, a_2, \dots, a_{n-1}, a_n\}$ وذلك لأننا نحتاج إلى معرفة القيم $\{a_1, a_2, \dots, a_{n-\ell}\}, \ell \geq 1$.

تعريف 18 :

مجموعة المعلومات $I(\{z_1, z_2, \dots, z_{n-1}, z_n\})$ تكافئ مجموعة المعلومات

$I(\{a_1, a_2, \dots, a_{n-1}, a_n\})$ وذلك بالمعنى أن المجموعة $\{a_1, a_2, \dots, a_{n-1}, a_n\}$ تحتوى على نفس

المعلومات عن المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$.

ملاحظة: المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ يمكن مشاهدتها وقياسها ولكن المتسلسلة

$\{a_1, a_2, \dots, a_{n-1}, a_n\}$ لا يمكن مشاهدتها أو قياسها.

نظريّة 3 :

المنتبئ ذا متوسط مربع الخطأ الأدنى MMSE Forecasts يعطى بالعلاقة

$$z_n(\ell) = E(z_{n+\ell} | z_n, z_{n-1}, \dots), \ell \geq 1$$

أي هو التوقع الشرطي للقيمة المستقبلية $z_{n+\ell}, \ell \geq 1$, z_n معطى

تستخدم نظريّة 2 عمليا لإيجاد قيم التنبؤات بدلا من الصيغة

$$z_n(\ell) = \psi_\ell a_n + \psi_{\ell+1} a_{n-1} + \psi_{\ell+2} a_{n-2} + \cdots, \ell \geq 1$$

وذلك تبعاً للملاحظة السابقة.

قاعدة 2:

$$1 - E(a_{n+j} | z_n, z_{n-1}, \dots) = \begin{cases} a_{n+j}, & j \leq 0 \\ 0, & j > 0 \end{cases}$$

$$2 - E(z_{n+j} | z_n, z_{n-1}, \dots) = \begin{cases} z_{n+j}, & j \leq 0 \\ z_n(j), & j > 0 \end{cases}$$

نظيرية 3 مع القاعدة 2 تعطي طريقة عملية وسهلة لإيجاد تنبؤات للقيم المستقبلية $z_{n+\ell}$, $\ell \geq 1$

تعريف 19:

الدالة 1 $z_n(\ell)$, $\ell \geq 1$ كدالة لزمن التقدم ℓ عند نقطة الأصل لزمن n تسمى دالة التنبؤ.

دوال التنبؤ لنماذج ARIMA(p,d,q)

أولاً: دالة التنبؤ لنموذج AR(1)

لنفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها

تبعد نموذج AR(1) والذي يكتب على الشكل

$$z_t - \mu = \phi_1(z_{t-1} - \mu) + a_t, \quad a_t \sim WN(0, \sigma^2), |\phi_1| < 1, \mu \in (-\infty, \infty)$$

نريد أن نتنبأ عن القيم المستقبلية $\dots, z_{n+1}, z_{n+2}, z_{n+3}$ أو بشكل عام

من نظيرية 3 نجد

$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= \mu + E[\phi_1(z_{n+\ell-1} - \mu) + a_{n+\ell}] | z_n, z_{n-1}, \dots, \ell \geq 1 \\ &= \mu + E[\phi_1(z_{n+\ell-1} - \mu) | z_n, z_{n-1}, \dots + a_{n+\ell} | z_n, z_{n-1}, \dots], \quad \ell \geq 1 \\ &= \mu + \phi_1 E[(z_{n+\ell-1} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+\ell} | z_n, z_{n-1}, \dots], \quad \ell \geq 1 \end{aligned}$$

أي

$$z_n(\ell) = \mu + \phi_1 E[(z_{n+\ell-1} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+\ell} | z_n, z_{n-1}, \dots], \quad \ell \geq 1$$

نحل هذه العلاقة تكراريا وباستخدام القاعدة 2

$$\ell = 1 : z_n(1) = \mu + \phi_1 E[(z_n | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+1} | z_n, z_{n-1}, \dots]$$

$$= \mu + \phi_1(z_n - \mu)$$

$$\ell = 2 : z_n(2) = \mu + \phi_1 E[(z_{n+1} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+2} | z_n, z_{n-1}, \dots]$$

$$= \mu + \phi_1[z_n(1) - \mu]$$

$$\ell = 3 : z_n(3) = \mu + \phi_1 E[(z_{n+2} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+3} | z_n, z_{n-1}, \dots]$$

$$= \mu + \phi_1[z_n(2) - \mu]$$

وهكذا بشكل عام

$$z_n(\ell) = \mu + \phi_1[z_n(\ell-1) - \mu], \quad \ell \geq 1$$

وهي دالة التنبؤ ذات متوسط مربع الأخطاء الأدنى لنموذج AR(1)

تعريف 20:

شرط الإستمرارية Continuity Condition يتطلب أنه عندما تكون $\ell = 1$ فإن

$$z_n(\ell-1) = z_n(0) = z_n$$

من نظرية 2 تبادل أخطاء التنبؤ تعطى من العلاقة

$$V[e_n(\ell)] = \sigma^2 (1 + \psi_1^2 + \psi_2^2 + \dots + \psi_{\ell-1}^2), \quad \ell \geq 1$$

سبق أن اشتققنا دالة الأوزان لنموذج AR(1) وهي

$$\psi_j = \phi_1^j, \quad |\phi_1| < 1$$

وبالتعويض في صيغة التبادل نجد

$$V[e_n(\ell)] = \sigma^2 (1 + \phi_1^2 + \phi_1^4 + \dots + \phi_1^{2(\ell-1)}), \quad \ell \geq 1$$

$$= \sigma^2 \frac{1 - \phi_1^{2\ell}}{1 - \phi_1^2}, \quad \ell \geq 1$$

مثال: متسلسلة زمنية مشاهدة وجد أنها تتبع النموذج

$$z_t - 0.97 = 0.85(z_{t-1} - 0.97) + a_t, \quad a_t \sim WN(0, 0.024)$$

إذا كانت المشاهدة الأخيرة هي $z_{156} = 0.49$ ، أوجد تنبؤات لقيم المستقبلية $z_{157}, z_{158}, z_{159}$ ، وأوجد أخطاء التنبؤ لها.

الحل: من الصيغة $e_n(\ell) = \mu + \phi_1[z_n(\ell-1) - \mu]$, $\ell \geq 1$ نجد

$$\begin{aligned} z_{156}(1) &= 0.97 + 0.85(z_{156} - 0.97) \\ &= 0.97 + 0.85(0.49 - 0.97) = 0.56 \end{aligned}$$

$$\begin{aligned} z_{156}(2) &= 0.97 + 0.85(z_{156}(1) - 0.97) \\ &= 0.97 + 0.85(0.56 - 0.97) = 0.62 \end{aligned}$$

$$\begin{aligned} z_{156}(3) &= 0.97 + 0.85(z_{156}(2) - 0.97) \\ &= 0.97 + 0.85(0.62 - 0.97) = 0.68 \end{aligned}$$

والتباينات

$$V[e_n(\ell)] = \sigma^2 \frac{1 - \phi_1^{2\ell}}{1 - \phi_1^2}, \quad \ell \geq 1$$

$$V[e_{156}(1)] = 0.024$$

$$V[e_{156}(2)] = 0.024 \frac{1 - (0.85)^4}{1 - (0.85)^2} = 0.041$$

$$V[e_{156}(3)] = 0.024 \frac{1 - (0.85)^6}{1 - (0.85)^2} = 0.054$$

ثانياً: دالة التنبئ لنموذج AR(2)

لنفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها

تبعد نموذج AR(2) والذي يكتب على الشكل

$$z_t = \mu + \phi_1(z_{t-1} - \mu) + \phi_2(z_{t-2} - \mu) + a_t, \quad a_t \sim WN(0, \sigma^2), \quad \mu \in (-\infty, \infty),$$

$$\phi_2 - \phi_1 < 1, \quad \phi_2 + \phi_1 < 1, \quad |\phi_2| < 1$$

نريد أن نتنبأ عن القيم المستقبلية $\dots, z_{n+1}, z_{n+2}, z_{n+3}$ أو بشكل عام $z_{n+\ell}$ ، $\ell \geq 1$

من نظرية 3 نجد

$$z_n(\ell) = E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1$$

$$= \mu + E[\phi_1(z_{n+\ell-1} - \mu) + \phi_2(z_{n+\ell-2} - \mu) + a_{n+\ell}] | z_n, z_{n-1}, \dots, \ell \geq 1$$

$$\begin{aligned}
&= \mu + E[\phi_1(z_{n+\ell-1} - \mu) | z_n, z_{n-1}, \dots + \phi_2(z_{n+\ell-2} - \mu) | z_n, z_{n-1}, \dots + a_{n+\ell} | z_n, z_{n-1}, \dots], \quad \ell \geq 1 \\
&= \mu + \phi_1 E[(z_{n+\ell-1} | z_n, z_{n-1}, \dots) - \mu] + \phi_2 E[(z_{n+\ell-2} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+\ell} | z_n, z_{n-1}, \dots], \quad \ell \geq 1
\end{aligned}$$

أي

$$z_n(\ell) = \mu + \phi_1 E[(z_{n+\ell-1} | z_n, z_{n-1}, \dots) - \mu] + \phi_2 E[(z_{n+\ell-2} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+\ell} | z_n, z_{n-1}, \dots], \quad \ell \geq 1$$

نحل هذه العلاقة تكراريا وباستخدام القاعدة 2

$$\begin{aligned}
\ell = 1: z_n(1) &= \mu + \phi_1 E[(z_n | z_n, z_{n-1}, \dots) - \mu] + \phi_2 E[(z_{n-1} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+1} | z_n, z_{n-1}, \dots] \\
&= \mu + \phi_1(z_n - \mu) + \phi_2(z_{n-1} - \mu) \\
\ell = 2: z_n(2) &= \mu + \phi_1 E[(z_{n+1} | z_n, z_{n-1}, \dots) - \mu] + \phi_2 E[(z_n | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+2} | z_n, z_{n-1}, \dots] \\
&= \mu + \phi_1[z_n(1) - \mu] + \phi_2(z_n - \mu) \\
\ell = 3: z_n(3) &= \mu + \phi_1 E[(z_{n+2} | z_n, z_{n-1}, \dots) - \mu] + \phi_2 E[(z_{n+1} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+3} | z_n, z_{n-1}, \dots] \\
&= \mu + \phi_1[z_n(2) - \mu] + \phi_2[z_n(1) - \mu] \\
\ell = 4: z_n(4) &= \mu + \phi_1 E[(z_{n+3} | z_n, z_{n-1}, \dots) - \mu] + \phi_2 E[(z_{n+2} | z_n, z_{n-1}, \dots) - \mu] + E[a_{n+4} | z_n, z_{n-1}, \dots] \\
&= \mu + \phi_1[z_n(3) - \mu] + \phi_2[z_n(2) - \mu]
\end{aligned}$$

وهكذا بشكل عام

$$z_n(\ell) = \mu + \phi_1[z_n(\ell-1) - \mu] + \phi_2[z_n(\ell-2) - \mu], \quad \ell \geq 1$$

وهي دالة التنبؤ ذات متوسط مربع الأخطاء الأدنى لنموذج AR(2)

ويمكن حساب تباينات أخطاء التنبؤ من نظرية 2 ودالة الأوزان

$$\psi_j = \begin{cases} 1, & j = 0 \\ \phi_1, & j = 1 \\ \phi_1^2 + \phi_2, & j = 2 \\ \phi_1 \psi_{j-1} + \phi_2 \psi_{j-2}, & j \geq 3 \end{cases}$$

ثالثاً: دالة التنبؤ لنموذج ARIMA(0,1,1)

لنفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها

تتبع نموذج ARIMA(0,1,1) والذي يكتب على الشكل

$$z_t = z_{t-1} + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2)$$

نريد أن نتنبأ عن القيم المستقبلية $\dots, z_{n+3}, z_{n+2}, z_{n+1}, z_n$ أو بشكل عام $\cdot z_{n+\ell}, \ell \geq 1$

من نظرية 3 نجد

$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= E(z_{n+\ell-1} | z_n, z_{n-1}, \dots) + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \end{aligned}$$

نحل هذه العلاقة تكراريا وباستخدام القاعدة 2

$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell-1} | z_n, z_{n-1}, \dots) + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ \ell = 1: \quad z_n(1) &= E(z_n | z_n, z_{n-1}, \dots) + E(a_{n+1} | z_n, z_{n-1}, \dots) - \theta_1 E(a_n | z_n, z_{n-1}, \dots) \\ &= z_n - \theta_1 a_n \\ \ell = 2: \quad z_n(2) &= E(z_{n+1} | z_n, z_{n-1}, \dots) + E(a_{n+2} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+1} | z_n, z_{n-1}, \dots) \\ &= z_n(1) \\ \ell = 3: \quad z_n(3) &= E(z_{n+2} | z_n, z_{n-1}, \dots) + E(a_{n+3} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+2} | z_n, z_{n-1}, \dots) \\ &= z_n(2) \end{aligned}$$

وهكذا بشكل عام

$$z_n(\ell) = z_n(\ell-1), \quad \ell \geq 2$$

وهكذا فإن دالة التنبؤ ذات متوسط مربع الأخطاء الأدنى لنموذج ARIMA(0,1,1) تعطى

بالعلاقة

$$z_n(\ell) = \begin{cases} z_n - \theta_1 a_n, & \ell = 1 \\ z_n(\ell-1), & \ell > 1 \end{cases}$$

رابعاً : دالة التنبؤ لنموذج (I) :

لفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها

تبعد نموذج MA(1) والذي يكتب على الشكل

$$z_t = \mu + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2)$$

نريد أن نتنبأ عن القيم المستقبلية $\dots, z_{n+3}, z_{n+2}, z_{n+1}, z_n$ أو بشكل عام $\cdot z_{n+\ell}, \ell \geq 1$

من نظرية 3 نجد

$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= \mu + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \end{aligned}$$

نحل هذه العلاقة تكراريا وباستخدام القاعدة 2

$$\begin{aligned}
z_n(\ell) &= \mu + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\
\ell = 1: \quad z_n(1) &= \mu + E(a_{n+1} | z_n, z_{n-1}, \dots) - \theta_1 E(a_n | z_n, z_{n-1}, \dots) \\
&= \mu - \theta_1 a_n \\
\ell = 2: \quad z_n(2) &= \mu + E(a_{n+2} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+1} | z_n, z_{n-1}, \dots) \\
&= \mu \\
\ell = 3: \quad z_n(3) &= \mu + E(a_{n+3} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+2} | z_n, z_{n-1}, \dots) \\
&= \mu
\end{aligned}$$

وهكذا بشكل عام

$$z_n(\ell) = \mu, \quad \ell \geq 2$$

وهكذا فإن دالة التنبؤ ذات متوسط مربع الأخطاء الأدنى لنموذج MA(1) تعطى بالعلاقة

$$z_n(\ell) = \begin{cases} \mu - \theta_1 a_n, & \ell = 1 \\ \mu, & \ell \geq 2 \end{cases}$$

خامساً : دالة التنبؤ لنموذج MA(2) :

لنفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها

تتبع نموذج MA(2) والذي يكتب على الشكل

$$z_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}, \quad a_t \sim WN(0, \sigma^2)$$

نريد أن نتبأ عن القيم المستقبلية $\dots, z_{n+1}, z_{n+2}, z_{n+3}$ أو بشكل عام

من نظرية 3 نجد

$$\begin{aligned}
z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\
&= \mu + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots) - \theta_2 E(a_{n+\ell-2} | z_n, z_{n-1}, \dots), \quad \ell \geq 1
\end{aligned}$$

نحل هذه العلاقة تكرارياً وباستخدام القاعدة 2

$$\begin{aligned}
z_n(\ell) &= \mu + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots) - \theta_2 E(a_{n+\ell-2} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\
\ell = 1: \quad z_n(1) &= \mu + E(a_{n+1} | z_n, z_{n-1}, \dots) - \theta_1 E(a_n | z_n, z_{n-1}, \dots) - \theta_2 E(a_{n-1} | z_n, z_{n-1}, \dots) \\
&= \mu - \theta_1 a_n - \theta_2 a_{n-1} \\
\ell = 2: \quad z_n(2) &= \mu + E(a_{n+2} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+1} | z_n, z_{n-1}, \dots) - \theta_2 E(a_n | z_n, z_{n-1}, \dots) \\
&= \mu - \theta_2 a_n \\
\ell = 3: \quad z_n(3) &= \mu + E(a_{n+3} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+2} | z_n, z_{n-1}, \dots) - \theta_2 E(a_{n+1} | z_n, z_{n-1}, \dots) \\
&= \mu
\end{aligned}$$

وهكذا بشكل عام

$$z_n(\ell) = \mu, \quad \ell \geq 3$$

وهكذا فإن دالة التنبؤ ذات متوسط مربع الأخطاء الأدنى لنموذج (2) MA(2) تعطى بالعلاقة

$$z_n(\ell) = \begin{cases} \mu - \theta_1 a_n - \theta_2 a_{n-1}, & \ell = 1 \\ \mu - \theta_2 a_n, & \ell = 2 \\ \mu, & \ell \geq 3 \end{cases}$$

سادساً : دالة التنبؤ لنموذج ARMA(1,1)

لنفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها

تتبع نموذج ARMA(1,1) والذي يكتب على الشكل

$$z_t = \mu + \phi_1(z_{t-1} - \mu) + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2), \quad \phi_1 \neq \theta_1, |\phi_1| < 1$$

نريد أن نتنبأ عن القيم المستقبلية $\dots, z_{n+1}, z_{n+2}, z_{n+3}$ أو بشكل عام

من نظرية 3 نجد

$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= \mu + \phi_1 E[(z_{n+\ell-1} - \mu) | z_n, z_{n-1}, \dots] + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \end{aligned}$$

نحل هذه العلاقة تكرارياً وباستخدام القاعدة 2

$$\begin{aligned} z_n(\ell) &= \mu + \phi_1 E[(z_{n+\ell-1} - \mu) | z_n, z_{n-1}, \dots] + E(a_{n+\ell} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ \ell = 1: \quad z_n(1) &= \mu + \phi_1 E[(z_n - \mu) | z_n, z_{n-1}, \dots] + E(a_{n+1} | z_n, z_{n-1}, \dots) - \theta_1 E(a_n | z_n, z_{n-1}, \dots) \\ &= \mu + \phi_1(z_n - \mu) - \theta_1 a_n \\ \ell = 2: \quad z_n(2) &= \mu + \phi_1 E[(z_{n+1} - \mu) | z_n, z_{n-1}, \dots] + E(a_{n+2} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+1} | z_n, z_{n-1}, \dots) \\ &= \mu + \phi_1[z_n(1) - \mu] \\ \ell = 3: \quad z_n(3) &= \mu + \phi_1 E[(z_{n+2} - \mu) | z_n, z_{n-1}, \dots] + E(a_{n+3} | z_n, z_{n-1}, \dots) - \theta_1 E(a_{n+2} | z_n, z_{n-1}, \dots) \\ &= \mu + \phi_1[z_n(2) - \mu] \end{aligned}$$

وهكذا بشكل عام

$$z_n(\ell) = \mu + \phi_1[z_n(\ell-1) - \mu], \quad \ell \geq 2$$

وهكذا فإن دالة التنبؤ ذات متوسط مربع الأخطاء الأدنى لنموذج ARMA(1,1) تعطى بالعلاقة

$$z_n(\ell) = \begin{cases} \mu + \phi_1(z_n - \mu) - \theta_1 a_n, & \ell = 1 \\ \mu + \phi_1[z_n(\ell-1) - \mu], & \ell \geq 2 \end{cases}$$

تمرين:

لنموذج ARMA(1,1) والذي يكتب على الشكل

$$z_t = \mu + \phi_1(z_{t-1} - \mu) + a_t - \theta_1 a_{t-1}, \quad a_t \sim WN(0, \sigma^2), \quad |\phi_1| < 1$$

برهن ان عندما تؤول $\phi_1 \rightarrow 1$ فإن $ARMA(1,1) \rightarrow IMA(1,1)$ ومن ثم أوجد دالة التنبؤ $IMA(1,1)$.

تمرين:

أوجد دوال التنبؤ وتبين أخطاء التنبؤ لكل من النماذج التالية:

$ARIMA(1,1,1), \quad ARIMA(2,1,0), \quad ARIMA(0,1,2), \quad ARIMA(1,2,0),$
 $ARIMA(0,2,1), \quad ARIMA(0,2,0).$

حدود التنبؤ : Forecasting Limits

دالة التنبؤ $z_n(\ell), \ell \geq 1$ عند قيمة معينة تعطي مايسمى بتنبؤ النقطة Point Forecast والذي

لايكفي او يفيد في إتخاذ قرارات إحصائية عن الظاهرة العشوائية المدروسة لأن

$$P(Z_{n+m} = z_n(m)) = 0, \text{ for some } m > 0$$

أي أن مقدار تأكيناً (أو احتمال) من أن القيمة المستقبلية المراد التنبؤ عنها تساوي القيمة المعطاة من دالة التنبؤ تساوي الصفر أي إننا غير متأكدين إطلاقاً وبالتالي لفائدة من التنبؤ.

للغلب على ذلك وألاستفادة من التنبؤات نستخدم مايسمى بتنبؤ الفترة Interval Forecast وهي عبارة عن فترة مثل $[a, b]$ على خط الأعداد الحقيقة بحيث يكون

$$P(a \leq Z_{n+m} \leq b) = (1 - \alpha)$$

وبهذا نستطيع أن نحدد درجة تأكيناً من أن القيمة المستقبلية المراد التنبؤ عنها تقع بين القيم

a و b بدرجة تأكيد أو احتمال $1 - \alpha$ (أو $100 \times (1 - \alpha)\%$) فمثلاً لو كانت $\alpha = 0.05$ فإننا

نكون متأكدين وبإحتمال 95% أن القيمة المستقبلية تقع بين القيم a و b .

تعريف 21:

على إفتراض أن $a_t \sim N(0, \sigma^2)$ فإن حدود $100 \times (1 - \alpha)\%$ فترة تنبؤ للقيمة المستقبلية

تعطى بالعلاقة $z_{n+\ell}, \ell \geq 1$

$$z_n(\ell) \pm u_{\alpha/2} \{V[e_n(\ell)]\}^{1/2}$$

حيث $u_{\alpha/2}$ المئين $N(0,1)$ للتوزيع $100 \left(1 - \frac{\alpha}{2}\right)$

فمثلاً عندما $\alpha = 0.05$ فإن $u_{0.025} = 1.96$

ملاحظة: في التعريف إفترضنا أن متسلسلة الضجة البيضاء $a_t \sim N(0, \sigma^2)$ وهذا ممكن

إعتماداً على نظرية نهاية مركبة.

مثال: متسلسلة زمنية مشاهدة وجد أنها تتبع النموذج

$$z_t - 0.97 = 0.85(z_{t-1} - 0.97) + a_t, \quad a_t \sim N(0, 0.024)$$

إذا كانت المشاهدة الأخيرة هي $z_{156} = 0.49$ ، أوجد تنبؤات لقيم المستقبلية $z_{157}, z_{158}, z_{159}$

وأوجد أخطاء التنبؤ لها ومن ثم أوجد فترات تنبؤ 95% لقيم المستقبلية.

الحل: سبق أن حسبنا في مثال سابق التنبؤات وأخطاء التنبؤ كالتالي:

التنبؤات

$$z_{156}(1) = 0.56, z_{156}(2) = 0.62, z_{156}(3) = 0.68$$

والبيانات

$$V[e_{156}(1)] = 0.024, V[e_{156}(2)] = 0.041, V[e_{156}(3)] = 0.054$$

فترات تنبؤ 95% لقيم المستقبلية $z_{157}, z_{158}, z_{159}$ نوجدها من صيغة تعريف 21

$$z_n(\ell) \pm u_{\alpha/2} \{V[e_n(\ell)]\}^{1/2}$$

$$1 - z_{156}(1) \pm u_{0.025} \{V[e_{156}(1)]\}^{1/2} = 0.56 \pm 1.96\sqrt{0.024} = 0.56 \pm 0.304$$

$$2 - z_{156}(2) \pm u_{0.025} \{V[e_{156}(2)]\}^{1/2} = 0.62 \pm 1.96\sqrt{0.041} = 0.62 \pm 0.397$$

$$3 - z_{156}(3) \pm u_{0.025} \{V[e_{156}(3)]\}^{1/2} = 0.68 \pm 1.96\sqrt{0.054} = 0.68 \pm 0.455$$

أي أن $z_{157} \in (0.223, 1.017)$ بإحتمال 0.95 و كذلك $z_{158} \in (0.256, 0.864)$ و كذلك أيضاً

$$\cdot z_{159} \in (0.225, 1.135)$$

الفصل الخامس

تصميم وبناء نظام تنبؤ احصائي Designing and Building Statistical Forecasting System

سبق أن ذكرنا ان الخطوة الأولى لتصميم نظام تنبؤ هي بناء نموذج . إن عملية بناء نموذج احصائي هي عملية تكرارية Iterative تتكون من تحديد النموذج ، تقدير النموذج (ونقصد بها تقدير معالم النموذج) و اختبار النموذج.

تعيين أو تحديد النموذج (Specification : Model Identification)

في مرحلة تحديد النموذج نستخدم البيانات أو المشاهدات السابقة (التاريخ) واي معلومات أخرى عن الكيفية التي تولدت بها المتسلسلة وذلك لإقتراح مجموعة من النماذج المناسبة. ويتم تعيين أو تحديد النموذج حسب الخطوات العريضة التالية:

الخطوة الاولى: تحويل ثبات التباين : Variance-stabilizing Transformation

بعد رسم المتسلسلة في مخطط زمني Time Plot وإجراء بعض الإختبارات الإحصائية لمعرفة فيما إذا كان التباين ثابت، وفي حالة عدم ثبات التباين او إذا كان التباين يتغير مع مستوى المتسلسلة فإننا نطبق التحويل اللوغاريتمي على المتسلسلة ونفحصها من جديد فإذا تم ثبات التباين وإلا نلجأ إلى تطبيق أحد التحويلات التي ذكرناها في جدول صفحة 41.

الخطوة الثانية: اختيار درجة التفريق d :

إذا كانت المتسلسلة أو تحويلها غير مستقرة في المتوسط فيجب علينا تحديد درجة التفريق d التي تجعل الممتسلسلة أو تحويلها مستقرة في المتوسط ونقوم بأخذ التفريق الأول ثم نفحص التالي:

- 1- المخططات الزمنية للممتسلسلة أو تحويلها.
- 2- مخططات دالة الترابط الذاتي العيني والترابط الذاتي الجزئي العيني SACF و SPACF .
- 3- إجراء تفريقي آخر إذا احتاج الأمر وإعادة الخطوات 1 و 2 السابقتين.

المخططات الزمنية للممتسلسلات غير المستقرة تبين تغير في المستوى ودالة ترابط ذاتي عيني متاخمة ببطء كما ان دالة الترابط الذاتي الجزئي العيني تعطي قيمة واحدة قريبة من الواحد الصحيح (بعض النظر عن الإشارة) وبقية القيم قريبة جداً من الصفر.

ملاحظة: درجة التفريق d غالباً ما تكون 0 او 1 او 2 .

الخطوة الثالثة: تحديد p و q :

بعد ان نحصل على متسلسلة مستقرة في كل من التباين والمتوسط نقوم بتحديد درجة الإنحدار الذاتي p ودرجة المتوسط المتحرك q وذلك بمقارنة أنماط دالتي الترابط الذاتي العيني والترابط الذاتي الجزئي العيني مع الأنماط النظرية لدالتي الترابط الذاتي والترابط الذاتي الجزئي مسترشدين بخواص نماذج $ARMA(p,q)$ المذكورة في صفحة 38 والجدول التالي يعطي هذه الخواص لبعض النماذج الشائعة:

PACF	ACF	النموذج
$\phi_{kk} = 0, k > 1$	تخامد اسي او اسي متعدد	$AR(1, d, 0)$
$\phi_{kk} = 0, k > 2$	تخامد اسي او تخامد جيبي	$AR(2, d, 0)$
$\phi_{kk} = 0, k > p$	تخامد اسي و/ او تخامد جيبي	$AR(p, d, 0)$
يسسيطر عليها تخامد اسي	$\rho_k = 0, k > 1$	$MA(1) \text{ و } (0, d, 1)$
يسسيطر عليها تخامد اسي او جيبي	$\rho_k = 0, k > 2$	$MA(2) \text{ و } (0, d, 2)$
يسسيطر عليها تخامد اسي و/ او جيبي	$\rho_k = 0, k > q$	$MA(q) \text{ و } (0, d, q)$
تناقص وتتخامد اسيا	تناقص ويسطر عليها تخامد اسي	$ARMA(1, 1) \text{ و } (1, d, 1)$
من التخلف 1	من التخلف 1	
تناقص بعد التخلف	تناقص بعد التخلف $p - q$ وتخامد	$ARMA(p, q) \text{ و } (p, d, q)$
اسيا و/ او جيبيا بعد التخلف $p - q$ ويسطر		
عليها تخامد اسي		
و/ او جيبي بعد		
الخلف $p - q$		

الخطوة الرابعة: إضافة معلم إنجراف:

إذا كانت المتسلسلة تحتاج إلى تفريق فيجب علينا التأكد فيما إذا كان علينا إضافة إنجراف معلوم δ إلى النموذج وهذا يتم بمقارنة متوسط العينة \bar{w} للمتسلسلة المفرقة المستقرة مع الخطأ المعياري لهذا المتوسط

$$s.e(\bar{w}) \equiv \left[\frac{c_0}{n} (1 + 2r_1 + 2r_2 + \dots + 2r_K) \right]^{1/2}$$

حيث $\hat{\gamma}_0 = c_0$ و r_1, \dots, r_K هي الترابطات الذاتية العينية المعنوية للدرجة K . ويكون الإختبار

$$H_0: \delta = 0$$

$$H_1: \delta \neq 0$$

ونرفض H_0 عند $\alpha = 0.05$ إذا كانت $\left| \frac{\bar{w}}{s.e(\bar{w})} \right| > 1.96$

تقدير النموذج : Model Estimation

بعد تحديد شكل النموذج لابد من تقدير معالم النموذج δ و $\theta_1, \dots, \theta_q$ و σ^2 وذلك بإستخدام البيانات التاريخية المتوفرة لدينا.

لنفترض ان لدينا المتسلسلة الزمنية المشاهدة z_n, z_{n-1}, \dots, z_1 و النموذج المقترن

$$\phi_p(B)w_t = \delta + \theta_q(B)a_t, a_t \sim N(0, \sigma^2)$$

أو

$$\phi_p(B)z_t = \delta + \theta_q(B)a_t, a_t \sim N(0, \sigma^2)$$

حيث $(\phi_p(B))$ و $(\theta_q(B))$ لا يوجد بينها جذور مشتركة وجذور المعادلة $= 0$ تقع جميعها خارج دائرة الوحدة (شرط الاستقرار).

هناك طرق كثيرة لتقدير المعالم سنذكر منها هنا فقط طريقتين تدخل ضمن نطاق هذا المقرر وهما طريقة العزوم وطريقة المربعات الدنيا الشرطية.

أولاً: طريقة العزوم The Method of Moments

وتعتمد على مساوات عزوم العينة مثل متوسط العينة \bar{z} والترابطات الذاتية للعينة ρ_k بالعزوم النظرية مثل المتوسط μ ودالة الترابط الذاتي ρ وحل المعادلات الناتجة بالنسبة للمعلم المراد تقديرها.

سوف نستعرض الطريقة للنموذج AR(p) كالتالي:

$$1- \text{يقدر المتوسط } \mu \text{ بالمقدار } \bar{z} = \sum_{i=1}^n z_i / n \text{ اي}$$

2- لتقدير ϕ_1, \dots, ϕ_p نستخدم العلاقة:

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}, k > 1$$

والتي تنتج من ضرب المعادلة المعرفة لنموذج AR(p) بالحد $\mu - z_{t-k}$ وأخذ التوقع. في المعادلة السابقة بوضع $k = 1, 2, \dots, p$ نحصل على نظام المعادلات المسمى معادلات يول ووكر Yule-Walker التالي:

$$\rho_1 = \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1}$$

$$\rho_2 = \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2}$$

⋮

$$\rho_p = \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p$$

و بالتعويض عن ρ_k بالمقدار r_k نحصل على مقدرات العزوم للمعلم $\hat{\phi}_1, \dots, \hat{\phi}_p$ كالتالي:

بوضع معادلات يول و ووكر على الشكل المصفوفي:

$$\begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{pmatrix} = \begin{pmatrix} 1 & r_1 & r_2 & \cdots & r_{p-2} & r_{p-1} \\ r_1 & 1 & r_1 & \cdots & r_{p-3} & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & r_1 & 1 \end{pmatrix} \begin{pmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_p \end{pmatrix}$$

وبحل هذه المعادلة للمعلم

$$\begin{pmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_p \end{pmatrix} = \begin{pmatrix} 1 & r_1 & r_2 & \cdots & r_{p-2} & r_{p-1} \\ r_1 & 1 & r_1 & \cdots & r_{p-3} & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & r_1 & 1 \end{pmatrix}^{-1} \begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{pmatrix}$$

تقدر σ^2 كالتالي

$$\hat{\sigma}^2 = \hat{\gamma}_0 \left(1 - \hat{\phi}_1 r_1 - \hat{\phi}_2 r_2 - \cdots - \hat{\phi}_p r_p \right)$$

حيث

$$\hat{\gamma}_0 = \frac{1}{n} \sum_{t=1}^n (z_t - \bar{z})^2$$

هو تباين العينة.

تقدير العزوم لبعض النماذج:

AR(1) - نموذج

$$z_t - \mu = \phi_1 (z_{t-1} - \mu) + a_t, \quad a_t \sim N(0, \sigma^2)$$

مقدر العزوم للمعلم ϕ_1 هو

$$\hat{\phi}_1 = r_1$$

مقدر العزوم للمعلم μ هو

$$\hat{\mu} = \bar{z}$$

مقدر العزوم للمعلم σ^2 هو

$$\hat{\sigma}^2 = \hat{\gamma}_0 \left(1 - \hat{\phi}_1 r_1 \right)$$

حيث

$$\hat{\gamma}_0 = \frac{1}{n} \sum_{t=1}^n (z_t - \bar{z})^2$$

2- نموذج MA(1)

$$z_t - \mu = a_t - \theta_1 a_{t-1}, a_t \sim N(0, \sigma^2)$$

لإيجاد مقدر العزوم للمعلم θ_1 نستخدم العلاقة

$$\rho_1 = \frac{-\theta_1}{1 + \theta_1^2}$$

وبتعويض المعالم بمقدراتها

$$r_1 = \frac{-\hat{\theta}_1}{1 + \hat{\theta}_1^2}$$

وبحل المعادلة للمقدر $\hat{\theta}_1$ نجد

$$\hat{\theta}_1 = \frac{-1 \pm \sqrt{1 - 4r_1}}{2r_1}$$

هذا الحل يعطي قيمتين للمقدر $\hat{\theta}_1$ نأخذ القيمة التي تحقق $r_1 = -0.4$ فإن

$$\hat{\theta}_1 = -0.77 \quad \text{و} \quad (\hat{\theta}_1)_{-0.77} = 3.27 \quad (\hat{\theta}_1)_{-0.77} = -0.77$$

3- نموذج AR(2)

$$z_t - \mu = \phi_1(z_{t-1} - \mu) + \phi_2(z_{t-2} - \mu) + a_t, a_t \sim N(0, \sigma^2)$$

باستخدام معادلات يول ووكر مقدرات العزوم للمعلم ϕ_1 و ϕ_2 هي

$$\begin{pmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \end{pmatrix} = \begin{pmatrix} 1 & r_1 \\ r_1 & 1 \end{pmatrix}^{-1} \begin{pmatrix} r_1 \\ r_2 \end{pmatrix}$$

ومنها نجد

$$\hat{\phi}_1 = \frac{r_1 - r_1 r_2}{1 - r_1^2}, \quad \hat{\phi}_2 = \frac{r_2 - r_1^2}{1 - r_1^2}$$

مقدر العزوم للمعلم μ هو

$$\hat{\mu} = \bar{z}$$

مقدر العزوم للمعلم σ^2 هو

$$\hat{\sigma}^2 = \hat{\gamma}_0 \left(1 - \hat{\phi}_1 r_1 - \hat{\phi}_2 r_2 \right)$$

حيث

$$\hat{\gamma}_0 = \frac{1}{n} \sum_{t=1}^n (z_t - \bar{z})^2$$

4- نموذج MA(2)

$$z_t - \mu = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}, a_t \sim N(0, \sigma^2)$$

لإيجاد مقدرات العزوم للمعلم θ_1 و θ_2 نستخدم العلاقات

$$\rho_1 = \frac{-\theta_1(1-\theta_2)}{1+\theta_1^2+\theta_2^2}, \quad \rho_2 = \frac{-\theta_2}{1+\theta_1^2+\theta_2^2}$$

وبتعويض المقدرات r_1 و r_2 نحصل على مقدرات العزوم للمعلم θ_1 و θ_2

$$r_1 = \frac{-\hat{\theta}_1(1-\hat{\theta}_2)}{1+\hat{\theta}_1^2+\hat{\theta}_2^2}, \quad r_2 = \frac{-\hat{\theta}_2}{1+\hat{\theta}_1^2+\hat{\theta}_2^2}$$

ونحل لكل من $\hat{\theta}_1$ و $\hat{\theta}_2$ ونأخذ الحلول التي تحقق $. \theta_2 - \theta_1 < 1, \quad \theta_2 + \theta_1 < 1, \quad |\theta_2| < 1$

5- نموذج ARMA(1,1)

$$z_t - \mu = \phi_1(z_{t-1} - \mu) + a_t - \theta_1 a_{t-1}, a_t \sim N(0, \sigma^2)$$

لإيجاد مقدرات العزوم للمعلم θ_1 و ϕ_1 نستخدم العلاقات

$$\rho_1 = \frac{(1-\phi_1\theta_1)(\phi_1-\theta_1)}{1+\theta_1^2-2\phi_1\theta_1}, \quad \rho_2 = \frac{(1-\phi_1\theta_1)(\phi_1-\theta_1)}{1+\theta_1^2-2\phi_1\theta_1} \phi_1$$

وبتعويض المقدرات r_1 و r_2 نحصل على مقدرات العزوم للمعلم θ_1 و ϕ_1

$$r_1 = \frac{(1-\hat{\phi}_1\hat{\theta}_1)(\hat{\phi}_1-\hat{\theta}_1)}{1+\hat{\theta}_1^2-2\hat{\phi}_1\hat{\theta}_1}, \quad r_2 = \frac{(1-\hat{\phi}_1\hat{\theta}_1)(\hat{\phi}_1-\hat{\theta}_1)}{1+\hat{\theta}_1^2-2\hat{\phi}_1\hat{\theta}_1} \hat{\phi}_1$$

وبقسمة المعادلة المعرفة للمقدر r_2 على المعادلة المعرفة للمقدر r_1 نجد

$$\hat{\phi}_1 = \frac{r_2}{r_1}$$

وهو مقدر العزوم للمعلم ϕ_1 . لإيجاد مقدر العزوم للمعلم θ_1 نعرض عن $\hat{\phi}_1$ في المعادلة المعرفة

للمقدر r_1 نجد

$$r_1 = \frac{\left(1 - \frac{r_2}{r_1} \hat{\theta}_1\right) \left(\frac{r_2}{r_1} - \hat{\theta}_1\right)}{1 + \hat{\theta}_1^2 - 2 \frac{r_2}{r_1} \hat{\theta}_1}$$

ونحل المعادلة التربيعية الناتجة للمقدار $\hat{\theta}_1$ و نأخذ القيمة التي تحقق $1 < |\hat{\theta}_1|$.

تمارين: أوجد مقدرات العزوم لمعامل النماذج التالية

ARIMA(1,1,1), ARIMA(2,1,0), ARIMA(0,1,2), ARIMA(1,2,0),
ARIMA(0,2,1), ARIMA(0,2,0).

ملاحظة: مقدرات العزوم تستخدم كقيم أولية لإيجاد مقدرات أكثر دقة.

ثانياً: طريقة المربعات الدنيا الشرطية Conditional Least Square Method

لنماذج ARMA(p,q) والتي تكتب على الشكل

$$\phi_p(B)(z_t - \mu) = \theta_q(B)a_t, \quad a_t \sim N(0, \sigma^2)$$

حيث $\phi_p(B)$ و $\theta_q(B)$ لا يوجد بينها جذور مشتركة وجذور المعادلة $\theta_q(B) = 0$ تقع جميعها

خارج دائرة الوحدة (شرط الإنقلاب). بإعادة كتابة النموذج السابق للأخطاء a_t كالتالي:

$$a_t = \frac{\phi_p(B)}{\theta_q(B)}(z_t - \mu)$$

الطرف الأيمن يمكن اعتباره كدالة في المعامل $\Phi = \{\phi_1, \phi_2, \dots, \phi_p\}$ و $\Theta = \{\theta_1, \theta_2, \dots, \theta_q\}$ و μ

ويكتب

$$a_t(\Phi, \Theta, \mu) = \frac{(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)}{(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)}(z_t - \mu)$$

تعتمد طريقة المربعات الدنيا الشرطية و لمشاهدات معطاة $\mathbf{z} = \{z_1, z_2, \dots, z_n\}$ على تصغير

الدالة

$$\min_{\Phi, \Theta, \mu} S_c(\Phi, \Theta, \mu) = \sum_{t=p+1}^n a_t^2(\Phi, \Theta, \mu | \mathbf{z})$$

وحل المعادلات الطبيعية Normal Equations الناتجة التالية بالنسبة للمقدرات.

$$\frac{\partial}{\partial \Phi} S_c(\Phi, \Theta, \mu) \Bigg|_{\begin{array}{l} \Phi = \hat{\Phi} \\ \Theta = \hat{\Theta} \\ \mu = \hat{\mu} \end{array}} = \frac{\partial}{\partial \Phi} \sum_{t=p+1}^n a_t^2(\Phi, \Theta, \mu | \mathbf{z}) \Bigg|_{\begin{array}{l} \Phi = \hat{\Phi} \\ \Theta = \hat{\Theta} \\ \mu = \hat{\mu} \end{array}} = 0$$

$$\frac{\partial}{\partial \Theta} S_c(\Phi, \Theta, \mu) \Bigg|_{\begin{array}{l} \Phi = \hat{\Phi} \\ \Theta = \hat{\Theta} \\ \mu = \hat{\mu} \end{array}} = \frac{\partial}{\partial \Theta} \sum_{t=p+1}^n a_t^2(\Phi, \Theta, \mu | \mathbf{z}) \Bigg|_{\begin{array}{l} \Phi = \hat{\Phi} \\ \Theta = \hat{\Theta} \\ \mu = \hat{\mu} \end{array}} = 0$$

$$\frac{\partial}{\partial \mu} S_c(\Phi, \Theta, \mu) \Bigg|_{\begin{array}{l} \Phi = \hat{\Phi} \\ \Theta = \hat{\Theta} \\ \mu = \hat{\mu} \end{array}} = \frac{\partial}{\partial \mu} \sum_{t=p+1}^n a_t^2(\Phi, \Theta, \mu | \mathbf{z}) \Bigg|_{\begin{array}{l} \Phi = \hat{\Phi} \\ \Theta = \hat{\Theta} \\ \mu = \hat{\mu} \end{array}} = 0$$

هذه المقدرات تسمى شرطية لأننا هنا نشترط أن القيم $a_p = a_{p-1} = \dots = a_{p+1-q} = 0$ أي مساوية

لتوقعها. (لاحظ أن التجميع في المعادلات السابقة يبدأ من القيمة $t = p + 1$).

يقدر التباين σ^2 من

$$\hat{\sigma}^2 = \frac{S_c(\hat{\Phi}, \hat{\Theta}, \hat{\mu})}{n - (p + q + 1)}$$

تقديرات المربعات الدنيا الشرطية لبعض النماذج:

AR(1) - نموذج 1

$$z_t - \mu = \phi_1(z_{t-1} - \mu) + a_t, a_t \sim N(0, \sigma^2)$$

لتبسيط الإشتقاقات سوف نستبدل μ بمقدره \bar{z}

$$z_t - \bar{z} = \phi_1(z_{t-1} - \bar{z}) + a_t, a_t \sim N(0, \sigma^2)$$

لمشاهدات معطاة $\mathbf{z} = \{z_1, z_2, \dots, z_n\}$ نكتب الأخطاء

$$a_t(\phi_1) = (z_t - \bar{z}) - \phi_1(z_{t-1} - \bar{z}), t = 2, 3, \dots, n$$

وتربع الطرفين والجمع على كل المشاهدات

$$a_t^2(\phi_1) = [(z_t - \bar{z}) - \phi_1(z_{t-1} - \bar{z})]^2, t = 2, 3, \dots, n$$

$$S_c(\phi_1) = \sum_{t=2}^n a_t^2(\phi_1) = \sum_{t=2}^n [(z_t - \bar{z}) - \phi_1(z_{t-1} - \bar{z})]^2$$

وهذه دالة للمعلم ϕ_1 فقط ، نشتق المعادلة السابقة بالنسبة للمعلم ϕ_1 وتكون النتيجة مساوية للصفر

عندما $\phi_1 = \hat{\phi}_1$ أي

$$\begin{aligned}
S_c(\phi_1) &= \sum_{t=2}^n a_t^2(\phi_1) = \sum_{t=2}^n [(z_t - \bar{z}) - \phi_1(z_{t-1} - \bar{z})]^2 \\
\frac{\partial}{\partial \phi_1} S_c(\phi_1) &= \frac{\partial}{\partial \phi_1} \sum_{t=2}^n [(z_t - \bar{z}) - \phi_1(z_{t-1} - \bar{z})]^2 \\
&= \sum_{t=2}^n -2(z_{t-1} - \bar{z})[(z_t - \bar{z}) - \phi_1(z_{t-1} - \bar{z})] \\
\frac{\partial}{\partial \phi_1} S_c(\phi_1) \Big|_{\phi_1=\hat{\phi}_1} &= \sum_{t=2}^n -2(z_{t-1} - \bar{z})[(z_t - \bar{z}) - \hat{\phi}_1(z_{t-1} - \bar{z})] = 0 \\
\therefore \sum_{t=2}^n (z_{t-1} - \bar{z})[(z_t - \bar{z}) - \hat{\phi}_1(z_{t-1} - \bar{z})] &= 0 \\
\sum_{t=2}^n (z_{t-1} - \bar{z})(z_t - \bar{z}) - \hat{\phi}_1 \sum_{t=2}^n (z_{t-1} - \bar{z})^2 &= 0
\end{aligned}$$

أي

$$\hat{\phi}_1 = \frac{\sum_{t=2}^n (z_{t-1} - \bar{z})(z_t - \bar{z})}{\sum_{t=2}^n (z_{t-1} - \bar{z})^2}$$

وهو مقدر المربعات الدنيا الشرطية للمعلم ϕ_1 .

تمرين: قارن بين هذا المقدر ومقدر العزوم للمعلم ϕ_1 .

2- نموذج MA(1)

$$z_t - \mu = a_t - \theta_1 a_{t-1}, a_t \sim N(0, \sigma^2)$$

لتبسيط الإستقادات سوف نستبدل μ بمقدره \bar{z} ونعمل على المتسلسلة المعدلة للمتوسط

فيصبح النموذج $x_t = z_t - \bar{z}$

$$x_t = a_t - \theta_1 a_{t-1}, a_t \sim N(0, \sigma^2)$$

وبكتابة المعادلة الأخيرة على الشكل

$$a_t = x_t - \theta_1 a_{t-1}$$

ولمشاهدات معطاة x_1, x_2, \dots, x_n و بوضع $a_0 = 0$ شرطياً نكتب الأخطاء

$$a_1 = x_1$$

$$a_2 = x_2 - \theta_1 a_1$$

$$a_3 = x_3 - \theta_1 a_2$$

⋮

$$a_n = x_n - \theta_1 a_{n-1}$$

وبالتالي

$$S_c(\theta_1) = \sum_{t=1}^n a_t^2$$

الدالة السابقة غير خطية في المعلم θ_1 و يمكن إيجاد قيمة θ_1 والتي تصغر $S_c(\theta_1)$ بطرق البحث العددية مثل البحث الشبكي في المجال (1,1-) أو استخدام طريقة جاوس-نيوتن والتي تتلخص في تقرير $a_t(\theta_1) = a_t(\theta^*)$ بدالة خطية للمعلم θ_1 حول قيمة أولية θ^* مثلاً أي

$$a_t(\theta_1) \approx a_t(\theta^*) + (\theta_1 - \theta^*) \frac{da_t(\theta^*)}{d\theta_1}$$

المشتقة $\frac{da_t(\theta^*)}{d\theta_1}$ يمكن حسابها تكرارياً وذلك باشتقاق طرفي المعادلة $a_t = x_t - \theta_1 a_{t-1}$ بالنسبة

للعلم θ_1 لنحصل على

$$\frac{da_t(\theta_1)}{d\theta_1} = \frac{\theta_1 da_{t-1}(\theta_1)}{d\theta_1} + a_{t-1}(\theta_1)$$

و بقيمة أولية $0 = \frac{da_0(\theta_1)}{d\theta_1}$. المعادلة

$$a_t(\theta_1) \approx a_t(\theta^*) + (\theta_1 - \theta^*) \frac{da_t(\theta^*)}{d\theta_1}$$

خطية في المعلم θ_1 وبالتالي بالامكان تصغير مجموع المربعات

$$S_c(\theta_1) = \sum_{t=1}^n a_t^2$$

تحليلياً لنحصل على مقدر جديد وأفضل للمعلم θ_1 ونكرر هذه العملية بإستبدال θ^* بالمقدر الجديد ونستمر حتى يصبح الفرق بين مقدرين تاليين صغير جداً أو النقص في مجموع المربعات صغير جداً. ممكن استخدام طريقة العزوم لإيجاد القيمة الأولية θ^* لكي نحصل على تقارب سريع. طبعاً الطريقة السابقة لا تتم يدوياً بل تحتاج إلى حاسب لذلك.

يلاحظ أن تقدير المعلم للنموذج في حالة نماذج المتوسط المتحرك او النماذج المختلطة التي تحوي على متوسط متحرك تشكل تعقيداً لأنها تحوى معالم المتوسط المتحرك بشكل غير خطى ولهذا تحتاج إلى طرق عدديّة لحلها كما شاهدنا في حالة النموذج (1) MA وهو أبسطها جمّعاً.

سوف نكتفي في مقرننا هذا على الطريقيتين السابقتين ولكن نذكر بعض الطرق الأخرى المستخدمة في تقدير معالم النموذج مثل:

- 1- طريقة الأرجحية العظمى Maximum Likelihood Method
- 2- طريقة المربعات الدنيا غير الشرطية Unconditional Least Squares Method
- 3- طرق التقدير غير الخطية Nonlinear Estimation Methods

تشخيص وإختبار النموذج : Model Checking and Diagnostics

بعد التعرف على نموذج مبدئي وتقدير معالم هذا النموذج نجري بعض التشخيصات على البوافي أو أخطاء التطبيق (انظر تعريف 4) لنرى مدى مطابقة النموذج للمتسلسلة المشاهدة ، ويفترض أن البوافي هي مقدرات لمتسلسلة الضجة البيضاء a_t والتي نفترض أنها موزعة طبيعياً بمتباين صفرى وتباين σ^2 . البوافي تعطى بالعلاقة

$$e_t = z_t - \hat{z}_t = \hat{a}_t, \quad t = 1, 2, \dots, n$$

أي ان البوافي هي القيم المشاهدة ناقص القيم المطبقة.

يقوم التشخيص والإختبارات على فحص البوافي والنظر في مدى تحقيقها لفرضيات النموذج

والتي هي:

1- متوسط صفرى

2- العشوائية

3- عدم الترابط

4- موزعة توزيع طبيعي (مستقل ومتواافق بمتباين صفرى وتباين σ^2)

أي $(a_t \sim IIDN(0, \sigma^2))$

لهذا فإننا نجري تشخيص وهو مجموعة من الإختبارات على البوافي لنري فيما إذا كانت تحقق هذه الشروط وفي هذه الحالة تعتبر النموذج المطبق مقبولاً أما إذا فشل أحد هذه الإختبارات فيجب علينا إعادة النظر وإقتراح نموذج آخر

أولاً: اختبار المتوسط:

$$H_0 : E(a_t) = 0$$

$$H_1 : E(a_t) \neq 0$$

وهو إختبار بذيلين ونستخدم فيه الإحصائية $\frac{\bar{e}}{se(\bar{e})} = u$ والتي لها توزيع طبيعي قياسي فعند

مستوى معنوية $\alpha = 0.05$ نعتبر ان $|u| > 1.96$ إذا كانت $E(a_t) = 0$ (هذا علي اعتبار ان

حجم العينة اكبر من 30 وحدة وهذا دائماً متحقق للمتسلسلات الزمنية التي ندرسها)

ثانياً: اختبار العشوائية:

نختبر عشوائية البوافي بواسطة اختبار الجري Runs test حول المتوسط و حول الصفر وهو احد الاختبارات الامثلية (يوجد كثير من الاختبارات للعشوائية يدرسها الطالب في المقرر 241 بحث ولكن نكتفي هنا بهذا الاختبار).

ثالثاً: اختبار الترابط أو الإستقلال:

يختبر ترابط أو إستقلال البوافي بواسطة اختبار الترابط الذاتي Autocorrelation test وذلك بحساب ورسم الترابطات الذاتية العينية SACF للبوافي ومقارنتها مع دالة الترابط الذاتي لمتسلسة الضجة البيضاء.

الاختبار

$$H_0 : \rho_1 = 0$$

$$H_1 : \rho_1 \neq 0$$

حيث الإحصائية $\frac{r_1}{se(r_1)}$ لها توزيع طبيعي قياسي فعند مستوى معنوية $\alpha = 0.05$ نعتبر

ان $|\rho_1| > 1.96$ إذا كانت

رابعاً: اختبار طبيعية البوافي:

نختبر في ما إذا كانت البوافي موزعة طبيعياً وذلك بعدة طرق مثل:

- 1- اختبار حسن التطابق Goodness of Fit Test ونستخدم الاختبار الامثل كولموجروف-سميرنوف Kolmogorov-Smirnov Test .
- 2- مخطط الإحتمال الطبيعي Normal Probability Plot .
- 3- مخطط الريعات-الريعات Q-Q Plot .

بعض المعايير الأخرى لاختيار نموذج المناسب:

- (1) إحصائية كيو لـ لجنق-بوكس Ljung-Box Q statistic وتختر LQ ونستخدم لاختبار الفرضية:

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

وتعطى بالعلاقة:

$$Q = n(n+2) \sum_{k=1}^K \frac{r_k^2}{n-k} \sim \chi^2(K-m)$$

حيث m عدد المعالم المقدرة في النموذج.

(2) معيار المعلومات الذاتي Automatic Information Criteria AIC وتخصر AIC وتعطى
بالعلاقة:

$$AIC(m) = n \ln \sigma_a^2 + 2m$$

حيث m عدد المعالم المقدرة في النموذج ونختار النموذج الذي يعطي

أمثلة وحالات دراسة : Examples and Case Studies

1- البيانات التالية لمتسلسلة زمنية مشاهدة

$z(t)$

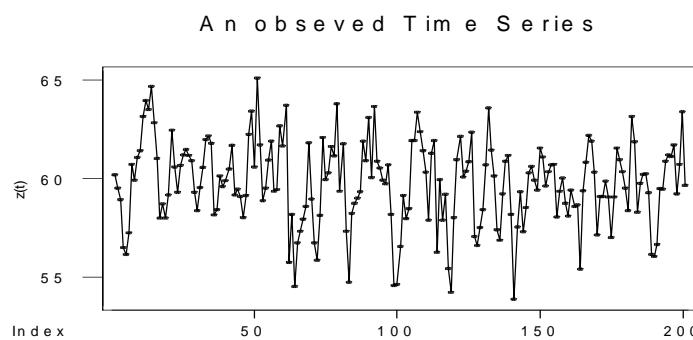
60.1815	59.5257	58.9275	56.4828	56.1346	57.2318	60.7196	59.9315
61.0640	61.4230	63.1547	63.9622	63.5049	64.6886	62.8556	61.0344
58.0059	58.7108	57.9813	59.1721	62.4654	60.5820	59.3191	60.6643
61.2223	61.4761	61.1856	60.9225	59.3054	58.3755	59.5353	60.5777
61.9753	62.1789	61.8108	58.1483	58.4174	60.1325	59.6004	59.9086
60.4833	61.7008	59.1609	59.4554	59.0903	58.0151	59.1455	62.2658
63.4411	60.5918	65.1325	61.7122	58.8802	59.5333	60.9492	61.9013
59.3478	59.4444	62.6899	61.6708	63.7261	55.7339	58.1690	54.5045
56.7241	57.3334	57.9363	58.5870	61.8370	58.9585	56.7437	55.8451
58.1281	62.1017	59.9443	60.2990	61.6337	61.1520	63.8189	59.3572
61.7840	57.3292	54.7163	58.2273	58.7564	59.0087	59.3402	61.8956
60.9021	63.1070	60.0538	63.6776	60.8942	60.5289	59.9246	59.7252
60.7001	58.1895	54.5550	54.6083	56.5413	59.1567	57.9624	58.4651
61.9462	61.9205	63.3933	62.3827	61.4310	60.3373	57.8803	61.2797
61.9448	56.2599	59.9569	57.8763	59.2086	55.4219	54.2185	58.0143
60.9805	62.1362	60.0855	60.3843	60.8605	62.3728	57.0642	56.6085
57.5151	58.4221	60.6919	63.5907	61.4451	60.1458	57.3940	56.8697
59.2145	60.8962	61.1852	58.1711	53.8560	57.5307	59.3236	57.2961
58.5278	60.3030	60.6201	59.9346	59.4119	61.5614	61.1107	59.6266
60.3550	60.7021	60.7227	58.0423	59.3488	60.0377	58.7336	58.1105
59.4242	58.5790	58.6501	55.4010	59.3839	60.8256	62.1957	61.9152
60.3319	57.1459	59.0970	59.0997	59.8597	59.0780	56.9972	59.0778

61.5555 60.9815 60.3563 59.5097 58.3583 63.1777 61.8685 58.2759
 59.7755 60.2052 60.2513 59.2927 56.1494 56.0309 56.6666 59.5015
 59.4755 60.9013 61.2179 61.1168 61.7218 59.2298 60.7356 63.4124

أولاً نرسم المتسلسلة في مخطط زمني Time Plot بإستخدام الحزمة الإحصائية MINITAB كالتالي:

```

MTB > TSPlot 'z(t)';
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect;
SUBC> Title "An observed Time Series".
  
```

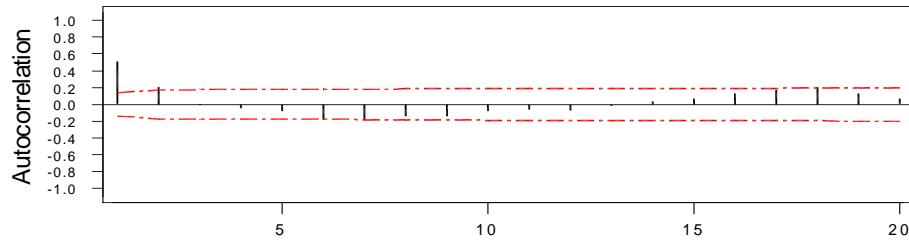


ثانياً نحسب ونرسم الترابط الذاتي العيني بإستخدام الأمر

```

MTB > %ACF 'z(t)';
SUBC> MAXLAG 20;
SUBC> TITLE"SACF of observed Time Series".
Executing from file: H:\MTBWIN\MACROS\ACF.MAC
  
```

SACF of observed Time Series



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.51	7.19	52.48	8	-0.14	-1.50	81.76	15	0.07	0.68	91.23
2	0.20	2.32	60.78	9	-0.14	-1.52	86.14	16	0.13	1.33	94.86
3	-0.00	-0.01	60.78	10	-0.09	-0.90	87.73	17	0.17	1.75	101.33
4	-0.05	-0.59	61.34	11	-0.07	-0.71	88.73	18	0.20	2.06	110.63
5	-0.08	-0.95	62.82	12	-0.08	-0.79	89.97	19	0.12	1.21	113.98
6	-0.18	-2.05	69.92	13	-0.02	-0.21	90.05	20	0.06	0.61	114.86
7	-0.19	-2.09	77.58	14	0.03	0.32	90.27				

ثالثاً نحسب ونرسم الترابط الذاتي الجزئي العيني باستخدام الأمر

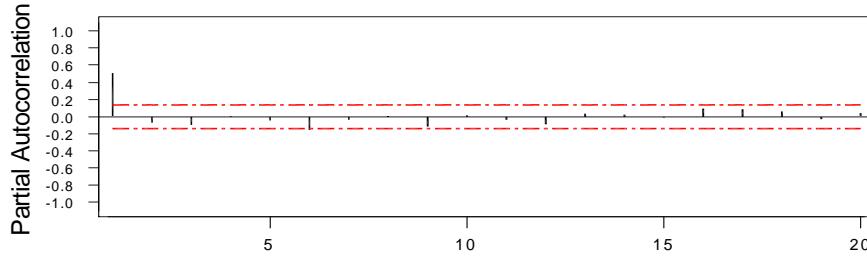
```
MTB > %PACF 'z(t)';

SUBC> MAXLAG 20;

SUBC> TITLE"SPACF of obseved Time Series".

Executing from file: H:\MTBWIN\MACROS\PACF.MAC
```

SPACF of obseved Time Series



Lag	PAC	T	Lag	PAC	T	Lag	PAC	T
1	0.51	7.19	8	-0.01	-0.12	15	-0.02	-0.23
2	-0.08	-1.07	9	-0.12	-1.63	16	0.09	1.28
3	-0.10	-1.38	10	0.01	0.16	17	0.08	1.20
4	0.00	0.04	11	-0.04	-0.60	18	0.06	0.86
5	-0.05	-0.73	12	-0.09	-1.34	19	-0.03	-0.45
6	-0.16	-2.34	13	0.03	0.39	20	0.04	0.52
7	-0.04	-0.50	14	0.02	0.32			

من أنماط الترابط الذاتي و الترابط الذاتي الجزئي العيني نلاحظ ان المتسلسلة تتبع نموذج AR(1) ولهذا نطبق النموذج المقترن على المشاهدات باستخدام الأمر

```
MTB > Name c7 = 'RESI1'

MTB > ARIMA 1 0 0 'z(t)' 'RESI1';
```

```
SUBC> Constant;
SUBC> Forecast 5 c4 c5 c6;
SUBC> GACF;
SUBC> GPACF;
SUBC> GHistogram;
SUBC> GNormalplot.
```

ARIMA Model

ARIMA model for $z(t)$

Estimates at each iteration

Iteration	SSE	Parameters	
0	839.667	0.100	53.870
1	746.819	0.250	44.876
2	695.840	0.400	35.883
3	685.086	0.502	29.769
4	685.054	0.507	29.458
5	685.054	0.507	29.443

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.5073	0.0611	8.30
Constant	29.4429	0.1309	224.98
Mean	59.7571	0.2656	

Number of observations: 201

Residuals: SS = 685.020 (backforecasts excluded)
MS = 3.442 DF = 199

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	10.8 (DF=11)	27.6 (DF=23)	35.9 (DF=35)
	45.0 (DF=47)		

Forecasts from period 201

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
202	59.7079	56.0707	63.3451
203	59.7322	55.6537	63.8106
204	59.7445	55.5600	63.9290
205	59.7507	55.5394	63.9620
206	59.7539	55.5357	63.9721

ونستنتج التالي:

1- النموذج المقترن هو

$$z_t = 59.76 + 0.51(z_{t-1} - 59.76) + a_t, \quad a_t \sim WN(0, 3.44)$$

2- المعالم المقدرة وإنحرافها المعياري و قيمة t لها هي:

$$\hat{\phi}_1 = 0.51, \quad s.e.(\hat{\phi}_1) = 0.061, \quad t = 8.3$$

$$\hat{\mu} = 59.76, \quad s.e.(\hat{\mu}) = 0.66$$

$$\hat{\delta} = 29.44, \quad s.e.(\hat{\delta}) = 0.131, \quad t = 224.98$$

$$\hat{\sigma}^2 = 3.44, \quad \text{with } d.f. = 199$$

رابعاً نفحص البوافي:

1- اختبار متوسط البوافي

```
MTB > ZTest 0.0 1.855 'RESI1';
SUBC> Alternative 0;
SUBC> GHistogram;
SUBC> GDotplot;
SUBC> GBoxplot.
```

Z-Test

Test of mu = 0.000 vs mu not = 0.000

The assumed sigma = 1.85

Variable	N	Mean	StDev	SE Mean	Z	P
RESI1	201	-0.002	1.851	0.131	-0.01	0.99

لأن رفض الفرضية الصفرية بأن المتوسط يساوي الصفر

2- اختبار عشوائية البوافي

MTB > Runs 0 'RESI1'.

Runs Test

RESI1

K = 0.0000

The observed number of runs = 94

The expected number of runs = 101.0796

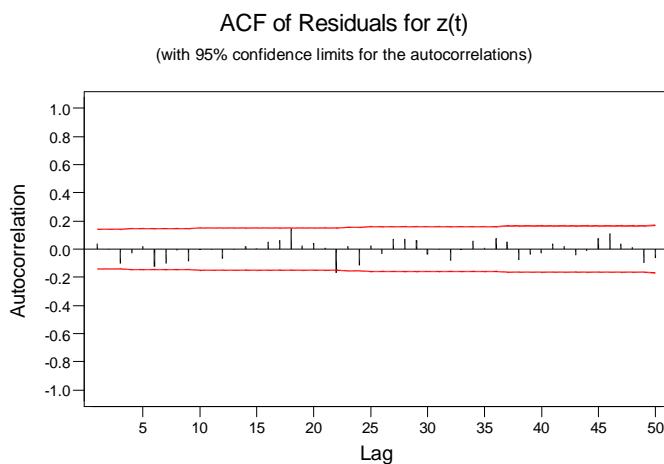
107 Observations above K 94 below

The test is significant at 0.3149

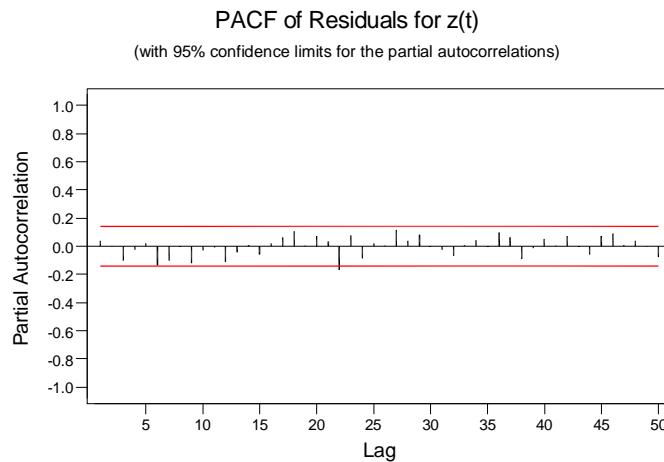
Cannot reject at alpha = 0.05

لأن رفض الفرضية الصفرية بأن الباقي عشوائية

3- الترابط الذاتي للباقي



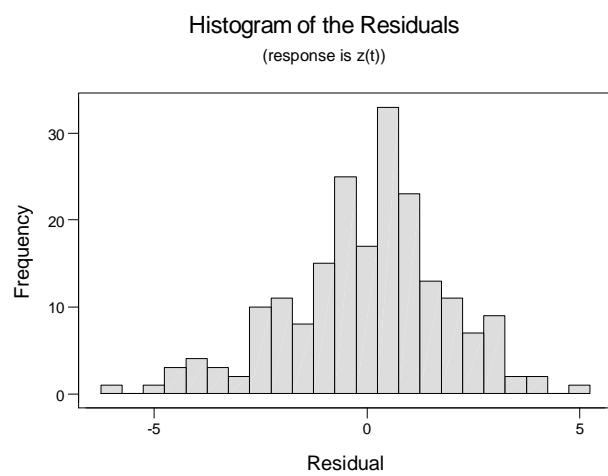
4- الترابط الذاتي الجزئي للباقي



نلاحظ ان أنماط الترابط الذاتي والترابط الذاتي الجزئي تتبع أنماط متسلسلة الضجة البيضاء

5- اختبار طبيعة الباقي :

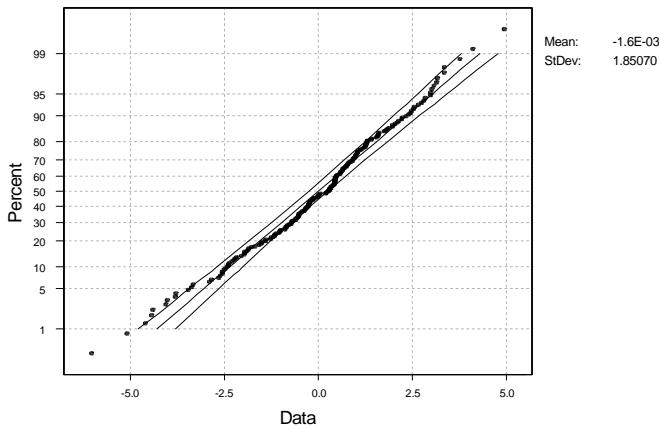
ا- رسم المضلع التكراري للباقي



نلاحظ أنه متناظر وله شكل التوزيع الطبيعي تقريبا. وهذا لا يكفي بل يجب ان ننظر الى:

ب- رسم الاحتمال الطبيعي

Normal Probability Plot for RESI1

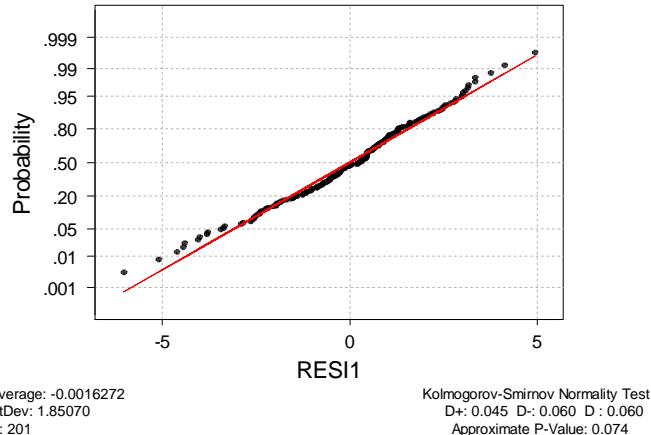


واضح من الرسم أن الباقي طبيعيه وللتاكد نقوم:

ج- بإختبار K-S Test لطبيعة الباقي

```
MTB > %NormPlot 'RESI1';
SUBC>   Kstest;
SUBC>   Title "Normal Test for Residuals".
Executing from file: H:\MTBWIN\MACROS\NormPlot.MAC
```

Normal Test for Residuals



ونلاحظ التالي:

الإختبار هو

$$H_0 : \text{Residuals} \sim N(0, 3.44)$$

$$H_1 : \text{Residuals} \not\sim N(0, 3.44)$$

اختبار كولموجروف-سميرنوف اعطى

$$D^+ = 0.045, \quad D^- = 0.06, \quad D = 0.06$$

الـ P-Value لـ اختبار هي 0.074 وهي أكبر من $\alpha=0.05$ أي اننا لا نرفض الفرضية الصفرية.

توليد تنبؤات:

استخدمنا النموذج للتنبؤ عن 5 قيم مستقبلية

Forecasts from period 201

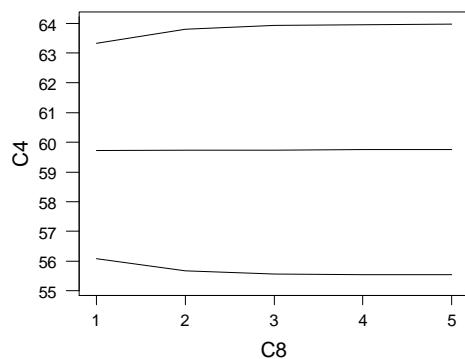
95 Percent Limits

Period	Forecast	Lower	Upper	Actual
202	59.7079	56.0707	63.3451	
203	59.7322	55.6537	63.8106	
204	59.7445	55.5600	63.9290	
205	59.7507	55.5394	63.9620	
206	59.7539	55.5357	63.9721	

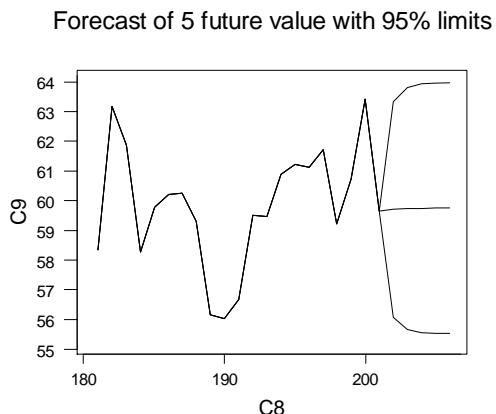
ونرسمها بالأمر التالي

```
Plot C4*C8 C5*C8 C6*C8;
SUBC>   Connect;
SUBC>   Type 1;
SUBC>   Color 1;
SUBC>   Size 1;
SUBC>   Title "Forecast of 5 future value with 95%
limits";
SUBC>   Overlay.
```

Forecast of 5 future value with 95% limits



والرسم التالي يعطي الجزء الأخير من المتسلسلة مع التنبؤات وفترات التنبؤ.



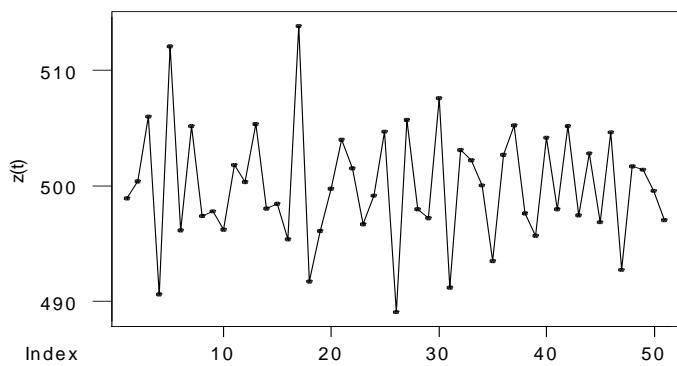
2- البيانات التالية لمتسلسلة زمنية مشاهدة

$z(t)$

499.148	496.650	511.026	488.539	498.440	507.382	496.208	494.948
503.975	501.649	489.348	506.040	496.678	502.233	498.429	503.170
498.758	502.969	498.229	501.605	493.371	505.884	496.227	496.806
493.057	506.459	502.545	497.785	506.329	496.665	491.923	504.340
499.890	494.559	503.107	502.891	498.598	500.074	499.260	496.372
507.416	500.508	496.830	491.981	516.373	492.286	500.356	503.506
498.090	498.319	507.020	493.161	499.217	508.489	494.033	496.062
504.877	498.304	495.355	505.581	495.000	504.965	497.393	501.521
494.918	501.527	504.712	501.064	492.352	500.664	495.431	507.886
499.173	494.833	504.072	497.883	495.423	507.072	496.285	506.345
496.765	504.129	495.737	500.744	505.577	485.991	507.673	507.735
482.567	507.594	503.580	493.866	501.819	500.921	503.415	497.295
500.989	498.294	501.700	495.868	501.175	503.852	499.783	497.642
501.331	496.932	507.582	494.885	504.666	498.380	496.181	510.287
489.314	504.394	501.928	494.814	509.407	498.060	497.133	496.029
502.720	499.982	503.325	495.954	504.408	500.199	494.878	503.134
502.489	498.640	500.484	493.552	501.417	504.785	497.943	501.634
495.691	502.173	502.066	497.130	492.318	505.517	499.299	499.611

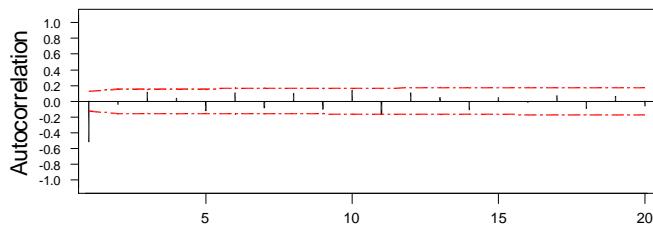
496.252 504.346 501.082 497.626 496.757 505.475 498.787 500.388
 499.279 504.913 493.843 506.259 498.403 497.462 499.467 505.987
 498.169 500.712 498.571 504.085 491.707 504.817 502.933 493.858
 497.015 504.204 501.703 490.683 505.429 504.336 495.430 494.857
 503.195 506.403 498.599 487.344 514.220 490.887 511.741 497.861
 500.252 502.721 500.256 494.614 502.414 503.465 501.999 493.017
 498.158 503.746 497.643 507.438 491.418 506.649 496.078 498.931
 500.409 506.001 490.619 512.122 496.150 505.218 497.413 497.794
 496.225 501.827 500.324 505.367 498.016 498.477 495.353 513.900
 491.726 496.063 499.779 504.012 501.542 496.680 499.134 504.717
 489.032 505.709 497.956 497.231 507.590 491.202 503.130 502.209
 500.024 493.502 502.681 505.234 497.647 495.699 504.174 497.992
 505.194 497.421 502.823 496.877 504.640 492.716 501.701 501.387
 499.574 497.048

أولاً : سوف نرسم فقط 50 مشاهدة من هذه المتسلسلة



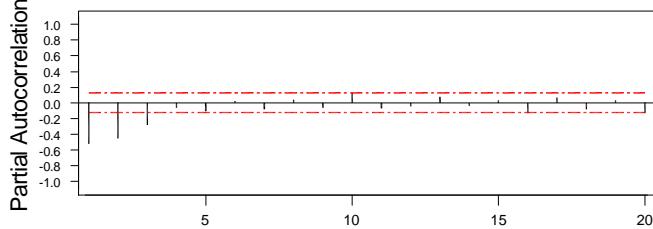
ثانياً: نحسب ونرسم الترابط الذاتي العيني:

Autocorrelation Function for $z(t)$



ثالثاً: نحسب ونرسم الترابط الذاتي الجزئي العيني:

Partial Autocorrelation Function for $z(t)$



من الأنماط المشاهدة نلاحظ ان المتسلسلة قد تتبع نموذج $MA(1)$ وبتطبيق هذا النموذج نجد

```
MTB > Name c7 = 'RESI1'
MTB > ARIMA 0 0 1 'z(t)' 'RESI1';
SUBC> Constant;
SUBC> Forecast 5 c4 c5 c6;
SUBC> GACF;
SUBC> GPACF;
SUBC> GHistogram;
SUBC> GNormalplot.
```

ARIMA Model

ARIMA model for $z(t)$

Estimates at each iteration

Iteration	SSE	Parameters	
0	6081.19	0.100	500.046
1	5265.34	0.250	500.004
2	4615.22	0.400	499.980
3	4109.70	0.550	499.967
4	3766.60	0.700	499.960
5	3727.32	0.841	499.959
6	3687.70	0.797	499.963
7	3687.08	0.790	499.962
8	3687.07	0.791	499.962
9	3687.07	0.790	499.962

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	0.7905	0.0386	20.50
Constant	499.962	0.051	9708.40
Mean	499.962	0.051	

Number of observations: 250

Residuals: SS = 3684.13 (backforecasts excluded)
MS = 14.86 DF = 248

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	26.7 (DF=11)	35.9 (DF=23)	63.1 (DF=35)
	82.8 (DF=47)		

Forecasts from period 250

Period	Forecast	95 Percent Limits		Actual
		Lower	Upper	
251	502.256	494.700	509.812	
252	499.962	490.330	509.593	
253	499.962	490.330	509.593	
254	499.962	490.330	509.593	

255 499.962 490.330 509.593

ونستنتج التالي:

1- النموذج المقترن هو

$$z_t = 499.962 + a_t - 0.7905a_{t-1}, \quad a_t \sim WN(0, 14.86)$$

2- المعالم المقدرة وإنحرافها المعياري و قيمة t لها هي:

$$\hat{\theta}_1 = 0.7905, \quad s.e.(\hat{\theta}_1) = 0.0386, \quad t = 20.50$$

$$\hat{\mu} = \hat{\delta} = 499.962, \quad s.e.(\hat{\delta}) = 0.051, \quad t = 9708.40$$

$$\hat{\sigma}^2 = 14.86, \quad \text{with } d.f. = 248$$

رابعاً نفحص الباقي:

1- اختبار متوسط الباقي

```
MTB > ZTest 0.0 3.847 'RESI1';
SUBC> Alternative 0.
```

Z-Test

```
Test of mu = 0.000 vs mu not = 0.000
The assumed sigma = 3.85
```

Variable	N	Mean	StDev	SE Mean	Z	P
RESI1	250	-0.007	3.847	0.243	-0.03	0.98

لأن رفض الفرضية الصفرية بأن المتوسط يساوي الصفر

2- اختبار عشوائية الباقي

```
MTB > Runs 0 'RESI1'.
```

Runs Test

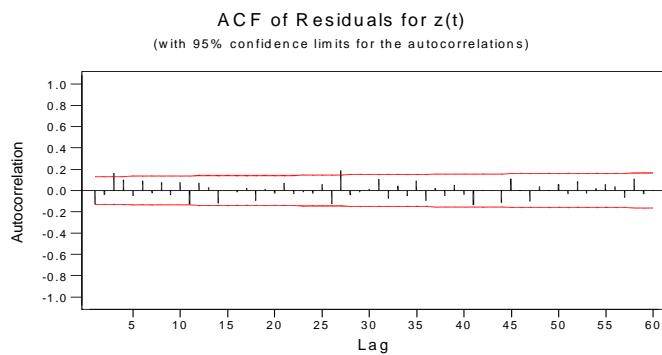
RESI1

K = 0.0000

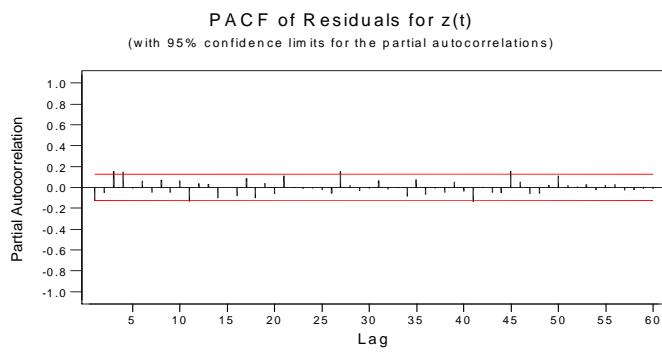
The observed number of runs = 134
 The expected number of runs = 125.9920
 126 Observations above K 124 below
 The test is significant at 0.3103
 Cannot reject at alpha = 0.05

لأنه لا يرفض الفرضية الصفرية بأن البوافي عشوائية

3- الترابط الذاتي للبوافي



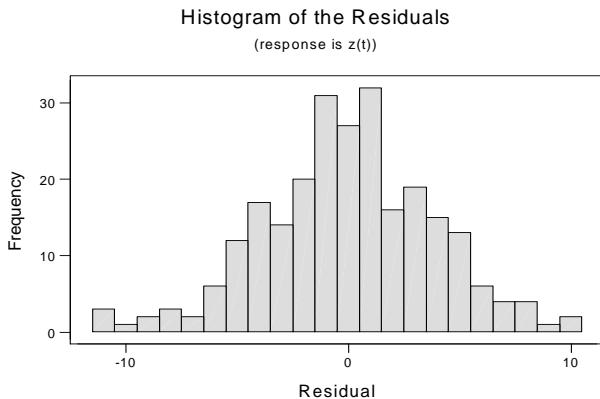
4- الترابط الذاتي الجزئي للبوافي



نلاحظ أن أنماط الترابط الذاتي والترابط الذاتي الجزئي تتبع أنماط متسلسلة الضجة البيضاء

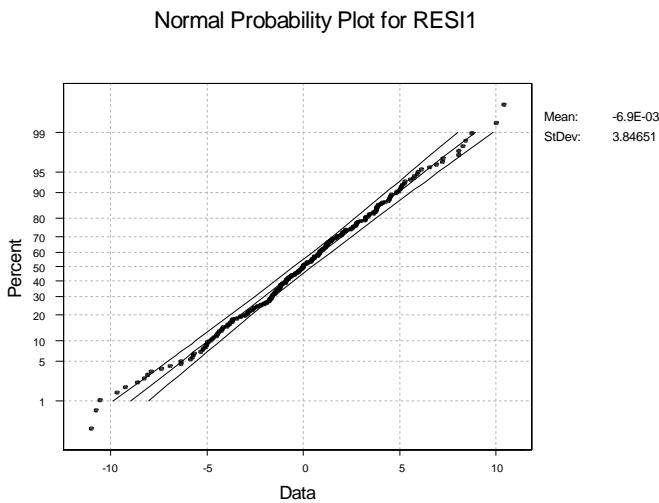
5- اختبار طبيعة البوافي :

ا- نرسم المضلع التكراري للبوافي



نلاحظ أنه متناظر وله شكل التوزيع الطبيعي تقريباً وهذا لا يكفي بل يجب أن ننظر إلى:

ب- رسم الاحتمال الطبيعي



واضح من الرسم أن الباقي طبيعي وللتتأكد نقوم:

ج- باختبار K-S Test لطبيعة الباقي

```
MTB > %Qqplot 'RESI1';
SUBC>   Conf 95;
SUBC>   Ci.
Executing from file: H:\MTBWIN\MACROS\Qqplot.MAC
```

Distribution Function Analysis

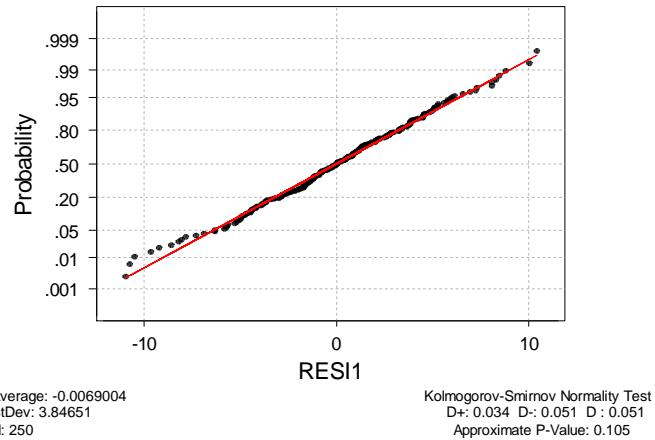
Normal Dist. Parameter Estimates

```

Data      : RESI1
Mean:     -6.9E-03
StDev:    3.84651
MTB > %NormPlot 'RESI1';
SUBC> Kstest.
Executing from file: H:\MTBWIN\MACROS\NormPlot.MAC

```

Normal Probability Plot



اختبار كولموجروف-سميرنوف اعطي

$$D^+ = 0.034, \quad D^- = 0.051, \quad D = 0.051$$

الـ P-Value لـ D+ هي 0.105 وهي أكبر من $\alpha = 0.05$ أي اننا لا نرفض الفرضية ان الباقي موزعة طبيعيا.

توليد تنبؤات:

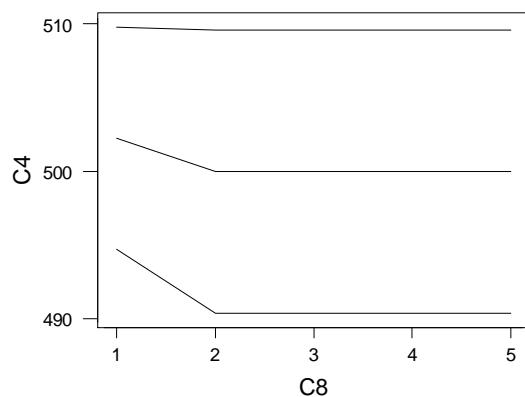
استخدمنا النموذج للتنبؤ عن 5 قيم مستقبلية

Forecasts from period 250

Period	Forecast	95 Percent Limits		Actual
		Lower	Upper	
251	502.256	494.700	509.812	
252	499.962	490.330	509.593	
253	499.962	490.330	509.593	
254	499.962	490.330	509.593	
255	499.962	490.330	509.593	

والرسم التالي يعطي التنبؤات مع فترات 95% تنبؤ

Forecast of 5 future values with 95% limits



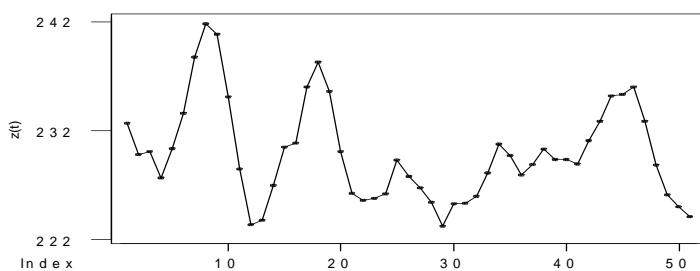
3- البيانات التالية لمتسلسلة زمنية مشاهدة

$z(t)$

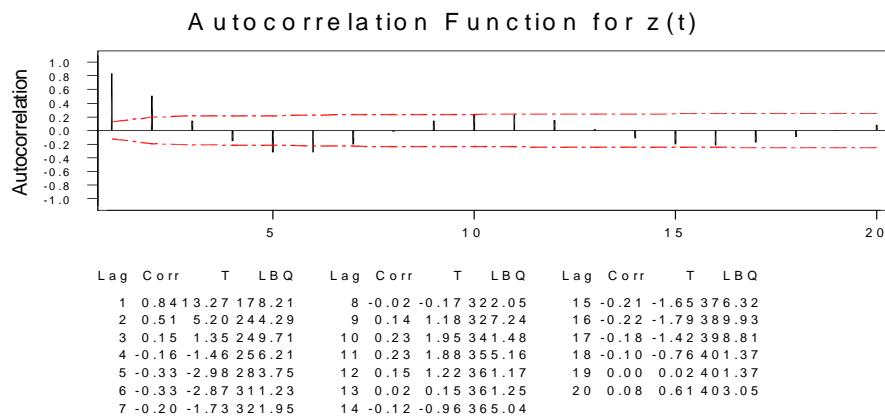
229.574	227.346	230.260	229.903	226.778	226.641	226.760	224.678
224.077	225.772	223.390	222.482	221.562	222.515	224.063	227.500
230.713	234.323	236.033	236.488	232.308	229.136	225.663	221.632
215.405	213.619	217.433	223.408	232.653	239.577	238.463	234.178
228.758	221.484	217.123	218.067	222.156	227.621	232.209	233.005
234.678	236.419	235.744	229.359	229.331	229.564	230.102	232.432
234.155	233.918	235.767	234.668	231.319	231.633	231.121	228.189
227.075	226.765	224.927	225.721	225.734	227.982	229.848	231.718
230.421	228.200	228.472	230.888	230.122	227.859	223.115	222.468
224.663	225.799	228.227	229.851	228.225	228.618	228.418	231.163
233.335	236.399	236.659	235.024	235.122	228.989	224.483	226.479
223.571	222.523	225.196	226.724	228.198	229.792	232.738	234.207
234.561	232.976	231.266	227.812	224.928	225.447	228.163	230.455
232.473	232.067	233.891	233.841	234.707	234.825	232.232	233.640
231.653	230.148	230.327	228.922	231.665	235.224	236.562	233.725
230.146	227.077	227.032	227.089	229.575	233.044	233.427	233.089
233.444	233.256	232.820	228.954	224.747	224.207	225.484	228.655
230.076	231.062	232.461	232.152	226.865	222.819	220.782	220.958
221.171	224.050	228.727	232.135	232.027	232.315	232.030	231.531
230.582	232.032	231.411	232.684	233.852	233.127	230.938	231.363

232.344 233.622 233.799 235.038 232.160 229.733 229.757 228.285
 224.880 223.599 225.273 223.994 224.258 227.948 230.636 229.320
 227.449 229.100 231.898 228.203 228.606 227.046 230.713 235.587
 239.660 242.860 243.963 239.883 234.243 230.662 230.360 228.729
 225.860 225.123 225.070 229.486 231.265 234.107 234.625 232.700
 229.792 230.082 227.643 230.342 233.628 238.762 241.821 240.884
 235.112 228.468 223.381 223.795 226.994 230.499 230.865 236.017
 238.292 235.623 230.088 226.271 225.616 225.771 226.222 229.321
 227.805 226.745 225.447 223.250 225.291 225.358 225.985 228.141
 230.794 229.727 227.934 228.920 230.296 229.369 229.352 228.958
 231.092 232.891 235.210 235.339 236.029 232.881 228.837 226.114
 225.020 224.096

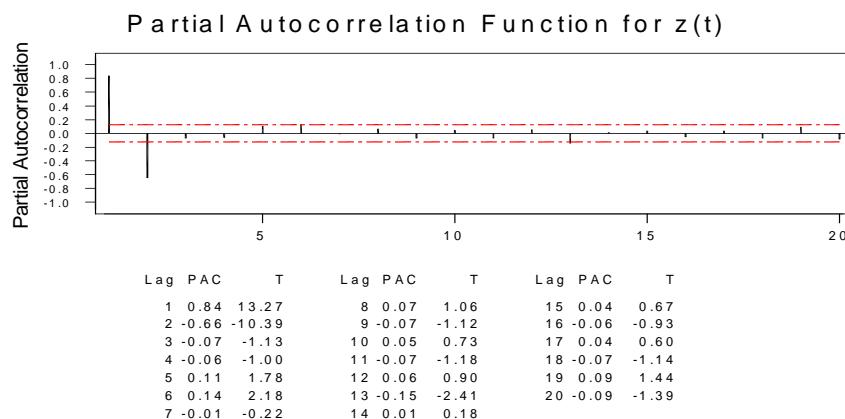
اولاً نرسم المتسلسلة في مخطط زمني Time Plot بإستخدام الحزمة الإحصائية MINITAB
 كالتالي: (50 مشاهدة فقط)



ثانياً نحسب ونرسم الترابط الذاتي العيني



ثالثاً نحسب ونرسم الترابط الذاتي الجزئي العيني



من أنماط الترابط الذاتي و الترابط الذاتي الجزئي العيني نلاحظ ان المتسلسلة تتبع نموذج AR(2) ولهذا نطبق النموذج المقترن على المشاهدات

```

MTB > Name c7 = 'RESI1'
MTB > ARIMA 2 0 0 'z(t)' 'RESI1';
SUBC> Constant;
SUBC> Forecast 10 c4 c5 c6;
SUBC> GACF;
SUBC> GPACF;
SUBC> GHistogram;
SUBC> GNormalplot.
```

ARIMA Model

ARIMA model for $z(t)$

Estimates at each iteration

Iteration	SSE	Parameters		
0	4257.23	0.100	0.100	183.784
1	3528.31	0.250	0.012	169.535
2	2889.23	0.400	-0.076	155.360
3	2338.97	0.550	-0.165	141.201
4	1877.39	0.700	-0.253	127.051
5	1504.46	0.850	-0.342	112.913
6	1220.13	1.000	-0.430	98.789
7	1024.34	1.150	-0.519	84.690
8	916.97	1.300	-0.608	70.623
9	894.38	1.402	-0.668	61.154
10	894.31	1.408	-0.672	60.670
11	894.31	1.408	-0.672	60.646

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	1.4079	0.0473	29.78
AR 2	-0.6720	0.0474	-14.19
Constant	60.6458	0.1203	504.11
Mean	229.638	0.456	

Number of observations: 250

Residuals: SS = 893.567 (backforecasts excluded)
MS = 3.618 DF = 247

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	17.5(DF=10)	27.2(DF=22)	49.7(DF=34)	67.7(DF=46)

Forecasts from period 250

95 Percent Limits

Period	Forecast	Lower	Upper	Actual
251	224.939	221.211	228.668	
252	226.747	220.308	233.186	

253	228.725	220.642	236.808
254	230.296	221.546	239.045
255	231.177	222.311	240.044
256	231.363	222.494	240.233
257	231.033	222.070	239.996
258	230.442	221.327	239.558
259	229.833	220.600	239.067
260	229.372	220.090	238.655

ونستنتج التالي:

1- النموذج المقترن هو

$$z_t = 60.6458 + 1.4079 z_{t-1} - 0.672 z_{t-2} + a_t, \quad a_t \sim WN(0, 3.618)$$

2- المعالم المقدرة وإنحرافها المعياري و قيمة t لها هي:

$$\hat{\phi}_1 = 1.4079, \quad s.e.(\hat{\phi}_1) = 0.0473, \quad t = 29.78$$

$$\hat{\phi}_2 = -0.672, \quad s.e.(\hat{\phi}_2) = 0.0474, \quad t = -14.19$$

$$\hat{\mu} = 229.638, \quad s.e.(\hat{\mu}) = 0.456$$

$$\hat{\delta} = 60.6458, \quad s.e.(\hat{\delta}) = 0.1203, \quad t = 504.11$$

$$\hat{\sigma}^2 = 3.618, \quad \text{with } d.f. = 247$$

رابعاً نفحص الباقي:

1- اختبار متوسط الباقي

```
MTB > ZTest 0.0 3.618 'RESI1';
SUBC> Alternative 0.
```

Z-Test

```
Test of mu = 0.000 vs mu not = 0.000
The assumed sigma = 3.62
```

Variable	N	Mean	StDev	SE Mean	Z	P
RESI1	250	-0.005	1.894	0.229	-0.02	0.98

لأن رفض الفرضية الصفرية بأن المتوسط يساوي الصفر

2- اختبار عشوائية البوافي

MTB > Runs 0 'RESI1'.

Runs Test

RESI1

K = 0.0000

The observed number of runs = 125

The expected number of runs = 125.8720

129 Observations above K 121 below

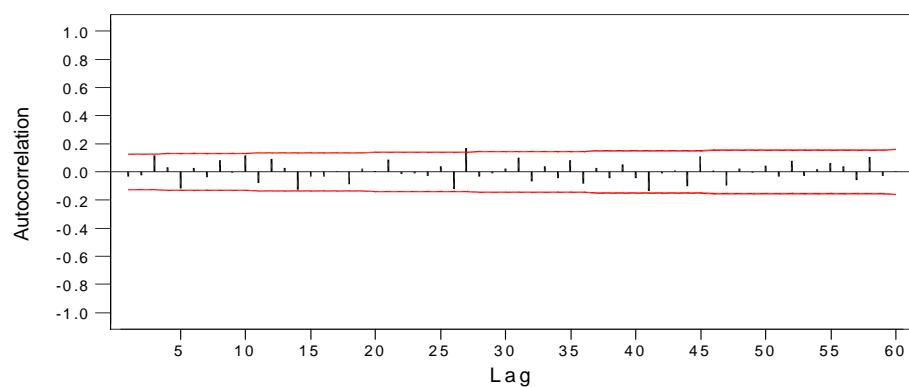
The test is significant at 0.9119

Cannot reject at alpha = 0.05

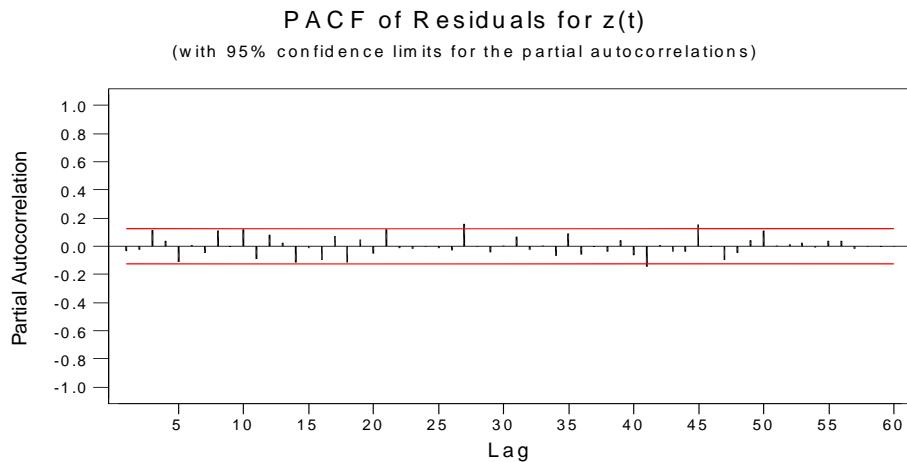
لأنرفض الفرضية الصفرية بأن البوافي عشوائية

3- الترابط الذاتي للبوافي

ACF of Residuals for z(t)
(with 95% confidence limits for the autocorrelations)



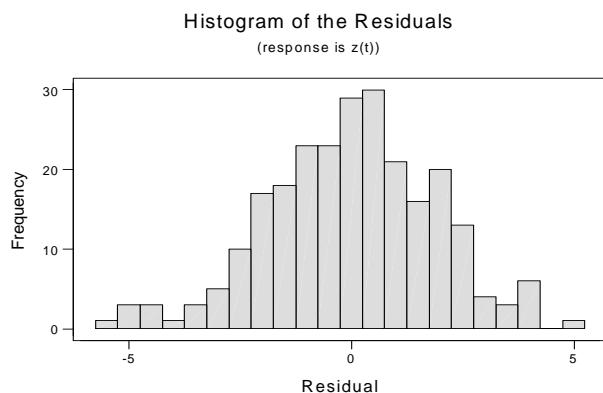
4- الترابط الذاتي الجزئي للبوافي



نلاحظ ان أنماط الترابط الذاتي والترابط الذاتي الجزئي تتبع أنماط متسلسلة الضجة البيضاء

5- اختبار طبيعة الباقي :

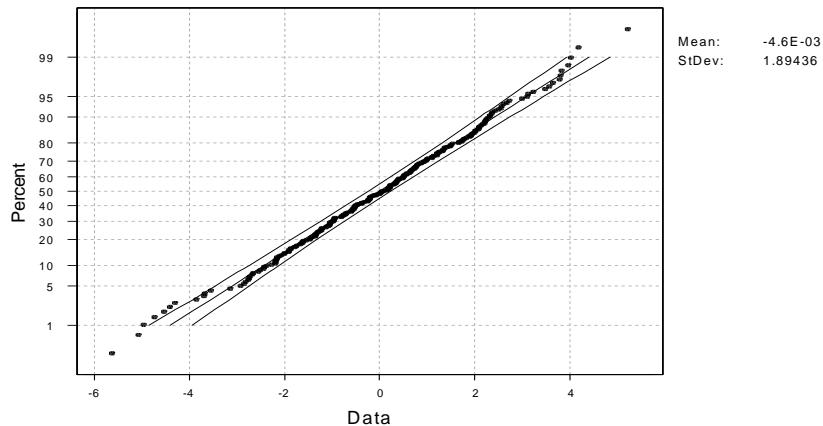
ا- نرسم المضلع التكراري للباقي



نلاحظ أنه متناظر وله شكل التوزيع الطبيعي تقريبا. وهذا لا يكفي بل يجب ان ننظر الى:

ب- رسم الاحتمال الطبيعي

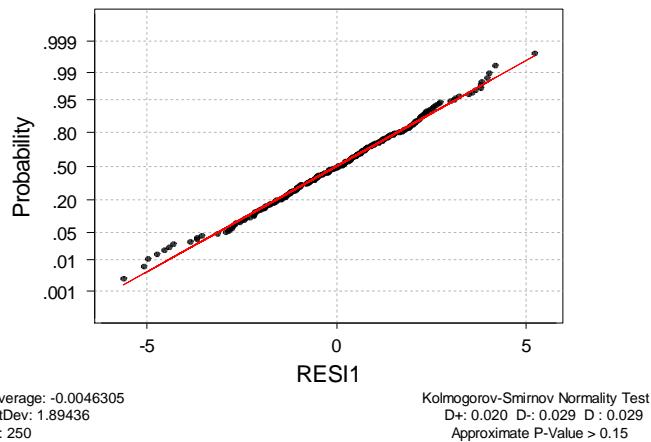
Normal Probability Plot for RESI1



واضح من الرسم أن الباقي طبيعيه وللتاكد نقوم:

ج- بإختبار K-S Test لطبيعة الباقي

Normal Probability Plot



إختبار كولموجروف-سميرنوف اعطى الـ P-Value هي 0.15 وهي أكبر من $\alpha = 0.05$ أي اننا لا نرفض فرضية طبيعة الباقي.

توليد تنبؤات:

استخدمنا النموذج للتنبؤ عن 10 قيم مستقبلية

Forecasts from period 250

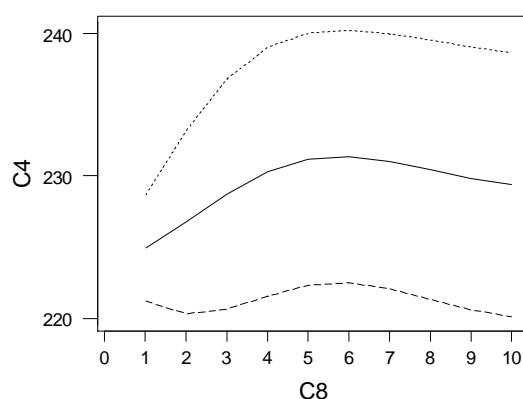
95 Percent Limits

Period	Forecast	Lower	Upper	Actual
251	224.939	221.211	228.668	
252	226.747	220.308	233.186	

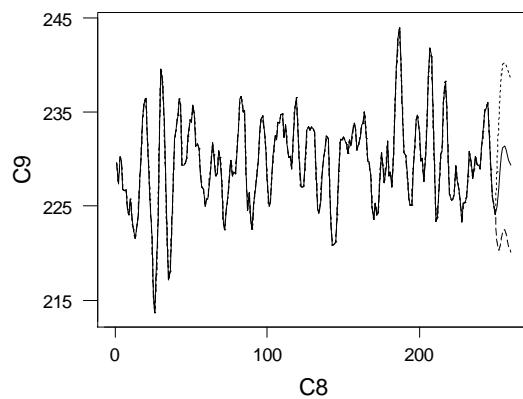
253	228.725	220.642	236.808
254	230.296	221.546	239.045
255	231.177	222.311	240.044
256	231.363	222.494	240.233
257	231.033	222.070	239.996
258	230.442	221.327	239.558
259	229.833	220.600	239.067
260	229.372	220.090	238.655

والرسم التالي يعطي التنبؤات و 95% فترات تنبؤ

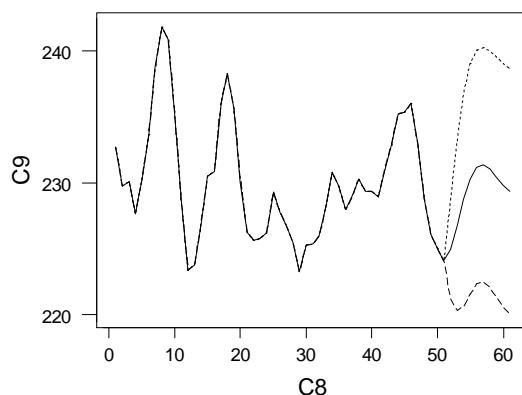
Forecast of 10 future values with 95% limits



Forecast of 10 future values with 95% limits



Forecast of 10 future values with 95% limits



الشكل الأول يبين المتسلسلة الزمنية بكمالها مع التنبؤات والشكل الثاني للخمسين قيمة الأخيرة مع التنبؤات لتوضيح شكل دالة التنبؤ.

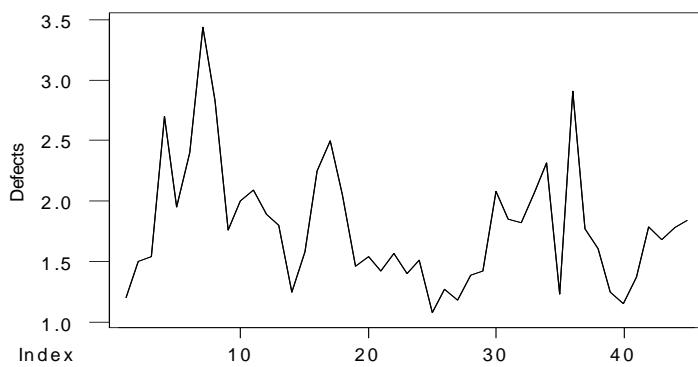
حالة دراسة:

المتسلسلة التالية المتوسط اليومي لعدد التلفزيونات المعيبة في خط إنتاج مصنع ما (اقرأ سطراً بسطراً)

Defects

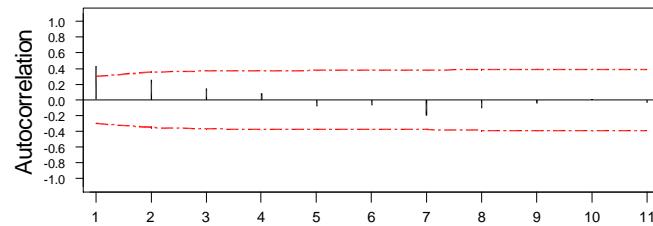
1.20	1.50	1.54	2.70	1.95	2.40	3.44	2.83	1.76	2.00
2.09	1.89	1.80	1.25	1.58	2.25	2.50	2.05	1.46	1.54
1.42	1.57	1.40	1.51	1.08	1.27	1.18	1.39	1.42	2.08
1.85	1.82	2.07	2.32	1.23	2.91	1.77	1.61	1.25	1.15
1.37	1.79	1.68	1.78	1.84					

المخطط الزمني للمتسلسلة



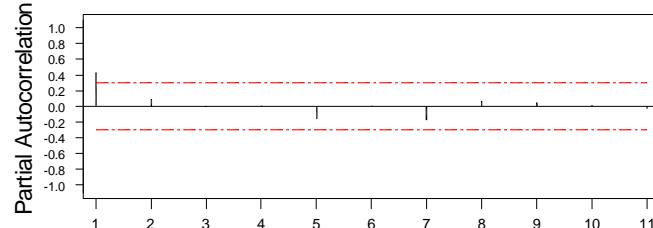
الترابط الذاتي والذاتي الجزئي

Autocorrelation Function for Defects



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.43	2.88	8.84	8	-0.11	-0.57	17.25
2	0.26	1.49	12.18	9	-0.05	-0.27	17.41
3	0.14	0.77	13.18	10	-0.01	-0.04	17.41
4	0.08	0.43	13.50	11	-0.04	-0.19	17.50
5	-0.09	-0.46	13.89				
6	-0.07	-0.39	14.18				
7	-0.21	-1.10	16.57				

Partial Autocorrelation Function for Defects



Lag	PAC	T	Lag	PAC	T
1	0.43	2.88	8	0.07	0.44
2	0.09	0.63	9	0.05	0.35
3	-0.00	-0.01	10	0.01	0.09
4	0.00	0.00	11	-0.03	-0.23
5	-0.16	-1.07			
6	0.00	0.02			
7	-0.18	-1.19			

لاختيار النموذج المناسب سوف نستخدم معيار المعلومات الذاتي AIC والذي يعطى بالعلاقة:

$$AIC(m) = n \ln \sigma_a^2 + 2m$$

حيث m عدد المعالم المقدرة في النموذج ونختار النموذج الذي يعطي

سوف نطبق النماذج على التوالي:

```
MTB > ARIMA 1 0 0 'Defects' 'RESI1';
SUBC> Constant;
```

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.4421	0.1365	3.24
Constant	0.99280	0.06999	14.19
Mean	1.7795	0.1254	

Number of observations: 45

Residuals: SS = 9.47811 (backforecasts excluded)

MS = 0.22042 DF = 43

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	4.9 (DF=11)	8.9 (DF=23)	30.9 (DF=35)
* (DF= *)			

```
MTB > ARIMA 2 0 0 'Defects' 'RESI2';
```

```
SUBC> Constant;
```

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.3999	0.1533	2.61
AR 2	0.0989	0.1531	0.65
Constant	0.89019	0.07047	12.63
Mean	1.7762	0.1406	

Number of observations: 45

Residuals: SS = 9.38567 (backforecasts excluded)
MS = 0.22347 DF = 42

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	4.0 (DF=10)	8.1 (DF=22)	28.8 (DF=34)
* (DF= *)			

MTB > ARIMA 1 0 1 'Defects' 'RESI3';
SUBC> Constant;

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.5983	0.2691	2.22
MA 1	0.1926	0.3294	0.58
Constant	0.71334	0.05693	12.53
Mean	1.7759	0.1417	

Number of observations: 45

Residuals: SS = 9.39423 (backforecasts excluded)
MS = 0.22367 DF = 42

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	4.1 (DF=10)	8.3 (DF=22)	29.1 (DF=34)
* (DF= *)			

```
MTB > ARIMA 0 0 1 'Defects' 'RESI4';
SUBC> Constant;
```

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters			
Type	Coef	StDev	T
MA 1	-0.3409	0.1431	-2.38
Constant	1.78480	0.09651	18.49
Mean	1.78480	0.09651	

Number of observations: 45
Residuals: SS = 10.0362 (backforecasts excluded)
MS = 0.2334 DF = 43

Modified Box-Pierce (Ljung-Box) Chi-Square statistic			
Lag	12	24	36
48			
Chi-Square	8.0 (DF=11)	13.2 (DF=23)	35.7 (DF=35)
* (DF= *)			

```
MTB > ARIMA 0 0 2 'Defects' 'RESI5';
SUBC> Constant;
```

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	-0.3869	0.1516	-2.55
MA 2	-0.1816	0.1516	-1.20
Constant	1.7839	0.1118	15.96
Mean	1.7839	0.1118	

Number of observations: 45

Residuals: SS = 9.61059 (backforecasts excluded)
MS = 0.22882 DF = 42

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	4.6(DF=10)	9.2(DF=22)	31.0(DF=34)
* (DF= *)			

MTB > ARIMA 2 0 1 'Defects' 'RESI6';

SUBC> Constant;

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.4134	1.5680	0.26
AR 2	0.0929	0.7113	0.13
MA 1	0.0136	1.5749	0.01
Constant	0.87675	0.07036	12.46
Mean	1.7761	0.1425	

Number of observations: 45

Residuals: SS = 9.38561 (backforecasts excluded)
MS = 0.22892 DF = 41

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	4.0 (DF= 9)	8.1 (DF=21)	28.8 (DF=33)
* (DF= *)			

MTB > ARIMA 1 0 2 'Defects' 'RESI7';
SUBC> Constant;

ARIMA Model

ARIMA model for Defects

* ERROR * Model cannot be estimated with these data

MTB > ARIMA 2 0 2 'Defects' 'RESI8';
SUBC> Constant;

ARIMA Model

ARIMA model for Defects

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	1.6720	0.1165	14.35
AR 2	-0.7263	0.1251	-5.80
MA 1	1.3199	0.0184	71.63
MA 2	-0.3196	0.0731	-4.37
Constant	0.096224	0.003323	28.95
Mean	1.77238	0.06121	

Number of observations: 45

Residuals: SS = 8.33225 (backforecasts excluded)
MS = 0.20831 DF = 40

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			

Chi-Square 4 . 7 (DF= 8) 8 . 9 (DF=20) 29 . 7 (DF=32)
* (DF= *)

ونلخص ذلك بالجدول التالي:

<i>Model</i>	$\hat{\sigma}^2$	<i>m</i>	<i>AIC</i>
<i>AR(1)</i>	0.22042	3	-62.0499
<i>AR(2)</i>	0.22347	4	-59.4315
<i>MA(1)</i>	0.23340	3	-59.4751
<i>MA(2)</i>	0.22882	4	-58.3669
<i>ARMA(1,1)</i>	0.22367	4	-59.3913
<i>ARMA(2,1)</i>	0.22892	5	-56.3472
<i>ARMA(1,2)</i>	-	-	-
<i>ARMA(2,2)</i>	0.20831	6	-58.5928

$$\min_m AIC(m) = -62.0499$$

أي ان أفضل نموذج هو $AR(1)$.
يترك للطالب كتمرين فحص الباقي وتوليد تنبؤات.

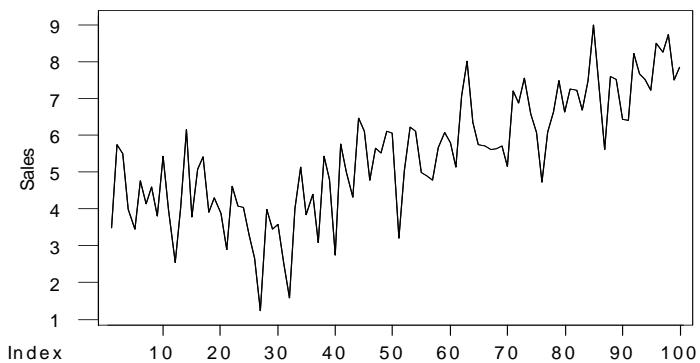
حالة دراسة:

المتسلسلة التالية هي دخل المبيعات السنوية بملايين الريالات لشركة ما

Sales

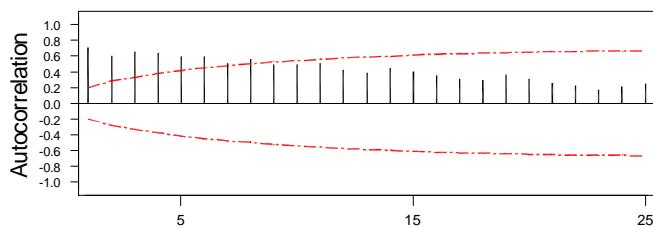
3.49	5.74	5.51	3.99	3.45	4.77	4.14	4.60	3.80	5.43
3.96	2.54	4.05	6.16	3.78	5.07	5.42	3.91	4.30	3.88
2.89	4.61	4.08	4.05	3.28	2.65	1.22	3.98	3.45	3.57
2.52	1.58	4.00	5.14	3.84	4.40	3.08	5.43	4.80	2.75
5.77	4.99	4.31	6.46	6.11	4.79	5.65	5.52	6.12	6.06
3.20	5.05	6.23	6.12	4.99	4.89	4.78	5.67	6.08	5.80
5.13	7.07	8.02	6.36	5.75	5.70	5.61	5.63	5.71	5.16
7.20	6.87	7.56	6.57	6.08	4.72	6.09	6.64	7.49	6.64
7.26	7.22	6.69	7.49	9.01	7.27	5.62	7.59	7.53	6.43
6.42	8.22	7.67	7.53	7.23	8.50	8.27	8.75	7.50	7.86

مخطط زمني للمتسلسلة



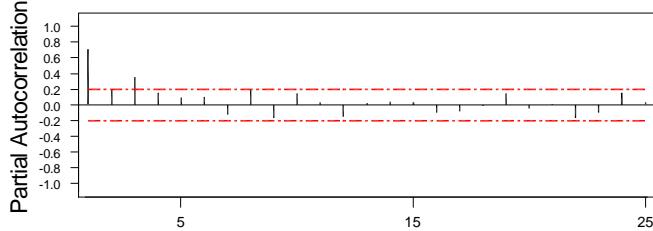
دوال الترابط الذاتي والذاتي الجزئي العينية

Autocorrelation Function for Sales



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.71	7.10	51.97	8	0.56	2.223	17.32	15	0.41	1.324	83.85	22	0.22	0.675	65.04
2	0.60	4.26	89.85	9	0.49	1.873	44.49	16	0.35	1.134	99.04	23	0.17	0.505	68.77
3	0.65	3.94	134.64	10	0.49	1.793	71.67	17	0.31	0.975	10.68	24	0.21	0.645	74.90
4	0.64	3.36	177.75	11	0.51	1.824	01.71	18	0.30	0.925	21.52	25	0.25	0.755	83.43
5	0.59	2.83	215.72	12	0.42	1.464	22.60	19	0.36	1.115	37.81				
6	0.59	2.63	253.97	13	0.38	1.294	39.91	20	0.31	0.955	50.11				
7	0.51	2.122	82.61	14	0.45	1.504	64.06	21	0.26	0.775	58.52				

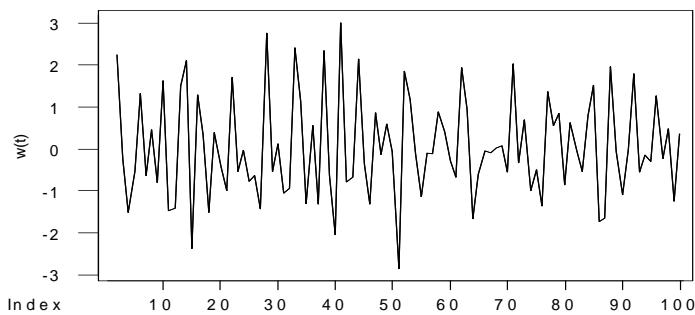
Partial Autocorrelation Function for Sales



Lag	PAC	T									
1	0.71	7.10	8	0.19	1.93	15	0.03	0.32	22	-0.17	-1.68
2	0.20	1.99	9	-0.17	-1.70	16	-0.10	-0.96	23	-0.10	-1.00
3	0.35	3.53	10	0.14	1.44	17	-0.08	-0.84	24	0.15	1.55
4	0.15	1.49	11	0.03	0.34	18	-0.01	-0.10	25	0.03	0.34
5	0.09	0.92	12	-0.15	-1.52	19	0.14	1.43			
6	0.10	1.03	13	0.02	0.25	20	-0.04	-0.44			
7	-0.13	-1.27	14	0.04	0.39	21	0.00	0.04			

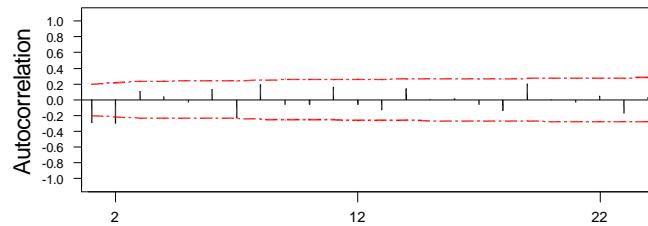
دالة الترابط الذاتي العيني تدل على تخدام بطيء مما قد يدل على عدم استقرار في المتوسط.

لنجرب التفريق الأول للمتسلسلة $\nabla z_t = w_t$ ونرسمها

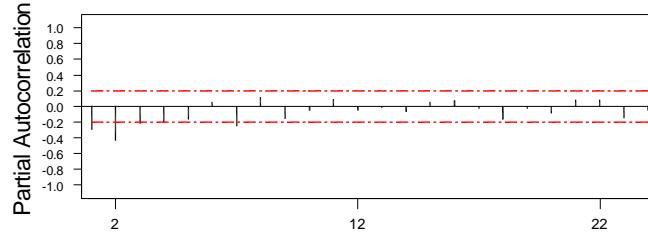


تبعد المتسلسلة مستقرة الآن. دوال الترابط الذاتي والذاتي الجزئي للمتسلسلة المستقرة

Autocorrelation Function for $w(t)$



Partial Autocorrelation Function for $w(t)$



لإختيار النموذج المناسب سوف نستخدم معيار المعلومات الذاتي AIC والذي يعطى بالعلاقة:

$$AIC(m) = n \ln \sigma_a^2 + 2m$$

حيث m عدد المعالم المقدرة في النموذج ونختار النموذج الذي يعطي

سوف نطبق النماذج على التوالي:

```
MTB > ARIMA 1 1 0 'Sales';
SUBC> NoConstant.
```

ARIMA Model

ARIMA model for Sales

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	-0.3114	0.0959	-3.25

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99

Residuals: SS = 133.134 (backforecasts excluded)
MS = 1.359 DF = 98

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	31.9 (DF=11)	51.2 (DF=23)	62.8 (DF=35)
	81.0 (DF=47)		

MTB > ARIMA 2 1 0 'Sales';

SUBC> NoConstant.

ARIMA Model

ARIMA model for Sales

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	-0.4532	0.0897	-5.05
AR 2	-0.4656	0.0901	-5.17

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99

Residuals: SS = 104.715 (backforecasts excluded)
MS = 1.080 DF = 97

```

Modified Box-Pierce (Ljung-Box) Chi-Square statistic
Lag           12            24            36
48
Chi-Square    21.8 (DF=10)    40.9 (DF=22)    49.4 (DF=34)
59.9 (DF=46)

```

```

MTB > ARIMA 0 1 1 'Sales';
SUBC> NoConstant.

```

ARIMA Model

ARIMA model for Sales

```

Final Estimates of Parameters
Type      Coef      StDev      T
MA 1      0.7636    0.0648    11.78

```

```

Differencing: 1 regular difference
Number of observations: Original series 100, after
differencing 99
Residuals: SS = 101.411 (backforecasts excluded)
            MS = 1.035 DF = 98

```

```

Modified Box-Pierce (Ljung-Box) Chi-Square statistic
Lag           12            24            36
48
Chi-Square    12.6 (DF=11)    27.8 (DF=23)    35.9 (DF=35)
48.5 (DF=47)

```

```

MTB > ARIMA 0 1 2 'Sales';
SUBC> NoConstant.

```

ARIMA Model

ARIMA model for Sales

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	0.5756	0.0990	5.81
MA 2	0.2029	0.0998	2.03

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99

Residuals: SS = 99.2463 (backforecasts excluded)
MS = 1.0232 DF = 97

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	14.3 (DF=10)	28.3 (DF=22)	36.5 (DF=34)
	47.0 (DF=46)		

MTB > ARIMA 1 1 1 'Sales';

SUBC> NoConstant.

ARIMA Model

ARIMA model for Sales

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.1283	0.1334	0.96
MA 1	0.8027	0.0799	10.04

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99

Residuals: SS = 100.421 (backforecasts excluded)
MS = 1.035 DF = 97

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	13.3 (DF=10)	27.9 (DF=22)	36.1 (DF=34)
	48.2 (DF=46)		

```
MTB > ARIMA 2 1 1 'Sales';
SUBC> NoConstant.
```

ARIMA Model

ARIMA model for Sales

* WARNING * Back forecasts not dying out rapidly

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	-1.1389	0.0987	-11.53
AR 2	-0.1440	0.0983	-1.47
MA 1	-0.9889	0.0002	-3987.49

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99

Residuals: SS = 134.250 (backforecasts excluded)
 MS = 1.398 DF = 96

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	35.1 (DF= 9)	53.5 (DF=21)	66.6 (DF=33)
	83.2 (DF=45)		

```
MTB > ARIMA 1 1 2 'Sales';
SUBC> NoConstant.
```

ARIMA Model

ARIMA model for Sales

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	-0.3476	0.4077	-0.85
MA 1	0.2422	0.3771	0.64
MA 2	0.4506	0.2656	1.70

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99

Residuals: SS = 97.2357 (backforecasts excluded)
MS = 1.0129 DF = 96

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	11.9 (DF= 9)	25.0 (DF=21)	32.1 (DF=33)
	41.8 (DF=45)		

MTB > ARIMA 2 1 2 'Sales';
SUBC> NoConstant.

ARIMA Model

ARIMA model for Sales

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	-0.0691	0.3618	-0.19
AR 2	-0.2941	0.1450	-2.03
MA 1	0.5637	0.3737	1.51
MA 2	0.0840	0.3266	0.26

Differencing: 1 regular difference

Number of observations: Original series 100, after differencing 99
 Residuals: SS = 93.6368 (backforecasts excluded)
 MS = 0.9857 DF = 95

Modified Box-Pierce (Ljung-Box) Chi-Square statistic
 Lag 12 24 36
 48
 Chi-Square 11.0 (DF= 8) 23.4 (DF=20) 30.1 (DF=32)
 36.5 (DF=44)

ونلخص ذلك بالجدول التالي:

Model	$\hat{\sigma}^2$	m	AIC
<i>ARI</i> (1,1)	1.359	2	34.368
<i>ARI</i> (2,1)	1.080	3	13.619
<i>IMA</i> (1,1)	1.035	2	7.4057
<i>IMA</i> (1,2)	1.023	3	8.2706
<i>ARIMA</i> (1,1,1)	1.035	3	9.4057
<i>ARIMA</i> (2,1,1)	1.398	4	41.169
<i>ARIMA</i> (1,1,2)	1.013	4	9.2689
<i>ARIMA</i> (2,1,2)	0.986	5	8.5741

$$\min_m AIC(m) = 7.406$$

أي ان أفضل نموذج هو $IMA(1,1)$. يترك للطالب كتمرين فحص الباقي وتوليد تنبؤات.

الفصل السادس

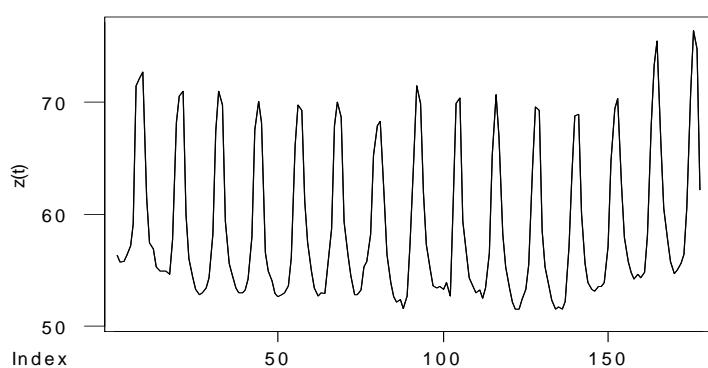
نماذج الانحدار الذاتي التكاملی المتوسط المتحرك الموسمية

Seasonal Autoregressive Integrated Moving Average Models

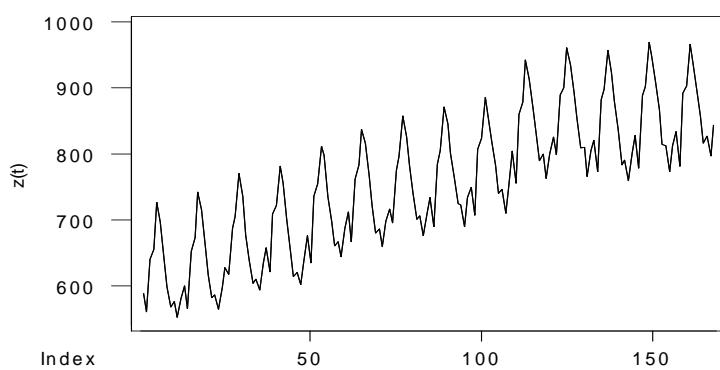
المتسلسلات الزمنية الموسمية تعطي انماط متشابهة تتكرر على فترات زمنية متساوية البعد مثل ان يتكرر النمط كل اربعة وعشرون ساعة او كل سبعة ايام او كل شهر او ثلاثة اشهر او سنة.

الأشكال التالية تبين مثل هذه المتسلسلات

Seasonal Time Series



Seasonal Time Series



في هذا الفصل سوف نستعرض خواص المتسلسلات الزمنية الموسمية وطرق نمذجتها بواسطة نماذج الانحدار الذاتي التكاملی المتوسط المتحرك SARIMA(p,d,q)(P,D,Q)_s فمثلا النموذج SARIMA(0,1,1)(1,1,0)₁₂ يكتب على الشكل

$$(1 - \Phi_1 B^s)(1 - B) z_t = (1 - \theta_1 B) a_t, \quad a_t \sim WN(0, \sigma^2)$$

وبشكل عام فإن نموذج الإنحدار الذاتي التكاملی المتوازن المتحرك بالدرجة s

يكتب على الشكل $SARIMA(p,d,q)(P,D,Q)_s$

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D z_t = \delta + \theta_q(B)\Theta_Q(B^s)a_t, \quad a_t \sim WN(0, \sigma^2)$$

حيث $\phi_p(B)$ و $\theta_q(B)$ عمال الإنحدار الذاتي والمتوسط المتحرك غير الموسمية والتي مررت

علينا سابقاً و $\Phi_P(B^s) = 1 + \Phi_1 B^s + \Phi_2 B^{2s} + \dots + \Phi_p B^{ps}$ عامل الإنحدار الذاتي الموسمي و

$\Theta_Q(B^s) = 1 + \Theta_1 B^s + \Theta_2 B^{2s} + \dots + \Theta_q B^{qs}$ عامل المتوسط المتحرك الموسمي ويسمى هذا

بالنموذج الموسمي التضاعفي .Multiplicative Seasonal Models

ملاحظة: في جميع النماذج القادمة سيكون مفهوماً ضمنياً أن $a_t \sim WN(0, \sigma^2)$

دوال الترابط الذاتي والترابط الذاتي الجزئي لبعض النماذج الموسمية:

في الإشتقاقات التالية سوف نستخدم المتسلسلة الموسمية المستقرة $z_t = (1 - B)^d(1 - B^s)^D$

والتي تتبع النموذج $SARMA(p,q)(P,Q)_s$

$$\phi_p(B)\Phi_P(B^s)w_t = \delta + \theta_q(B)\Theta_Q(B^s)a_t, \quad a_t \sim WN(0, \sigma^2)$$

سوف نشق دالة الترابط الذاتي للنموذج الموسمي التضاعفي $SARMA(0,1)(1,1)_{12}$

$$w_t = \Phi w_{t-12} + a_t - \theta a_{t-1} - \Theta a_{t-12} + \theta \Theta a_{t-13}, \quad a_t \sim WN(0, \sigma^2)$$

بضرب طرفي المعادلة المعرفة في w_t وأخذ التوقع نجد

$$\begin{aligned} \gamma_0 &= \Phi \gamma_{12} + \sigma^2 + \theta^2 \sigma^2 - \Theta(\Phi - \Theta) \sigma^2 + \theta \Theta(-\Phi \theta + \theta \Theta) \sigma^2 \\ &= \Phi \gamma_{12} + \sigma^2 \left[(1 + \theta^2) + \Theta(\Phi - \Theta)(1 + \theta^2) \right] \\ &= \Phi \gamma_{12} + \sigma^2 (1 + \theta^2) [1 + \Theta(\Phi - \Theta)] \end{aligned}$$

وبضرب طرفي المعادلة المعرفة في w_{t-12} وأخذ التوقع نجد

$$\gamma_{12} = \Phi \gamma_0 - \Theta \sigma^2 + \theta \Theta(-\theta) \sigma^2$$

$$= \Phi \gamma_0 - \Theta \sigma^2 (1 + \theta^2)$$

وبحل العلاقتين السابقتين نجد

$$\gamma_0 = \sigma^2 (1 + \theta^2) \frac{1 + \Theta^2 - 2\Phi\Theta}{1 - \Phi^2}$$

$$\gamma_{12} = \sigma^2 (1 + \theta^2) \left[\Phi - \Theta + \frac{\Phi(\Theta - \Phi)^2}{1 - \Phi^2} \right]$$

أيضا

$$\begin{aligned}\gamma_1 &= E(w_t w_{t-1}) \\ &= \Phi \gamma_{11} - \theta \sigma^2 - \Theta E(a_{t-12} w_{t-1}) + \theta \Theta E(a_{t-13} w_{t-1}) \\ &= \Phi \gamma_{11} - \theta \sigma^2 + \theta \Theta (\Phi - \Theta) \sigma^2\end{aligned}$$

و

$$\gamma_{11} = E(w_t w_{t-11}) = \Phi \gamma_1 + \Theta \theta \sigma^2$$

وبحل العلاقاتين السابقتين نجد

$$\begin{aligned}\gamma_1 &= -\theta \sigma^2 \left[1 + \frac{(\Theta - \Phi)^2}{1 - \Phi^2} \right] \\ \gamma_{11} &= \theta \sigma^2 \left[\Theta - \Phi - \frac{\Phi(\Theta - \Phi)^2}{1 - \Phi^2} \right]\end{aligned}$$

وبنفس الطريقة يمكن إثبات أن

$$\gamma_2 = \gamma_3 = \dots = \gamma_{10} = 0$$

$$\gamma_{13} = \gamma_{11}$$

$$\gamma_k = \Phi \gamma_{k-12}, \quad k > 13$$

ومن جميع العلاقات السابقة نوجد دالة الترابط الذاتي

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \begin{cases} 1, & k = 0 \\ -\frac{\theta}{1 + \theta^2}, & k = 1 \\ 0, & k = 2, \dots, 10 \\ \frac{\theta}{1 + \theta^2} \frac{(\Theta - \Phi)(1 - \Phi\Theta)}{1 + \Theta^2 - 2\Phi\Theta}, & k = 11 \\ -\frac{(\Theta - \Phi)(1 - \Phi\Theta)}{1 + \Theta^2 - 2\Phi\Theta}, & k = 12 \\ \rho_{11}, & k = 13 \\ \Phi \rho_{k-12}, & k > 13 \end{cases}$$

دوال الترابط الذاتي لبعض النماذج الموسمية:

$$w_t = (1 - \Theta B^s) a_t \quad \text{SARIMA}(0,d,0)(0,D,1)_s \quad \text{- نموذج 1}$$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{\Theta}{1 + \Theta^2}, & k = s \\ 0, & otherwise \end{cases}$$

$$(1 - \Phi B^s) w_t = a_t \quad \text{SARIMA}(0,d,0)(1,D,1)_s \quad \text{- نموذج 2}$$

$$\rho_k = \begin{cases} 1, & k = 0 \\ \Phi^{k/s}, & k = s, 2s, \dots \\ 0, & otherwise \end{cases}$$

$$w_t = (1 - \theta B)(1 - \Theta B^s) a_t \quad \text{SARIMA}(0,d,1)(0,D,1)_s \quad \text{- نموذج 3}$$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{\theta}{1 + \theta^2}, & k = 1 \\ \frac{\theta \Theta}{(1 + \theta^2)(1 + \Theta^2)}, & k = s - 1 \\ -\frac{\Theta}{1 + \Theta^2}, & k = s \\ \rho_{s-1}, & k = s + 1 \\ 0, & otherwise \end{cases}$$

$$(1 - \Phi B^s) w_t = (1 - \Theta B^s) a_t \quad \text{SARIMA}(0,d,0)(1,D,1)_s \quad \text{- نموذج 4}$$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{(\Theta - \Phi)(1 - \Phi \Theta)}{1 + \Theta^2 - 2\Phi\Theta} \Phi^{k/s-1}, & k = s, 2s, \dots \\ 0, & otherwise \end{cases}$$

$$(1 - \Phi B^s) w_t = (1 - \theta B) a_t \quad \text{SARIMA}(0,d,1)(1,D,0)_s \quad \text{- نموذج 5}$$

$$\rho_k = \begin{cases} 1, & k=0 \\ -\frac{\theta}{1+\theta^2}, & k=1 \\ 0, & k=2, \dots, s-2 \\ -\frac{\theta\Phi}{1+\theta^2}, & k=s-1 \\ \Phi, & k=s \\ \rho_{s-1}, & k=s+1 \\ \Phi\rho_{k-s}, & k>s+1 \end{cases}$$

نموذج 6 - SARIMA(0,d,2)(0,D,1)_s

$$\rho_k = \begin{cases} 1, & k=0 \\ -\frac{\theta_1(1-\theta_2)}{1+\theta_1^2+\theta_2^2}, & k=1 \\ -\frac{\theta_2}{1+\theta_1^2+\theta_2^2}, & k=2 \\ \frac{\theta_2\Theta}{(1+\theta_1^2+\theta_2^2)(1+\Theta^2)}, & k=s-2 \\ \frac{\theta_1\Theta(1-\theta_2)}{(1+\theta_1^2+\theta_2^2)(1+\Theta^2)}, & k=s-1 \\ -\frac{\Theta}{1+\Theta^2}, & k=s \\ \rho_{s-1}, & k=s+1 \\ \rho_{s-2}, & k=s+2 \\ 0, & otherwise \end{cases}$$

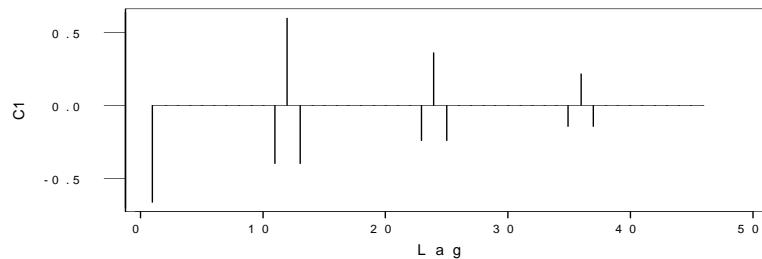
سوف نستعرض بعض الرسومات لدالة الترابط الذاتي للمتسلسلات الزمنية الموسمية لأعطاء فكرة عن أشكالها.

الأشكال التالية لنموذج SARIMA(0,d,1)(1,D,0)₁₂

شکل (1)

$$\Phi = 0.6, \quad \theta = 0.5$$

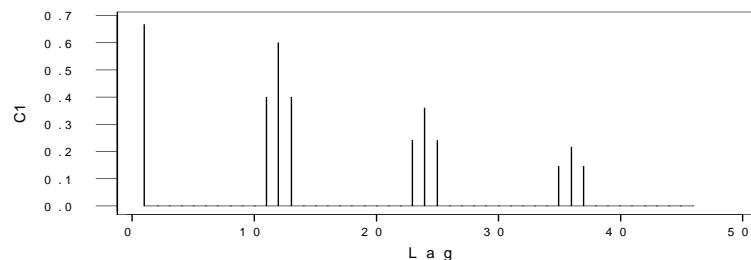
A C F o f S A R I M A (0, d, 1)(1, D, 0)1 2



شکل (2)

$$\Phi = 0.6, \quad \theta = -0.5$$

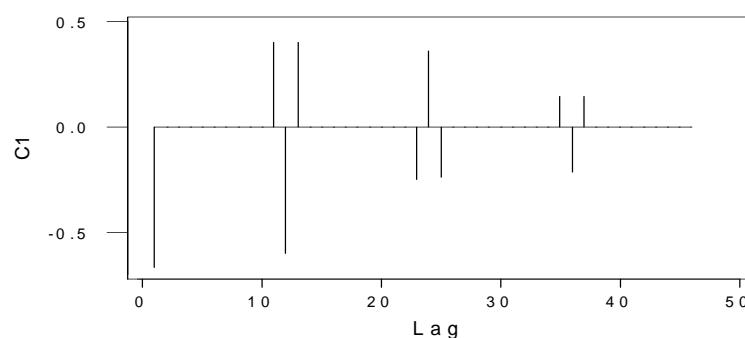
A C F o f S A R I M A (0, d, 1)(1, D, 0)1 2



شکل (3)

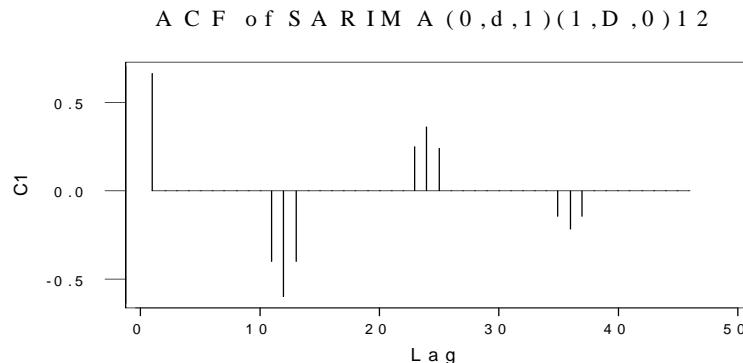
$$\Phi = -0.6, \quad \theta = 0.5$$

A C F o f S A R I M A (0, d, 1)(1, D, 0)1 2



شكل (4)

$$\Phi = -0.6, \quad \theta = -0.5$$



دالة الترابط الذاتي الجزئي للنموذج الموسمى التضاعفى:

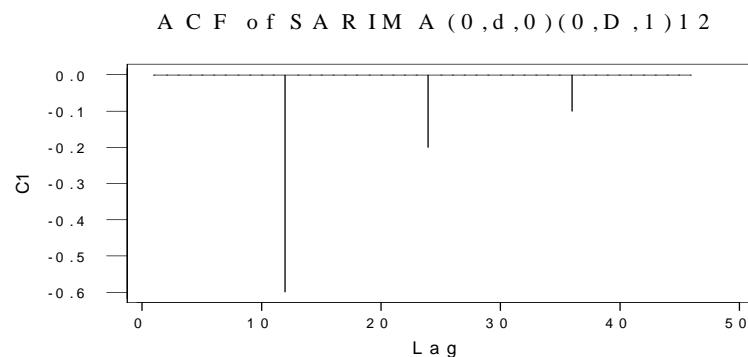
من الصعوبة إشتقاق وتقدير أنماط دالة الترابط الذاتي الجزئي للنماذج الموسمية التضاعفية ولكنها وبشكل عام فإن أجزاء النموذج الموسمية وغير الموسمية والتي تندمج المتوسط المتحرك تعطي تخامدات اسية وتخامدات جبية عند التخلفات الموسمية وغير الموسمية وفي النماذج التي تحوي إنحدار ذاتي فإن الترابطات الذاتية الجزئية تعطي قطعاً cut off.

الأشكال التالية لإعطاء فكرة عن بعض دوال الترابط الذاتي الجزئي لبعض النماذج :

1- شكل دالة الترابط الذاتي الجزئي لنموذج

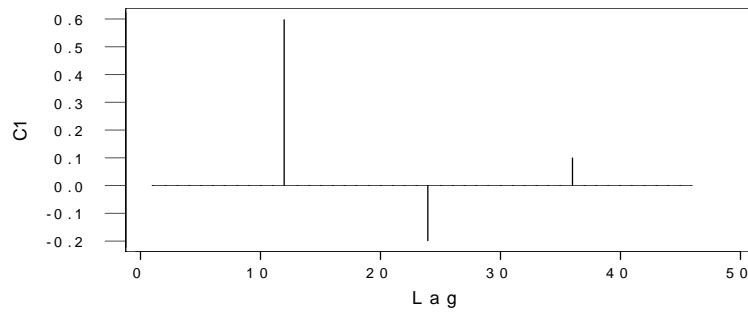
$$w_t = (1 - \Theta B^{12}) a_t \quad (1)$$

$$\Theta = 0.6$$



$$\Theta = -0.6 \quad (b)$$

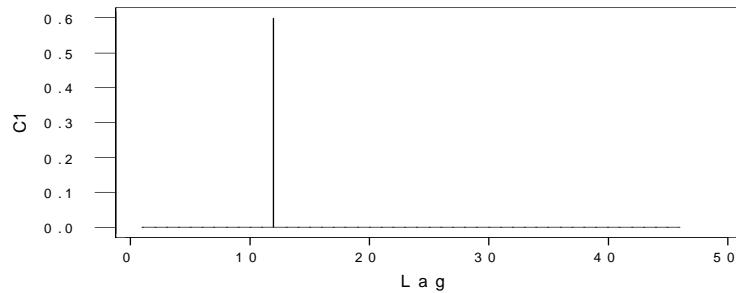
A C F o f S A R I M A (0 , d , 0)(0 , D , 1) 1 2



2- شكل دالة الترابط الذاتي الجزئي لنموذج

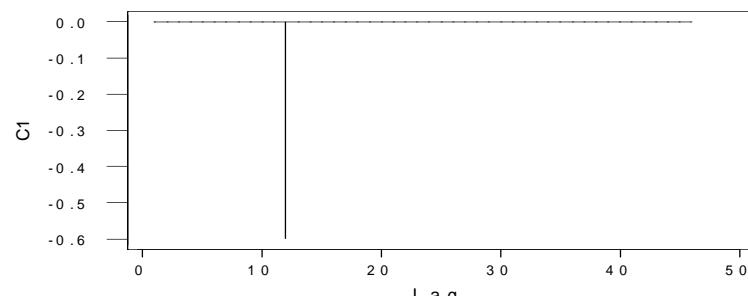
$$\Phi = 0.6 \quad (ا)$$

A C F o f S A R I M A (0 , d , 1)(0 , D , 0) 1 2



$$\Phi = -0.6 \quad (ب)$$

A C F o f S A R I M A (0 , d , 1)(0 , D , 0) 1 2



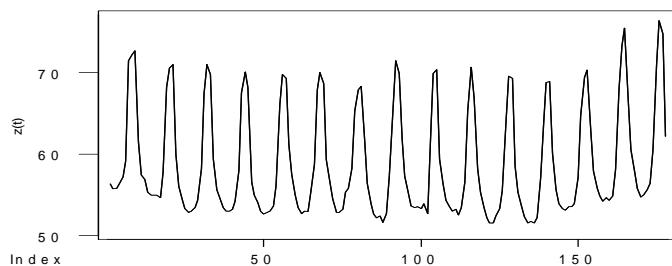
أمثلة: للمتسلسلة الزمنية الموسمية (في جميع الأمثلة التالية إقرأ سطراً بسطر)

$z(t)$

56.3	55.7	55.8	56.3	57.2	59.1	71.5	72.2	72.7	61.5	57.4	56.9
55.3	54.9	54.9	54.9	54.6	57.7	68.2	70.6	71.0	60.0	56.0	54.4
53.3	52.8	53.0	53.4	54.3	58.2	67.4	71.0	69.8	59.4	55.6	54.6

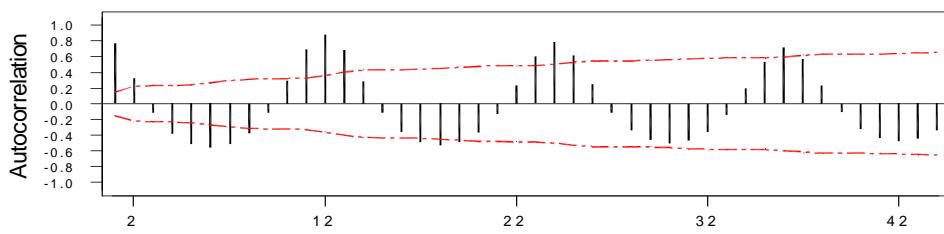
53.4	53.0	53.0	53.2	54.2	58.0	67.5	70.1	68.2	56.6	54.9	54.0
52.9	52.6	52.8	53.0	53.6	56.1	66.1	69.8	69.3	61.2	57.5	54.9
53.4	52.7	53.0	52.9	55.4	58.7	67.9	70.0	68.7	59.3	56.4	54.5
52.8	52.8	53.2	55.3	55.8	58.2	65.3	67.9	68.3	61.7	56.4	53.9
52.6	52.1	52.4	51.6	52.7	57.3	65.1	71.5	69.9	61.9	57.3	55.1
53.6	53.4	53.5	53.3	53.9	52.7	61.0	69.9	70.4	59.4	56.3	54.3
53.5	53.0	53.2	52.5	53.4	56.5	65.3	70.7	66.9	58.2	55.3	53.4
52.1	51.5	51.5	52.4	53.3	55.5	64.2	69.6	69.3	58.5	55.3	53.6
52.3	51.5	51.7	51.5	52.2	57.1	63.6	68.8	68.9	60.1	55.6	53.9
53.3	53.1	53.5	53.5	53.9	57.1	64.7	69.4	70.3	62.6	57.9	55.8
54.8	54.2	54.6	54.3	54.8	58.1	68.1	73.3	75.5	66.4	60.5	57.7
55.8	54.7	55.0	55.6	56.4	60.6	70.8	76.4	74.8	62.2		

شكل المتسلسلة هو



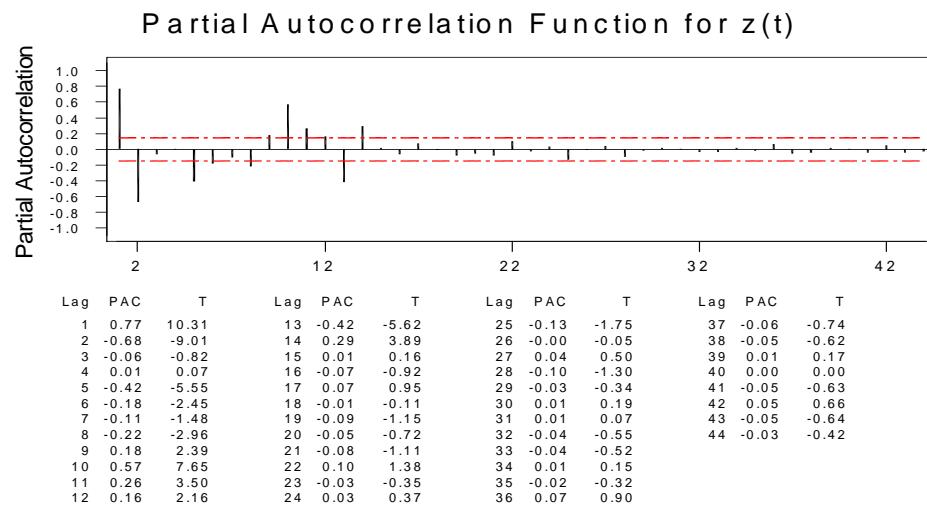
دالة الترابط الذاتي

Autocorrelation Function for $z(t)$



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.77	10.31	108.10	13	0.68	3.34	694.28	25	0.61	2.30	1220.07	37	0.57	1.82	1709.36
2	0.33	2.93	127.34	14	0.28	1.30	709.82	26	0.25	0.91	1233.18	38	0.23	0.73	1721.70
3	-0.11	-0.99	129.74	15	-0.12	-0.53	712.43	27	-0.11	-0.42	1235.98	39	-0.11	-0.34	1724.43
4	-0.38	-3.28	156.83	16	-0.36	-1.65	738.30	28	-0.34	-1.24	1261.29	40	-0.33	-1.02	1749.06
5	-0.52	-4.22	207.24	17	-0.49	-2.21	786.28	29	-0.47	-1.67	1308.32	41	-0.44	-1.38	1795.00
6	-0.56	-4.16	266.55	18	-0.53	-2.33	843.04	30	-0.51	-1.80	1364.72	42	-0.48	-1.48	1849.41
7	-0.52	-3.50	316.80	19	-0.49	-2.10	892.36	31	-0.48	-1.65	1414.08	43	-0.45	-1.37	1897.05
8	-0.38	-2.39	343.71	20	-0.37	-1.54	920.39	32	-0.36	-1.23	1442.71	44	-0.34	-1.04	1925.30
9	-0.12	-0.71	346.25	21	-0.14	-0.56	924.24	33	-0.14	-0.49	1447.34				
10	0.29	1.76	362.08	22	0.23	0.95	935.37	34	0.19	0.66	1455.79				
11	0.69	4.15	453.58	23	0.61	2.46	1011.31	35	0.54	1.82	1520.89				
12	0.88	4.86	603.87	24	0.79	3.10	1140.90	36	0.72	2.37	1636.49				

والترابط الذاتي الجزئي

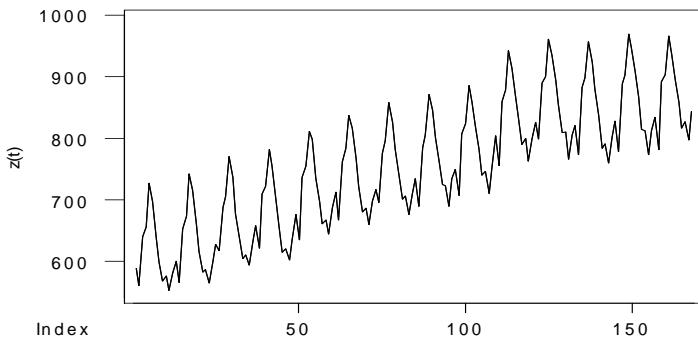


نلاحظ الأنماط الموسمية واضحة في الأشكال السابقة.

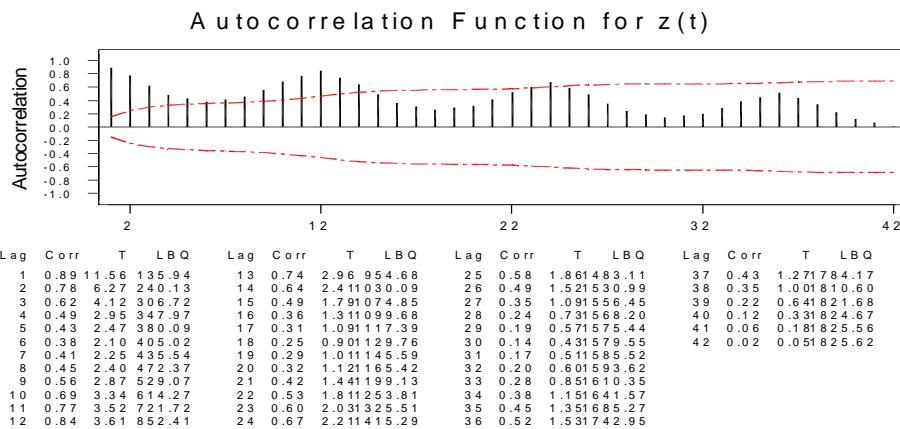
مثال آخر

$z(t)$												
589	561	640	656	727	697	640	599	568	577	553	582	
600	566	653	673	742	716	660	617	583	587	565	598	
628	618	688	705	770	736	678	639	604	611	594	634	
658	622	709	722	782	756	702	653	615	621	602	635	
677	635	736	755	811	798	735	697	661	667	645	688	
713	667	762	784	837	817	767	722	681	687	660	698	
717	696	775	796	858	826	783	740	701	706	677	711	
734	690	785	805	871	845	801	764	725	723	690	734	
750	707	807	824	886	859	819	783	740	747	711	751	
804	756	860	878	942	913	869	834	790	800	763	800	
826	799	890	900	961	935	894	855	809	810	766	805	
821	773	883	898	957	924	881	837	784	791	760	802	
828	778	889	902	969	947	908	867	815	812	773	813	
834	782	892	903	966	937	896	858	817	827	797	843	

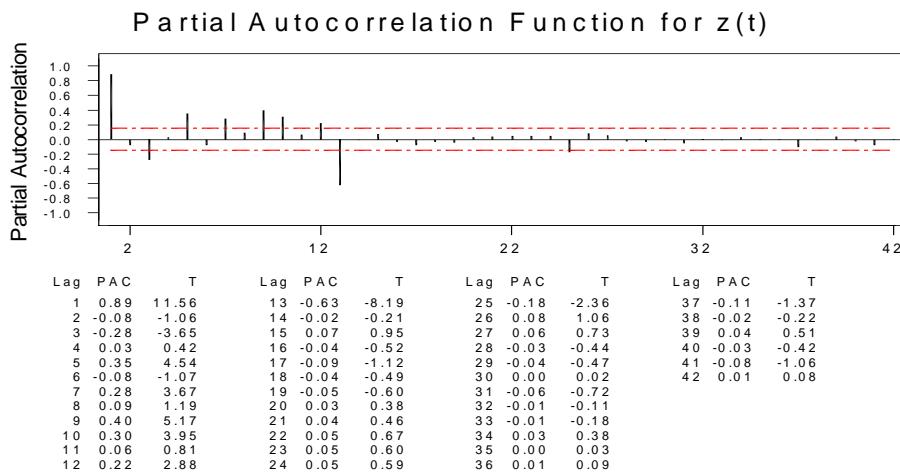
شكل المتسلسلة



الترابط الذاتي



والترابط الذاتي الجزئي

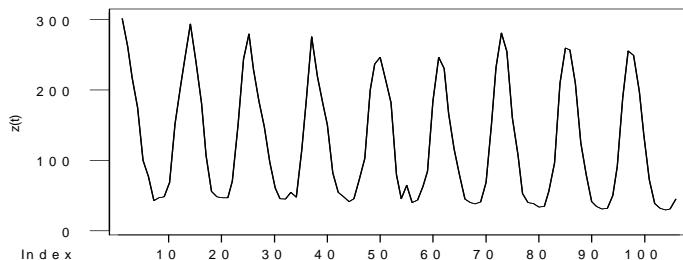


مثال آخر

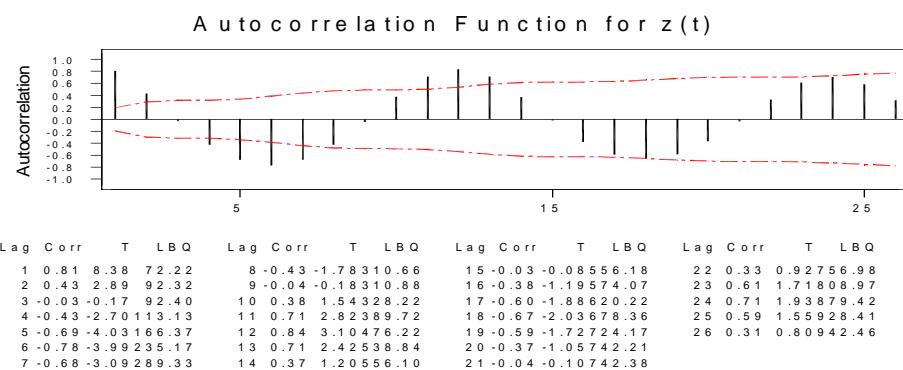
$z(t)$

302	262	218	175	100	077	043	047	049	069	152	205	246	294
242	181	107	056	049	047	047	071	151	244	280	230	185	148
098	061	046	045	055	048	115	185	276	220	181	151	083	055
049	042	046	074	103	200	237	247	215	182	080	046	065	
040	044	063	085	185	247	231	167	117	079	045	040	038	041
069	152	232	282	255	161	107	053	040	039	034	035	056	097
210	260	257	210	125	080	042	035	031	032	050	092	189	256
250	198	136	073	039	032	030	031	045					

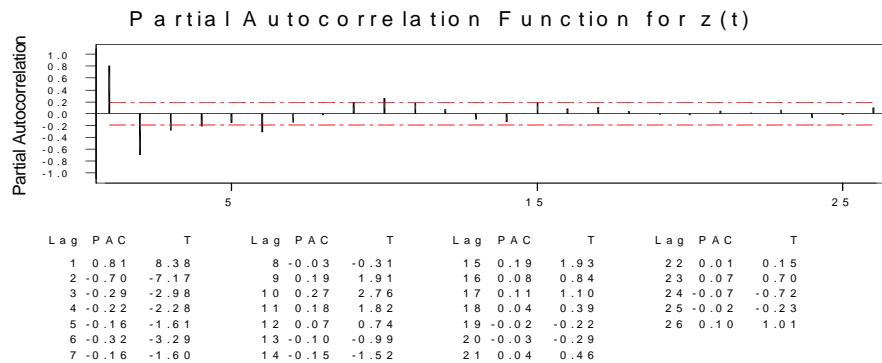
ولها الشكل



ودالة الترابط الذاتي



ودالة الترابط الذاتي الجزئي



وكل هذه المتسلسلات تبدي انماط موسمية واضحة.

استفاق دوال تنبؤ لبعض نماذج المتسلسلات الزمنية الموسمية التضاعفية:

بما ان نماذج المتسلسلات الزمنية الموسمية هي حالة خاصة من نماذج ARIMA فإن طرق التعامل معها هي نفس الطرق السابقة من حيث التعرف على شكل النموذج وتقدير معالم النموذج والاختبارات التفحصية ومن ثم التنبؤ. جميع الطرق والمعدلات التي درسناها سابقاً للنماذج غير الموسمية تتطبق هنا. سوف نشتق دوال التنبؤ لبعض النماذج للتوضيح فقط.

1- دالة التنبؤ للنموذج $\text{SARIMA}(0,0,0)(0,1,1)_{12}$:

ويكتب النموذج على الشكل

$$(1 - B^{12})z_t = (1 - \Theta B^{12})a_t$$

من المعادلة الفروقية

$$z_{n+\ell} = z_{n+\ell-12} + a_{n+\ell} - \Theta a_{n+\ell-12}$$

يمكن الحصول على التنبؤات كالتالي

$$z_n(1) = z_{n-11} - \Theta a_{n-11}$$

$$z_n(2) = z_{n-10} - \Theta a_{n-10}$$

⋮

$$z_n(12) = z_n - \Theta a_n$$

$$z_n(\ell) = z_n(\ell-12), \quad \ell \geq 12$$

أو

$$z_n(\ell) = \begin{cases} z_{n+\ell-12} - \Theta a_{n+\ell-12}, & \ell = 1, 2, \dots, 12 \\ z_n(\ell-12), & \ell > 12 \end{cases}$$

واضح أن

$$\begin{aligned}z_n(1) &= z_n(13) = z_n(25) = \dots \\z_n(2) &= z_n(14) = z_n(26) = \dots \\&\vdots \\z_n(12) &= z_n(24) = z_n(36) = \dots\end{aligned}$$

تباین أخطاء التنبؤ

$$V[e_n(\ell)] = \sigma^2 (1 + \psi_1^2 + \dots + \psi_{\ell-1}^2)$$

ودالة الأوزان تعطى بالعلاقة (برهن ذلك)

$$\psi_j = \begin{cases} 1 - \Theta, & j = 12, 24, \dots \\ 0, & \text{otherwise} \end{cases}$$

وبتعويض الأوزان في صيغة تباین أخطاء التنبؤ نجد

$$V[e_n(\ell)] = \sigma^2 \left\{ 1 + \left\lfloor \frac{\ell-1}{12} \right\rfloor (1 - \Theta)^2 \right\}$$

حيث $\lfloor x \rfloor$ تعني الجزء الصحيح من x .

2- دالة التنبؤ للنموذج $SARIMA(0,1,1)(0,1,1)_{12}$

ويكتب النموذج على الشكل

$$(1 - B)(1 - B^{12})z_t = (1 - \theta B)(1 - \Theta B^{12})a_t$$

من المعادلة الفروقية

$$z_{n+\ell} = z_{n+\ell-1} + z_{n+\ell-12} - z_{n+\ell-13} + a_{n+\ell} - \theta a_{n+\ell-1} - \Theta a_{n+\ell-12} + \theta \Theta a_{n+\ell-13}$$

يمكن الحصول على التنبؤات كالتالي

$$\begin{aligned}z_n(1) &= z_n + z_{n-11} - z_{n-13} - \theta a_n - \Theta a_{n-11} + \theta \Theta a_{n-12} \\z_n(2) &= z_n(1) + z_{n-10} - z_{n-11} - \Theta a_{n-10} + \theta \Theta a_{n-11} \\&\vdots \\z_n(12) &= z_n(11) + z_n - z_{n-1} - \Theta a_n + \theta \Theta a_{n-1} \\z_n(13) &= z_n(12) + z_n(1) - z_n + \theta \Theta a_n \\z_n(\ell) &= z_n(\ell-1) + z_n(\ell-12) - z_n(\ell-13)\end{aligned}$$

وهكذا بقيم أولية

$$\begin{aligned}
 z_n(1) &= z_n + z_{n-1} - z_{n-13} - \theta a_n - \Theta a_{n-11} + \theta \Theta a_{n-12} \\
 z_n(2) &= z_n(1) + z_{n-10} - z_{n-11} - \Theta a_{n-10} + \theta \Theta a_{n-11} \\
 &\vdots \\
 z_n(12) &= z_n(11) + z_n - z_{n-1} - \Theta a_n + \theta \Theta a_{n-1} \\
 z_n(13) &= z_n(12) + z_n(1) - z_n + \theta \Theta a_n
 \end{aligned}$$

و علاقه تكراريه

$$z_n(\ell) = z_n(\ell-1) + z_n(\ell-12) - z_n(\ell-13), \quad \ell > 13$$

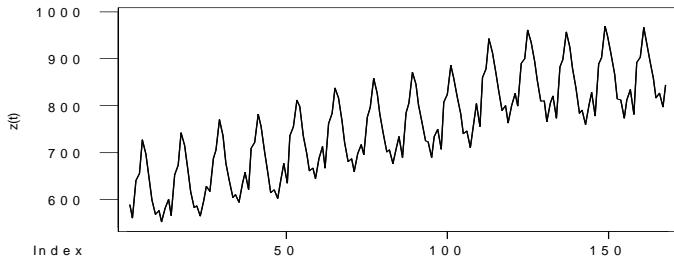
يمكن توليد العدد المطلوب من التنبؤات.

أمثلة وحالات دراسة لبعض المتسلسلات الزمنية الموسمية:

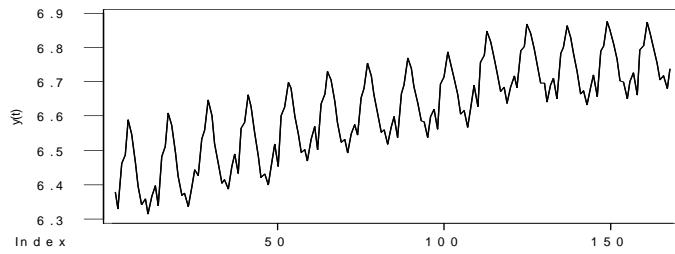
مثال (1): سوف نحاول إيجاد نموذج من عائلة SARIMA ينطبق على المشاهدات التالية:

$z(t)$	589	561	640	656	727	697	640	599	568	577	553	582
	600	566	653	673	742	716	660	617	583	587	565	598
	628	618	688	705	770	736	678	639	604	611	594	634
	658	622	709	722	782	756	702	653	615	621	602	635
	677	635	736	755	811	798	735	697	661	667	645	
	688	713	667	762	784	837	817	767	722	681	687	660
	698	717	696	775	796	858	826	783	740	701	706	677
	711	734	690	785	805	871	845	801	764	725	723	690
	734	750	707	807	824	886	859	819	783	740	747	711
	751	804	756	860	878	942	913	869	834	790	800	763
	800	826	799	890	900	961	935	894	855	809	810	766
	805	821	773	883	898	957	924	881	837	784	791	760
	802	828	778	889	902	969	947	908	867	815	812	773
	813	834	782	892	903	966	937	896	858	817	827	797
	843											

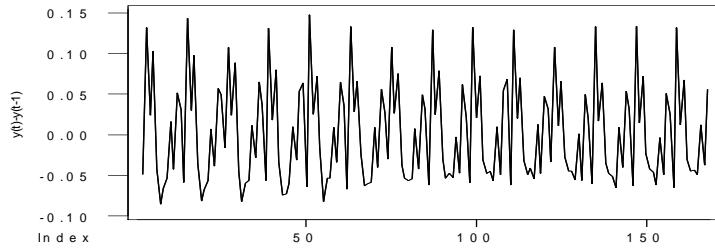
والمخطط الزمني للمشاهدات



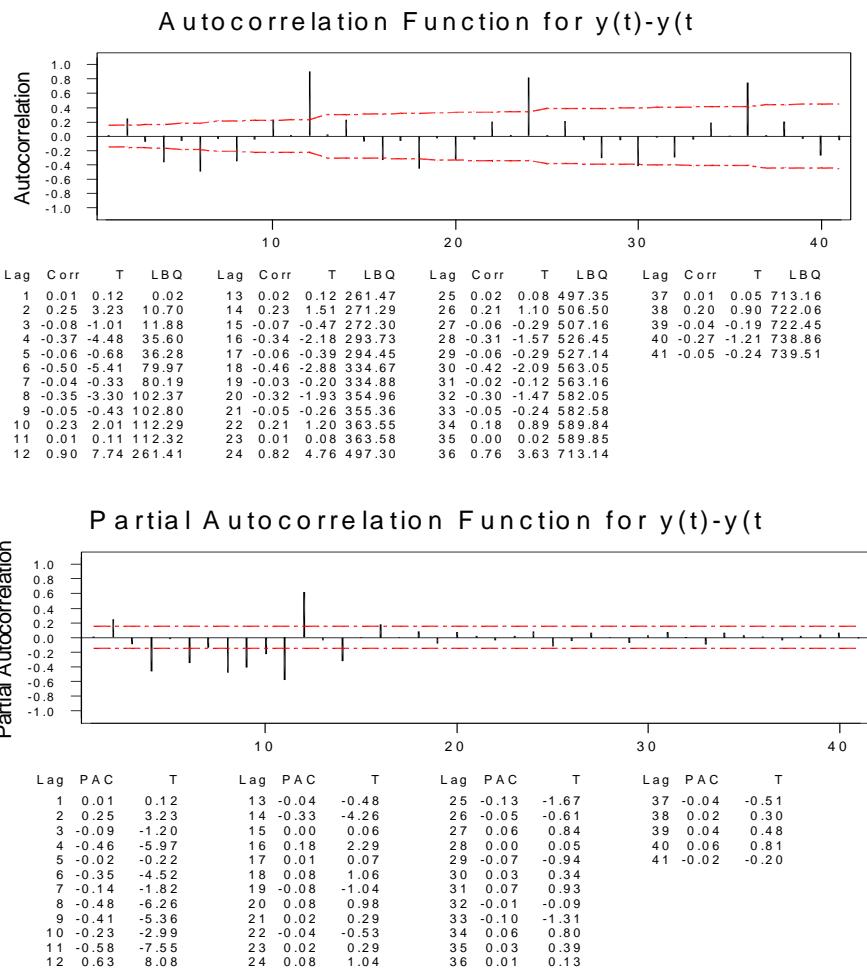
يلاحظ ان المتسلسلة غير مستقرة في التباين والمتوسط لذلك ثبت التباين أولا بتحويل لوغارثمي
أي $y_t = \ln(z_t)$ ورسم المخطط الزمني لها



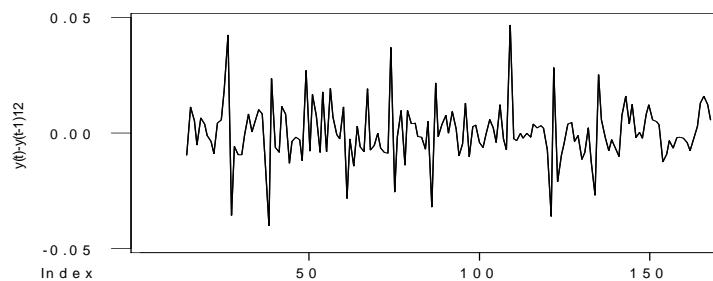
نلاحظ ان المتسلسلة استقرت في التباين ولكن لاتزال غير مستقرة في المتوسط لذلك نأخذ الفرق
الأول $(x_t - B)$ ولها الشكل التالي



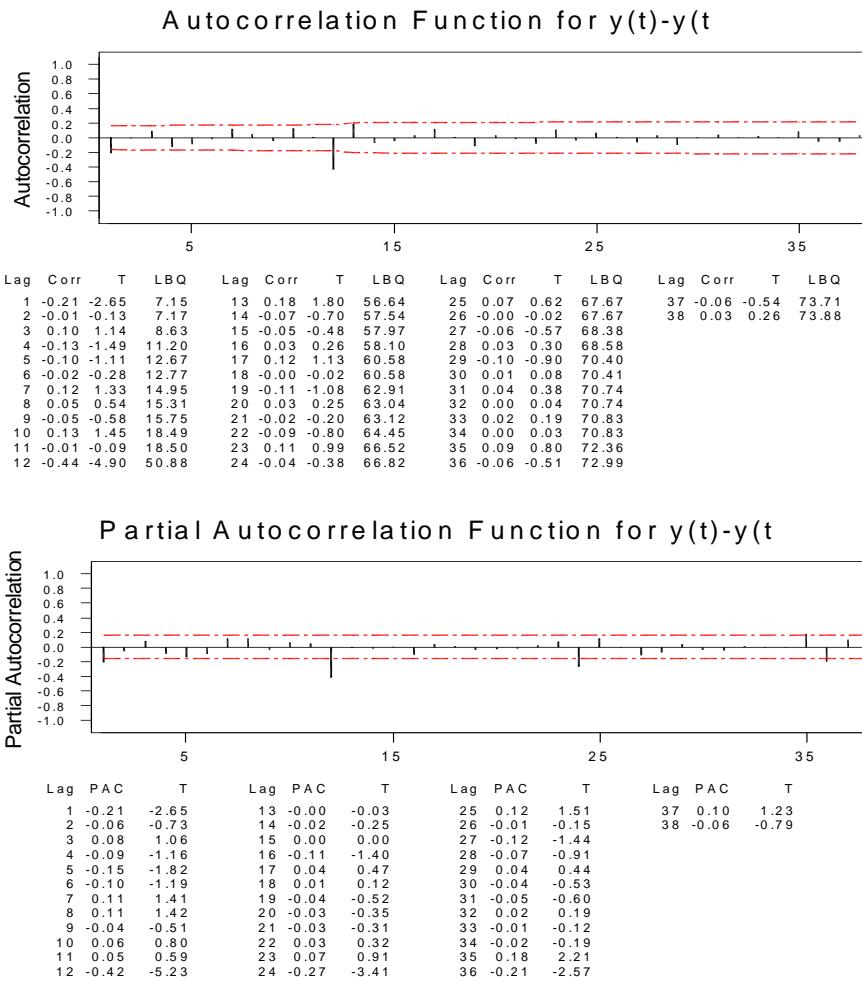
المتسلسلة الآن مستقرة في كل من التباين والمتوسط. لنظر إلى دوال الترابط الذاتي والترابط
الذاتي الجزئي لها



يلاحظ من دالة الترابط الذاتي ان المتسلسلة غير مستقرة موسميا لأن قيمها عند التخلفات 12 و 24 و 36 تتخامد ببطء لذلك نأخذ الفرق الموسمي الأول $w_t = (1-B^{12})(1-B)\ln(z_t)$ ونرسمها بعد هذا التفريق



نوجد دوال الترابط الذاتي والترابط الذاتي الجزئي لها



من انماط دوال الترابط الذاتي والترابط الذاتي الجزئي للمتسلسلة $w_t = (1 - B^{12})(1 - B)\ln(z_t)$

نجد ان قيم p و q الممكنة هي 0 و 0 اي نطبق النموذج

$$(1 - B^{12})(1 - B)\ln(z_t) = (1 - \Theta B^{12})a_t$$

هو $(1 - B)^{12}$ الأمر التالي في MINITAB يطبق هذا النموذج SARIMA(0,1,0)(0,1,1)

ARIMA 0 1 0 0 1 1 12 'y(t)' ;

NoConstant.

لاحظ انا استخدمنا $z_t = e^{y_t}$ وللحصول على النتائج النهائية نجري التحويل $y_t = \ln(z_t)$

النتائج:

```
MTB > Name c14 = 'RESI3' c15 = 'FITS3'
MTB > ARIMA 0 1 0 0 1 1 12 'y(t)' 'RESI3' 'FITS3';
SUBC>   NoConstant;
SUBC>   Forecast 24 c7 c8 c9;
```

```
SUBC> GACF;  
SUBC> GPACF;  
SUBC> GHistogram;  
SUBC> GNormalplot.
```

ARIMA Model

ARIMA model for y(t)

Estimates at each iteration

Iteration	SSE	Parameters
0	0.0228597	0.100
1	0.0204943	0.250
2	0.0187066	0.400
3	0.0174234	0.550
4	0.0169841	0.684
5	0.0169841	0.683
6	0.0169841	0.683

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
SMA 12	0.6831	0.0610	11.20

Differencing: 1 regular, 1 seasonal of order 12

Number of observations: Original series 168, after differencing 155

Residuals: SS = 0.0165799 (backforecasts excluded)

MS = 0.0001077 DF = 154

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36
48			
Chi-Square	9.0 (DF=11)	29.9 (DF=23)	44.5 (DF=35)
	59.4 (DF=47)		

Forecasts from period 168

95 Percent Limits

Period	Forecast	Lower	Upper
Actual			
169	6.76750	6.74716	6.78784
170	6.70901	6.68024	6.73778
171	6.83815	6.80292	6.87338
172	6.85381	6.81313	6.89450
173	6.92288	6.87739	6.96836
174	6.89349	6.84366	6.94331
175	6.84654	6.79272	6.90035
176	6.80008	6.74255	6.85761
177	6.74395	6.68293	6.80497
178	6.75028	6.68596	6.81461
179	6.70664	6.63918	6.77410
180	6.75999	6.68952	6.83045
181	6.79052	6.71514	6.86590
182	6.73203	6.65203	6.81203
183	6.86117	6.77680	6.94554
184	6.87684	6.78832	6.96535
185	6.94590	6.85342	7.03838
186	6.91651	6.82023	7.01279
187	6.86956	6.76962	6.96950
188	6.82310	6.71963	6.92657
189	6.76697	6.66009	6.87385
190	6.77330	6.66312	6.88349
191	6.72966	6.61627	6.84305
192	6.78301	6.66649	6.89952

أي أن النموذج المقترن لهذه المتسلسلة هو

$$(1 - B^{12})(1 - B) \ln(z_t) = (1 - 0.683B^{12})a_t, \quad a_t \sim N(0, 0.0001077)$$

لاحظ ان

$$\Theta = 0.683, \quad s.e.(\Theta) = 0.061, \quad t = 11.2$$

أي ان المعلم عالي المعنوية.

فحص الباقي:

اختبار المتوسط

MTB > ZTest 0.0 0.0103778 'RESI3';

SUBC> Alternative 0.

Z-Test

Test of mu = 0.000000 vs mu not = 0.000000

The assumed sigma = 0.0104

Variable	N	Mean	StDev	SE Mean	Z	P
RESI3	155	-0.000111	0.010375	0.000834	-0.13	0.89

لاحظ ان الـ P-value=0.89 وهي اكبر من 0.05 اي لا نرفض أن متوسط الباقي صفر

اختبار عشوائية الباقي

MTB > Runs 0 'RESI3'.

Runs Test

RESI3

K = 0.0000

The observed number of runs = 70

The expected number of runs = 78.1097

72 Observations above K 83 below

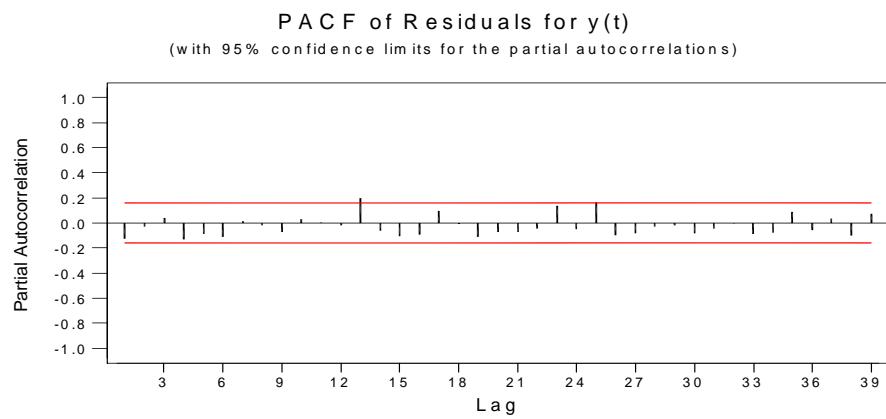
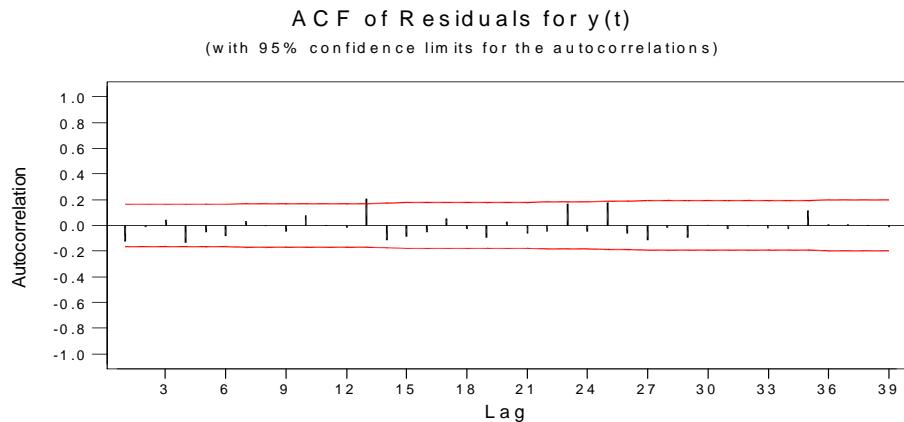
The test is significant at 0.1893

Cannot reject at alpha = 0.05

الاختبار معنوي عند 0.1893 اي انا لا نرفض فرضية عشوائية الباقي

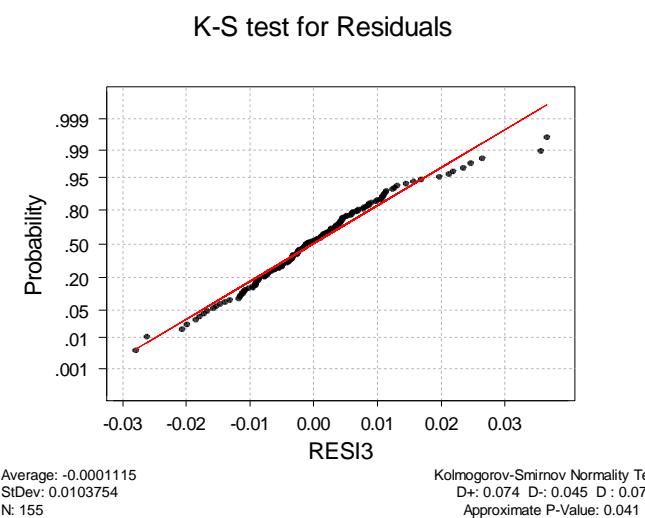
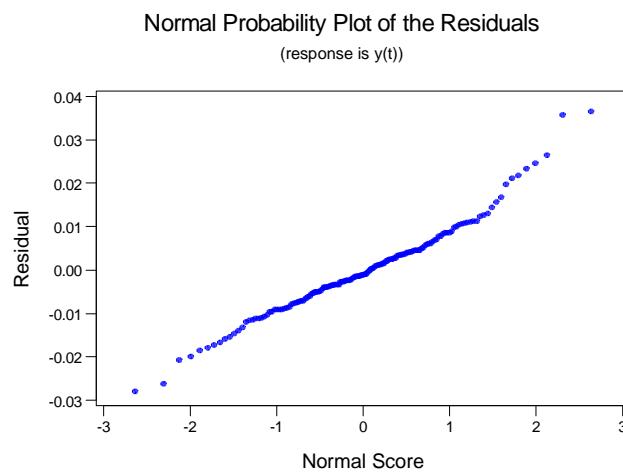
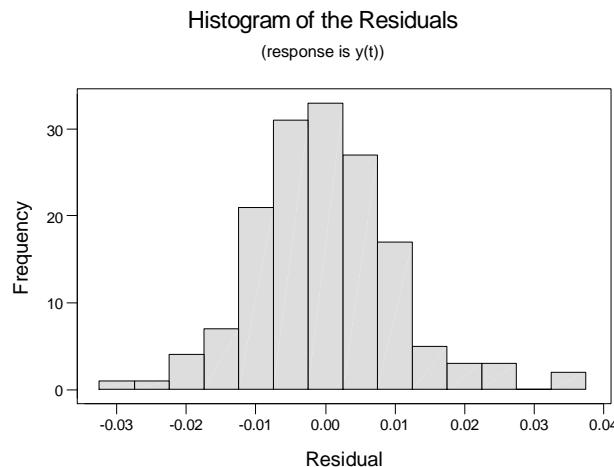
اختبار استقلال الباقي:

دوال الترابط الذاتي والترابط الذاتي الجزئي



نلاحظ أنها تعطي انماط الضجة البيضاء أي أنها غير مترابطة وإذا كانت طبيعية فهي مستقلة.

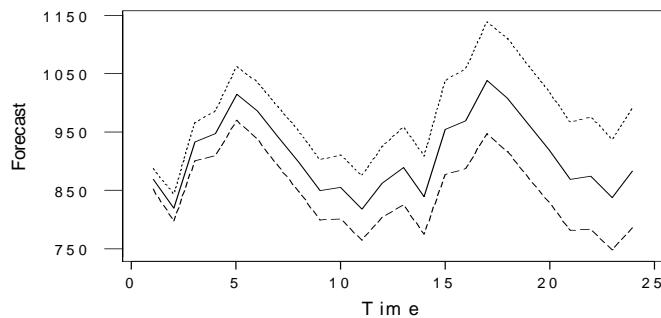
اختبار طبيعية الباقي:



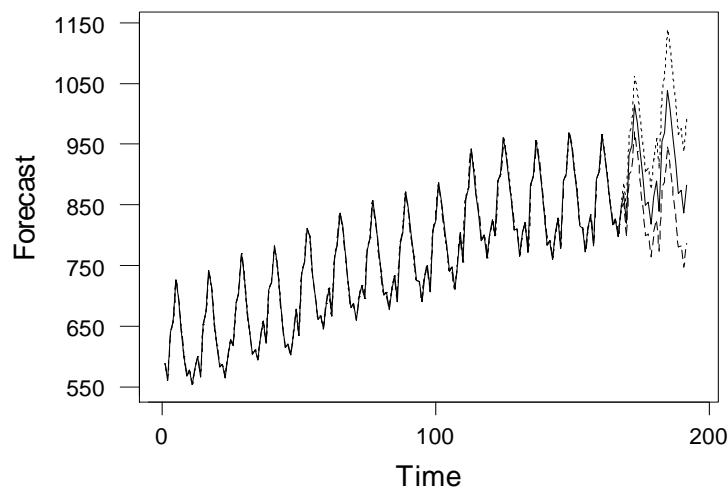
لاحظ ان الـ $P\text{-value}$ لاختبار K-S يعطي 0.041 وهي اقل من 0.05 اذا الاختبار معنوي عند $\alpha = 0.05$.

التنبؤ باستخدام النموذج:

في المخرجات السابقة قمنا بالتنبؤ عن 24 قيمة مستقبلية مع 95% فترات تنبؤ ونرسمها بالرسم التالي:



والرسم التالي للمتسلسلة مع التنبؤات وحدود التنبؤ



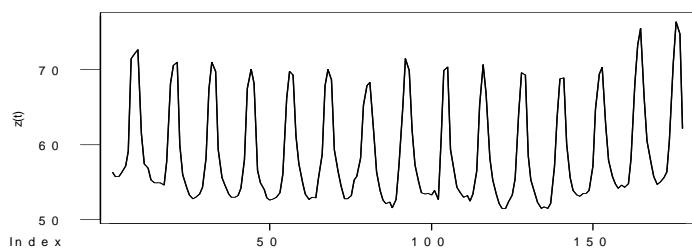
حالة دراسة :

سوف نحاول إيجاد نموذج من عائلة SARIMA ينطبق على المشاهدات التالية:

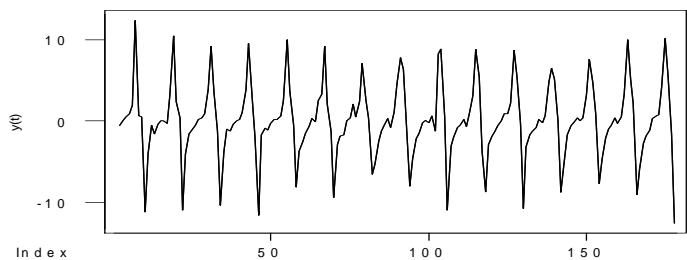
$z(t)$	56.3	55.7	55.8	56.3	57.2	59.1	71.5	72.2
	72.7	61.5	57.4	56.9	55.3	54.9	54.9	54.9
	54.6	57.7	68.2	70.6	71.0	60.0	56.0	54.4

53.3	52.8	53.0	53.4	54.3	58.2	67.4	71.0
69.8	59.4	55.6	54.6	53.4	53.0	53.0	53.2
54.2	58.0	67.5	70.1	68.2	56.6	54.9	54.0
52.9	52.6	52.8	53.0	53.6	56.1	66.1	69.8
69.3	61.2	57.5	54.9	53.4	52.7	53.0	52.9
55.4	58.7	67.9	70.0	68.7	59.3	56.4	54.5
52.8	52.8	53.2	55.3	55.8	58.2	65.3	67.9
68.3	61.7	56.4	53.9	52.6	52.1	52.4	51.6
52.7	57.3	65.1	71.5	69.9	61.9	57.3	55.1
53.6	53.4	53.5	53.3	53.9	52.7	61.0	69.9
70.4	59.4	56.3	54.3	53.5	53.0	53.2	52.5
53.4	56.5	65.3	70.7	66.9	58.2	55.3	53.4
52.1	51.5	51.5	52.4	53.3	55.5	64.2	69.6
69.3	58.5	55.3	53.6	52.3	51.5	51.7	51.5
52.2	57.1	63.6	68.8	68.9	60.1	55.6	53.9
53.3	53.1	53.5	53.5	53.9	57.1	64.7	69.4
70.3	62.6	57.9	55.8	54.8	54.2	54.6	54.3
54.8	58.1	68.1	73.3	75.5	66.4	60.5	57.7
55.8	54.7	55.0	55.6	56.4	60.6	70.8	76.4
74.8	62.2						

المخطط الزمني

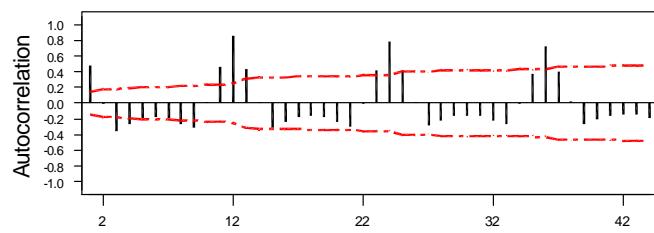


بأخذ الفرق الأول لاستقرار المتوسط $w_t = (1 - B)z_t$ نجد



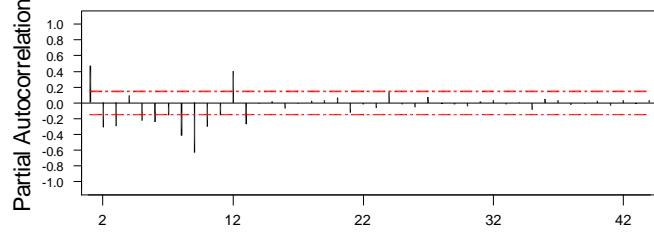
ولها دوال ترابط ذاتي وترابط ذاتي جزئي

Autocorrelation Function for $y(t)$



Lag	Corr	T	LBQ												
1	0.47	6.32	40.60	13	0.43	2.76	354.69	25	0.41	2.06	638.60	37	0.40	1.72	896.48
2	-0.02	0.22	40.67	14	-0.01	-0.03	354.69	26	-0.00	-0.01	638.60	38	0.02	0.07	896.54
3	-0.37	4.10	65.83	15	-0.33	-2.00	375.77	27	-0.29	-1.43	656.89	39	-0.27	-1.14	913.29
4	-0.28	2.82	80.10	16	-0.25	-1.49	380.04	28	-0.23	-1.08	667.77	40	-0.21	-0.89	923.75
5	-0.21	2.00	67.92	17	-0.19	-1.12	395.15	29	-0.17	-0.82	674.14	41	-0.17	-0.71	930.47
6	-0.19	-1.77	94.41	18	-0.17	-0.97	400.68	30	-0.16	-0.78	679.93	42	-0.15	-0.61	935.55
7	-0.21	-1.92	102.29	19	-0.19	-1.09	407.71	31	-0.17	-0.83	686.56	43	-0.16	-0.65	941.37
8	-0.27	-2.46	115.89	20	-0.25	-1.42	419.89	32	-0.23	-1.06	697.63	44	-0.20	-0.83	950.82
9	-0.32	-2.85	135.47	21	-0.31	-1.76	438.21	33	-0.28	-1.31	714.89				
10	-0.00	-0.02	135.48	22	-0.01	-0.06	438.24	34	-0.01	-0.06	714.93				
11	0.46	3.91	176.37	23	0.42	2.35	475.10	35	0.37	1.70	745.11				
12	0.86	6.71	318.37	24	0.79	4.28	602.75	36	0.72	3.27	860.42				

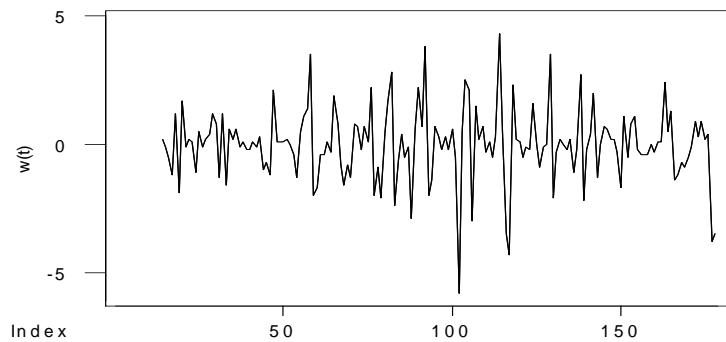
Partial Autocorrelation Function for $y(t)$



Lag	PAC	T									
1	0.47	6.32	13	-0.27	-3.62	25	-0.02	-0.33	37	0.03	0.38
2	-0.32	-4.21	14	-0.01	-0.17	26	-0.06	-0.74	38	-0.03	-0.35
3	-0.30	-4.00	15	0.01	0.13	27	0.07	0.99	39	-0.01	-0.17
4	0.09	1.22	16	-0.07	-0.95	28	-0.00	-0.05	40	0.02	0.23
5	-0.23	-3.05	17	-0.01	-0.16	29	-0.02	-0.26	41	-0.04	-0.56
6	-0.25	-3.33	18	0.02	0.24	30	-0.04	-0.60	42	0.03	0.35
7	-0.16	-2.09	19	0.03	0.44	31	0.01	0.20	43	-0.00	-0.00
8	-0.43	-5.67	20	0.07	0.89	32	0.03	0.37	44	0.03	0.43
9	-0.64	-8.56	21	-0.12	-1.62	33	-0.02	-0.25			
10	-0.31	-4.11	22	-0.02	-0.26	34	0.00	0.06			
11	-0.16	-2.18	23	-0.06	-0.86	35	-0.09	-1.17			
12	0.41	5.42	24	0.13	1.74	36	0.05	0.61			

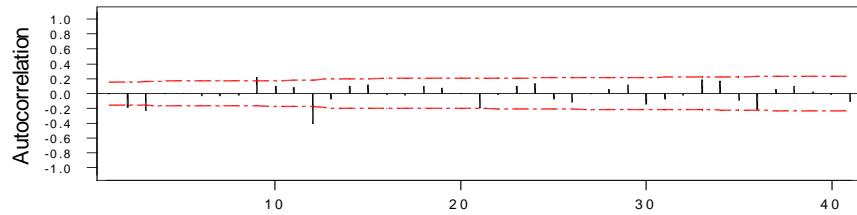
نرى أنها تحتاج إلى تفريغ موسمي من الرتبة 12 أي $w_t = (1 - B^{12})(1 - B)(z_t)$ وينتج المتسلسلة

التالية



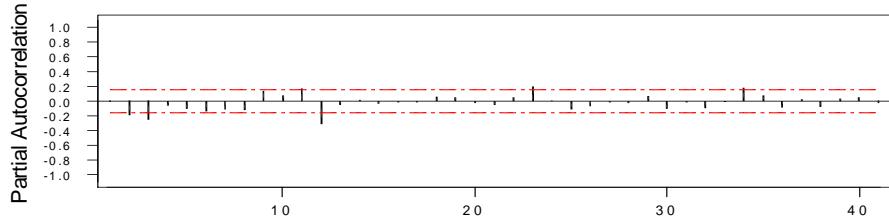
ولها دوال ترابط ذاتي وترتبط ذاتي جزئي

Autocorrelation Function for $w(t)$



Lag	Corr	T	LB Q	Lag	Corr	T	LB Q	Lag	Corr	T	LB Q	Lag	Corr	T	LB Q
1	-0.01	-0.19	0.04	13	-0.08	-0.84	60.69	25	-0.08	-0.76	83.09	37	0.05	0.46	122.40
2	-0.19	-2.48	6.31	14	0.10	0.98	62.50	26	-0.13	-1.18	86.28	38	0.10	0.84	124.52
3	-0.24	-2.97	16.10	15	0.12	1.15	65.01	27	-0.01	-0.13	86.33	39	0.02	0.15	124.59
4	-0.00	-0.03	16.10	16	-0.02	-0.17	65.07	28	0.06	0.56	87.07	40	-0.02	-0.16	124.67
5	0.00	0.03	16.10	17	-0.03	-0.28	65.22	29	0.12	1.09	89.94	41	-0.12	-1.01	127.84
6	-0.04	-0.50	16.41	18	0.10	1.01	67.24	30	-0.15	-1.36	94.47				
7	-0.04	-0.49	16.71	19	0.07	0.70	68.23	31	-0.08	-0.72	95.80				
8	-0.03	-0.31	16.83	20	-0.01	-0.05	68.24	32	-0.03	-0.28	96.01				
9	0.22	2.56	25.26	21	-0.20	-1.94	75.94	33	0.19	1.66	103.20				
10	0.10	1.16	27.13	22	-0.02	-0.23	76.05	34	0.17	1.49	109.19				
11	0.08	0.93	28.37	23	0.10	0.95	78.02	35	-0.10	-0.86	111.24				
12	-0.42	-4.63	59.40	24	0.14	1.30	81.78	36	-0.22	-1.92	121.77				

Partial Autocorrelation Function for $w(t)$



Lag	PAC	T									
1	-0.01	-0.19	13	-0.05	-0.69	25	-0.12	-1.49	37	0.02	0.24
2	-0.19	-2.48	14	0.01	0.15	26	-0.08	-0.97	38	-0.08	-1.06
3	-0.26	-3.28	15	-0.04	-0.50	27	-0.03	-0.32	39	0.03	0.44
4	-0.07	-0.85	16	-0.03	-0.33	28	-0.03	-0.36	40	0.05	0.63
5	-0.11	-1.43	17	-0.02	-0.23	29	0.07	0.87	41	-0.03	-0.36
6	-0.14	-1.84	18	0.06	0.78	30	-0.11	-1.39			
7	-0.11	-1.46	19	0.05	0.62	31	-0.02	-0.29			
8	-0.13	-1.66	20	-0.03	-0.42	32	-0.10	-1.29			
9	0.14	1.76	21	-0.05	-0.68	33	-0.01	-0.09			
10	0.07	0.95	22	0.05	0.63	34	0.18	2.31			
11	0.17	2.19	23	0.19	2.50	35	0.07	0.95			
12	-0.32	-4.08	24	0.01	0.09	36	-0.09	-1.18			

من الأنماط المشاهدة لدوال الترابط الذاتي والترابط الذاتي الجزئي قد يكون النموذج المناسب هو أي SARIMA(1,1,1)(0,1,1)_{I2}

$$(1-\phi B)(1-B^{12})(1-B)z_t = (1-\theta B)(1-\Theta B^{12})a_t$$

نطبق هذا النموذج على المتسلسلة كالتالي:

```
MTB > ARIMA 1 1 1 0 1 1 12 'z(t)' 'RESI2';
SUBC>   NoConstant;
SUBC>   GACF;
SUBC>   GPACF;
SUBC>   GHistogram;
SUBC>   GNormalplot.
```

ARIMA Model

ARIMA model for z(t)

Estimates at each iteration

Iteration	SSE	Parameters		
0	307.653	0.100	0.100	0.100
1	281.217	0.100	0.100	0.250
2	262.275	0.226	0.231	0.400
3	262.027	0.376	0.381	0.401
4	261.770	0.526	0.531	0.401
5	261.426	0.675	0.681	0.402
6	260.905	0.824	0.831	0.403
7	260.036	0.970	0.981	0.405
8	227.926	0.835	0.980	0.536
9	221.838	0.748	0.980	0.576
10	221.665	0.738	0.980	0.586
11	221.637	0.738	0.980	0.589
12	221.610	0.737	0.980	0.589
13	221.585	0.737	0.980	0.590

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.7374	0.0620	11.89
MA 1	0.9796	0.0017	582.86
SMA 12	0.5898	0.0736	8.01

```

Differencing: 1 regular, 1 seasonal of order 12
Number of observations: Original series 178, after
differencing 165
Residuals: SS = 214.393 (backforecasts excluded)
            MS = 1.323 DF = 162

```

Modified Box-Pierce (Ljung-Box) Chi-Square statistic			
Lag	12	24	36
Chi-Square	15.7 (DF= 9)	30.9 (DF=21)	61.6 (DF=33)
	67.1 (DF=45)		

أي أن النموذج المقترن لهذه المتسلسلة هو

$$(1 - 0.74B)(1 - B^{12})(1 - B)z_t = (1 - 0.98B)(1 - 0.59B^{12})a_t, \quad a_t \sim N(0, 1.323)$$

لاحظ ان

$$\phi = 0.74, \quad s.e.(\phi) = 0.062, \quad t = 11.89$$

$$\theta = 0.96, \quad s.e.(\theta) = 0.0017, \quad t = 582.86$$

$$\Theta = 0.59, \quad s.e.(\Theta) = 0.074, \quad t = 8.01$$

أي ان المعالم عالية المعنوية.

فحص الباقي:

اختبار المتوسط

```

MTB > ZTest 0.0 1.15 'RESI1';
SUBC> Alternative 0.

```

Z-Test

```

Test of mu = 0.0000 vs mu not = 0.0000
The assumed sigma = 1.15

```

Variable	N	Mean	StDev	SE Mean	Z	P
RESI1	165	-0.0144	1.1433	0.0895	-0.16	0.87

لاظ ان الـ P-value=0.87 وهي اكبر من 0.05 اي لا نرفض أن متوسط الباقي صفراء

اختبار عشوائية الباقي

```
MTB > Runs 0 'RESI1'.
```

Runs Test

RESI1

K = 0.0000

The observed number of runs = 67

The expected number of runs = 82.4061

73 Observations above K 92 below

The test is significant at 0.0149

الاختبار غير معنوي عند 0.05 اي اننا نرفض فرضية عشوائية البوافي وهذا يحتاج إلى إجراء اختبار آخر أكثر قوة من اختبار الجري مثل اختبار الإشارة Sign Test على الوسيط التالي:

```
MTB > STest 0.0 'RESI1';
SUBC> Alternative 0.
```

Sign Test for Median

Sign test of median = 0.00000 versus not = 0.00000

	N	N*	Below	Equal	Above	P	Median
RESI1	165	13	92	0	73	0.1611	-0.08139

والاختبار معنوي عند 0.1611 وللتتأكد نجري اختبار ولكوكسون لإشارات الرتب على الوسيط التالي

```
MTB > WTest 0.0 'RESI1';
SUBC> Alternative 0.
```

Wilcoxon Signed Rank Test

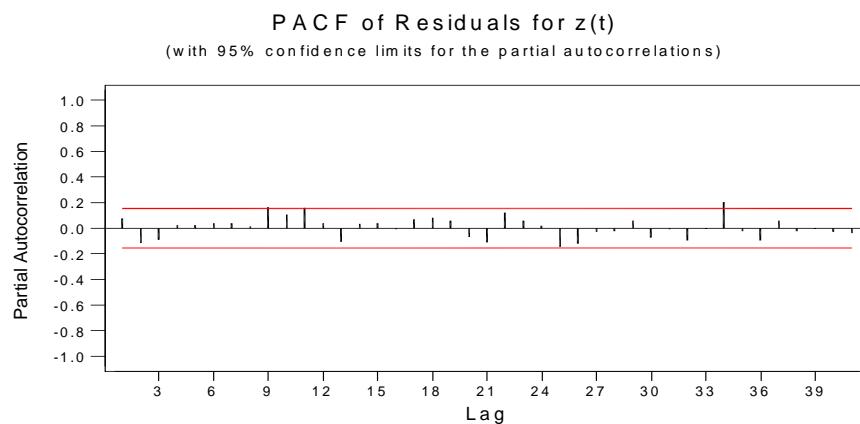
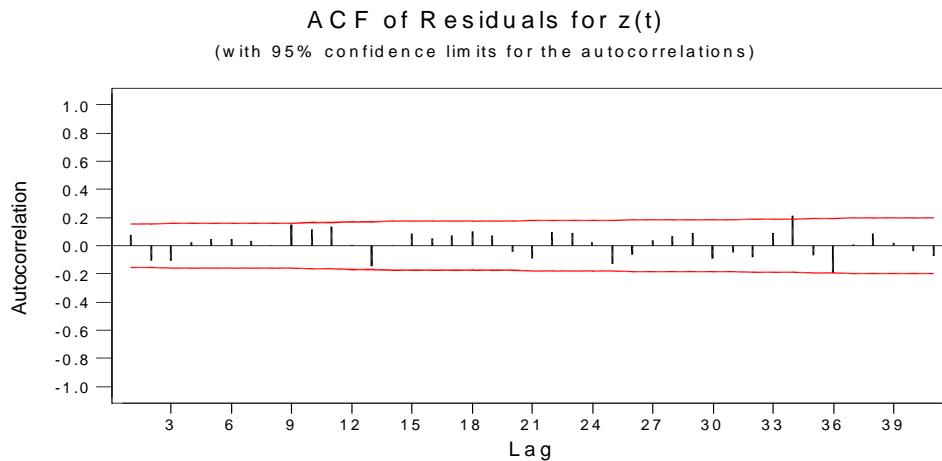
Test of median = 0.000000 versus median not = 0.000000

	Number	N for	Wilcoxon	Estimated	
	N	Missing	Test Statistic	P	Median
RESI1	165	13	165	6321.0	0.392 -0.05940

والاختبار ايضاً معنوي عند 0.392

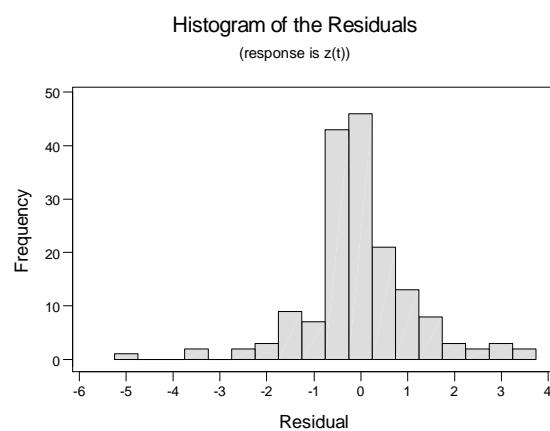
اختبار استقلال البوافي:

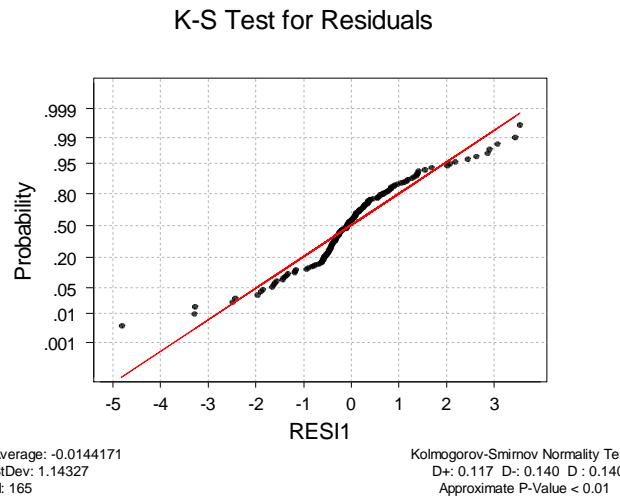
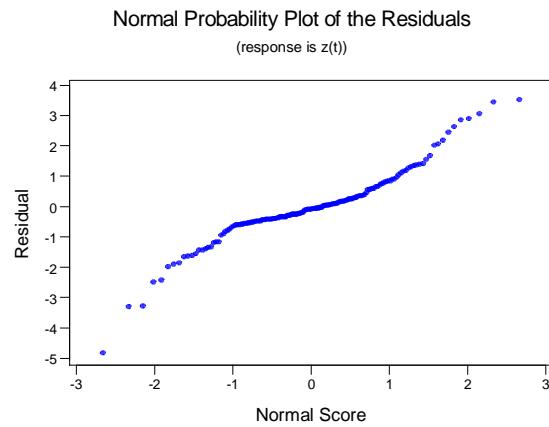
دوال الترابط الذاتي والترابط الذاتي الجزئي



نلاحظ انها تعطي انماط الضجة البيضاء أي انها غير مترابطة وإذا كانت طبيعية فهى مستقلة.

اختبار طبيعة الباقي:





لاحظ ان الـ P-value لاختبار K-S أقل من 0.01 اذا الاختبار معنوي عند $\alpha=0.05$ اي لا نرفض فرضية طبيعية الباقي.

التنبؤ باستخدام النموذج:

سنقوم بالتنبؤ عن 36 قيمة مستقبلية مع 95% فترات تنبؤ

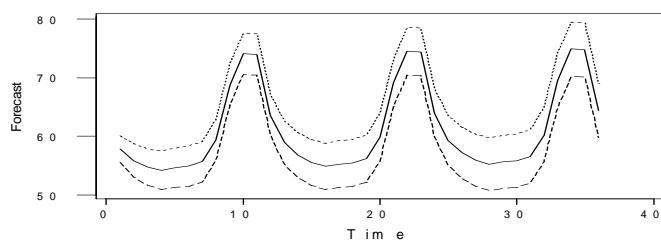
Forecasts from period 178

95 Percent Limits

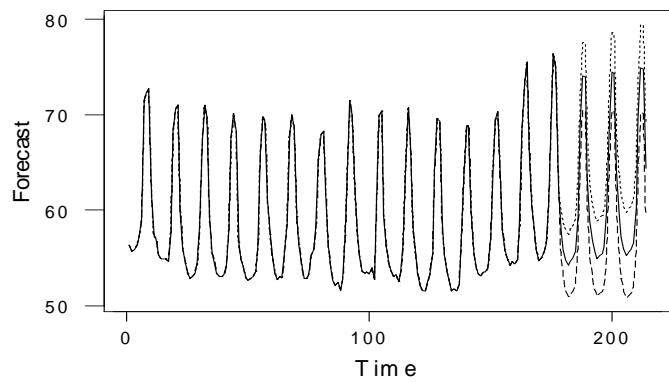
Period	Forecast	Lower	Upper	Actual
179	57.7885	55.5332	60.0437	
180	55.8516	53.0220	58.6812	
181	54.7429	51.6264	57.8594	
182	54.1820	50.9063	57.4578	

183	54.6298	51.2601	57.9994
184	54.9152	51.4875	58.3430
185	55.6640	52.1986	59.1294
186	59.3778	55.8869	62.8688
187	68.6924	65.1833	72.2015
188	74.0698	70.5472	77.5925
189	73.9650	70.4317	77.4983
190	63.5866	60.0447	67.1286
191	58.9095	55.1843	62.6347
192	56.7768	52.9407	60.6128
193	55.5237	51.6169	59.4305
194	54.8564	50.9022	58.8105
195	55.2256	51.2380	59.2131
196	55.4531	51.4409	59.4653
197	56.1592	52.1278	60.1905
198	59.8416	55.7947	63.8885
199	69.1329	65.0729	73.1929
200	74.4932	70.4217	78.5647
201	74.3758	70.2940	78.4575
202	63.9881	59.8968	68.0793
203	59.3041	55.0418	63.5664
204	57.1663	52.7962	61.5364
205	55.9095	51.4676	60.3514
206	55.2394	50.7472	59.7315
207	55.6066	51.0774	60.1357
208	55.8326	51.2749	60.3903
209	56.5376	51.9568	61.1184
210	60.2191	55.6189	64.8194
211	69.5099	64.8927	74.1270
212	74.8697	70.2374	79.5021
213	74.7520	70.1057	79.3983
214	64.3640	59.7046	69.0235

ونرسمها بالرسم التالي:



الرسم التالي للمتسلسلة بكاملها مع التنبؤات وفترات التنبؤ



الفصل السابع

ورقة تدريب عملی على التنبؤ بواسطة نماذج المتوسط المتحرك-الإتحاد الذاتي

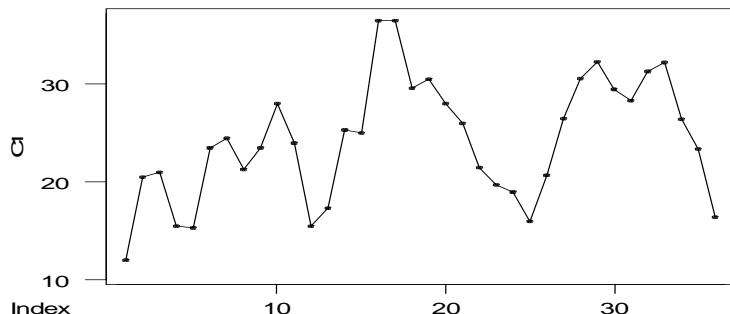
Forecasting By ARMA Models

المشاهدات التالية لظاهرة عشوائية مسجلة على شكل متسلسلة زمنية

12.0	20.5	21.0	15.5	15.3	23.5	24.5	21.3
23.5	28.0	24.0	15.5	17.3	25.3	25.0	36.5
36.5	29.6	30.5	28.0	26.0	21.5	19.7	19.0
16.0	20.7	26.5	30.6	32.3	29.5	28.3	31.3
32.2	26.4	23.4	16.4				

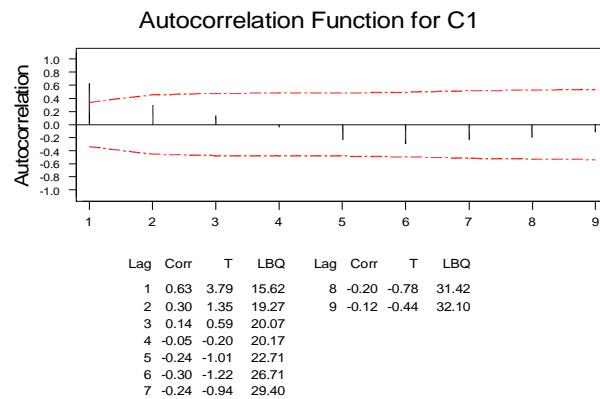
ولها الشكل التالي:

```
MTB > TSPlot C1;
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect.
```



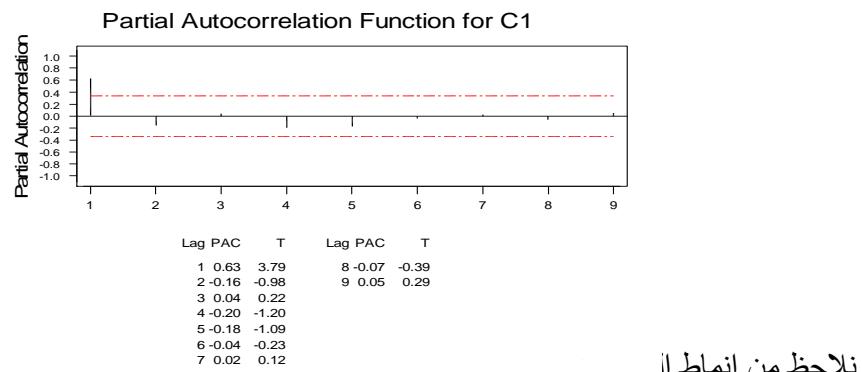
اولاً نوجد دوال الترابط الذاتي والترابط الذاتي الجزئي

MTB > %ACF C1.



MTB > %PACF C1.

Executing from file: E:\MTBWIN\MACROS\PACF.MAC



نلاحظ من انمطاً

نطبق النموذج المقترن

```
MTB > Name c17 = 'RESI1'  
MTB > ARIMA 1 0 1 C1 'RESI1';  
SUBC> Constant;  
SUBC> Forecast 5 c14 c15 c16;  
SUBC> GACF;  
SUBC> GPACF;  
SUBC> GNormalplot.
```

ARIMA Model

ARIMA model for C1

Estimates at each iteration

Iteration	SSE	Parameters		
0	1337.71	0.100	0.100	21.918
1	936.95	0.250	-0.049	18.193
2	849.78	0.211	-0.199	19.106
3	751.53	0.215	-0.349	18.941
4	658.66	0.266	-0.499	17.594
5	592.30	0.372	-0.649	14.890
6	580.80	0.433	-0.699	13.314
7	579.30	0.455	-0.714	12.698
8	579.11	0.464	-0.719	12.470
9	579.08	0.467	-0.721	12.386
10	579.08	0.468	-0.722	12.356
11	579.08	0.468	-0.722	12.345

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.4684	0.1755	2.67
MA 1	-0.7221	0.1380	-5.23
Constant	12.345	1.154	10.70
Mean	23.221	2.170	

Number of observations: 36

Residuals: SS = 523.365 (backforecasts excluded)
MS = 15.860 DF = 33

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	7.2 (DF=10)	15.9 (DF=22)	* (DF= *)	* (DF= *)

Forecasts from period 36

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
37	14.7649	6.9578	22.5720

38	19.2606	7.1228	31.3985
39	21.3663	8.4715	34.2610
40	22.3524	9.2975	35.4074
41	22.8143	9.7245	35.9041

النموذج المقترن هو:

$$z_t = 12.345 + 0.4684 z_{t-1} + a_t - 0.7221 a_{t-1}, \quad a_t \sim WN(0, 15.86) \quad \forall t$$

حيث

$$\hat{\phi}_1 = 0.4684 \quad se(\hat{\phi}_1) = 0.1755 \quad t = 2.67$$

$$\hat{\theta}_1 = -0.7221 \quad se(\hat{\theta}_1) = 0.1380 \quad t = -5.23$$

$$\hat{\delta} = 12.345 \quad se(\hat{\delta}) = 1.154 \quad t = 10.70$$

$$\hat{\sigma}^2 = 15.86 \quad df = 33$$

ونلاحظ ان جميع المقدرات معنوية عند $\alpha = 0.05$ فمثلا الفرضية

$$H_0 : \phi_1 = 0$$

$$H_1 : \phi_1 \neq 0$$

نختبرها بالإحصاء $t = \frac{\hat{\phi}_1}{se(\hat{\phi}_1)} = \frac{0.4684}{0.1755} = 2.6689$ وهي معنوية عند $\alpha = 0.05$ أي

اننا نرفض ان $\phi_1 = 0$ وبالمثل لجميع القدرات الاخرى

ثانياً فحص الباقي

اختبار متوسط الباقي:

الاختبار هو

$$H_0 : \mu_a = 0, \quad H_1 : \mu_a \neq 0$$

```
MTB > TTest 0.0 'RESI1';
SUBC> Alternative 0.
```

T-Test of the Mean

```
Test of mu = 0.000 vs mu not = 0.000
```

Variable	N	Mean	StDev	SE Mean	T	P
----------	---	------	-------	---------	---	---

RESI1 36 0.344 3.851 0.642 0.54 0.60
 لاحظ ان $t = 0.54$ وال $P\text{-Value} = 0.6$ لها هي 0.6 وهي اكبر من $\alpha = 0.05$ أي ان الإختبار غير معنوي أي يمكن اعتبار متوسط الباقي يساوي الصفر

إختبار عشوائية الباقي:

ونستخدم لذلك إختبار الجري Runs Test

MTB > Runs 'RESI1'.

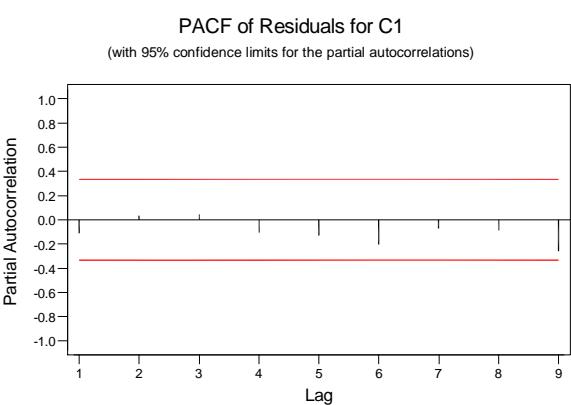
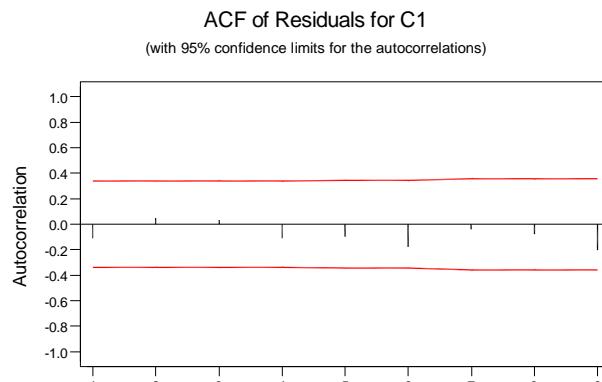
Runs Test

```
RESI1
K = 0.3443
The observed number of runs = 21
The expected number of runs = 19.0000
18 Observations above K 18 below
The test is significant at 0.4989
Cannot reject at alpha = 0.05
```

لما كنا رفض عشوائية الباقي عند $\alpha = 0.05$

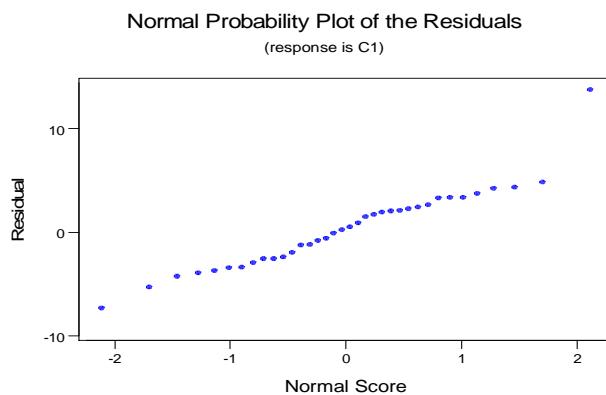
إختبار ترابط الباقي:

ونستخدم لذلك إختبار الترابط الذاتي



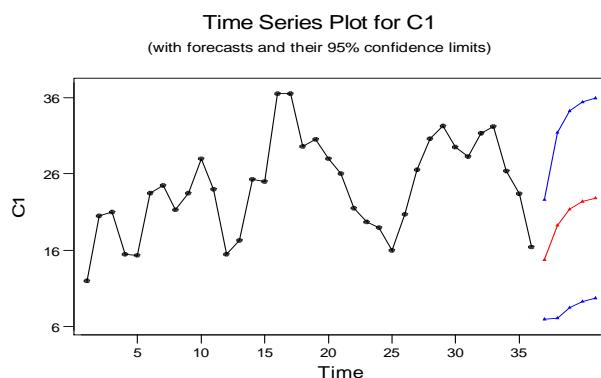
نلاحظ انه لا يوجد أي ترابط من أي درجة بين القيم المختلفة للبواقي أي انها تظهر انمط تتمشى مع كونها متسلسة ضجة بيضاء

واخيرا نختبر طبيعية البواقي بالـ Normal Probability Plot



وهو مقبول (نوعا)
إذا يمكن اعتبار النموذج المقترن مناسبا
الرسم التالي للتنبؤات لخمسة قيم مستقبلية وفترات 95% تتبع لها

```
MTB > TSPlot C14 C15 C16;
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect;
SUBC> overlay.
```

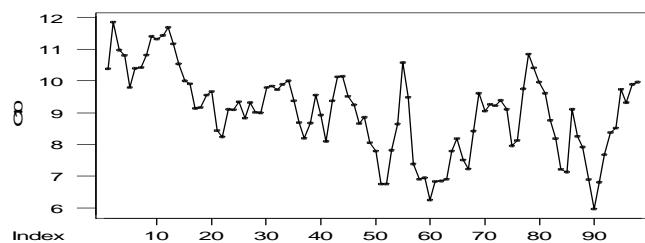


مثال آخر:

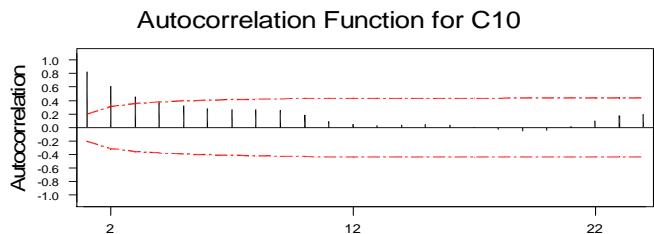
المشاهدات التالية لظاهرة عشوائية مسجلة على شكل متسلسلة زمنية

10.38	11.86	10.97	10.80	9.79	10.39	10.42	10.82
11.40	11.32	11.44	11.68	11.17	10.53	10.01	9.91
9.14	9.16	9.55	9.67	8.44	8.24	9.10	9.09
9.35	8.82	9.32	9.01	9.00	9.80	9.83	9.72
9.89	10.01	9.37	8.69	8.19	8.67	9.55	8.92
8.09	9.37	10.13	10.14	9.51	9.24	8.66	8.86
8.05	7.79	6.75	6.75	7.82	8.64	10.58	9.48
7.38	6.90	6.94	6.24	6.84	6.85	6.90	7.79
8.18	7.51	7.23	8.42	9.61	9.05	9.26	9.22
9.38	9.10	7.95	8.12	9.75	10.85	10.41	9.96
9.61	8.76	8.18	7.21	7.13	9.10	8.25	7.91
6.89	5.96	6.80	7.68	8.38	8.52	9.74	9.31
9.89	9.96						

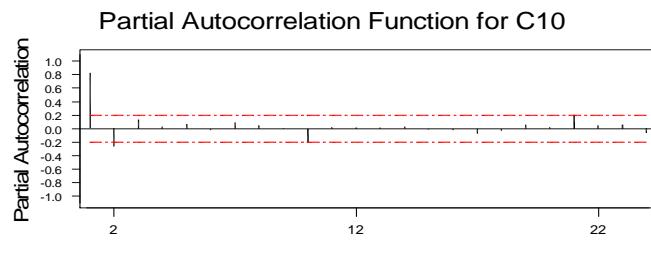
```
MTB > TSPlot C10;
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect.
```



نفحص دوال الترابط الذاتي والترابط الذاتي الجزئي



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.83	8.24	69.92	8	0.26	1.26	178.83	15	0.05	0.21	191.63	22	0.10	0.47	194.02
2	0.61	3.91	107.90	9	0.26	1.21	186.14	16	0.04	0.16	191.78	23	0.18	0.81	198.12
3	0.46	2.56	129.56	10	0.18	0.84	189.86	17	0.00	0.02	191.78	24	0.20	0.89	203.24
4	0.37	1.95	143.87	11	0.09	0.43	190.87	18	-0.03	-0.15	191.91				
5	0.33	1.65	155.04	12	0.04	0.20	191.09	19	-0.05	-0.24	192.26				
6	0.28	1.40	163.68	13	0.03	0.13	191.19	20	-0.05	-0.24	192.60				
7	0.26	1.28	171.23	14	0.04	0.19	191.39	21	0.01	0.07	192.63				



Lag	PAC	T									
1	0.83	8.24	8	0.05	0.45	15	-0.01	-0.15	22	0.05	0.51
2	-0.27	-2.64	9	0.00	0.03	16	-0.03	-0.25	23	0.06	0.59
3	0.13	1.29	10	-0.20	-1.98	17	-0.07	-0.73	24	-0.07	-0.65
4	0.03	0.34	11	0.02	0.19	18	-0.03	-0.26			
5	0.06	0.61	12	0.01	0.09	19	0.06	0.60			
6	-0.02	-0.21	13	0.01	0.12	20	0.02	0.20			
7	0.09	0.91	14	0.03	0.34	21	0.21	2.03			

نلاحظ ان الأنماط تقترح نموذج إنحدار ذاتي من الدرجة الثانية ($AR(2)$)

نطبق النموذج المقترن

```

MTB > Name c17 = 'RESI1'
MTB > ARIMA 2 0 0 C10 'RESI1';
SUBC> Constant;
SUBC> Forecast 5 c14 c15 c16;
SUBC> GSeries;
SUBC> GACF;
SUBC> GPACF;
SUBC> GNormalplot.

```

ARIMA Model

ARIMA model for C10

Estimates at each iteration

Iteration	SSE	Parameters		
0	126.398	0.100	0.100	7.283
1	103.515	0.250	0.043	6.434
2	84.535	0.400	-0.014	5.586
3	69.407	0.550	-0.071	4.738
4	58.132	0.700	-0.128	3.887
5	50.724	0.850	-0.184	3.030
6	47.212	1.000	-0.239	2.163
7	46.918	1.053	-0.256	1.838
8	46.916	1.054	-0.255	1.816
9	46.916	1.054	-0.255	1.814
10	46.916	1.054	-0.255	1.814

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	1.0542	0.0992	10.63
AR 2	-0.2547	0.0993	-2.56
Constant	1.81360	0.07092	25.57
Mean	9.0480	0.3538	

Number of observations: 98

Residuals: SS = 46.7518 (backforecasts excluded)
MS = 0.4921 DF = 95

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	7.2(DF=10)	13.7(DF=22)	21.3(DF=34)	
	28.8(DF=46)			

Forecasts from period 98

95 Percent Limits

Period	Forecast	Lower	Upper
Actual			

99	9.7950	8.4198	11.1703
100	9.6033	7.6050	11.6016
101	9.4432	7.1234	11.7629
102	9.3232	6.8446	11.8018
103	9.2375	6.6825	11.7925

النموذج المقترن هو

$$z_t = 1.8136 + 1.0542 z_{t-1} - 0.2547 z_{t-2} + a_t, \quad a_t \sim WN(0, 0.4921) \quad \forall t$$

مقدرات المعامل وإنحرافاتها المعيارية وقيم t لها هي

$$\hat{\phi}_1 = 1.0542 \quad se(\hat{\phi}_1) = 0.0992 \quad t = 10.63$$

$$\hat{\phi}_2 = -0.2547 \quad se(\hat{\phi}_2) = 0.0993 \quad t = -2.56$$

$$\hat{\delta} = 1.8136 \quad se(\hat{\delta}) = 0.07092 \quad t = 25.57$$

$$\hat{\sigma}^2 = 0.4921 \quad df = 95$$

نلاحظ ان جميع المقدرات معنوية عند $\alpha = 0.05$

لكي نقبل بهذا النموذج علي انه مناسب للتنبؤ نجري اختبارات علي الباقي

```
MTB > TTest 0.0 'RESI1';
SUBC> Alternative 0.
```

T-Test of the Mean

```
Test of mu = 0.0000 vs mu not = 0.0000
```

Variable	N	Mean	StDev	SE Mean	T	P
RESI1	98	-0.0082	0.6942	0.0701	-0.12	0.91

واضح جدا ان الاختبار غير معنوي (ملاحظة الـ P-Value) هي إحتمال ان الفرضية الصفرية

(صحيحة)

نختبر عشوائية الباقي

```
MTB > Runs 'RESI1'.
```

Runs Test

```
RESI1
```

```
K = -0.0082
```

```
The observed number of runs = 47
```

```
The expected number of runs = 49.9184
```

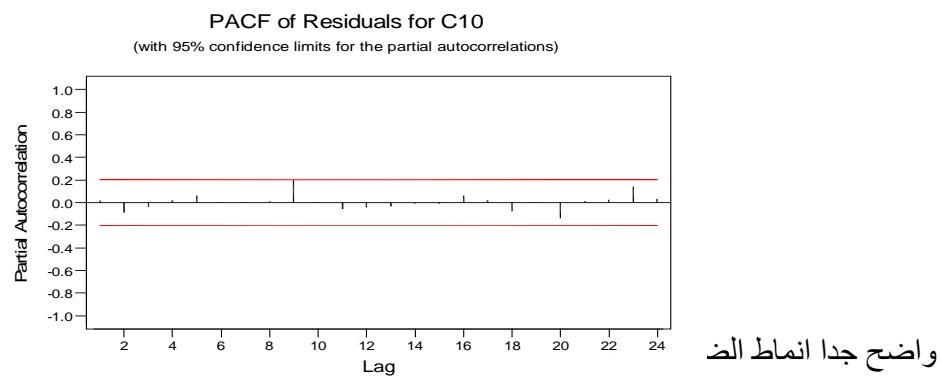
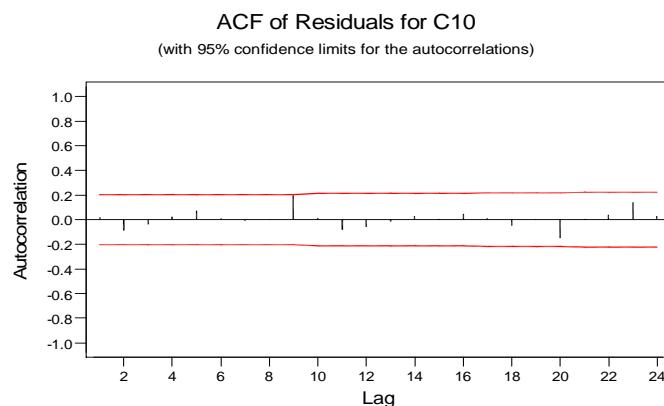
47 Observations above K 51 below

The test is significant at 0.5529

Cannot reject at alpha = 0.05

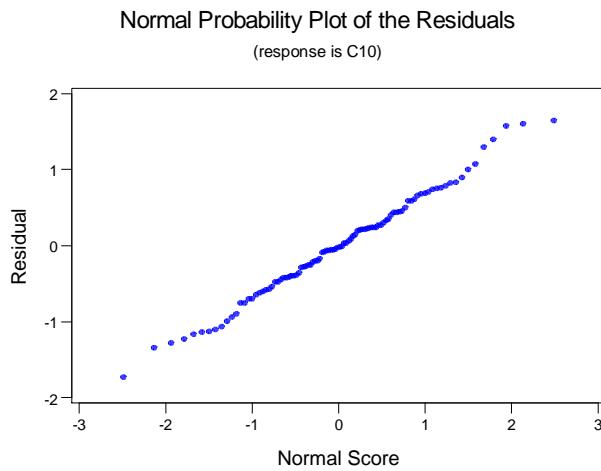
أي لا يمكننا رفض فرضية عشوائية الباقي

نفحص الترابط الذاتي والترابط الذاتي الجزئي



واضح جداً انماط الـ

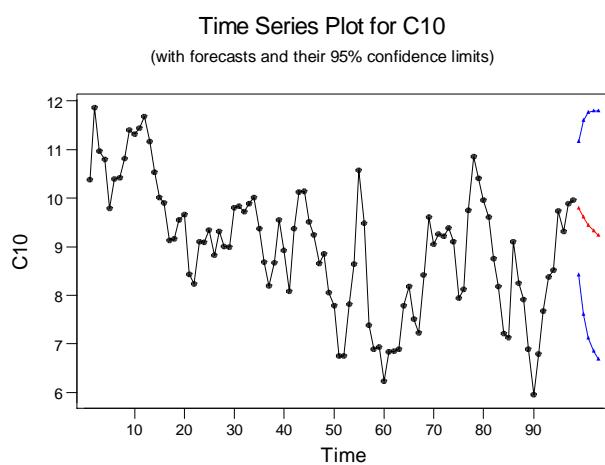
يبقى فحص طبيعة الباقي



ونستطيع ارجاع ذلك إلى انتشار اقل من 95% للبيانات حول الخط المترافق

الرسم التالي للتنبؤات لخمسة قيم مستقبلية وفترات 95% تنبؤ لها

```
MTB > TSPLOT C14 C15 C16;
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect;
SUBC> overlay.
```



تمرين: طبق على المشاهدات السابقة نموذج $AR(1)$ وقارن بين النتائج

الفصل الثامن

مثال على تحليل الباقي ومعايير اختيار النموذج المناسب

: Example on Residual Analysis and Model Selection Criteria

لقد عرفنا سابقاً الباقي على أنها القيم المشاهدة ناقص القيم المطبقة فمن مشاهدات معطاة z_1, z_2, \dots, z_n ونموذج مطبق ينتج لدينا قيم مطبقة $\hat{z}_1, \hat{z}_2, \dots, \hat{z}_n$ وتكتب الباقي:

$$e_i = z_i - \hat{z}_i, \quad i = 1, 2, \dots, n$$

والباقي هي مقدرات الأخطاء في النموذج أي $\hat{a}_i = e_i, i = 1, 2, \dots, n$ ولهذا يجب أن تتحقق الشروط المفروضة على الأخطاء في هذا النموذج والتي منها:

1- متوسط الأخطاء يساوي الصفر

2- الأخطاء عشوائية وغير مترابطة أو مستقلة (وفي كثير من النماذج نفترض أن الأخطاء لها توزيع طبيعي مستقل ومتطابق بمتوسط صفر وتبالين σ^2 أي $(a_t \sim IIDN(0, \sigma^2))$)

لهذا فإننا نجري تحليلًا وهو مجموعة من الإختبارات على الباقي لنري فيما إذا كانت تتحقق هذه الشروط وفي هذه الحالة نعتبر النموذج المطبق مقبولًا أما إذا فشل أحد هذه الإختبارات فيجب علينا إعادة النظر وإقتراح نموذج آخر
أولاً: اختبار المتوسط

$$H_0: E(a_t) = 0$$

$$H_1: E(a_t) \neq 0$$

وهو اختبار بذيلين ونستخدم فيه الإحصائية $\frac{\bar{e}}{se(\bar{e})} = u$ والتي لها توزيع طبيعي قياسي فعند

مستوى معنوية $\alpha = 0.05$ نعتبر ان $|u| > 1.96$ إذا كانت $E(a_t) \neq 0$ (هذا على اعتبار ان حجم العينة أكبر من 30 وحدة وهذا دائمًا متحقق للمتسلسلات الزمنية التي ندرسها)

مثال:

سوف نعود إلى مثال تطبيق متوسط متحرك من الدرجة الثالثة على المتغير Metals

```
MTB > RETR 'E:\Mtbwin\DATA\EMPLOY.MTW'.
```

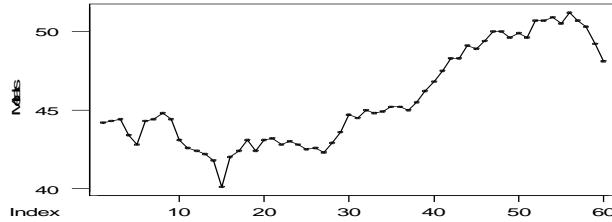
```
Retrieving worksheet from file: E:\Mtbwin\DATA\EMPLOY.MTW
```

```
Worksheet was saved on 6/ 5/1996
```

```
MTB > TSPlot 'Metals';
```

```
SUBC> Index;
```

```
SUBC> TDisplay 11;  
SUBC> Symbol;  
SUBC> Connect.
```



```
MTB > Name c4 = 'AVER1' c5 = 'FITS1' c6 = 'RESI1'  
MTB > %MA 'Metals' 3;  
SUBC> Averages 'AVER1';  
SUBC> Fits 'FITS1';  
SUBC> Residuals 'RESI1'.  
Executing from file: E:\MTBWIN\MACROS\MA.MAC
```

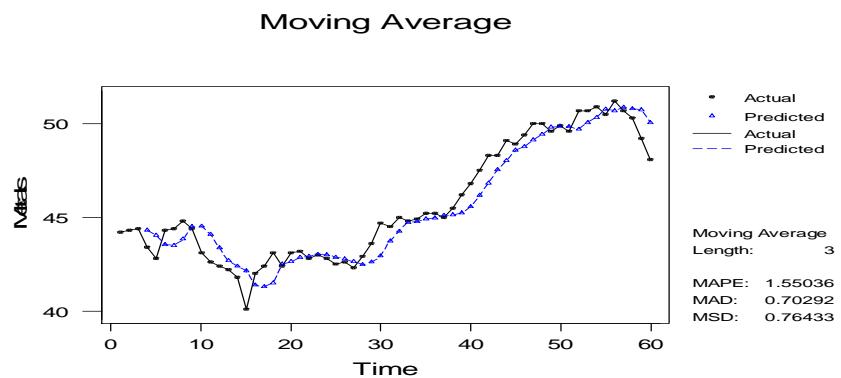
Moving average

```
Data          Metals  
Length       60.0000  
NMissing     0
```

Moving Average

Length: 3

```
Accuracy Measures  
MAPE: 1.55036  
MAD: 0.70292  
MSD: 0.76433
```



لاحظ اننا خزنا الباقي في العمود السادس والقيم المطبقة في العمود الخامس

MTB > print c3 c6 c5

Data Display

Row	Metals	RESI1	FITS1
1	44.2	*	*
2	44.3	*	*
3	44.4	*	*
4	43.4	-0.90000	44.3000
5	42.8	-1.23333	44.0333
6	44.3	0.76667	43.5333
7	44.4	0.90000	43.5000
8	44.8	0.96667	43.8333
9	44.4	-0.10000	44.5000
10	43.1	-1.43333	44.5333
11	42.6	-1.50000	44.1000
12	42.4	-0.96667	43.3667
13	42.2	-0.50000	42.7000
14	41.8	-0.60000	42.4000
15	40.1	-2.03333	42.1333

16	42.0	0.63333	41.3667
17	42.4	1.10000	41.3000
18	43.1	1.60000	41.5000
19	42.4	-0.10000	42.5000
20	43.1	0.46667	42.6333
21	43.2	0.33333	42.8667
22	42.8	-0.10000	42.9000
23	43.0	-0.03333	43.0333
24	42.8	-0.20000	43.0000
25	42.5	-0.36667	42.8667
26	42.6	-0.16667	42.7667
27	42.3	-0.33333	42.6333
28	42.9	0.43333	42.4667
29	43.6	1.00000	42.6000
30	44.7	1.76667	42.9333
31	44.5	0.76667	43.7333
32	45.0	0.73333	44.2667
33	44.8	0.06667	44.7333
34	44.9	0.13333	44.7667
35	45.2	0.30000	44.9000
36	45.2	0.23333	44.9667
37	45.0	-0.10000	45.1000
38	45.5	0.36667	45.1333
39	46.2	0.96667	45.2333
40	46.8	1.23333	45.5667
41	47.5	1.33333	46.1667
42	48.3	1.46667	46.8333
43	48.3	0.76667	47.5333
44	49.1	1.06667	48.0333
45	48.9	0.33333	48.5667
46	49.4	0.63333	48.7667
47	50.0	0.86667	49.1333
48	50.0	0.56667	49.4333
49	49.6	-0.20000	49.8000

50	49.9	0.03333	49.8667
51	49.6	-0.23333	49.8333
52	50.7	1.00000	49.7000
53	50.7	0.63333	50.0667
54	50.9	0.56667	50.3333
55	50.5	-0.26667	50.7667
56	51.2	0.50000	50.7000
57	50.7	-0.16667	50.8667
58	50.3	-0.50000	50.8000
59	49.2	-1.53333	50.7333
60	48.1	-1.96667	50.0667

الآن نختبر متوسط الباقي

```
MTB > TTest 0.0 'RESI1';
SUBC> Alternative 0.
```

T-Test of the Mean

Test of mu = 0.000 vs mu not = 0.000

Variable	N	Mean	StDev	SE Mean	T	P
RESI1	57	0.158	0.868	0.115	1.37	0.17

ملاحظة: في Minitab يستخدم برنامج عام عندما يكون الإنحراف المعياري (او التباين) غير معروف ويطلق عليه Ttest . لاحظ ان قيمة الإحصائية هي $T=1.37$ وهي اقل من 1.96 أي لا نرفض الفرضية الصفرية

ثانيا: نختبر عشوائية الباقي بواسطه إختبار الجري Runs test حول المتوسط و حول الصفر تابع المثال:

```
MTB > Runs 'RESI1'.
```

Runs Test

RESI1

K = 0.1579

The observed number of runs = 17

The expected number of runs = 29.4211

30 Observations above K 27 below

The test is significant at 0.0009

MTB > Runs 0 'RESI1'.

Runs Test

RESI1

K = 0.0000

The observed number of runs = 17

The expected number of runs = 28.7895

33 Observations above K 24 below

The test is significant at 0.0013

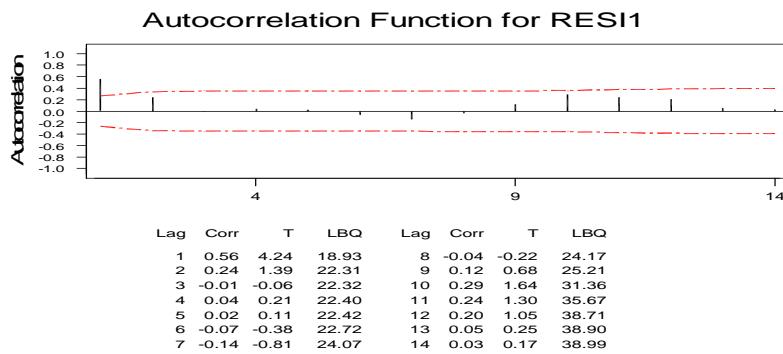
نلاحظ انه في كلتا الحالتين لا نرفض عشوائية الباقي

ثالثاً: اختبار ترابط أو استقلال الباقي بواسطة اختبار الترابط الذاتي Autocorrelation test

تابع المثال:

MTB > %ACF 'RESI1'.

Executing from file: E:\MTBWIN\MACROS\ACF.MAC



لاحظ ان الـ T للترابط الذاتي عند التخلف الأول تساوي 4.24 أي اننا نرفض ان $\rho_1 = 0$ أي يوجد ترابط بين الباقي من الدرجة الاولى في الإختبار

$$H_0 : \rho_1 = 0$$

$$H_1 : \rho_1 \neq 0$$

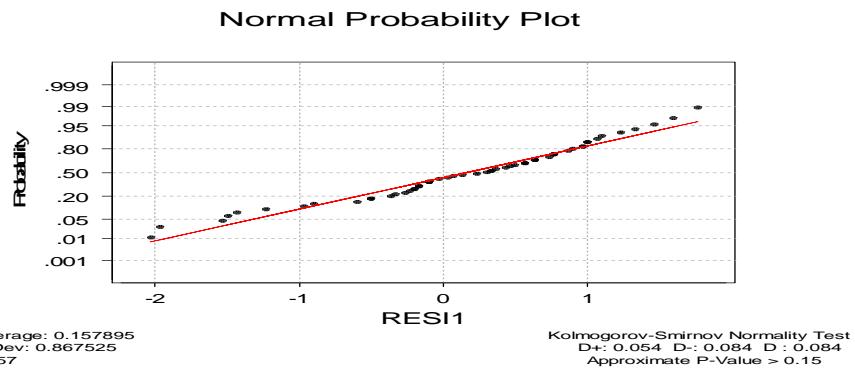
حيث الإحصائية هي $\frac{r_1}{se(r_1)} = 4.24$

رابعاً: نختبر في ما إذا كانت الباقي موزعة طبيعياً

تابع المثال:

```
MTB > %NormPlot 'RESI1';
SUBC> Kstest.
```

Executing from file: E:\MTBWIN\MACROS\NormPlot.MAC



لاحظ الـ P-Value الناتجة تساوي 0.15 وهي اكبر من 0.05 أي لانرفض فرضية التوزيع الطبيعي عند $\alpha = 0.05$ هناك ايضا اختبار آخر للطبيعة هو الـ Q-Q Plot والذي يبين مدى تطابق مشاهدات ما مع توزيع معين

```
MTB > %Qqplot 'RESI1';
SUBC>   Table;
SUBC>   Conf 95;
SUBC>   Ci.

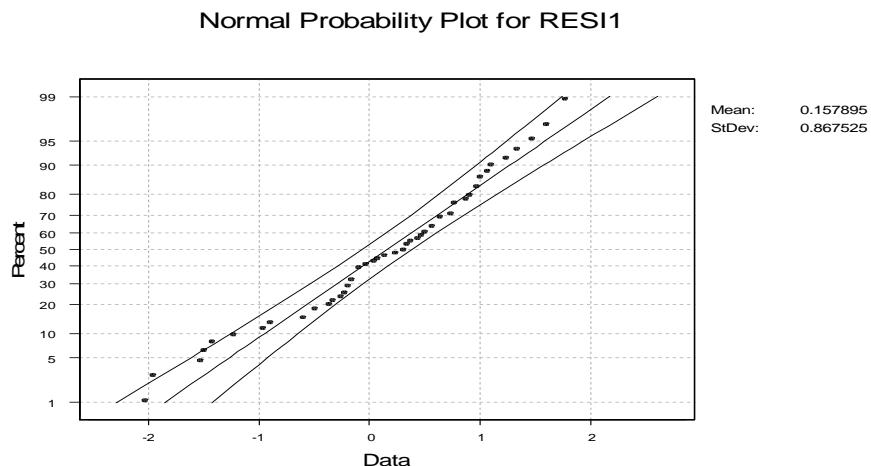
Executing from file: E:\MTBWIN\MACROS\Qqplot.MAC
```

Distribution Function Analysis

Normal Dist. Parameter Estimates

Data : RESI1

Mean: 0.157895
StDev: 0.867525



لاحظ ان في كلتا الحالتين فإننا لانرفض ان الباقي لها توزيع طبيعي

ملاحظة اخيرة: يبدو ان الباقي تحقق معظم الشروط فيما عدى الترابط الذي يوجد بين القيم المتتالية وهذا يجعلنا نرفض جودة التطبيق لطريقة المتوسط المتحرك من الدرجة الثالثة حيث ادى الى بواقي مترابطة.

الفصل التاسع

تحليل او تفكيك المتسلسلة الى مركبات Decomposition Method

ينظر إلى المتسلسلة الزمنية على أنها مكونة من عدة مركبات أو أجزاء متحدة مع بعضها لتكوين هذه المتسلسلة،

لنفترض أن لدينا المتسلسلة الزمنية المشاهدة z_1, z_2, \dots, z_n . لقد وجد بالتجربة أنه يمكن نمذجتها على الشكل

$$z_t = T_t + S_t + C_t + E_t, \quad t = 1, 2, \dots, n$$

حيث Z_t المتسلسلة الزمنية المشاهدة و T_t مركبة الإنجراف وهي التي تتمذج الإتجاه العام الذي تتحي أو تتجزأ إليه المتسلسلة و S_t مركبة موسمية وتتمذج التأثير الموسمي (إذا وجد) وهو التغير الذي يحدث للمتسلسلة نتيجة التأثيرات الموسمية مثل الشهرية والسنوية و C_t مركبة دورية (إذا وجدت) و تتمذج منحى أو إتجاه يتكرر بعد فترات زمنية طويلة غير موسمية و E_t مركبة الخطأ وتشمل جميع العوامل الأخرى التي تؤثر على المتسلسلة والتي لايمكن نمذجتها ضمنيا أو التي لايمكن مشاهدتها أو قياسها. النموذج السابق يسمى بالنماذج الإضافي Additive Model وذلك لأن كل المركبات تدخل بشكل إضافي في النموذج. هناك أشكال أخرى مثل

$$z_t = T_t S_t + C_t + E_t, \quad t = 1, 2, \dots, n$$

$$z_t = T_t S_t C_t + E_t, \quad t = 1, 2, \dots, n$$

والتي تسمى بالنماذج التضاعفية Multiplicative Models

في هذا المستوى سوف نهمل المركبة الدورية C_t وذلك لأن المركبة الدورية نادراً ما تكون موجودة في المتسلسلات القصيرة أو الطويلة نسبياً لأنها تحتاج إلى مشاهدات طويلة جداً على مدي عدد كبير من العقود.

ونكتفي بالنماذج على الشكل

$$z_t = T_t + S_t + E_t, \quad t = 1, 2, \dots, n$$

$$z_t = T_t S_t + E_t, \quad t = 1, 2, \dots, n$$

أنظر كتاب FORECASTING: METHODS AND APPLICATIONS للمؤلفين MAKRIDAKIS/ WHEELWRIGHT/ McGEE ص 131-141

سوف نستعرض في المثال التالي طرق التحليل الإضافية والتضاعفية بدون المركبة الدورية أي النماذج

$$z_t = T_t + S_t + E_t, \quad t=1,2,\dots,n$$

$$z_t = T_t S_t + E_t, \quad t=1,2,\dots,n$$

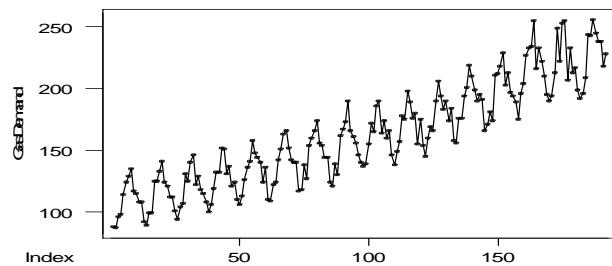
البيانات التالية هي الطلب على البنزين بمليين اللترات في مدينة اونتاريو بكندا من سنة 1960
وحتى سنة 1975

GasDemand

MONTHLY GASOLINE DEMAND ONTARIO GALLON MILLIONS 1960-1975										
87695	86890	96442	98133	113615	123924	128924	134775	117357	114626	
107677	108087	92188	88591	98683	99207	125485	124677	132543		
140735	124008	121194	111634	111565	101007	94228	104255	106922		
130621	125251	140318	146174	122318	128770	117518	115492	108497		
100482	106140	118581	132371	132042	151938	150997	130931	137018		
121271	123548	109894	106061	112539	125745	136251	140892	158390		
148314	144148	140138	124075	136485	109895	109044	122499	124264		
142296	150693	163331	165837	151731	142491	140229	140463	116963		
118049	137869	127392	154166	160227	165869	173522	155828	153771		
143963	143898	124046	121260	138870	129782	162312	167211	172897		
189689	166496	160754	155582	145936	139625	137361	138963	155301		
172026	165004	185861	190270	163903	174270	160272	165614	146182	137728	
148932	156751	177998	174559	198079	189073	175702	180097	155202	174508	
154277	144998	159644	168646	166273	190176	205541	193657	182617	189614	
174176	184416	158167	156261	176353	175720	193939	201269	218960	209861	
198688	190474	194502	190755	166286	170699	181468	174241	210802	212262	
218099	229001	203200	212557	197095	193693	188992	175347	196265	203526	
227443	233038	234119	255133	216478	232868	221616	209893	194784	189756	
193522	212870	248565	221532	252642	255007	206826	233231	212678	217173	
199024	191813	195997	208684	244113	243108	255918	244642	237579	237579	
217775	227621									

أولاً نرسم المتسلسلة في مخطط زمني

```
MTB > TSPlot 'GasDemand';
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect.
```



نلاحظ ان المتسلسلة الزمنية موسمية و منجرفة الى الاعلى

اولا: تطبيق النموذج الإضافي:

```
MTB > %Decomp 'GasDemand' 12;
SUBC> Additive ;
SUBC> Forecasts 24;
SUBC> Title "Forecast of Gasoline Demand";
SUBC> Start 1.
```

Time Series Decomposition

Data	GasDeman
Length	192.000
NMissing	0

Trend Line Equation

$$Y_t = 96.4074 + 0.680579*t$$

Seasonal Indices

Period	Index
1	-20.5625
2	-26.8125
3	-14.8958
4	-11.0625

5	9.89583
6	11.8958
7	22.7708
8	25.1875
9	5.64583
10	7.27083
11	-4.81250
12	-4.52083

Accuracy of Model

MAPE: 3.6952

MAD: 5.6622

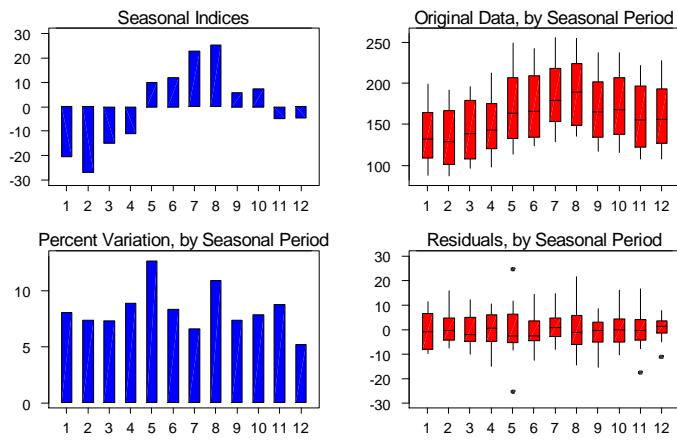
MSD: 52.7851

Forecasts

Row	Period	Forecast
1	193	207.197
2	194	201.627
3	195	214.225
4	196	218.738
5	197	240.377
6	198	243.058
7	199	254.614
8	200	257.711
9	201	238.850
10	202	241.155
11	203	229.753
12	204	230.725
13	205	215.364
14	206	209.794
15	207	222.391
16	208	226.905
17	209	248.544
18	210	251.225
19	211	262.780
20	212	265.878
21	213	247.017
22	214	249.322
23	215	237.919
24	216	238.892

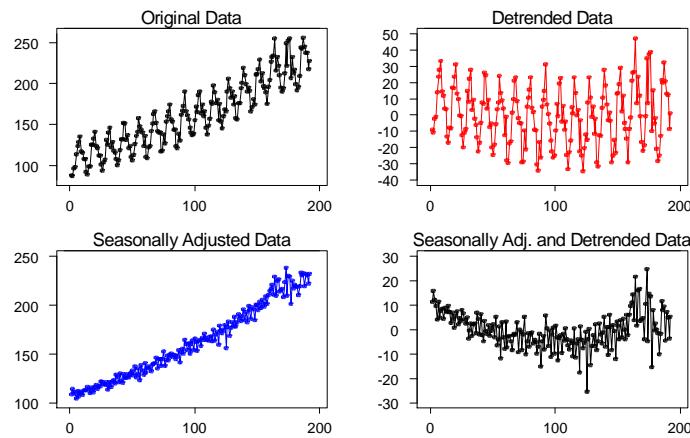
شكل (1)

Forecast of Gasoline Demand

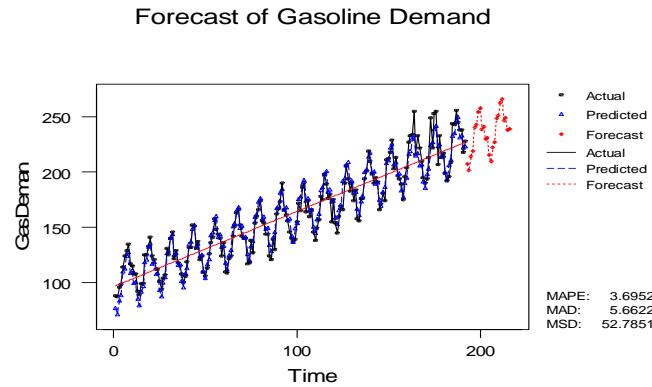


شكل (2)

Forecast of Gasoline Demand



شكل (3)



مناقشة النتائج:

شكل (1) يوضح المؤشرات الموسمية Seasonal Indices ، فالشكل الأعلى من اليسار يبين تأثر الطلب في الأشهر المختلفة من السنة ففي الأشهر 11 و 12 و 1 و 2 و 3 و 4 يحدث نقص في الطلب إذ يتناقص تدريجيا حتى يصل إلى أقل معدل له في الشهر 2 ثم يتزايد حتى يصبح موجبا في الشهر 5 ويتجاوز حتى يصل أقصى قيمة موجبة في الشهر 8 ثم ينقص بشكل كبير بعده. الشكل الأعلى من اليمين يعطي رسم الصندوق Box Plot للمشاهدات الأصلية موزعة على الأشهر وهو يوضح توزيع وإنشار المشاهدات على كل شهر والقيم الخارجة Out Liers . الشكل الأسفل من اليسار يعطي التغير النسبي المئوي على الفترات الموسمية (الأشهر). الشكل الأسفل الأيمن يعطي رسم الصندوق للبواقي أو الأخطاء موزعة على الأشهر.

شكل (2) الشكل الأعلى من اليمين يعطي المشاهدات الأصلية، الشكل الأعلى من اليسار يعطي المشاهدات بعد إزاحة مركبة الإنجراف أي

$$w_t = z_t - T_t, \quad t = 1, 2, \dots, n \\ = S_t + E_t, \quad t = 1, 2, \dots, n$$

الشكل الأسفل من اليسار يعطي المشاهدات الأصلية بعد إزاحة المركبة الموسمية أي

$$y_t = z_t - S_t, \quad t = 1, 2, \dots, n \\ = T_t + E_t, \quad t = 1, 2, \dots, n$$

الشكل الأسفل الأيمن يعطي مركبة الخطأ E_t أو البواقي بعد إزاحة مركبة الإنجراف والموسمية من المشاهدات الأصلية أي

$$e_t = z_t - T_t - S_t, \quad t = 1, 2, \dots, n \\ = E_t, \quad t = 1, 2, \dots, n$$

شكل (3) يعطي التنبؤات للفترة 24 المستقبلية مع مقاييس دقة التطبيق.

$$z_t = T_t S_t + E_t, \quad t=1, 2, \dots, n$$

```
MTB > %Decomp 'GasDemand' 12;
SUBC>   Forecasts 24;
SUBC>   Title "Forecast of Gasoline Demand";
SUBC>   Start 1.
Executing from file: D:\MTBWIN\MACROS\Decomp.MAC
```

Macro is running ... please wait

Time Series Decomposition

Data	GasDeman
Length	192.000
NMissing	0

Trend Line Equation

$$Y_t = 96.4074 + 0.680579*t$$

Seasonal Indices

Period	Index
--------	-------

1	0.860355
2	0.828555
3	0.892431
4	0.936273
5	1.06124
6	1.07274
7	1.15775
8	1.17075
9	1.03409
10	1.05059
11	0.966300
12	0.968923

Accuracy of Model

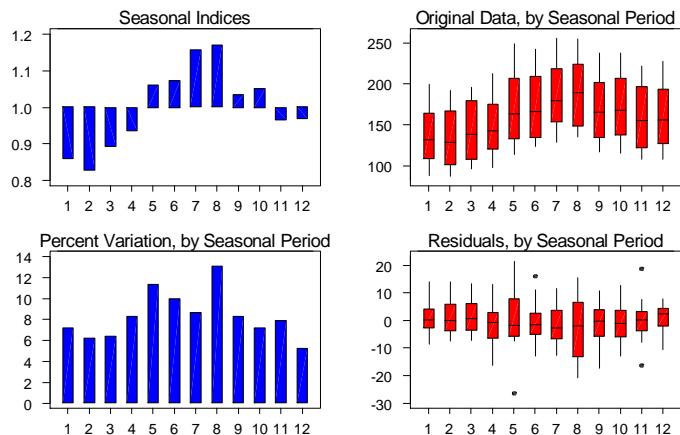
MAPE: 3.6338
MAD: 5.7720
MSD: 56.8996

Forecasts

Row	Period	Forecast
1	193	195.954
2	194	189.275
3	195	204.474
4	196	215.156
5	197	244.596
6	198	247.977
7	199	268.415
8	200	272.227
9	201	241.154
10	202	245.718
11	203	226.660
12	204	227.935
13	205	202.980
14	206	196.042
15	207	211.762
16	208	222.803
17	209	253.263
18	210	256.738
19	211	277.870
20	212	281.789
21	213	249.599
22	214	254.298
23	215	234.552
24	216	235.848

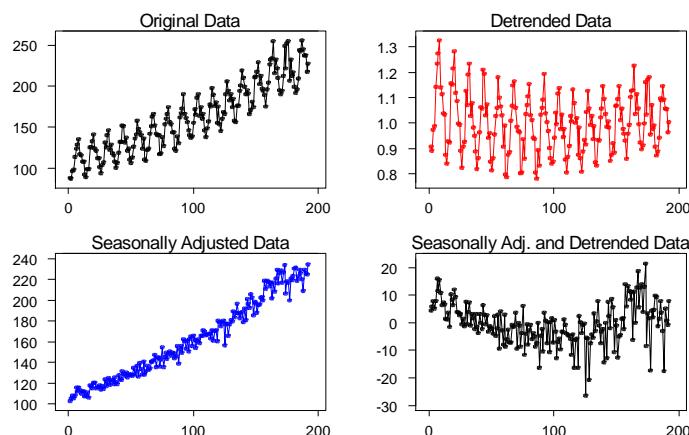
شكل (4)

Forecast of Gasoline Demand



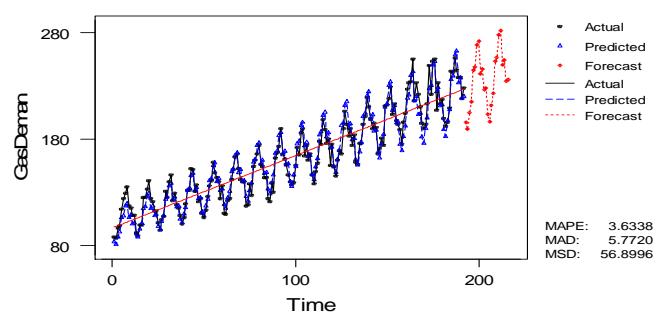
شكل (5)

Forecast of Gasoline Demand



شكل (6)

Forecast of Gasoline Demand



مناقشة النتائج:

الأشكل (4) و (5) و (6) لها نفس التفسير كما في الأشكال (1) و (2) و (3).

بما اننا طبقنا نموذجين على المتسلسلة المشاهدة فيجب أن نختار افضل نموذج، وهنا يأتي دور مقاييس دقة التطبيق والتي تنتج من البرنامج، لدينا ثلاثة مقاييس دقة:

1- متوسط الخطأ النسبي المطلق Mean Absolute Percentage Error أو MAPE ويعطى بالعلاقة

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{z_t - \hat{z}_t}{z_t} \right|}{n} \times 100, \quad z_t \neq 0$$

2- متوسط الإنحراف المطلق Mean Absolute Deviation أو MAD ويعطى بالعلاقة

$$MAD = \frac{\sum_{t=1}^n |z_t - \hat{z}_t|}{n}$$

3- متوسط الإنحراف المربع (أو متوسط الخطأ المربع) MSE (أو MSD) ويعطى بالعلاقة

$$MSD = \frac{\sum_{t=1}^n (z_t - \hat{z}_t)^2}{n}$$

بإختيار أحد هذه المقاييس نختار النموذج الذي يعطي أقل قيمة لهذا المقياس، المقياس الأكثر استخداماً وشيوعاً هو MSE أو MSD وهو الذي سوف هنا.

للنموذج الإضافي مقاييس الدقة هي:

MAPE: 3.6952

MAD: 5.6622

MSD: 52.7851

و للنموذج التضاعفي:

MAPE: 3.6338

MAD: 5.7720

MSD: 56.8996

نلاحظ أن النموذج الإضافي أعطى أقل قيمة للمقياس MSD ولذلك نقرر استخدام هذا النموذج للتنبؤ عن القيم المستقبلية لمتسلسلة الطلب.

توضيح طريقة تحليل او تفكك المتسلسلة الى مركبات :Decomposition Method

سوف نوضح بالمثال التالي طريقة تحليل او تفكك المتسلسلة إلى مركبات. البيانات التالية إنتاج 168 يوماً للحليب في أحد المزارع بالكيلو جرام

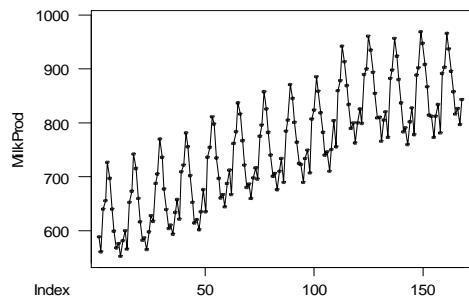
```
MTB > Read "E:\Mtbwin\milk.dat" c1.  
Entering data from file: E:\Mtbwin\milk.dat  
    168 rows read.  
MTB > name c1='MilkProd'  
MTB > print c1
```

Data Display

MilkProd										
589	561	640	656	727	697	640	599	568	577	
553	582	600	566	653	673	742	716	660	617	
583	587	565	598	628	618	688	705	770	736	
678	639	604	611	594	634	658	622	709	722	
782	756	702	653	615	621	602	635	677	635	
736	755	811	798	735	697	661	667	645	688	
713	667	762	784	837	817	767	722	681	687	
660	698	717	696	775	796	858	826	783	740	
701	706	677	711	734	690	785	805	871	845	
801	764	725	723	690	734	750	707	807	824	
886	859	819	783	740	747	711	751	804	756	
860	878	942	913	869	834	790	800	763	800	
826	799	890	900	961	935	894	855	809	810	
766	805	821	773	883	898	957	924	881	837	
784	791	760	802	828	778	889	902	969	947	
908	867	815	812	773	813	834	782	892	903	
966	937	896	858	817	827	797	843			

ونرسم البيانات السابقة بالأوامر:

```
MTB > TSPlot 'MilkProd';  
SUBC>   Index;  
SUBC>   TDisplay 11;  
SUBC>   Symbol;  
SUBC>   Connect.
```



اولا: تطبيق النموذج الإضافي:

لمشاهدات $z_t = T_t + S_t + E_t, t = 1, 2, \dots, n$ نكتب النموذج على الشكل لكي نقوم بتفكيك هذه المتسلسلة الزمنية الى المركبات السابقة سوف نستعرض طريقتين ممكنة:

الطريقة الأولى:

1- نطبق إندثار خطى بسيط للمشاهدات على الزمن لتقدير مركبة الانجراف T_t أي:

$$\hat{T}_t \equiv \hat{z}_t = a + bt, t = 1, 2, \dots, 168$$

أي:

```
MTB > set c2
DATA> 1:168
DATA> end
MTB > name c1='MilkProd' c2='Time' c3='Trend'
c5='Detrend' c6='Index' c8='Fitted' c9='Resid'
MTB > regr c1 1 c2;
SUBC> fits c3.
```

Regression Analysis

The regression equation is

MilkProd = 612 + 1.69 Time

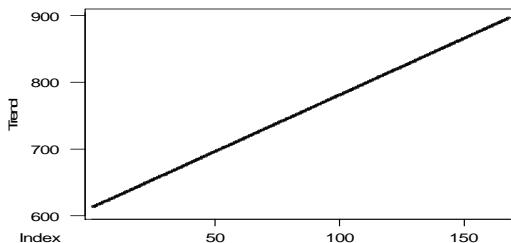
Predictor	Coef	StDev	T	P
Constant	611.682	9.414	64.97	0.000
Time	1.69262	0.09663	17.52	0.000

$S = 60.74$ $R-Sq = 64.9\%$ $R-Sq(\text{adj}) = 64.7\%$

Analysis of Variance

Source	DF	SS	MS	F
P				
Regression	1	1132003	1132003	306.83
0.000				
Error	166	612439	3689	
Total	167	1744443		

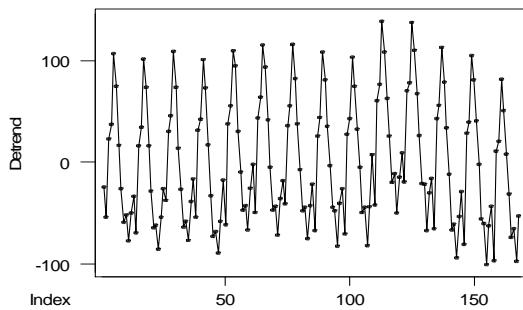
وشكل الإنجراف هو



2- نطرح مركبة الإنجراف من المشاهدات الأصلية فنحصل على ما يسمى بالمتسلسلة مزالة الإنجراف $\hat{z}_t - \hat{T}_t = z_t - \hat{T}_t$, $t = 1, 2, \dots, 168$ أي Detrended Series

MTB > let c5=c1-c3

ولها الشكل التالي:



$$z_t - \hat{T}_t = S_t + E_t, t = 1, 2, \dots, 168$$

3- لتقدير المركبة الموسمية نوجد المؤشرات الموسمية Seasonal Indices كالتالي:

لنرمز للمؤشرات الموسمية بالرمز $I_s, s = 1, 2, \dots, 12$ حيث I_1 المؤشر الموسمي للشهر

الأول و I_2 المؤشر الموسمي للشهر الثاني وهكذا ولنرمز بـ d_t المؤشر الموسمي للشهر

تقدر هذه المؤشرات كالتالي:

$$I_1 = \frac{1}{14} (d_1 + d_{13} + d_{25} + \dots + d_{157})$$

$$I_2 = \frac{1}{14} (d_2 + d_{14} + d_{26} + \dots + d_{158})$$

⋮

$$I_{12} = \frac{1}{14} (d_{12} + d_{24} + d_{36} + \dots + d_{168})$$

ويتم ذلك بإستخدام الأوامر التالية:

```
MTB > set c4
DATA> 14(1:12)
DATA> end
MTB > stat c5;
SUBC> by c4;
SUBC> mean c6.
MTB > Stack 'Index' 'Index' 'Index' 'Index' 'Index'
'Index' 'Index' &
CONT> 'Index' 'Index' 'Index' 'Index' 'Index' 'Index'
'Index' c7.
MTB > let c8=c3+c7
MTB > let c9=c1-c8
MTB > set c10
DATA> 1:12
DATA> end
MTB > print c10 c6
```

Data Display

Row	Season	Index
1	1	-18.328
2	2	-57.806
3	3	34.716
4	4	49.595
5	5	110.616
6	6	82.281
7	7	32.517
8	8	-9.747
9	9	-52.297
10	10	-48.775
11	11	-79.754
12	12	-43.018

4- التنبؤات تولد كالتالي:

$$z_{168}(\ell) = 612 + 1.69(\ell + 168) + I_{(\ell \bmod 12)}, \ell = 1, 2, \dots$$

فمثلا التنبؤ عند اليوم 169 هو

$$\begin{aligned} z_{168}(1) &= 612 + 1.69(169) + I_1 \\ &= 897.61 + (-18.328) = 879.282 \end{aligned}$$

الطريقة الثانية:

وهي التي يستخدمها برنامج Minitab :

1- كالطريقة الاولى نطبق إندار خطى بسيط للمشاهدات على الزمن لتقدير مركبة الانجراف

T_ℓ فنحصل على نفس النتيجة كما في الطريقة الاولى (1)

2- ايضا هنا نطرح مركبة الإنجراف من المشاهدات الأصلية فنحصل على المتسلسلة مزالة الإنجراف

Detrended Series

3- نطبق الآن متوسط متتحرك من درجة الموسم ونوسطه اذا احتاج الامر

4- نطرح المتواسطات المتحركة من نظيراتها في المتسلسلة مزالة الإنجراف فنحصل على

متسلسلة تحوي المركبات الموسمية

5- تقدر المركبات الموسمية كالتالي:

$$I_1 = \text{Median}(d_1, d_{13}, d_{25}, \dots, d_{157})$$

$$I_2 = \text{Median}(d_2, d_{14}, d_{26}, \dots, d_{158})$$

$$\vdots$$

$$I_{12} = \text{Median}(d_{12}, d_{24}, d_{36}, \dots, d_{168})$$

6- تولد التنبؤات كالسابق

وسوف نستعرض هذا كالتالي:

```
MTB > Read "E:\Mtbwin\milk.dat" c1.
Entering data from file: E:\Mtbwin\milk.dat
 168 rows read.
MTB > name c1='MilkProd'
MTB > set c2
DATA> 1:168
DATA> end
MTB > name c2='Time'
MTB > regr c1 1 c2;
SUBC> fits c3.
```

Regression Analysis

The regression equation is
 MilkProd = 612 + 1.69 Time

Predictor	Coef	StDev	T	P
Constant	611.682	9.414	64.97	0.000
Time	1.69262	0.09663	17.52	0.000

S = 60.74 R-Sq = 64.9% R-Sq(adj) = 64.7%

Analysis of Variance

Source	DF	SS	MS	F
P				
Regression	1	1132003	1132003	306.83
		0.000		
Error	166	612439	3689	
Total	167	1744443		

Unusual Observations

Obs	Time	MilkProd	Fit	StDev Fit	Residual
St Resid					
113	113	942.00	802.95	5.44	139.05
2.30R					
125	125	961.00	823.26	6.11	137.74
2.28R					

R denotes an observation with a large standardized residual

```
MTB > name c3='Trend'
```

```
MTB > let c4=c1-c3
```

```
MTB > name c4='Detrend'
```

```
MTB > Name c5 = 'AVER1'
```

في الخطوة التالية نطبق متوسط متراك من الدرجة 12 ونوسطه:

```
MTB > %MA 'Detrend' 12;
```

```
SUBC> Center;
```

```
SUBC> Averages 'AVER1'.
```

```
Executing from file: E:\MTBWIN\MACROS\MA.MAC
```

Macro is running ... please wait

Moving average

```
Data          Detrend
```

```
Length        168.000
```

```
NMissing      0
```

Moving Average

Length: 12

Accuracy Measures

MAPE: 111.68

MAD: 52.36

MSD: 3564.77

نطرح المتوسطات المتحركة الموسطة من المتسلسلة المزالت إنجرافها

```

MTB > let c6=c4-c5
MTB > name c6='DeSeason'
MTB > set c2
DATA> 14(1:12)
DATA> end
MTB > stat c6;
SUBC> by c2;
SUBC> median c7.
MTB > name c7='SeasInx'

```

Data Display

Row	Season	SeasInx
1	1	-20.750
2	2	-58.958
3	3	35.625
4	4	50.083
5	5	109.542
6	6	81.292
7	7	33.917
8	8	-10.000
9	9	-52.792
10	10	-50.250
11	11	-79.958
12	12	-44.375

نقارن الحسابات التي اجريناها مع البرنامج الاصلي:

```

MTB > %Decomp 'MilkProd' 12;
SUBC> Additive ;
SUBC> Start 1.
Executing from file: E:\MTBWIN\MACROS\Decomp.MAC

```

Macro is running ... please wait

Time Series Decomposition

Data	MilkProd
Length	168.000
NMissing	0

Trend Line Equation

$$Y_t = 611.682 + 1.69262 * t$$

Seasonal Indices

Period Index

1	-20.1979
2	-58.4062
3	36.1771
4	50.6354
5	110.094
6	81.8437
7	34.4687
8	-9.44792
9	-52.2396
10	-49.6979
11	-79.4063
12	-43.8229

Accuracy of Model

MAPE:	1.583
MAD:	12.088
MSD:	244.406

وبمقارنة النتائجتين نجد انهما تقربيا متساوين.

سوف نولد تنبؤات باستخدام البرنامج %Decomp كالتالي:

```
MTB > %Decomp 'MilkProd' 12;
SUBC> Additive ;
```

```
SUBC>   Forecasts 12;
SUBC> Start 1.
```

والتي تعطي التنبؤات:

Forecasts

Row	Period	Forecast
1	169	877.54
2	170	841.02
3	171	937.30
4	172	953.45
5	173	1014.60
6	174	988.04
7	175	942.36
8	176	900.13
9	177	859.04
10	178	863.27
11	179	835.25
12	180	872.53

تمرين: ولد تنبؤات لإنتاج الحليب اليومي باستخدام الطريقتين المعطاة وقارنها بالقيم الأخيرة الناتجة من البرنامج

الفصل العاشر

التمهيد و التنبؤ بواسطة المتوسط المتحرك

for Forecasting

يستخدم المتوسط المتحرك لتمهيد المشاهدات وذلك بتقليل تباين الأخطاء فمثلا لو كان لدينا مشاهدات من متسلسلة زمنية $z_1, z_2, z_3, \dots, z_{n-2}, z_{n-1}, z_n$ فال المتوسط المتحرك من الدرجة m للمشاهدات يحسب من العلاقة

$$\hat{z}_t = \frac{1}{m} (z_t + z_{t-1} + z_{t-2} + \dots + z_{t-m+1}), \quad t = m, m+1, \dots, n$$

أو

$$\hat{z}_t = \hat{z}_{t-1} + \frac{1}{m} (z_t - z_{t-m}), \quad t = m, m+1, \dots, n$$

لاحظ ان عدد المشاهدات اصبح بعد التمهيد $n - m + 1$.

ومثلا لو كانت $m=3$ فإن المتوسط المتحرك من الدرجة الثالثة هو

$$\hat{z}_3 = \frac{1}{3} (z_3 + z_2 + z_1)$$

$$\hat{z}_4 = \frac{1}{3} (z_4 + z_3 + z_2) \quad or \quad \hat{z}_4 = \hat{z}_3 + \frac{1}{3} (z_4 - z_1)$$

⋮

$$\hat{z}_n = \frac{1}{3} (z_n + z_{n-1} + z_{n-2}) \quad or \quad \hat{z}_n = \hat{z}_{n-1} + \frac{1}{3} (z_n - z_{n-3})$$

ولكي نرى كيف يعمل التمهيد لتقليل تباين الأخطاء لنفترض ان المشاهدات تتبع النموذج

$$z_t = \mu + a_t, \quad a_t \sim WN(0, \sigma^2), \quad t = 1, 2, \dots, n$$

فيمكون

$$V(z_t) = \sigma^2, \quad \forall t$$

وبالتالي

$$V(\hat{z}_t) = \frac{\sigma^2}{m}, \quad t = m, m+1, \dots, n$$

أي ان المشاهدات الممهدة اصغر تباينها بـ m ضعف من المشاهدات الأصلية وهذا التمهيد للأخطاء يظهر أي نمط في المتسلسلة كان مدفونا او مغطى من تأثير الأخطاء.
ملاحظة: تؤخذ m دائمًا فردية وذلك لتجنب توسيط القيم الممهدة.

التبؤ باستخدام المتوسط المتحرك:

يؤخذ كمتتبٍ لقيم المستقبلية المتوسط المتحرك:

$$z_n(\ell) = \hat{z}_{n-1}, \quad \ell > 0$$

مثال:

باستخدام الحزمة الإحصائية MINITAB نحمل البيانات من ورقة العمل EMPLOY.MTW

MTB > Retrieve 'E:\Mtbwin\DATA\EMPLOY.MTW'.

ننظر ماذا تحوي من متغيرات

MTB > info

Information on the Worksheet

Column	Count	Name
C1	60	Trade
C2	60	Food
C3	60	Metals

سوف نستخدم المشاهدات للمتغير Metals

Metals

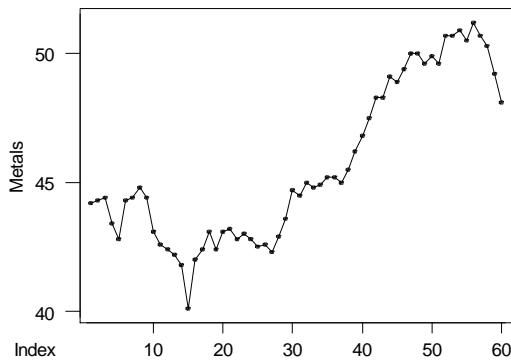
44.2	44.3	44.4	43.4	42.8	44.3	44.4
44.8	44.4	43.1	42.6	42.4	42.2	41.8
40.1	42.0	42.4	43.1	42.4	43.1	43.2
42.8	43.0	42.8	42.5	42.6	42.3	42.9
43.6	44.7	44.5	45.0	44.8	44.9	45.2
45.2	45.0	45.5	46.2	46.8	47.5	48.3
48.3	49.1	48.9	49.4	50.0	50.0	49.6
49.9	49.6	50.7	50.7	50.9	50.5	51.2
50.7	50.3	49.2	48.1			

نرسم هذه المشاهدات:

```

MTB > TSPlot 'Metals';
SUBC>   Index;
SUBC>   TDisplay 11;
SUBC>   Symbol;
SUBC>   Connect.

```



نطبق الآن تمهيداً لهذه المشاهدات بإستخدام المتوسط المتحرك من الدرجة $m=3$ ونوجد تنبؤات لـ 6 قيم مستقبلية:

```

MTB > %MA 'Metals' 3;
SUBC>   Forecasts 6;
SUBC>   Title "Smoothing and Forecasting Metals".
Executing from file: E:\MTBWIN\MACROS\MA.MAC

```

Moving average

```

Data      Metals
Length    60.0000
NMissing  0
Moving Average
Length: 3
Accuracy Measures
MAPE: 1.55036

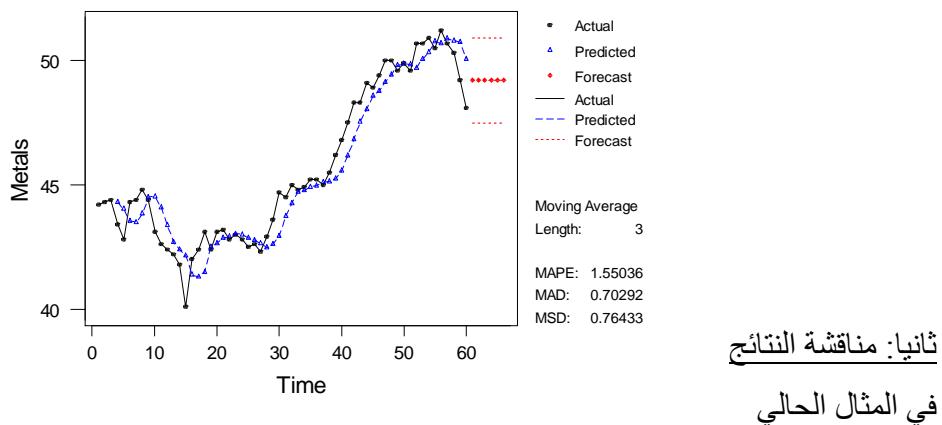
```

MAD: 0.70292

MSD: 0.76433

Row	Period	Forecast	Lower	Upper
1	61	49.2	47.4865	50.9135
2	62	49.2	47.4865	50.9135
3	63	49.2	47.4865	50.9135
4	64	49.2	47.4865	50.9135
5	65	49.2	47.4865	50.9135
6	66	49.2	47.4865	50.9135

Smoothing and Forecasting Metals



$$\hat{z}_{59} = \frac{50.3 + 49.2 + 48.1}{3} = \frac{147.6}{3} = 49.2$$

تؤخذ التنبؤات للقيم الـ 6 المستقبلية أي للقيم $z_{n+1}, z_{n+2}, \dots, z_{n+6}$ أو في هذا المثال

كالتالي: $z_{61}, z_{62}, \dots, z_{66}$

$$z_{60}(1) = z_{60}(2) = \dots = z_{60}(6) = 49.2$$

لحساب فترات تنبؤ 95% نحسب الكميات أي $[z_n(\ell) \pm 1.96\hat{\sigma}], \ell > 0$

لجميع قيم التنبؤات المستقبلية ، نأخذ القيمة $MSD = 0.76433$ كمقدار لـ

σ^2 أي $\hat{\sigma} = 0.8743$ فيكون $\hat{\sigma}^2 = 0.76433$ وعليه تكون فترة تنبؤ 95% لجميع القيم المستقبلية هي:

$$[49.2 \pm 1.96(0.8743)] = [49.2 \pm 1.7135] = [47.4865, 50.9135]$$

أي:

$$z_{60+\ell} \in [47.4865, 50.9135], \quad \ell > 0 \quad \text{with probability 0.95}$$

ملاحظة: تحسب MSD كالتالي

$$MSD = \hat{\sigma}^2 = \frac{\sum_{i=2}^{n-1} (z_i - \hat{z}_i)^2}{n-2}$$

تمرين:

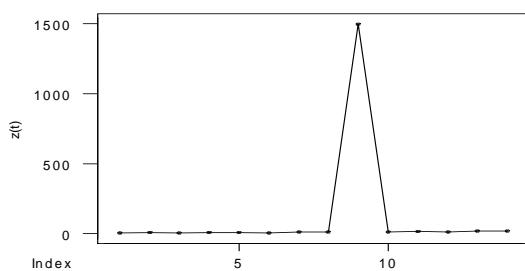
طبق متوسطات متحركة من الدرجات 5 و 7 على المشاهدات السابقة وقرر ايها افضل للتنبؤ عن القيم المستقبلية؟.

الوسيط الجارى

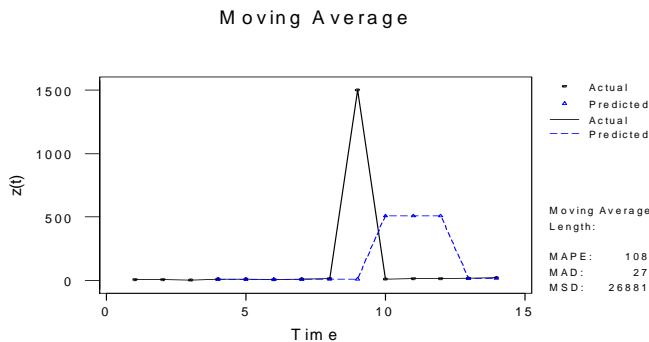
المتوسط المتحرك يتأثر كثيراً بالمشاهدات الخارجة Outliers او المتطرفة فالقيمة المتطرفة الواحدة تؤثر على m من المتوسطات المتحركة المتتالية فمثلاً لو كانت لدينا المشاهدات

$z(t)$	5	7	3	8	9	6	10	12	1500	11	15
	13		18		20						

ولها الشكل



بأخذ متوسط متحرك من الدرجة 3 نجد



لاحظ ان المتوسط المتحرك الناتج تأثرت فيه ثلاثة قيم بالقيمة المتطرفة.

لتغلب على مثل هذه الصعوبات يستخدم الوسيط الجاري ذا الطول الفردي كمهد غير خطى
والذى لايتاثر باقيم المتطرفة.

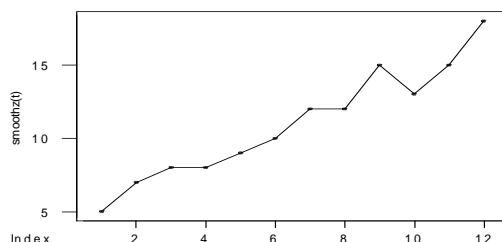
الوسيط الجاري ذا الطول الفردى $z_{j+1} = \text{med}(z_1, z_2, z_3, \dots, z_{n-2}, z_{n-1}, z_n)$ لمشاهدات

من العلاقة

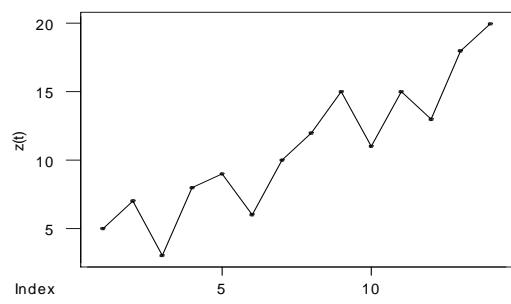
$$\tilde{z}_t = \text{med}(z_{t-i}, \dots, z_t, \dots, z_{t+i}), \quad j = 2i + 1$$

فمتلا لقيمة $j = 3$ تصبح العلاقة $\tilde{z}_t = \text{med}(z_{t-1}, z_t, z_{t+1})$ وبأخذ وسيط جاري ذا الطول 3

للمشاهدات السابقة نجد



وإذا كانت القيمة الحقيقية لـ z_9 هي 15 وليس 1500 فإن المشاهدات الحقيقية لها الشكل التالي



قارن بين النتائجين.

الفصل الحادي عشر

التمهيد و التنبؤ بواسطة التمهيد الاسي البسيط Using Single Exponential Smoothing for Forecasting

التمهيد بواسطة المتوسط المتحرك يعطي جميع البيانات نفس الأهمية وبالتالي فإن القيم القديمة نوعاً تؤثر نفس التأثير كالقيم الحديثة وهذا قد لا يكون من الناحية العملية صحيحاً، التمهيد الاسي على العكس يعطي القيم الأكثر

حداثة أهمية أكبر والقيم الاخرى تعطى اهمية تتناقص اسيا مع قدمها. فمثلاً لو كان لدينا مشاهدات من متسلسلة زمنية $z_1, z_2, z_3, \dots, z_{n-2}, z_{n-1}, z_n$ فال المتوسط المتحرك من الدرجة m للمشاهدات يحسب من العلاقة

$$\hat{z}_t = \frac{1}{m} (z_t + z_{t-1} + z_{t-2} + \dots + z_{t-m+1}), \quad t = m, m+1, \dots, n$$

والتي يمكن كتابتها

$$\hat{z}_t = \frac{1}{m} z_t + \frac{1}{m} z_{t-1} + \frac{1}{m} z_{t-2} + \dots + \frac{1}{m} z_{t-m+1}, \quad t = m, m+1, \dots, n$$

$$\hat{z}_t = \beta z_t + \beta z_{t-1} + \beta z_{t-2} + \dots + \beta z_{t-m+1}, \quad t = m, m+1, \dots, n, \quad \beta = \frac{1}{m}$$

أي ان المتوسط المتحرك يعطي جميع البيانات نفس الوزن β

الآن لو أعطينا البيانات اوزان تتناقص اسيا مع بُعد المشاهدات عن القيمة الحاضرة z_n كالتالي

$$s_t = \alpha z_t + \alpha(1-\alpha) z_{t-1} + \alpha(1-\alpha)^2 z_{t-2} + \dots, \quad t = 1, 2, \dots, n, \quad 0 < \alpha < 1$$

القيمة s_t هي متوسط موزون بأوزان تتناقص اسيا لجميع القيم السابقة وهذا ما يسمى بالتمهيد الاسي البسيط ويكتب بشكل تكراري

$$s_t = \alpha z_t + (1-\alpha) s_{t-1}, \quad t = 1, 2, \dots, n, \quad s_0 = \bar{z}$$

وتؤخذ التنبؤات

$$z_n(\ell) = s_n, \quad \ell \geq 1$$

مثال:

تحميل البيانات من ورقة العمل EMPLOY.MTW

MTB > Retrieve 'E:\Mtbwin\DATA\EMPLOY.MTW' .

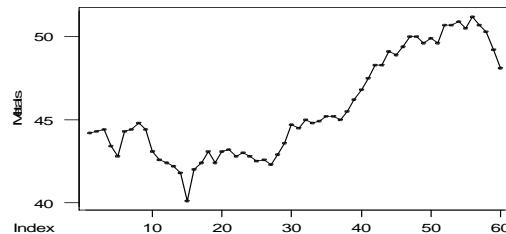
سوف نستخدم المشاهدات في التغير Metals

Metals

44.2	44.3	44.4	43.4	42.8	44.3	44.4
44.8	44.4	43.1	42.6	42.4	42.2	41.8
40.1	42.0	42.4	43.1	42.4	43.1	43.2
42.8	43.0	42.8	42.5	42.6	42.3	42.9
43.6	44.7	44.5	45.0	44.8	44.9	45.2
45.2	45.0	45.5	46.2	46.8	47.5	48.3
48.3	49.1	48.9	49.4	50.0	50.0	49.6
49.9	49.6	50.7	50.7	50.9	50.5	51.2
50.7	50.3	49.2	48.1			

نرسم هذه المشاهدات:

```
MTB > TSPlot 'Metals';
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect.
```



نطبق الآن تمهيداً لهذه المشاهدات بإستخدام التمهيد الأسني البسيط ونأخذ ثابت تمهيد $\alpha = 0.2$
ونوجد تنبؤات لـ 6 قيم مستقبلية:

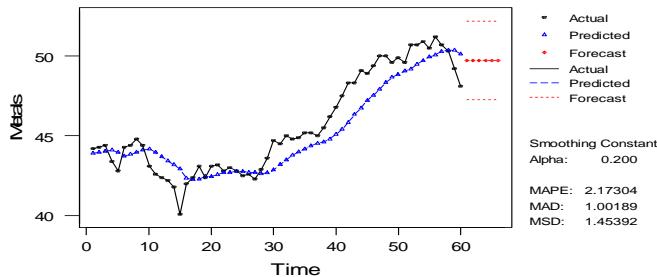
```
MTB > %SES 'Metals';
SUBC>   Weight 0.2;
SUBC>   Forecasts 6;
SUBC>   Title "Smoothing and Forecasting Metals";
SUBC>   Initial 6.
```

Single Exponential Smoothing

```
Data          Metals
Length       60.0000
NMissing     0
Smoothing Constant
Alpha: 0.2
Accuracy Measures
MAPE: 2.17304
MAD: 1.00189
MSD: 1.45392
```

Row	Period	Forecast	Lower	Upper
1	61	49.7216	47.2670	52.1763
2	62	49.7216	47.2670	52.1763
3	63	49.7216	47.2670	52.1763
4	64	49.7216	47.2670	52.1763
5	65	49.7216	47.2670	52.1763
6	66	49.7216	47.2670	52.1763

Smoothing and Forecasting Metals



ثانياً: مناقشة النتائج

- 1- يحسب التمهيد الاسي البسيط لمشاهدات $z_1, z_2, \dots, z_{n-1}, z_n$ بثابت تمهيد $\alpha = 0.2$ من العلاقة التكرارية:

$$s_i = \alpha z_i + (1 - \alpha) s_{i-1}, \quad i = 1, 2, \dots, n$$

لكي نبدأ العلاقة التكرارية لحساب القيم الممهدة اسيا نحتاج الي القيمة الاولية s_0 والتي تحسب بعدة طرق، أحد هذه الطرق والتي سنستخدمها هي وضع s_0 مساوية للمتوسط

$$s_0 = \frac{\sum_{i=1}^m z_i}{m}, \quad m = 6 \text{ (or } n, \text{ if } n < 6\text{)}$$

$$s_0 = \frac{44.2 + 44.3 + 44.4 + 43.4 + 42.8 + 44.3}{6} = 43.9$$

وبالتالي يكون

$$s_1 = \alpha z_1 + (1 - \alpha) s_0 = 0.2(44.2) + 0.8(43.9) = 8.84 + 35.12 = 43.96$$

$$s_2 = \alpha z_2 + (1 - \alpha) s_1 = 0.2(44.3) + 0.8(43.96) = 8.86 + 35.168 = 44.028$$

وهكذا نستمر حتى آخر مشاهدة فينتج التالي:

Time	Metals	SMO01	FITS1	RESI1
1	44.2	43.9600	43.9000	0.30000
2	44.3	44.0280	43.9600	0.34000
3	44.4	44.1024	44.0280	0.37200
4	43.4	43.9619	44.1024	-0.70240

5	42.8	43.7295	43.9619	-1.16192
6	44.3	43.8436	43.7295	0.57046
7	44.4	43.9549	43.8436	0.55637
8	44.8	44.1239	43.9549	0.84510
9	44.4	44.1791	44.1239	0.27608
10	43.1	43.9633	44.1791	-1.07914
11	42.6	43.6906	43.9633	-1.36331
12	42.4	43.4325	43.6906	-1.29065
13	42.2	43.1860	43.4325	-1.23252
14	41.8	42.9088	43.1860	-1.38601
15	40.1	42.3470	42.9088	-2.80881
16	42.0	42.2776	42.3470	-0.34705
17	42.4	42.3021	42.2776	0.12236
18	43.1	42.4617	42.3021	0.79789
19	42.4	42.4494	42.4617	-0.06169
20	43.1	42.5795	42.4494	0.65065
21	43.2	42.7036	42.5795	0.62052
22	42.8	42.7229	42.7036	0.09642
23	43.0	42.7783	42.7229	0.27713
24	42.8	42.7826	42.7783	0.02171
25	42.5	42.7261	42.7826	-0.28264
26	42.6	42.7009	42.7261	-0.12611
27	42.3	42.6207	42.7009	-0.40089
28	42.9	42.6766	42.6207	0.27929
29	43.6	42.8613	42.6766	0.92343
30	44.7	43.2290	42.8613	1.83875
31	44.5	43.4832	43.2290	1.27100
32	45.0	43.7866	43.4832	1.51680
33	44.8	43.9892	43.7866	1.01344
34	44.9	44.1714	43.9892	0.91075
35	45.2	44.3771	44.1714	1.02860
36	45.2	44.5417	44.3771	0.82288
37	45.0	44.6334	44.5417	0.45830
38	45.5	44.8067	44.6334	0.86664

39	46.2	45.0853	44.8067	1.39331
40	46.8	45.4283	45.0853	1.71465
41	47.5	45.8426	45.4283	2.07172
42	48.3	46.3341	45.8426	2.45738
43	48.3	46.7273	46.3341	1.96590
44	49.1	47.2018	46.7273	2.37272
45	48.9	47.5415	47.2018	1.69818
46	49.4	47.9132	47.5415	1.85854
47	50.0	48.3305	47.9132	2.08683
48	50.0	48.6644	48.3305	1.66947
49	49.6	48.8515	48.6644	0.93557
50	49.9	49.0612	48.8515	1.04846
51	49.6	49.1690	49.0612	0.53877
52	50.7	49.4752	49.1690	1.53101
53	50.7	49.7202	49.4752	1.22481
54	50.9	49.9561	49.7202	1.17985
55	50.5	50.0649	49.9561	0.54388
56	51.2	50.2919	50.0649	1.13510
57	50.7	50.3735	50.2919	0.40808
58	50.3	50.3588	50.3735	-0.07353
59	49.2	50.1271	50.3588	-1.15883
60	48.1	49.7216	50.1271	-2.02706

العمود الرابع SMOO1 يحوى القيم الممهدة أي $s_i, i = 1, 2, \dots, 60$ العمود الخامس FITS1

يحوى القيم المطبقة أي $\hat{s}_i = s_{i-1}, i = 1, 2, \dots, 60$ العمود الخامس RESI1 يحوى الأخطاء

(الباقي Residuals) أي $e_i = z_i - \hat{z}_i, i = 1, 2, \dots, 60$

2- يؤخذ كمتتبى للقيم المستقبلية آخر قيمة ممهدة أي:

$$z_n(\ell) = s_n, \quad \ell > 0$$

في المثال الحالى

$$z_{60}(\ell) = 49.7216, \quad \ell > 0$$

تؤخذ التنبؤات للقيم الـ 6 المستقبلية أي للقيم $z_{n+1}, z_{n+2}, \dots, z_{n+6}$ أو في هذا المثال

كالتالي: $z_{61}, z_{62}, \dots, z_{66}$

$$z_{60}(1) = z_{60}(2) = \dots = z_{60}(6) = 49.7216$$

3- لحساب فترات تنبؤ 95% نحسب الكميات 0 أي $[z_n(\ell) \pm 1.96\hat{\sigma}], \ell > 0$ نحسب القيم المستقبلية ، نأخذ القيمة $MSD = 1.45392$

كمقدار σ^2 أي $\hat{\sigma}^2 = 1.205786$ فيكون $\hat{\sigma} = 1.205786$ وعليه تكون فترة تنبؤ 95%

لجميع القيم المستقبلية هي:

$$[49.7216 \pm 1.96(1.205786)] = [49.7216 \pm 2.3633] = [47.35826, 52.08494]$$

أي:

$$z_{60+\ell} \in [47.3582, 50.0849], \ell > 0 \text{ with probability } 0.95$$

ملاحظة: تحسب MSD كالتالي

$$MSD = \hat{\sigma}^2 = \frac{\sum_{i=1}^n (z_i - \hat{z}_i)^2}{n-1}$$

تمرين:

طبق تمديد اسي بسيط على المشاهدات السابقة مستخدما $\alpha = 0.3, 0.4, 0.5$ وقرر ايها افضل

للتنبؤ عن القيم المستقبلية؟.

الفصل الثاني عشر

التمهيد و التنبؤ بواسطة التمهيد الاسي المزدوج : Smoothing for Forecasting

أولاً: طريقة براون Brown's Method

لمشاهدات $z_1, z_2, \dots, z_{n-1}, z_n$ ولثابت تمهيد $\alpha < 0 < \alpha < 1$ يوجد التالي:

$$s_t^{(1)} = \alpha z_t + (1 - \alpha) s_{t-1}^{(1)}, \quad t = 1, 2, \dots, n$$

حيث $s_t^{(1)}$ تمهيد اسي بسيط (انظر التمهيد الاسي البسيط) و (1) ترمز الي درجة هذا التمهيد

$$s_t^{(2)} = \alpha s_t^{(1)} + (1 - \alpha) s_{t-1}^{(2)}, \quad t = 1, 2, \dots, n$$

حيث $s_t^{(2)}$ تمهيد اسي مزدوج و (2) ترمز الي درجة هذا التمهيد

$$a_t = 2s_t^{(1)} - s_t^{(2)}, \quad t = 1, 2, \dots, n$$

$$b_t = \frac{\alpha}{1 - \alpha} (s_t^{(1)} - s_t^{(2)}), \quad t = 1, 2, \dots, n$$

تحسب القيم المطبقة من المعادلة

$$\hat{z}_t = a_t + b_t t, \quad t = 1, 2, \dots, n$$

وتحسب التنبؤات للفيما المستقبلية $z_{n+\ell}$ من

$$z_n(\ell) = a_n + b_n \ell, \quad \ell > 0$$

حساب القيم الاولية $s_0^{(1)}$ و $s_0^{(2)}$: من العلاقات السابقة نجد

$$s_0^{(1)} = a_0 - \frac{1 - \alpha}{\alpha} b_0$$

$$s_0^{(2)} = a_0 - 2 \frac{1 - \alpha}{\alpha} b_0$$

نوجد a_0 و b_0 بإنحدار المشاهدات على الزمن $z_t = \alpha + \beta t + e_t$, $t = 1, 2, \dots, n$ ويكون

$$b_0 = \hat{\beta} \quad \text{و} \quad a_0 = \hat{\alpha}$$

ثانياً: طريقة هولت Holt's Method

لمشاهدات $z_1, z_2, \dots, z_{n-1}, z_{n-2}$ وثابتى تمهيد $\alpha < 1 < \gamma < 0$ يوجد التالى:

$$s_t = \alpha z_t + (1-\alpha)(s_{t-1} + b_{t-1}), \quad t = 1, 2, \dots, n$$

$$b_t = \gamma(s_t - s_{t-1}) + (1-\gamma)b_{t-1}, \quad t = 1, 2, \dots, n$$

نحسب القيم المطبقة من

$$\hat{z}_t = s_t + b_t t, \quad t = 1, 2, \dots, n$$

والتبؤات للفي المستقبلية من

$$z_n(\ell) = s_n + b_n \ell, \quad \ell > 0$$

نحسب القيم الاولية s_0 و b_0 من

$$s_0 = z_1$$

$$b_0 = z_2 - z_1 \quad \text{or}$$

$$b_0 = \frac{(z_2 - z_1) + (z_3 - z_2)}{2} = \frac{(z_3 - z_1)}{2} \quad \text{or}$$

$$b_0 = \frac{(z_2 - z_1) + (z_3 - z_2) + (z_4 - z_3)}{3} = \frac{(z_4 - z_1)}{3}$$

مثال:

تحمل البيانات من ورقة العمل EMPLOY.MTW

MTB > Retrieve 'E:\Mtbwin\DATA\EMPLOY.MTW'.

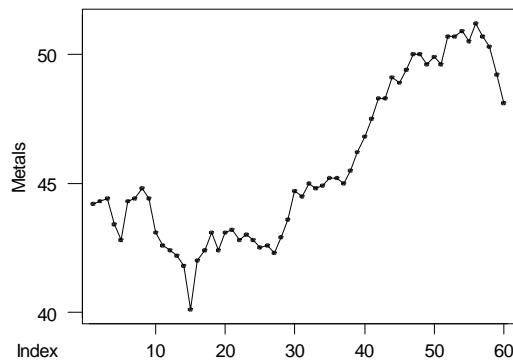
سوف نستخدم المشاهدات في التغير Metals

Metals

44.2	44.3	44.4	43.4	42.8	44.3	44.4
44.8	44.4	43.1	42.6	42.4	42.2	41.8
40.1	42.0	42.4	43.1	42.4	43.1	43.2
42.8	43.0	42.8	42.5	42.6	42.3	42.9
43.6	44.7	44.5	45.0	44.8	44.9	45.2
45.2	45.0	45.5	46.2	46.8	47.5	48.3
48.3	49.1	48.9	49.4	50.0	50.0	49.6
49.9	49.6	50.7	50.7	50.9	50.5	51.2
50.7	50.3	49.2	48.1			

نرسم هذه المشاهدات:

```
MTB > TSPlot 'Metals';
SUBC> Index;
SUBC> TDisplay 11;
SUBC> Symbol;
SUBC> Connect.
```



نطبق الآن تمهيداً لهذه المشاهدات بإستخدام التمهيد الأسني المزدوج بطريقة براون، نستخدم الآن البرمج Macro (%DES) مع الامر الفرعى WEIGHT بأوزان متساوية سوف نأخذها 0.2

```
MTB > %DES 'Metals';
SUBC> Weight 0.2 0.2;
SUBC> Forecasts 6;
SUBC> Title "Brown's Double Exponential Smoothing";
SUBC> Table.
```

Double Exponential Smoothing

Data	Metals
Length	60.0000

NMissing 0

Smoothing Constants

Alpha (level): 0.2

Gamma (trend): 0.2

Accuracy Measures

MAPE: 2.16187

MAD: 0.97032

MSD: 1.62936

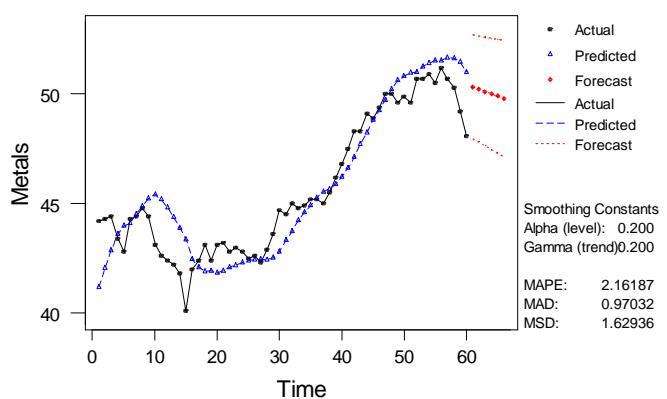
	Time	Metals	Smooth	Predict	Error
1		44.2	41.7739	41.1674	3.03257
2		44.3	42.4976	42.0470	2.25303
3		44.4	43.1686	42.8607	1.53927
4		43.4	43.5546	43.5933	-0.19330
5		42.8	43.7373	43.9716	-1.17163
6		44.3	44.1459	44.1074	0.19257
7		44.4	44.4990	44.5238	-0.12377
8		44.8	44.8575	44.8719	-0.07189
9		44.4	45.0620	45.2275	-0.82751
10		43.1	44.9391	45.3989	-2.29891
11		42.6	44.6673	45.1841	-2.58407
12		42.4	44.3271	44.8088	-2.40884
13		42.2	43.9378	44.3723	-2.17229
14		41.8	43.4769	43.8962	-2.09617
15		40.1	42.7011	43.3514	-3.25142
16		42.0	42.3565	42.4456	-0.44557
17		42.4	42.1465	42.0831	0.31694
18		43.1	42.1286	41.8857	1.21426
19		42.4	42.0132	41.9164	0.48355

20	43.1	42.0763	41.8204	1.27964
21	43.2	42.1877	41.9347	1.26533
22	42.8	42.2374	42.0967	0.70327
23	43.0	42.3396	42.1745	0.82549
24	42.8	42.4078	42.3098	0.49024
25	42.5	42.4181	42.3976	0.10244
26	42.6	42.4495	42.4119	0.18809
27	42.3	42.4207	42.4509	-0.15090
28	42.9	42.5129	42.4161	0.48394
29	43.6	42.7420	42.5276	1.07245
30	44.7	43.1797	42.7996	1.90036
31	44.5	43.5507	43.3133	1.18668
32	45.0	43.9854	43.7317	1.26826
33	44.8	44.3338	44.2172	0.58280
34	44.9	44.6511	44.5889	0.31112
35	45.2	44.9749	44.9187	0.28133
36	45.2	45.2430	45.2538	-0.05376
37	45.0	45.4157	45.5197	-0.51967
38	45.5	45.6373	45.6716	-0.17162
39	46.2	45.9491	45.8863	0.31368
40	46.8	46.3285	46.2106	0.58938
41	47.5	46.7909	46.6136	0.88637
42	48.3	47.3492	47.1115	1.18850
43	48.3	47.8339	47.7173	0.58266
44	49.1	48.4002	48.2253	0.87469
45	48.9	48.8413	48.8267	0.07332
46	49.4	49.2966	49.2707	0.12930
47	50.0	49.7849	49.7311	0.26890
48	50.0	50.1841	50.2302	-0.23017
49	49.6	50.4162	50.6202	-1.02022
50	49.9	50.6292	50.8114	-0.91145
51	49.6	50.7104	50.9880	-1.38797
52	50.7	50.9509	51.0137	-0.31368
53	50.7	51.1334	51.2417	-0.54169

54	50.9	51.3019	51.4024	-0.50244
55	50.5	51.3407	51.5509	-1.05093
56	51.2	51.4782	51.5477	-0.34770
57	50.7	51.4770	51.6712	-0.97120
58	50.3	51.3649	51.6311	-1.33115
59	49.2	51.0127	51.4659	-2.26587
60	48.1	50.4384	51.0230	-2.92300

Row	Period	Forecast	Lower	Upper
1	61	50.3318	47.9545	52.7091
2	62	50.2252	47.7984	52.6520
3	63	50.1186	47.6384	52.5987
4	64	50.0120	47.4749	52.5490
5	65	49.9054	47.3080	52.5027
6	66	49.7988	47.1381	52.4594

Brown's Double Exponential Smoothing



إيجاد a_0 و b_0 :

```
MTB > set c4
DATA> 1:60
DATA> end
MTB > regr c3 1 c4
```

Regression Analysis

The regression equation is

$$\text{Metals} = 41.0 + 0.152 \text{ C4}$$

إذا $b_0 = 0.152$ و $a_0 = 41.0$ ومنها نحسب

$$s_0^{(1)} = a_0 - \frac{1-\alpha}{\alpha} b_0 = 41.0 - \frac{0.8}{0.2}(0.152) = 41.608$$

$$s_0^{(2)} = a_0 - 2 \frac{1-\alpha}{\alpha} b_0 = 41.0 - 2 \left(\frac{0.8}{0.2} \right)(0.152) = 42.216$$

$$s_1^{(1)} = (0.2)(44.2) + (0.8)(41.608) = 42.1264$$

$$s_1^{(2)} = (0.2)(42.1264) + (0.8)(42.216) = 42.19808$$

$$a_1 = (2)(42.1264) - 42.19808 = 42.05472$$

$$b_1 = \frac{(0.2)}{(0.8)}(42.19808 - 42.05472) = 0.03584$$

$$\hat{z}_1 = 42.05472 + (0.03584)(1) = 42.09056$$

وهكذا الخ ...

تحسب فترات التنبؤ بإستخدام MSD كما في الأمثلة السابقة.

مثال:

لتطبيق طريقة هولت نستخدم الآن البرمج Macro (Macro) DES % مع الامر الفرعي WEIGHT

$$\text{بأوزان مختلفة سوف نأخذ } \alpha = 0.2 \text{ و } \gamma = 0.3$$

```
MTB > RETR 'E:\Mtbwin\DATA\EMPLOY.MTW'.
```

```
Retrieving worksheet from file: E:\Mtbwin\DATA\EMPLOY.MTW
```

```
Worksheet was saved on 6/ 5/1996
```

```

MTB > %DES 'Metals';
SUBC>   Weight 0.2 0.3;
SUBC>   Forecasts 6;
SUBC>   Title "Holt's Double Exponential Smoothing";
SUBC>   Table.

```

Double Exponential Smoothing

Data Metals
 Length 60.0000
 NMissing 0

Smoothing Constants
 Alpha (level): 0.2
 Gamma (trend): 0.3

Accuracy Measures
 MAPE: 2.15656
 MAD: 0.96328
 MSD: 1.56274

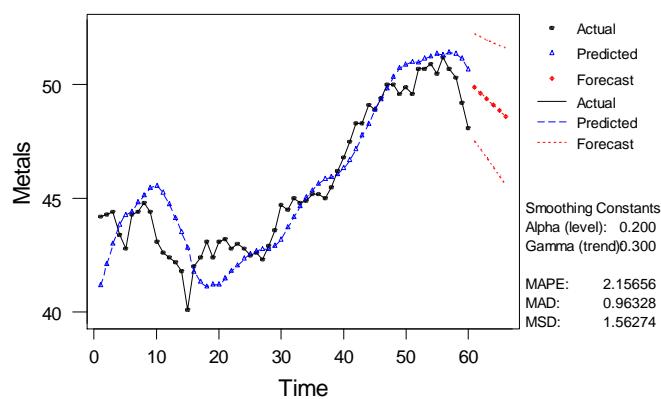
Time	Metals	Smooth	Predict	Error
1	44.2	41.7739	41.1674	3.03257
2	44.3	42.5461	42.1076	2.19238
3	44.4	43.2891	43.0113	1.38868
4	43.4	43.7501	43.8376	-0.43760
5	42.8	43.9779	44.2724	-1.47237
6	44.3	44.3895	44.4118	-0.11184
7	44.4	44.7334	44.8167	-0.41671
8	44.8	45.0685	45.1356	-0.33560
9	44.4	45.2405	45.4506	-1.05057

10	43.1	45.0676	45.5595	-2.45952
11	42.6	44.7113	45.2391	-2.63911
12	42.4	44.2595	44.7244	-2.32443
13	42.2	43.7466	44.1332	-1.93322
14	41.8	43.1634	43.5043	-1.70426
15	40.1	42.2751	42.8188	-2.71884
16	42.0	41.8139	41.7674	0.23263
17	42.4	41.5361	41.3202	1.07985
18	43.1	41.5057	41.1072	1.99283
19	42.4	41.4371	41.1964	1.20365
20	43.1	41.5799	41.1999	1.90008
21	43.2	41.8054	41.4568	1.74322
22	42.8	41.9895	41.7869	1.01314
23	43.0	42.2254	42.0317	0.96829
24	42.8	42.4205	42.3257	0.47431
25	42.5	42.5395	42.5493	-0.04933
26	42.6	42.6522	42.6653	-0.06528
27	42.3	42.6793	42.7741	-0.47413
28	42.9	42.7982	42.7728	0.12724
29	43.6	43.0394	42.8993	0.70070
30	44.7	43.4861	43.1826	1.51743
31	44.5	43.8762	43.7202	0.77977
32	45.0	44.3257	44.1571	0.84285
33	44.8	44.6858	44.6573	0.14275
34	44.9	45.0007	45.0259	-0.12590
35	45.2	45.3066	45.3333	-0.13327
36	45.2	45.5449	45.6312	-0.43116
37	45.0	45.6749	45.8436	-0.84361
38	45.5	45.8384	45.9230	-0.42295
39	46.2	46.0888	46.0610	0.13895
40	46.8	46.4159	46.3199	0.48014
41	47.5	46.8406	46.6757	0.82428
42	48.3	47.3799	47.1499	1.15014
43	48.3	47.8665	47.7582	0.54181

44	49.1	48.4419	48.2774	0.82265
45	48.9	48.9016	48.9020	-0.00205
46	49.4	49.3693	49.3617	0.03832
47	50.0	49.8653	49.8317	0.16832
48	50.0	50.2702	50.3378	-0.33779
49	49.6	50.4979	50.7224	-1.12240
50	49.9	50.6862	50.8827	-0.98275
51	49.6	50.7296	51.0121	-1.41206
52	50.7	50.9166	50.9708	-0.27079
53	50.7	51.0532	51.1415	-0.44152
54	50.9	51.1813	51.2516	-0.35162
55	50.5	51.1869	51.3586	-0.85860
56	51.2	51.2901	51.3127	-0.11267
57	50.7	51.2673	51.4092	-0.70916
58	50.3	51.1350	51.3438	-1.04381
59	49.2	50.7591	51.1489	-1.94889
60	48.1	50.1448	50.6560	-2.55603

Row	Period	Forecast	Lower	Upper
1	61	49.8884	47.5283	52.2484
2	62	49.6319	47.1597	52.1041
3	63	49.3755	46.7803	51.9707
4	64	49.1190	46.3915	51.8466
5	65	48.8626	45.9946	51.7306
6	66	48.6061	45.5908	51.6215

Holt's Double Exponential Smoothing



تمرين: تحقق من صحة الحسابات السابقة بتتبع بعض القيم يدويا (ملاحظة: يتوقع عدم تطابق الحسابات تماما وذلك لإختلاف طريق تمثيل الأعداد بين الحاسوب والآلة الحاسبة وكذلك في تخزين الأرقام في ذاكرت كل منها)

الفصل الثالث عشر

التمهيد الاسي الثلاثي و التنبؤ بواسطه طريقة ونترز للمتسلسلات الموسمية المنجرفة

Triple Exponential Smoothing: Winters' Three-Parameter Trend and Seasonality Smoothing Method

جميع الطرق السابقة التي درسناها في هذا الفصل لا تتفع لتحليل الظواهر الموسمية ماعدى طريقة التفكيك Winters' trend and Decomposition Method وطريقة ونترز seasonal smoothing التي سوف نستعرضها هنا طريقة ونترز للمتسلسلات الموسمية المنجرفة أو لا: تمهد المشاهدات تمهيدا كلبا بالعلاقة

$$s_t = \alpha \frac{z_t}{S_{t-s}} + (1-\alpha)(s_{t-1} + b_{t-1}), \quad t=1,2,\dots,n$$

ثانيا: تمهيد الإنجراف

$$b_t = \gamma(s_t - s_{t-1}) + (1-\gamma)b_{t-1}, \quad t=1,2,\dots,n$$

ثالثا: تمهيد الموسمية

$$S_t = \beta \frac{z_t}{S_t} + (1-\beta)S_{t-s}, \quad t=1,2,\dots,n$$

حيث S_t هي المركبة الموسمية عند الزمن t و s هي دورة الموسمية

القيم المطبقة تعطى بالعلاقة

$$\hat{z}_t = (s_t + b_t t) S_{t-s}, \quad t=1,2,\dots,n$$

والتنبؤات من العلاقة

$$z_n(\ell) = (s_n + b_n \ell) S_{n-s+\ell}, \quad \ell > 0$$

من الصعب جدا تتبع طريقة ونترز بالحسابات اليدوية حيث ان القيم الاولية تحسب بخوارزمات غير خطية باستخدام الحاسوب ولهذا لن نستعرضها هنا ونكتفي بالنتائج المخرجة من الحاسوب.

مثال:

تحمل البيانات من ورقة العمل EMPLOY.MTW

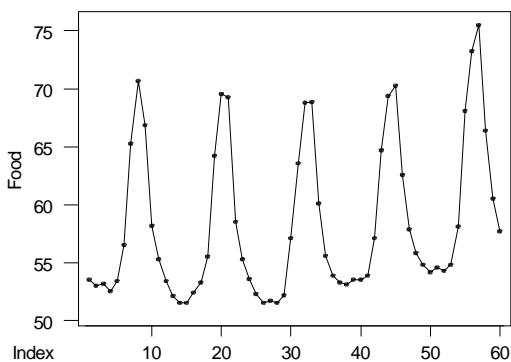
```
MTB > Retrieve 'E:\Mtbwin\DATA\EMPLOY.MTW'.
```

سوف نستخدم المشاهدات في المتغير Food

Food

53.5	53.0	53.2	52.5	53.4	56.5	65.3	70.7	66.9	58.2	55.3	53.4
52.1	51.5	51.5	52.4	53.3	55.5	64.2	69.6	69.3	58.5	55.3	53.6
52.3	51.5	51.7	51.5	52.2	57.1	63.6	68.8	68.9	60.1	55.6	53.9
53.3	53.1	53.5	53.5	53.9	57.1	64.7	69.4	70.3	62.6	57.9	55.8
54.8	54.2	54.6	54.3	54.8	58.1	68.1	73.3	75.5	66.4	60.5	57.7

ونرسم المشاهدات



نلاحظ ان الظاهرة موسمية بدوره 12 نطبق الان طريقة وتنرز كالتالي:

أولاً: للنموذج الإضافي Additive Model

$$z_t = b_t + S_t + e_t, \quad t = 1, 2, \dots, n$$

```
MTB > %Wintadd 'Food' 12;
SUBC>   Weight 0.2 0.2 0.2;
SUBC>   Forecasts 12;
SUBC>   Title "Wintrs' Trend and Seasonal Smoothing";
```

SUBC> Table.

Winters' additive model

Data Food
Length 60.0000
NMissing 0

Smoothing Constants

Alpha (level): 0.2
Gamma (trend): 0.2
Delta (seasonal): 0.2

Accuracy Measures

MAPE: 1.94769

MAD: 1.15100

MSD: 2.66711

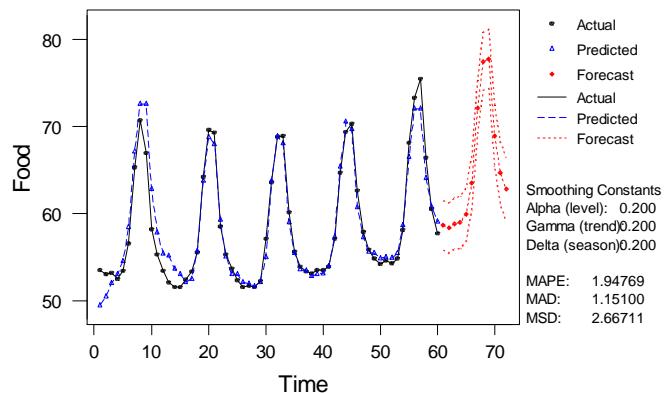
Time	Food	Smooth	Predict	Error
1	53.5	48.7755	49.4303	4.06965
2	53.0	49.6020	50.4197	2.58027
3	53.2	51.0736	51.9944	1.20556
4	52.5	52.0733	53.0424	-0.54244
5	53.4	53.5117	54.4591	-1.05914
6	56.5	57.4851	58.3901	-1.89013
7	65.3	66.2299	67.0593	-1.75932
8	70.7	71.7852	72.5443	-1.84430
9	66.9	71.8932	72.5785	-5.67851
10	58.2	62.3206	62.7787	-4.57874
11	55.3	57.5208	57.7958	-2.49577
12	53.4	55.1544	55.3296	-1.92957
13	52.1	55.0393	55.1373	-3.03734
14	51.5	53.6493	53.6258	-2.12584

15	51.5	53.1185	53.0100	-1.50996
16	52.4	52.2661	52.0971	0.30287
17	53.3	52.6528	52.4960	0.80401
18	55.5	55.7616	55.6369	-0.13695
19	64.2	63.8483	63.7181	0.48187
20	69.6	68.8787	68.7678	0.83218
21	69.3	68.0386	67.9610	1.33902
22	58.5	59.2825	59.2585	-0.75851
23	55.3	55.0979	55.0435	0.25650
24	53.6	53.0432	52.9991	0.60092
25	52.3	53.0377	53.0177	-0.71765
26	51.5	52.1394	52.0907	-0.59067
27	51.7	51.9889	51.9165	-0.21651
28	51.5	51.7214	51.6403	-0.14031
29	52.2	52.1875	52.1009	0.09913
30	57.1	55.0750	54.9923	2.10774
31	63.6	63.7515	63.7531	-0.15314
32	68.8	68.8427	68.8382	-0.03822
33	68.9	68.0160	68.0099	0.89007
34	60.1	58.9061	58.9356	1.16436
35	55.6	55.3220	55.3981	0.20190
36	53.9	53.4419	53.5262	0.37384
37	53.3	53.3084	53.4076	-0.10757
38	53.1	52.6717	52.7666	0.33345
39	53.5	52.9095	53.0177	0.48233
40	53.5	52.9745	53.1020	0.39803
41	53.9	53.7952	53.9386	-0.03858
42	57.1	57.2065	57.3484	-0.24838
43	64.7	65.2747	65.4066	-0.70661
44	69.4	70.4039	70.5076	-1.10758
45	70.3	69.6200	69.6794	0.62065
46	62.6	60.5655	60.6497	1.95031
47	57.9	57.0392	57.2014	0.69858
48	55.8	55.3721	55.5623	0.23773

49	54.8	55.2403	55.4399	-0.63993
50	54.2	54.6681	54.8422	-0.64220
51	54.6	54.8138	54.9622	-0.36218
52	54.3	54.7366	54.8705	-0.57048
53	54.8	55.3001	55.4112	-0.61119
54	58.1	58.5310	58.6176	-0.51765
55	68.1	66.4168	66.4827	1.61731
56	73.3	71.8806	72.0112	1.28878
57	75.5	71.8794	72.0616	3.43843
58	66.4	63.7240	64.0437	2.35629
59	60.5	60.3141	60.7281	-0.22810
60	57.7	58.6397	59.0446	-1.34455

Row	Period	Forecast	Lower	Upper
1	61	58.6167	55.7968	61.4366
2	62	58.3236	55.4449	61.2023
3	63	58.8195	55.8775	61.7614
4	64	58.9840	55.9746	61.9935
5	65	59.8723	56.7913	62.9532
6	66	63.4804	60.3243	66.6365
7	67	72.0757	68.8410	75.3104
8	68	77.4486	74.1321	80.7651
9	69	77.7540	74.3528	81.1552
10	70	68.9067	65.4180	72.3954
11	71	64.6434	61.0647	68.2221
12	72	62.7731	59.1020	66.4441

Wintrs' Trend and Seasonal Smoothing



ثانياً: للنموذج التضاعفي Multiplicative Model

$$z_t = b_t S_t + e_t, \quad t = 1, 2, \dots, n$$

```
MTB > %Wintmult 'Food' 12;
SUBC>   Weight 0.2 0.2 0.2;
SUBC>   Forecasts 12;
SUBC>   Title "Winters' Trend and Seasonal Smoothing";
SUBC>   Table.
```

Winters' multiplicative model

Data	Food
Length	60.0000
NMissing	0

Smoothing Constants

Alpha (level): 0.2

Gamma (trend): 0.2

Delta (seasonal): 0.2

Accuracy Measures

MAPE: 1.88377

MAD: 1.12068

MSD: 2.86696

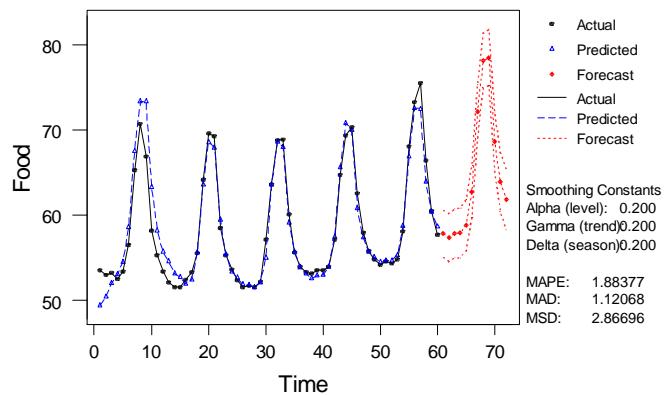
Time	Food	Smooth	Predict	Error
1	53.5	48.7870	49.3853	4.11470
2	53.0	49.6755	50.4303	2.56966
3	53.2	51.1521	52.0132	1.18677
4	52.5	52.1675	53.0746	-0.57458
5	53.4	53.6181	54.5132	-1.11323
6	56.5	57.6509	58.5541	-2.05414
7	65.3	66.6199	67.5607	-2.26072
8	70.7	72.4105	73.3280	-2.62800
9	66.9	72.5679	73.3777	-6.47768
10	58.2	62.7837	63.2634	-5.06337
11	55.3	57.9154	58.1732	-2.87320
12	53.4	55.5108	55.6485	-2.24849
13	52.1	54.4920	54.5392	-2.43920
14	51.5	53.2117	53.1621	-1.66212
15	51.5	52.8118	52.6957	-1.19573
16	52.4	52.0929	51.9302	0.46985
17	53.3	52.5894	52.4439	0.85611
18	55.5	55.7388	55.6209	-0.12087
19	64.2	63.7189	63.5782	0.62178
20	69.6	68.7087	68.5838	1.01617
21	69.3	67.9722	67.8890	1.41104
22	58.5	59.4594	59.4361	-0.93606
23	55.3	55.4037	55.3468	-0.04680
24	53.6	53.4103	53.3536	0.24639
25	52.3	52.6818	52.6356	-0.33562
26	51.5	51.8659	51.8071	-0.30705
27	51.7	51.8002	51.7290	-0.02902
28	51.5	51.6271	51.5549	-0.05492
29	52.2	52.1643	52.0890	0.11103

Row	Period	Forecast	Lower	Upper
30	57.1	55.0424	54.9676	2.13244
31	63.6	63.6079	63.6199	-0.01988
32	68.8	68.6702	68.6823	0.11774
33	68.9	67.9561	67.9727	0.92727
34	60.1	59.1021	59.1487	0.95133
35	55.6	55.6210	55.7003	-0.10032
36	53.9	53.7881	53.8609	0.03912
37	53.3	53.0479	53.1211	0.17892
38	53.1	52.4502	52.5294	0.57055
39	53.5	52.7444	52.8467	0.65329
40	53.5	52.8747	53.0029	0.49714
41	53.9	53.7689	53.9188	-0.01879
42	57.1	57.2790	57.4374	-0.33743
43	64.7	65.4702	65.6357	-0.93567
44	69.4	70.6713	70.8095	-1.40954
45	70.3	69.8908	69.9719	0.32815
46	62.6	60.7552	60.8370	1.76302
47	57.9	57.1925	57.3348	0.56523
48	55.8	55.5181	55.6775	0.12253
49	54.8	54.8764	55.0383	-0.23826
50	54.2	54.3244	54.4749	-0.27486
51	54.6	54.5372	54.6769	-0.07694
52	54.3	54.5298	54.6661	-0.36612
53	54.8	55.1925	55.3155	-0.51551
54	58.1	58.6054	58.7141	-0.61410
55	68.1	66.7739	66.8698	1.23016
56	73.3	72.4056	72.5622	0.73784
57	75.5	72.3385	72.5236	2.97638
58	66.4	63.6729	63.9378	2.46217
59	60.5	60.0395	60.3781	0.12191
60	57.7	58.3023	58.6338	-0.93381

Row Period Forecast Lower Upper

1	61	57.8102	55.0645	60.5558
2	62	57.3892	54.5864	60.1921
3	63	57.8332	54.9687	60.6977
4	64	57.9307	55.0005	60.8609
5	65	58.8311	55.8313	61.8309
6	66	62.7415	59.6686	65.8145
7	67	72.1849	69.0354	75.3344
8	68	78.1507	74.9215	81.3798
9	69	78.5092	75.1976	81.8208
10	70	68.6689	65.2721	72.0657
11	71	63.9258	60.4414	67.4103
12	72	61.8189	58.2446	65.3933

Winters' Trend and Seasonal Smoothing



ملاحظات:

لتطبيق طريقة ونترز نحتاج الي اختيار قيم ثلاثة معالم هي α ثابت التمهيد الكلي و γ ثابت تمهيد الإنجراف و β ثابت تمهيد الموسمية وهذه عملية أفضليّة Optimization في ثلاثة ابعاد (فضاء المعالم) إما أن نترك للبرنامِج الإحصائي المستخدم حسابها تلقائياً بإستخدام خوارزميات غير خطية مبنية داخل البرنامج أو نقوم نحن بإمداد البرنامج بذلك القيم . تمرير: في الأمثلة السابقة اخذنا $\alpha = \beta = \gamma = 0.2$. ثبت في كل مرة معلمين وغير الثالث حتى تحصل على أقل MSD

مثال عملى لبناء نموذج تنبؤ:

سوف نستخدم ورقة العمل CPI.MTW من مجموعة البيانات للبرنامج MINITAB

```
MTB > Retrieve 'C:\MTBWIN\STUDENT9\CPI.MTW'.
```

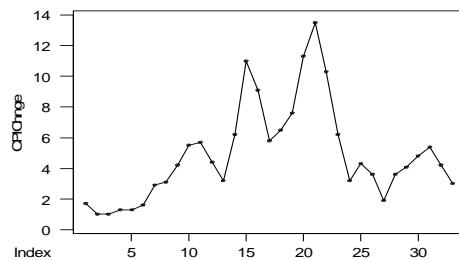
سوف نأخذ المتغير CPIChange

CPIChnge

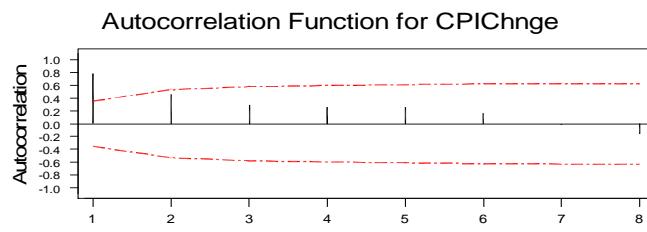
1.7	1.0	1.0	1.3	1.3	1.6	2.9
3.1	4.2	5.5	5.7	4.4	3.2	6.2
11.0	9.1	5.8	6.5	7.6	11.3	13.5
10.3	6.2	3.2	4.3	3.6	1.9	3.6
4.1	4.8	5.4	4.2	3.0		

نرسم المتسلسلة ونوجد الترابطات الذاتية والترابطات الذاتية الجزئية العينية

```
MTB > TSPlot
```

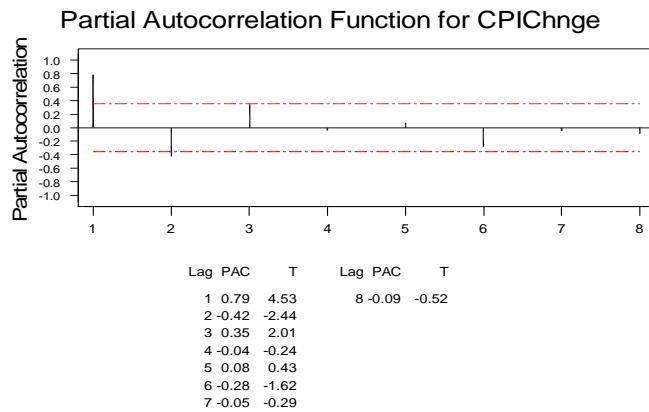


```
MTB > %acf c2
```



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.79	4.53	22.42	8	-0.16	-0.51	41.23
2	0.46	1.77	30.32				
3	0.29	1.02	33.59				
4	0.26	0.88	36.24				
5	0.26	0.86	38.97				
6	0.16	0.52	40.05				
7	-0.02	-0.06	40.07				

```
MTB > %pacf c2
```



من انماط التربطات الذاتية والترابطات الذاتية الجزئية العينية قد يكون النموذج ARMA(1,1)
ينطبق على المتسلسلة، الأوامر التالية تطبق النموذج المقترن وتولد 5 تنبؤات لقيمة المستقبلية

```
MTB > arima 1 0 1 c2;  
SUBC> fore 5 c3 c4 c5;  
SUBC> gser;  
SUBC> gacf;  
SUBC> gpacf;  
SUBC> ghist;  
SUBC> gnormal.
```

ARIMA Model

ARIMA model for CPIChnge

Estimates at each iteration

Iteration	SSE	Parameters		
0	323.251	0.100	0.100	4.522
1	200.616	0.250	-0.050	3.745
2	182.146	0.184	-0.200	4.067
3	163.067	0.135	-0.350	4.308

4	142.864	0.107	-0.500	4.434
5	121.402	0.111	-0.650	4.407
6	99.668	0.150	-0.800	4.197
7	77.036	0.268	-0.950	3.590
8	67.550	0.418	-0.956	2.828
9	62.802	0.568	-0.964	2.062
10	62.108	0.637	-0.973	1.687
11	62.030	0.644	-0.979	1.619
12	62.003	0.647	-0.982	1.584
13	61.996	0.651	-0.985	1.549
14	61.996	0.651	-0.986	1.539

Unable to reduce sum of squares any further

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.6513	0.1434	4.54
MA 1	-0.9857	0.0516	-19.11
Constant	1.5385	0.4894	3.14
Mean	4.412	1.403	

Number of observations: 33

Residuals: SS = 61.8375 (backforecasts excluded)
 MS = 2.0613 DF = 30

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	9.6 (DF=10)	17.0 (DF=22)	*	(DF= *)
(DF= *)				

Forecasts from period 33

95 Percent Limits				
Period	Forecast	Lower	Upper	Actual
34	3.1362	0.3216	5.9507	
35	3.5810	-1.8180	8.9801	
36	3.8708	-2.3061	10.0476	
37	4.0594	-2.4192	10.5380	
38	4.1823	-2.4201	10.7848	

أي ان النموذج المقترن هو

$$z_t = 1.54 + 0.65z_{t-1} + a_t - 0.99a_{t-1}, \quad a_t \sim N(0, 2.06)$$

مقدرات المعالم وإنحرافاتها المعيارية وقيمة اختبار t هي

$$\hat{\phi}_1 = 0.6513, \quad s.e.(\hat{\phi}_1) = 0.1434, \quad t = 4.54$$

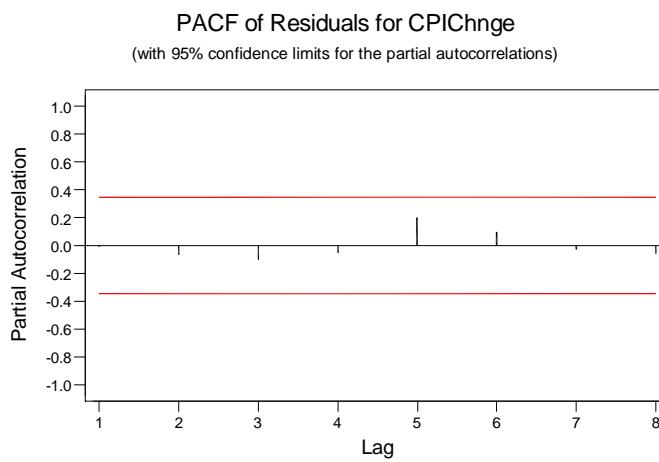
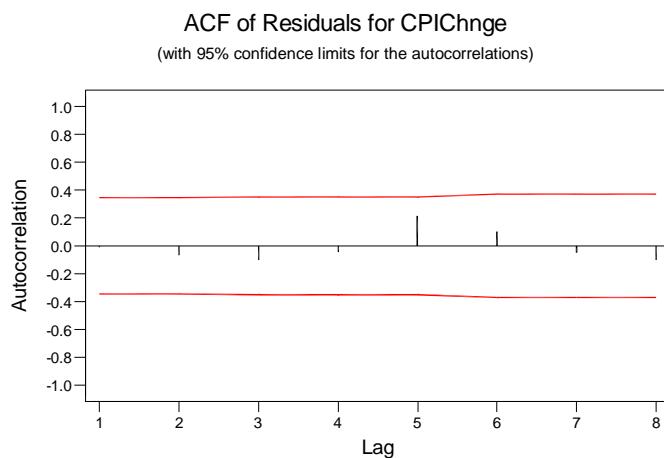
$$\hat{\theta}_1 = -0.9857, \quad s.e.(\hat{\theta}_1) = 0.0516, \quad t = -19.11$$

$$\hat{\delta} = 1.5385, \quad s.e.(\hat{\delta}) = 0.4894, \quad t = 3.14$$

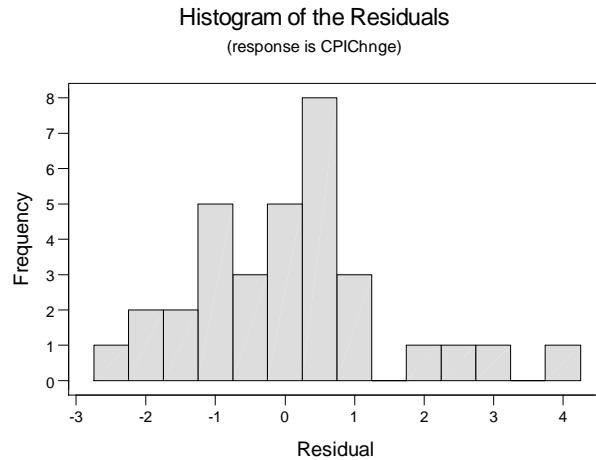
$$\hat{\sigma}^2 = 2.0613, \quad \text{with } d.f. = 30$$

نلاحظ ان جميع المعالم معنوية.

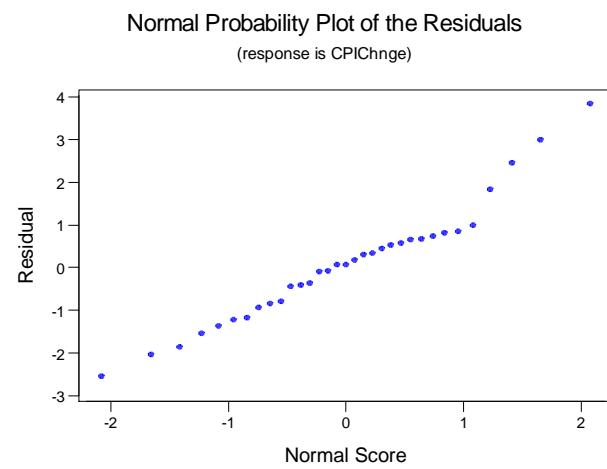
الآن نفحص الباقي:



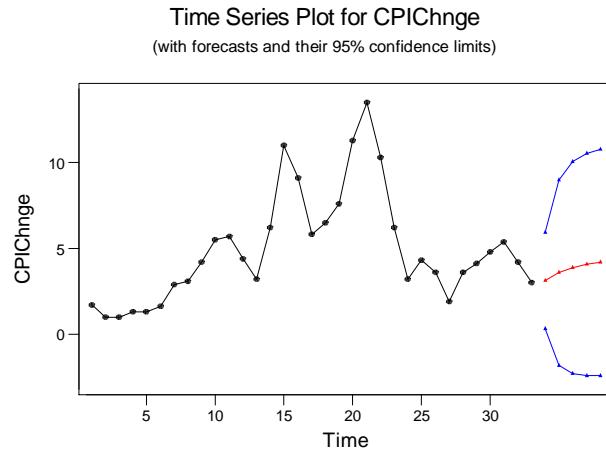
أنماط الترابط الذاتي والترابط الذاتي الجزئي للبواقي تدل على أن البواقي تتبع توزيع ضجة بيضاء أي غير مترابطة، لفحص طبيعة البواقي:
رسم المدرج التكراري



ينظر إلى مخطط الإحتمال الطبيعي للبواقي:
يبدو متناظر بعض الشيء.



نستطيع أن نقول إن الباقي طبيعية تقريبا.
الرسم التالي للمتسلسلة مع 5 تنبؤات للقيم المستقبلية.



دعنا نحاول تطبيق نموذج (2) AR على المتسلسلة كالتالي:

```
MTB > arima 2 0 0 c2
```

Type	Coef	StDev	T
AR 1	1.1872	0.1625	7.31
AR 2	-0.4657	0.1624	-2.87
Constant	1.3270	0.2996	4.43
Mean	4.765	1.076	

```
Number of observations: 33
Residuals: SS = 88.6206 (backforecasts excluded)
MS = 2.9540 DF = 30
```

```
Modified Box-Pierce (Ljung-Box) Chi-Square statistic
Lag 12 24 36 48
Chi-Square 19.8 (DF=10) 25.4 (DF=22) * (DF= *) *
(DF= *)
```

أي ان النموذج المقترن هو

$$z_t = 1.33 + 1.187 z_{t-1} - 0.4657 z_{t-1} + a_t, \quad a_t \sim N(0, 2.95)$$

مقدرات المعالم وإنحرافاتها المعيارية وقيمة اختبار t هي

$$\hat{\phi}_1 = 1.1872, \quad s.e.(\hat{\phi}_1) = 0.1625, \quad t = 7.31$$

$$\hat{\phi}_2 = -0.4657, \quad s.e.(\hat{\phi}_2) = 0.1624, \quad t = -2.87$$

$$\hat{\delta} = 1.327, \quad s.e.(\hat{\delta}) = 0.2996, \quad t = 4.43$$

$$\hat{\sigma}^2 = 2.954, \quad \text{with } d.f. = 30$$

لنظر إلى الإختبار

$$H_0 : \phi_2 = 0$$

$$H_1 : \phi_2 \neq 0$$

الإحصائية

$$t_0 = \frac{\hat{\phi}_2}{s.e.(\hat{\phi}_2)} = \frac{-0.4657}{0.1624} = -2.8676$$

نجد الـ P-value لها بالأمر

MTB > cdf -2.8676;

SUBC> t 30.

Cumulative Distribution Function

Student's t distribution with 30 DF

x	P(X ≤ x)
-2.8676	0.0037

أي الـ P-value لها تساوي 0.0037 وهي أقل من 0.05 أي لأنرفض ان $\phi_2 = 0$

وبالتالي نرفض النموذج (AR(2)).

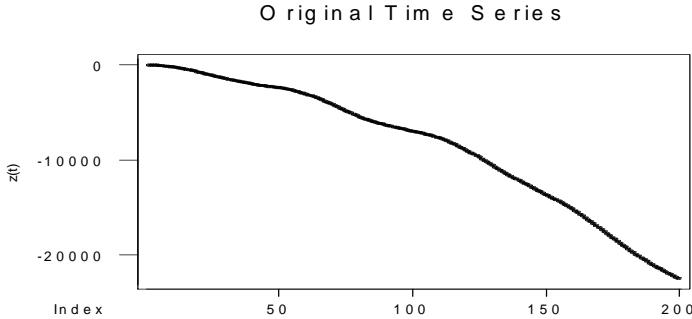
تمرين:

حاول تطبيق نماذج اخرى مناسبة على المتسلسلة السابقة وإختار أفضل نموذج، أجري الإختبارات المناسبة واستخدم ايضا المعيار AIC .

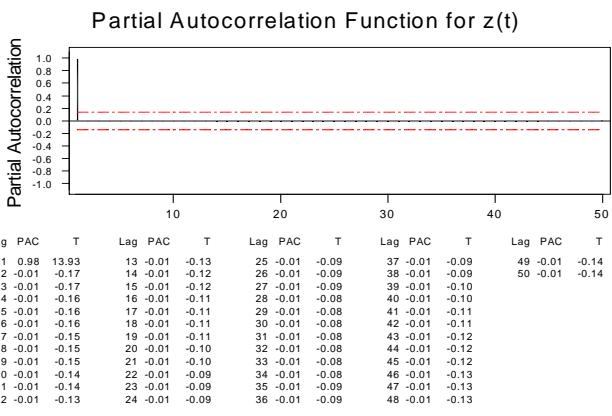
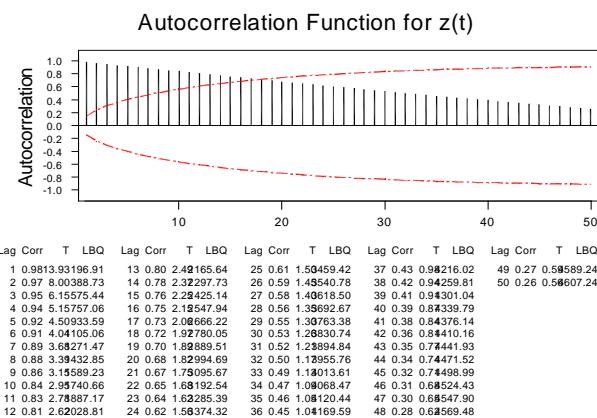
مثال عملی آخر لبناء نموذج تنبؤ:
سوف نحاول بناء نموذج للمتسلسلة

$z(t)$							
-2.5	-9.1	-19.2	-33.1	-52.8	-76.7	-103.2	
-132.4	-165.9	-204.0	-246.0	-291.3	-339.9	-391.4	
-446.4	-504.8	-566.7	-631.6	-698.2	-766.7	-836.1	
-905.3	-975.1	-1044.2	-1111.3	-1177.4	-1242.9	-1307.3	
-1371.8	-1436.5	-1500.0	-1561.5	-1620.8	-1679.0	-1736.9	
-1794.5	-1851.1	-1906.9	-1960.6	-2010.0	-2055.4	-2097.5	
-2136.4	-2173.3	-2210.8	-2250.5	-2290.6	-2328.5	-2363.4	
-2398.7	-2437.6	-2482.0	-2533.0	-2589.5	-2651.9	-2721.4	
-2797.6	-2880.4	-2968.6	-3060.8	-3156.1	-3253.4	-3353.3	
-3456.9	-3564.3	-3675.0	-3788.7	-3906.6	-4028.2	-4153.0	
-4281.7	-4412.0	-4542.3	-4673.3	-4805.0	-4937.2	-5068.7	
-5197.8	-5323.6	-5444.4	-5558.0	-5663.8	-5760.6	-5848.8	
-5931.6	-6011.8	-6090.4	-6167.9	-6244.3	-6317.8	-6387.3	
-6453.5	-6518.9	-6584.6	-6649.0	-6711.8	-6773.3	-6834.5	
-6896.0	-6957.1	-7015.6	-7073.1	-7131.7	-7193.3	-7259.9	
-7332.9	-7411.2	-7495.3	-7586.4	-7683.2	-7784.7	-7891.4	
-8004.6	-8124.0	-8249.2	-8379.1	-8512.3	-8649.8	-8791.2	
-8936.4	-9086.3	-9239.6	-9394.6	-9552.0	-9713.3	-9878.4	
-10047.2	-10219.0	-10392.1	-10564.0	-10734.0	-10903.2	-11071.9	
-11238.9	-11402.0	-11560.2	-11713.8	-11863.9	-12011.7	-12157.5	
-12302.5	-12447.5	-12593.4	-12740.8	-12889.7	-13039.8	-13190.3	
-13339.6	-13486.3	-13629.3	-13769.9	-13910.1	-14051.7	-14196.3	
-14345.9	-14499.7	-14657.5	-14819.8	-14986.4	-15158.3	-15335.9	
-15518.4	-15705.0	-15895.8	-16091.5	-16290.9	-16492.7	-16697.1	
-16904.2	-17113.5	-17324.4	-17535.7	-17745.2	-17951.5	-18155.6	
-18360.1	-18564.2	-18766.2	-18965.1	-19161.7	-19356.3	-19547.0	
-19733.5	-19919.5	-20107.3	-20294.5	-20478.0	-20655.7	-20827.7	
-20993.7	-21154.4	-21310.9	-21463.7	-21614.0	-21762.1	-21908.3	
-22053.2	-22195.6	-22335.1	-22474.4				

ولها الرسم الزمني التالي:



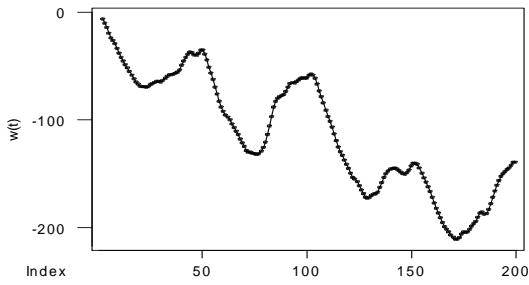
الاتجاهات الذاتية والاتجاهات الذاتية الجزئية هي:



واضح جداً أن المتسلسلة z_t غير مستقرة في المتوسط.

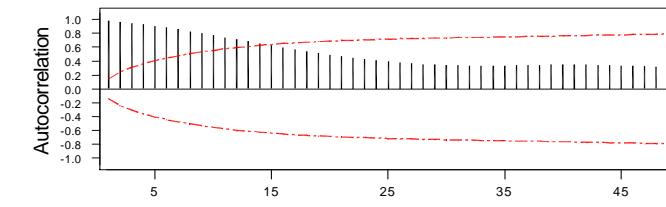
نأخذ الفروق الأولى $w_t = z_t - z_{t-1}$ ونرسمها

First Differences $w(t) = z(t) - z(t-1)$



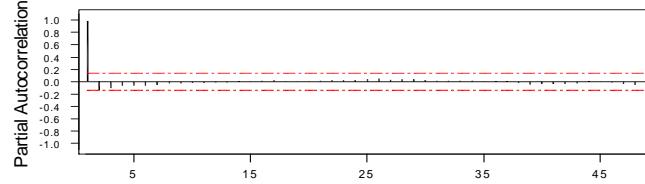
الترابطات الذاتية والترابطات الذاتية الجزئية للمتسلسلة المفرقة هي:

Autocorrelation Function for $w(t)$



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.9913	9.3197	10	13	0.69	2.2198	3	25	0.39	1.0270	1.91	37	0.34	0.9047	50
2	0.97	7.9839	0.03	14	0.66	2.0207	6.38	26	0.38	1.0273	4.99	38	0.35	0.9007	77.32
3	0.95	6.1257	4.74	15	0.63	1.9316	1.98	27	0.37	1.0276	1.16	39	0.35	0.9010	68
4	0.93	5.1075	3.55	16	0.60	1.8224	0.33	28	0.36	0.9879	5.84	40	0.35	0.9013	42
5	0.91	4.4392	4.81	17	0.57	1.7031	1.99	29	0.35	0.9284	4.46	41	0.35	0.9016	9.33
6	0.89	3.9408	7.93	18	0.54	1.6037	7.42	30	0.34	0.9285	2.35	42	0.35	0.8920	21
7	0.86	3.5824	2.44	19	0.52	1.5043	7.13	31	0.34	0.9287	9.79	43	0.35	0.8823	0.81
8	0.83	3.2538	8.10	20	0.49	1.4249	1.57	32	0.34	0.9290	7.03	44	0.34	0.8826	0.99
9	0.81	2.9852	4.83	21	0.47	1.3254	1.23	33	0.34	0.8293	4.32	45	0.34	0.8829	0.64
10	0.78	2.7665	2.58	22	0.45	1.2658	6.61	34	0.34	0.8296	1.85	46	0.33	0.8431	19.59
11	0.75	2.5677	1.42	23	0.43	1.1962	8.22	35	0.34	0.8298	9.82	47	0.33	0.8234	7.55
12	0.72	2.3888	1.49	24	0.41	1.1366	6.48	36	0.34	0.8901	8.34	48	0.32	0.7937	4.17

Partial Autocorrelation Function for $w(t)$

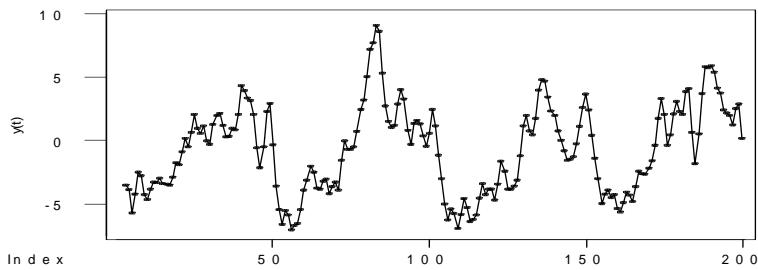


Lag	PAC	T	Lag												
1	0.99	13.93	13	-0.01	-0.16	25	0.04	0.52	37	-0.01	-0.07	49	-0.03	-0.48	
2	-0.14	-1.37	14	-0.00	-0.02	26	0.04	0.62	38	-0.02	-0.29				
3	-0.11	-1.51	15	0.01	0.10	27	0.03	0.47	39	-0.04	-0.63				
4	-0.07	-0.96	16	0.02	0.23	28	0.04	0.55	40	-0.04	-0.60				
5	-0.06	-0.90	17	0.02	0.25	29	0.04	0.56	41	-0.04	-0.54				
6	-0.07	-0.97	18	0.01	0.10	30	0.02	0.34	42	-0.04	-0.55				
7	-0.04	-0.76	19	0.01	0.12	31	0.01	0.22	43	-0.03	-0.2				
8	-0.03	-0.48	20	0.01	0.11	32	0.01	0.16	44	0.00	-0.07				
9	-0.03	-0.37	21	0.01	0.16	33	0.01	0.18	45	0.01	0.08				
10	-0.03	-0.37	22	0.03	0.35	34	0.01	0.15	46	-0.01	-0.18				
11	-0.02	-0.34	23	0.02	0.31	35	0.00	0.04	47	-0.04	-0.56				
12	-0.02	-0.22	24	0.02	0.27	36	-0.00	-0.07	48	-0.05	-0.76				

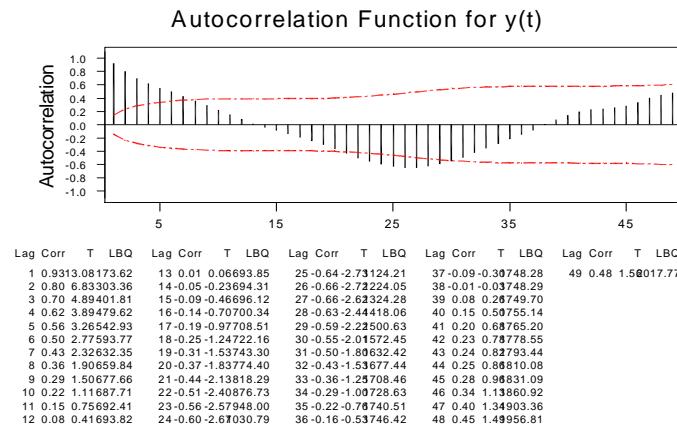
واضح جدا ان المتسلسلة w_t لا تزال غير مستقرة في المتوسط.

نأخذ الفروق الاولى $y_t = w_t - w_{t-1}$ (لاحظ ان هذا الفرق الثاني للمتسلسلة الأصلية) ونرسمها

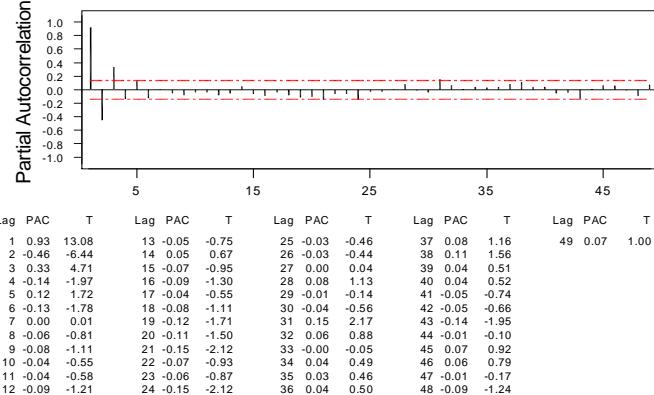
F i r s t D i f f e r e n c e s $y(t) = w(t) - w(t-1)$



الترابطات الذاتية والترابطات الذاتية الجزئية لهذه المتسلسلة المفرقة هي:



Partial Autocorrelation Function for $y(t)$



نلاحظ من شكل المتسلسلة و الترابطات الذاتية والترابطات الذاتية الجزئية انها أصبحت مستقرة في المتوسط اي ان $d=2$.

من انماط الترابطات الذاتية والترابطات الذاتية الجزئية نرى انها تتخادم من التخلف الأول مما يرشح نموذج (1,2,1) للمتسلسلة الأصلية z , وسوف نطبق هذا النموذج بالأمر

```
MTB > ARIMA 1 2 1 'z(t)' 'RESI2' 'FITS2';
SUBC>   NoConstant;
SUBC>   Forecast 10 c4 c5 c6;
SUBC>   GACF;
SUBC>   GPACF;
SUBC>   GHistogram;
SUBC>   GNormalplot.
```

ARIMA Model

ARIMA model for $z(t)$

Estimates at each iteration

Iteration	SSE	Parameters	
0	2462.77	0.100	0.100
1	1345.58	0.250	-0.050
2	1170.63	0.203	-0.200
3	984.83	0.182	-0.350
4	782.47	0.200	-0.500
5	560.15	0.278	-0.650
6	363.93	0.428	-0.765
7	259.20	0.578	-0.814
8	202.76	0.728	-0.842
9	185.51	0.861	-0.859
10	185.36	0.873	-0.860
11	185.36	0.875	-0.860
12	185.36	0.875	-0.860

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
------	------	-------	---

AR	1	0.8749	0.0353	24.75
MA	1	-0.8599	0.0357	-24.12

Differencing: 2 regular differences

Number of observations: Original series 200, after differencing 198

Residuals: SS = 183.717 (backforecasts excluded)
 MS = 0.937 DF = 196

Modified Box-Pierce (Ljung-Box) Chi-Square statistic

Lag	12	24	36	48
Chi-Square	3.9 (DF=10)	13.0 (DF=22)	33.1 (DF=34)	
	46.0 (DF=46)			

Forecasts from period 200

95 Percent Limits				
Period	Forecast	Lower	Upper	Actual
201	-22615.2	-22617.1	-22613.3	
202	-22757.2	-22764.6	-22749.9	
203	-22900.4	-22917.2	-22883.5	
204	-23044.5	-23075.3	-23013.7	
205	-23189.5	-23238.8	-23140.1	
206	-23335.2	-23407.8	-23262.6	
207	-23481.5	-23582.1	-23380.9	
208	-23628.4	-23761.8	-23495.0	
209	-23775.8	-23946.7	-23605.0	
210	-23923.7	-24136.6	-23710.7	

النموذج المقترن هو

$$z_t = 0.875_{t-1} z + a_t - 0.859 a_{t-1}, \quad a_t \sim N(0, 0.937)$$

ومقدرات المعامل وإنحرافاتها المعيارية وقيمة اختبار t هي

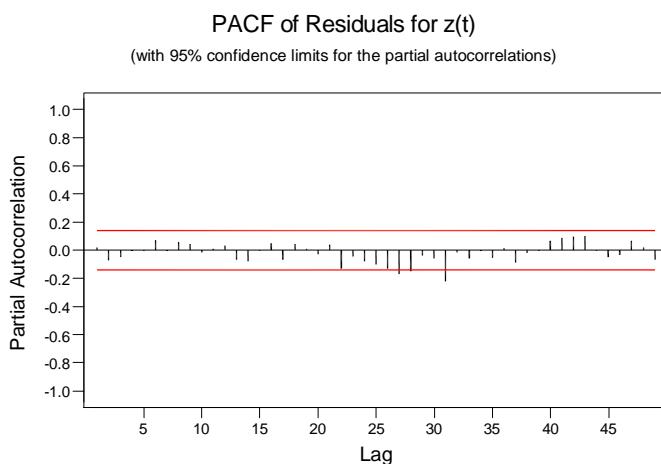
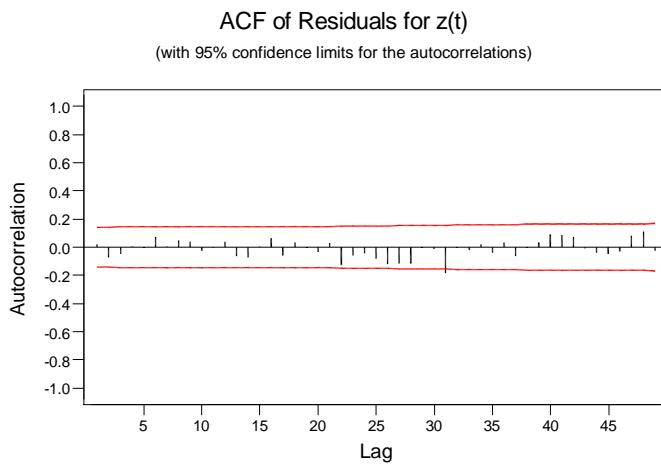
$$\hat{\phi}_1 = 0.8749, \quad s.e.(\hat{\phi}_1) = 0.0353, \quad t = 24.75$$

$$\hat{\theta}_1 = -0.8599, \quad s.e.(\hat{\theta}_1) = 0.0357, \quad t = -24.12$$

$$\hat{\sigma}^2 = 0.937, \quad \text{with } d.f. = 196$$

نلاحظ ان المعالم معنوية.

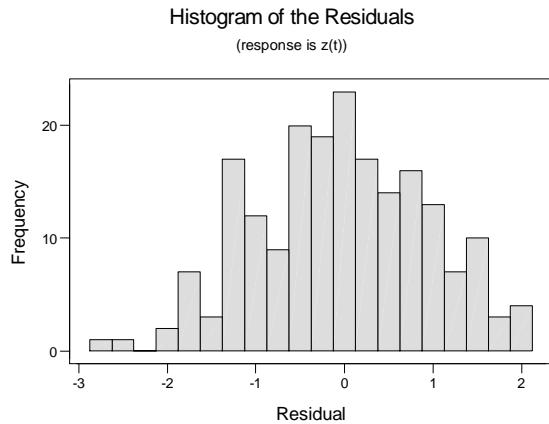
الآن نفحص الباقي:



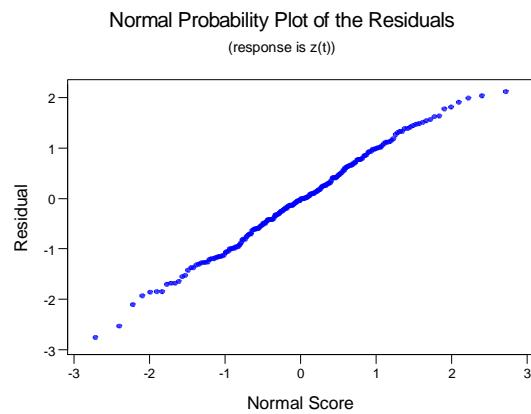
أنماط الترابط الذاتي والترابط الذاتي الجزئي للباقي تدل على أن الباقي تتبع توزيع ضجة

بيضاء أي غير مترابطة، لفحص طبيعة الباقي:

رسم المدرج التكراري

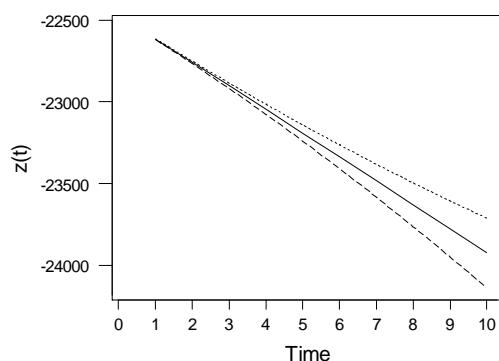


يبدو متاظر بعض الشيء.
لننظر إلى مخطط الإحتمال الطبيعي للبواقي:



نستطيع أن نقول إن البواقي طبيعية تقريباً.
الرسم التالي لـ 10 تنبؤات للقيم المستقبلية مع 95% فترات تنبؤ.

Forecast of 20 Future values with 95% limits



ملحق (1)

أسئلة بعض الإختبارات السابقة وبعض الإجابات المحتملة عليها

بسم الله الرحمن الرحيم

قسم الاحصاء وبحوث العمليات
كلية العلوم جامعة الملك سعود
الاختبار النهائي للفصل الاول 1420/1419 هـ
المادة 221 بحث طرق التنبؤ الاحصائي

اجب على جميع الاسئلة التالية:

السؤال الاول:

البيانات التالية تمثل عدد السيارات المباعة أسبوعياً لدى موزع ما

الاسبوع	10	9	8	7	6	5	4	3	2	1	العدد
	85	77	80	71	78	69	83	79	75	75	

اوجد تنبؤات لعدد السيارات التي ستباع في الأسبوعين التاليين واوجد فترات تنبؤ 95% لهذه

التنبؤات كلما امكن ذلك باستخدام:

- نموذج انحدار خطى للعدد المباع مع الزمن بالاسابيع.
- التمهيد بواسطة متوسط متحرك من الدرجة الثالثة.
- التمهيد الاسى البسيط مستخدماً $\alpha = 0.3$.

السؤال الثاني:

للمودج $a_t \sim WN(0, \sigma^2)$ حيث $(1 - \phi_1 B - \phi_2 B^2)z_t = \delta + (1 - \theta B)a_t$ هي معالم

المودج و B هو عامل الازاحة الخلفي اوجد:

$$E(z_t) \quad (1)$$

ب) دالة الترابط الذاتى $\rho_k \quad \forall k \geq 0$

ج) دالة الترابط الذاتى الجزئى $\phi_{kk} \quad \forall k \geq 0$

د) دالة الاوزان $\psi_j \quad \forall j \geq 0$

السؤال الثالث:

للنموذج حيث $z_t = 38.5 + 1.2z_{t-1} - 0.7z_{t-2} + a_t - 0.4a_{t-1}$ و اذا كانت $t=10$ و $a_t \sim WN(0,4)$

$$a_{10} = -1.6 \quad z_9 = 77 \quad z_{10} = 85$$

ا) دالة التنبؤ التي لها ادنى متوسط مربع اخطاء

ب) تباين دالة اخطاء التنبؤ حتى زمن النقدم $\ell = 3$

ج) تنبؤات للقيم المستقبلية z_{11} و z_{12}

د) فترات تنبؤ 95% للتنبؤات السابقة

هـ) اذا علمت ان $z_{11} = 81$ فجدد التنبؤ للقيمة z_{12} ولفترة تنبؤها.

قسم الاحصاء وبحوث العمليات
كلية العلوم جامعة الملك سعود
الاختبار النهائي للفصل الاول 1420/1419 هـ
المادة 221 بحث طرق التنبؤ الاحصائي

اجب على جميع الاسئلة التالية:

السؤال الاول:

البيانات التالية تمثل عدد السيارات المباعة اسبوعياً لدى موزع ما

Week	1	2	3	4	5	6	7	8	9	10
No. of cars	75	75	79	83	69	78	71	80	77	85

اوجد تنبؤات لعدد السيارات التي ستبع في الأسبوعين التاليين واوجد فترات تنبؤ 95% لهذه التنبؤات كلما امكن ذلك باستخدام:

- نموذج انحدار خطى للعدد المباع مع الزمن بالاسبوع.
- التمهيد بواسطة متوسط متحرك من الدرجة الثالثة.
- التمهيد الاسى البسيط مستخدماً $\alpha = 0.3$.

السؤال الثاني:

للمودج $(z_t)_{t \geq 0}$ حيث $(1 - \theta B)z_t = \delta + (1 - \theta B)a_t$ و $a_t \sim WN(0, \sigma^2)$ هي معلم النموذج و B هو عامل الازاحة الخلفي اوجد:

$$E(z_t) \quad (1)$$

ب) دالة الترابط الذاتى $\rho_k \forall k \geq 0$

ج) دالة الترابط الذاتى الجزئى $\phi_{kk} \forall k \geq 0$

د) دالة الاوزان $\psi_j \forall j \geq 0$

السؤال الثالث:

للنموذج حيث $z_t = 38.5 + 1.2z_{t-1} - 0.7z_{t-2} + a_t - 0.4a_{t-1}$ و اذا كانت $t=10$ و $a_t \sim WN(0,4)$

$$a_{10} = -1.6 \quad z_9 = 77 \quad z_{10} = 85$$

ا) دالة التنبؤ التي لها ادنى متوسط مربع اخطاء

ب) تباين دالة اخطاء التنبؤ حتى زمن النقدم $\ell = 3$

ج) تنبؤات لقيم المستقبلية z_{11} و z_{12}

د) فترات تنبؤ 95% للتنبؤات السابقة

هـ) اذا علمت ان $z_{11} = 81$ فجدد التنبؤ لقيمه z_{12} ولفترة التنبؤ

قسم الإحصاء وبحوث العمليات

المادة : طرق التنبؤ الاحصائي 221 بحث

الاختبار الاول للأعمال الفصلية

الفصل الأول 1420-1421 هـ

الزمن : ساعتين

أجب على جميع الأسئلة التالية:

السؤال الأول: لمتسلسة زمنية $\{z_t\}$

- 1- أذكر شروط الاستقرار
- 2- عرف دالة الترابط الذاتي

السؤال الثاني: للمتسلسة التالية

t	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
z_t	53	43	66	48	52	42	44	56	44	58	41	54	51	56	38

- 1- طبق خط إنحدار بين (t, z_t) ومن ثم أوجد z_{16}, z_{17}
- 2- طبق متوسط متحرك من الدرجة الثالثة ومن ثم أوجد z_{16}, z_{17}
- 3- طبق تمديد اسي بسيط $\alpha = 0.5$ ومن ثم أجد z_{16}, z_{17}
- 4- إذا كانت $z_{16} = 56$ و $z_{17} = 49$ فأي من الطرق السابقة أكثر دقة وذلك باستخدام معيار خطأ مناسب

السؤال الثالث:

$$z_t = 20 - 0.9z_{t-1} + a_t \quad , a_t \sim WN(0,4)$$

-1 هل النموذج مستقر؟

-2 أوجد μ

-3 أوجد ρ_k و ϕ_{kk} لقيم $k = 0, 1, 2, \dots, 5$

قسم الإحصاء وبحوث العمليات

المادة : طرق التنبؤ الاحصائي 221 بحث
الاختبار النهائي للفصل الثاني 1420-1421 هـ

الزمن : أربع ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول: (20 علامة)

أكمل الفراغات التالية:

1) لمتسلسة زمنية $\{Z_t\}$ دالة التغاییر الذاتی تعطى بالعلاقة $\gamma_k = Cov(Z_t, Z_{t+k})$ و دالة

الترابط الذاتي بالعلاقة $\rho_k = \frac{\gamma_k}{\rho_0}$ ولها الخواص $\rho_0 = 1$ و $|\rho_k| \leq 1$ و

(5 علامات) $\rho_k = \rho_{t+k}$

2) لمتسلسة زمنية مشاهدة z_1, z_2, \dots, z_n دالة الترابط الذاتي للعينة تقدر من العلاقة

$r_k = \frac{1}{n} \sum_{i=1}^n (z_i - \bar{z})(z_{i+k} - \bar{z})$ و الإنحراف المعياري

لدالة الترابط الذاتي للعينة تقدر من العلاقة $s.e(r_k) \approx \sqrt{\frac{1}{n}}$ كما ان دالة الترابط الذاتي

$r_{k+1,k+1} = \frac{r_{k+1} - \sum_{j=1}^k r_{kj} r_j}{1 - \sum_{j=1}^k r_j^2}$ و العلاقة المساعدة
الجزئي للعينة تقدر من العلاقة

$r_{k+1,j} = r_{kj} - r_{k+1,k+1} r_{k,j}$, $j = 1, \dots, n$ (8 علامات)

$$\text{بالعلاقة} \quad \text{يعطى} \quad AR(\square) \quad \text{نموذج } (3)$$

$$\text{و الذي يكتب على الشكل } \left(1 - \phi_1 \square - \phi_2 \square^2\right) Z_t = a_t, a_t \sim WN(\square, \square)$$

$$Z_t = \delta + \phi_1 \square + \phi_2 \square + a_t \quad (7 \text{ علامات})$$

السؤال الثاني: (40 علامة)

البيانات التالية هي حجم المبيعات اليومية لشركة ما بآلاف الريالات: (إقرأ من اليسار لليمين)

29.3	20.0	25.8	29.0	31.0	32.7	33.6
				27.5	26.8	30.6
28.9	28.5	28.2	26.1	27.8	27.6	29.9
				28.2	26.7	30.0
30.8	30.5	36.6	31.4	30.8	33.2	30.2
				27.1	33.7	36.6
29.0	28.1	30.3	29.4	33.6	30.3	20.1
				17.5	23.7	24.2
32.4	32.4	29.4	23.5	23.6	28.1	29.9
				30.6	32.3	31.6
28.0	24.1	29.2	34.3	26.4	28.8	21.3
				21.7	21.5	24.7
33.6	36.5	35.7	33.7	29.3	25.1	27.2
				30.6	29.1	28.5
32.0	31.9	31.7	29.0	31.9	24.3	22.7
				26.6	28.9	28.3
28.2	28.6	30.7	30.6	20.8	16.6	25.2
				31.8	32.5	30.3
26.1	19.0	24.3	31.5	32.0	31.7	29.1
						23.2

(1) بإستخدام الأمرين `%acf` و `%pacf` في *Minitab* تعرف على النموذج من عائلة

النماذج $ARIMA(p,d,q)$ والذي تتبعه البيانات (7 علامات)

(2) أوجد مقدرات أولية لمعامل النموذج المعروف عليه بطريقة العزوم وطريقة المربعات الدنيا الشرطية (9 علامات)

(3) بإستخدام مقدرات المعامل بطريقة المربعات الدنيا الشرطية أو العزوم أكتب النموذج على

$$\text{حيث } Z_t = \delta + \phi_1 Z_{t-1} + \cdots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \cdots - \theta_q a_{t-q} \quad \text{الشكل}$$

$$a_t \sim WN(0, \sigma^2) \quad (4 \text{ علامات})$$

(4) أوجد دالة التنبؤ للنموذج ومن ثم أوجد تنبؤات للقيم المستقبلية Z_{99} و Z_{100} وإذا علمت أن

$$\sigma^2 = 10.83 \text{ فلوجد فترات تنبؤ 95% للقيم المستقبلية } Z_{99} \text{ و } Z_{100} \quad (10 \text{ علامات})$$

(5) إذا علمت أن $z_{99} = 26.7$ فجدد التنبؤ للقيمة المستقبلية Z_{100} وإذا كانت $z_{100} = 32.4$ فهل

التنبؤ أفضل قبل أم بعد التجديد؟ (5 علامات)

(6) بإستخدام الأمر arima p d q C1 C2 C3 C4 و forecast 5 والأوامر الفرعية

gfit و gnormal و ghist و gpacf و gacf و gseries

في الفقرات السابقة. (5 علامات)

قسم الإحصاء وبحوث العمليات

إختبار الفصل الأول 1421هـ/1422هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

- 1- عرف التالي بإختصار: الضجة البيضاء، الترابط الذاتي، التمهيد، الإستقرار
- 2- اكتب المعادلات المعرفة للنماذج التالية: AR(2), MA(1), ARMA(1,2)
- ج) لنموذج AR(2) أي من المعالم التالية تحقق الإستقرار:

1) $\phi_1 = 1.2, \phi_2 = -0.8$

2) $\phi_1 = -1.2, \phi_2 = -0.8$

3) $\phi_1 = 0.8, \phi_2 = -0.8$

4) $\phi_1 = -0.8, \phi_2 = 1.2$

السؤال الثاني:

البيانات التالية تمثل مبيعات أجهزة الحاسوب في أحد الشركات شهريا (إقرأ من اليسار لليمين سطرا بسطر)

26	21	16	28	27	19
21	26	25	16	20	25
25	21	23	26	21	23
				17	25

- 1- أدخل البيانات في ورقة عمل ل البرنامج Minitab و أرسمها كمتسلسلة زمنية.

- 2- طبق على البيانات النماذج التالية:

i) Linear Trend Model

ii) Simple Moving Average Model of order 3

iii) Simple Exponential Smoothing Model with $\alpha=0.3$

- ج) طبق على البيانات نموذج من عائلة $ARMA(p,q)$ وذلك بالتعرف على p, q المناسبة
ومن ثم قدر المعالم للنموذج المقترن.
- د) أي نموذج من النماذج السابقة (في الفقرتين ب و ج) يصف المشاهدات بشكل أفضل؟
- هـ) بإستخدام النموذج الأفضل ولد تنبؤات لشهرين التاليين بفترات تنبؤ 95%

بسم الله الرحمن الرحيم

قسم الإحصاء وبموجب العمليات

المادة : طرق التنبؤ الاحصائي 221 بحث

الاختبار الأول للأعمال الفصلية

الفصل الثاني 1422/1421 هـ

الزمن : ساعتين

أجب على جميع الأسئلة التالية:

السؤال الأول: شوهدت المتسلسلة الزمنية التالية: (اقرأ من اليسار لليمين سطراً بسطراً)

47	64	23	71	38
			64	55
41	59	48	71	35
			57	40
58	44	80	55	37
			74	51
57	50	60	45	57
			50	45
25	59	50	71	56
			74	50
58	45	54	36	54
			48	55
45	57	50	62	44
			64	43
52	38	59	55	41
			53	49
34	35	54	45	68
			38	50

60	39	59	40	57
			54	23

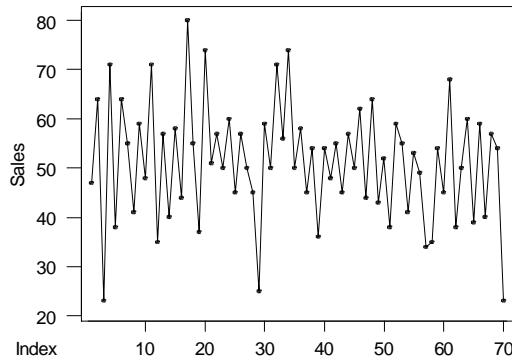
أدخل المشاهدات في صحيفة عمل Worksheet في برنامج Minitab وأجب على التالي:

- (أ) إفحص المشاهدات بواسطة Tsplot هل تبدو المتسلسلة مستقرة؟ لماذا؟ (علامة واحدة)
- (ب) هل نستخدم طريقة تحليل الإنجراف Trend Analysis لهذه المتسلسلة؟ ولماذا؟ (علامة واحدة)
- (ج) هل نستخدم طريقة التفكك Decomposition Method لهذه المتسلسلة؟ ولماذا؟ (علامة واحدة)
- (د) هل نستخدم طريقة التمهيد بالمتوسط المتحرك Moving Average Smoothing لهذه المتسلسلة؟ ولماذا؟ (علامة واحدة)
- (هـ) هل نستخدم طريقة التمهيد الاسي البسيط Simple Exponential Smoothing لهذه المتسلسلة؟ ولماذا؟ (علامة واحدة)
- (و) هل نستخدم طريقة التمهيد الاسي الثنائي Double Exponential Smoothing لهذه المتسلسلة؟ ولماذا؟ (علامة واحدة)
- (ز) هل نستخدم طريقة ونترز Winters' Method لهذه المتسلسلة؟ ولماذا؟ (علامة واحدة)

السؤال الثاني: من السؤال السابق توجد طريقة واحدة فقط هي الأنسب لتحليل المتسلسلة الزمنية المشاهدة! بإستخدام الطريقة المناسبة أوجد تنبؤات لخمسة قيم مستقبلية مع فترات تنبؤ 95% .
 (8 علامات)

إجابة السؤال الأول:

(أ)



المتسلسلة تبدو مستقرة حيث أنها تتغير حول مستوى ثابت

(ب) يمكن استخدام طريقة تحليل الإنجراف ولكنها غير مناسبة هنا لعدم وجود إتجاه معين تتجه
له المتسلسلة

(ج) يمكن استخدام طريقة التفكير ولكنها تناسب أكثر المتسلسلات التي فيها مركبات إنجراف و
موسمية

(د) يناسب التمهيد بال المتوسط المتحرك هذا النوع من المتسلسلات الزمنية أكثر من غيره من
الطرق لأنه كما نرى هذه المتسلسلة تحتاج إلى تمهد بسيط إذ ليس بها أي إنجراف أو موسمية

(هـ) التمهيد الأسوي البسيط ينفع لمثل هذه المتسلسلات أيضا وخاصة إذا كانت تحوي إنجرافا
بسيط

(و) التمهيد الأسوي الثنائي يفيد أكثر في حالة المتسلسلات التي تحوي إنجرافا غير خطى والذى
لا يبدو من تصرف المتسلسلة المشاهدة

(ز) طريقة ونترز تنفع للمتسلسلات الموسمية التي تحوى على مركبة إنجراف غير خطى
إجابة السؤال الثاني:

يبدو أن طريقة التمهيد بال المتوسط المتحرك هي الأكثر مناسبة لتحليل المتسلسلة المشاهدة. لنجد
عدة متوسطات متحركة لتمهد المتسلسلة وإيجاد تنبؤات لها.

(1) لنجد متوسط متحرك من الدرجة الثانية (مركز):

MTB > %MA 'Sales' 2;

SUBC> Center;
SUBC> Forecasts 5.
Executing from file: G:\MTBWIN\MACROS\MA.MAC

Macro is running ... please wait

Moving average

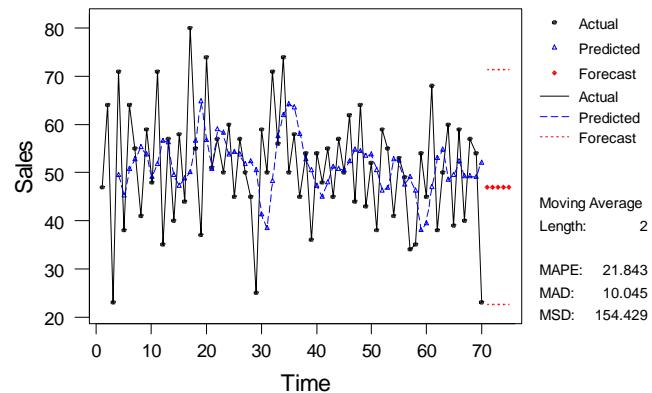
Data	Sales
Length	70.0000
NMissing	0

Moving Average
Length: 2

Accuracy Measures
MAPE: 21.843
MAD: 10.045
MSD: 154.429

Row	Period	Forecast	Lower	Upper
1	71	47	22.6432	71.3568
2	72	47	22.6432	71.3568
3	73	47	22.6432	71.3568
4	74	47	22.6432	71.3568
5	75	47	22.6432	71.3568

Moving Average



(2) لنجرب متوسط متراك من الدرجة الثالثة:

MTB > %MA 'Sales' 3;

SUBC> Forecasts 5.

Executing from file: G:\MTBWIN\MACROS\MA.MAC

Macro is running ... please wait

Moving average

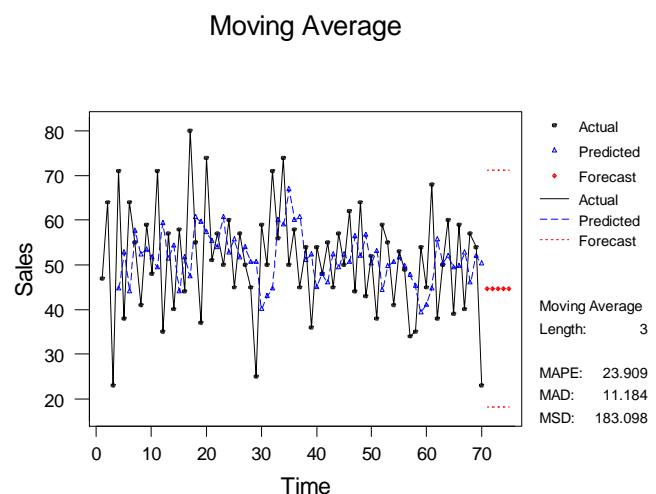
Data	Sales
Length	70.0000
NMissing	0

Moving Average

Length: 3

Accuracy Measures
MAPE: 23.909
MAD: 11.184
MSD: 183.098

Row	Period	Forecast	Lower	Upper
1	71	44.6667	18.1452	71.1881
2	72	44.6667	18.1452	71.1881
3	73	44.6667	18.1452	71.1881
4	74	44.6667	18.1452	71.1881
5	75	44.6667	18.1452	71.1881



(3) لنجرب متوسط متتحرك من الدرجة الرابعة (ممركر):

MTB > %MA 'Sales' 4;

SUBC> Center;

SUBC> Forecasts 5.

Executing from file: G:\MTBWIN\MACROS\MA.MAC

Macro is running ... please wait

Moving average

Data	Sales
------	-------

Length 70.0000

NMissing 0

Moving Average

Length: 4

Accuracy Measures

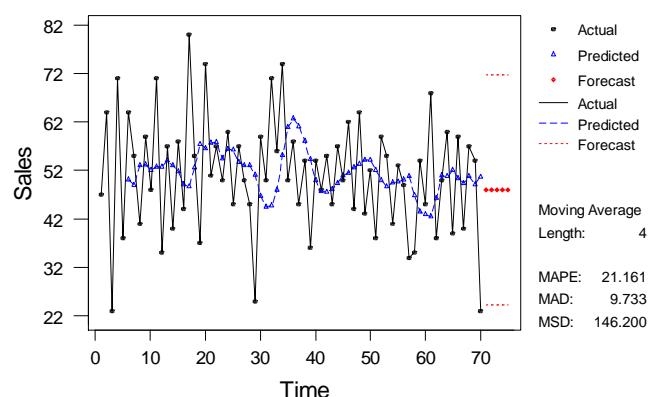
MAPE: 21.161

MAD: 9.733

MSD: 146.200

Row	Period	Forecast	Lower	Upper
1	71	48	24.3010	71.6990
2	72	48	24.3010	71.6990
3	73	48	24.3010	71.6990
4	74	48	24.3010	71.6990
5	75	48	24.3010	71.6990

Moving Average



(4) أخيراً نجرب متوسط متوازن من الدرجة الخامسة:

MTB > %MA 'Sales' 5;

SUBC> Forecasts 5.

Executing from file: G:\MTBWIN\MACROS\MA.MAC

Macro is running ... please wait

Moving average

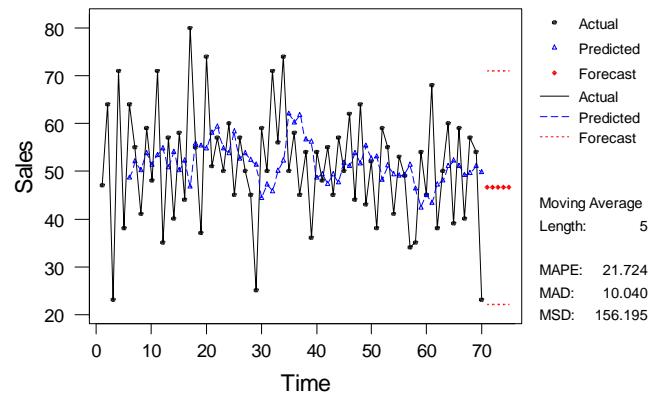
	Data	Sales
Length	70.0000	
NMissing	0	

Moving Average
Length: 5

Accuracy Measures
MAPE: 21.724
MAD: 10.040
MSD: 156.195

Row	Period	Forecast	Lower	Upper
1	71	46.6	22.1043	71.0957
2	72	46.6	22.1043	71.0957
3	73	46.6	22.1043	71.0957
4	74	46.6	22.1043	71.0957
5	75	46.6	22.1043	71.0957

Moving Average



من النتائج السابقة نجد أن المتوسط المتحرك من الدرجة الرابعة الممركز يعطي أقل قيمة لـ 146.2 (MSD) (Mean Square Deviation) التنبؤات الخمسة قيم المستقبلية مع فترات تنبؤ 95% هي

Row	Period	Forecast	Lower	Upper
1	71	48	24.3010	71.6990
2	72	48	24.3010	71.6990
3	73	48	24.3010	71.6990
4	74	48	24.3010	71.6990
5	75	48	24.3010	71.6990

بسم الله الرحمن الرحيم

قسم الإحصاء وبحوث العمليات

كلية العلوم

جامعة الملك سعود

الإختبار الثاني لأعمال الفصل الثاني 1422/1421 هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن: 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

للنموذج

$$(1 - 1.2B + 0.6B^2)(z_t - 65) = (1 - 0.4B)a_t, a_t \sim WN(0, 1)$$

(أ) تحقق من ان النموذج مستقر وقابل للإنقلاب.

(ب) أوجد كل من ρ_k و ϕ_{kk} لقيم $k = 1, 2, \dots, 5$.

(ج) أوجد دالة الأوزان μ_j لقيم $j = 1, 2, \dots, 5$.

السؤال الثاني:

للنموذج السابق إذا علمت أن $z_{76} = 60.4, z_{77} = 58.9, z_{78} = 64.7, z_{79} = 70.4, z_{80} = 62.6$

(أ) أوجد تنبؤات لقيم المستقبلية $z_{81}, z_{82}, z_{83}, z_{84}$.

(ب) أوجد فترات تنبؤ 95% للتنبؤات في الفقرة السابقة.

السؤال الثالث:

للنموذج

$$(1 - 0.43B)(1 - B)z_t = a_t, a_t \sim WN(0, 1)$$

(أ) هل النموذج مستقر؟ ولماذا؟

(ب) إذا كانت $z_{49} = 33.4, z_{50} = 33.9$ فأحسب التنبؤات (ℓ) لقيم $\ell = 1, 2, \dots, 5$.

(ج) أوجد فترات تنبؤ 95% للتنبؤات في الفقرة السابقة.

الإختبار النهائي للفصل الثاني 1422/1421 هـ

للمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

طبقنا على متسلسلة مبيعات نموذج $ARIMA(1,1,0)$ التالي:

$$(1 - 0.7B)(1 - B)z_t = a_t, \quad a_t \sim WN(0, 25)$$

المشاهدتين الأخيرتين هي $z_{143} = 770, z_{144} = 800$

(أ) هل النموذج مستقر أم لا ولماذا؟

(ب) أوجد دالة الأوزان r_j لقيم $j = 1, 2, \dots, 5$.

(ج) احسب التنبؤات للثلاثة (3) القيم المستقبلية التالية.

(د) اوجد فترات تنبؤ 95% للتنبؤات السابقة.

السؤال الثاني:

للمتسلسلة الزمنية التالية : (اقرأ من اليسار إلى اليمين سطراً بسطراً)

3.49	5.74	5.51	3.99	3.45	4.77	4.14
				4.60	3.80	5.43
3.96	2.54	4.05	6.16	3.78	5.07	5.42
				3.91	4.30	3.88
2.89	4.61	4.08	4.05	3.28	2.65	1.22
				3.98	3.45	3.57

2.52	1.58	4.00	5.14	3.84	4.40	3.08
				5.43	4.80	2.75
5.77	4.99	4.31	6.46	6.11	4.79	5.65
				5.52	6.12	6.06
3.20	5.05	6.23	6.12	4.99	4.89	4.78
				5.67	6.08	5.80
5.13	7.07	8.02	6.36	5.75	5.70	5.61
				5.63	5.71	5.16
7.20	6.87	7.56	6.57	6.08	4.72	6.09
				6.64	7.49	6.64
7.26	7.22	6.69	7.49	9.01	7.27	5.62
				7.59	7.53	6.43
6.42	8.22	7.67	7.53	7.23	8.50	8.27
				8.75	7.50	7.86

باستخدام MINITAB أوجد التالي:

(أ) أرسم المتسلسلة الزمنية بـاستخدام Time Series Plot.

(ب) أقترح طريقة لتمهيد المتسلسلة بعد فحص الرسم.

(ج) لكل طريقة مقرحة قم بفحص الباقي Residuals وأختبر الفرضية فيما إذا كانت الباقي موزعة توزيع طبيعي وذلك بـاستخدام اختبار Kolmogorov-Smirnov Test.

(د) قارن معايير الدقة للأخطاء Mean Absolute Percentage Error

Mean و Mean Absolute Deviation (MAD) و (MAPE)

لكل طريقة مقرحة ومن ثم أستخدم الطريقة الأكثر دقة لتوليد تنبؤات الخمسة القيم المستقبلية مع إيجاد فترات تنبؤ . 95%

السؤال الثالث:

للمتسلسلة الزمنية التالية: (إقرأ من اليسار لليمين سطراً بسطراً)

1.20	1.50	1.54	2.70	1.95	2.40
				3.44	2.83
1.76	2.00	2.09	1.89	1.80	1.25
				1.58	2.25

2.50	2.05	1.46	1.54	1.42	1.57
				1.40	1.51
1.08	1.27	1.18	1.39	1.42	2.08
				1.85	1.82
2.07	2.32	1.23	2.91	1.77	1.61
				1.25	1.15
	1.37	1.79	1.68	1.78	1.84

باستخدام MINITAB أوجد التالي:

(أ) أرسم المتسلسلة الزمنية باستخدام Time Series Plot.

(ب) أوجد كل من SACF و SPACF ومنها أقترح نموذج مناسب من عائلة $ARIMA(p,d,q)$.

وذلك بتعيين كل من p و d و q .

(ج) قدر المعالم للنموذج المقترن وأختبر الفرضيات فيما إذا كان أحد أو كل هذه المعالم مساويا للصفر.

(د) قم بفحص الباقي Residuals وأختبر الفرضية فيما إذا كانت الباقي موزعة توزيع طبيعي وذلك باستخدام اختبار Kolmogorov-Smirnov Test.

(هـ) أحسب تنبؤات الخمسة القيم المستقبلية التالية مع إيجاد فترات تنبؤ 95%.

بسم الله الرحمن الرحيم

إجابات محتملة لاختبار النهائي للفصل الثاني 1422/1421 هـ

لمادة 221 بحث

إجابة السؤال الأول:

(أ) النموذج غير مستقر لأنه يحوى عامل التفريق $(1-B)$

(ب)

$$(1-0.7B)(1-B)z_t = a_t$$

$$(1-1.7B+0.7B^2)z_t = a_t$$

$$\therefore z_t = \frac{1}{1-1.7B+0.7B^2}a_t \\ = \psi(B)a_t$$

$$\therefore \psi(B) = \frac{1}{1-1.7B+0.7B^2}$$

$$\therefore (1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - 1.7B + 0.7B^2) = 0$$

$$B : \psi_1 - 1.7 = 0 \Rightarrow \psi_1 = 1.7$$

$$B^2 : \psi_2 - 1.7\psi_1 + 0.7 = 0 \Rightarrow \psi_2 = 1.7\psi_1 - 0.7 = 2.19$$

$$B^3 : \psi_3 - 1.7\psi_2 + 0.7\psi_1 = 0 \Rightarrow \psi_3 = 1.7\psi_2 - 0.7\psi_1 = 2.53$$

⋮

$$B^j : \psi_j - 1.7\psi_{j-1} + 0.7\psi_{j-2} = 0 \Rightarrow \psi_j = 1.7\psi_{j-1} + 0.7\psi_{j-2}, j = 2, 3, \dots$$

$$\therefore \psi_4 = 1.7\psi_3 - 0.7\psi_2 = 2.768$$

$$\psi_5 = 1.7\psi_4 - 0.7\psi_3 = 2.9346$$

إذا الأوزان المطلوبة هي: $\psi_1 = 1.7, \psi_2 = 2.19, \psi_3 = 2.53, \psi_4 = 2.77, \psi_5 = 2.93$

(ج) نحسب التنبؤات كالتالي:

$$\begin{aligned}
& \because (1 - 1.7B + 0.7B^2)z_t = a_t \\
& \therefore z_t = 1.7z_{t-1} - 0.7z_{t-2} + a_t \\
& \therefore z_t(\ell) = E[z_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0 \\
& = E[1.7z_{t+\ell-1} - 0.7z_{t+\ell-2} + a_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0 \\
& = 1.7E[z_{t+\ell-1} | z_t, z_{t-1}, \dots] - 0.7E[z_{t+\ell-2} | z_t, z_{t-1}, \dots] + E[a_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0 \\
& \therefore \ell = 1: z_t(1) = 1.7E[z_t | z_t, z_{t-1}, \dots] - 0.7E[z_{t-1} | z_t, z_{t-1}, \dots] + E[a_{t+1} | z_t, z_{t-1}, \dots] \\
& = 1.7z_t - 0.7z_{t-1} \\
& \ell = 2: z_t(2) = 1.7E[z_{t+1} | z_t, z_{t-1}, \dots] - 0.7E[z_t | z_t, z_{t-1}, \dots] + E[a_{t+2} | z_t, z_{t-1}, \dots] \\
& = 1.7z_t(1) - 0.7z_t \\
& \ell = 3: z_t(3) = 1.7E[z_{t+2} | z_t, z_{t-1}, \dots] - 0.7E[z_{t+1} | z_t, z_{t-1}, \dots] + E[a_{t+3} | z_t, z_{t-1}, \dots] \\
& = 1.7z_t(2) - 0.7z_t(1) \\
& \therefore \ell \geq 3: z_t(\ell) = 1.7z_t(\ell-1) - 0.7z_t(\ell-2) \\
& \therefore t = 144
\end{aligned}$$

$$\begin{aligned}
& \therefore z_{144}(1) = 1.7z_{144} - 0.7z_{143} = 1.7(800) - 0.7(770) = 821 \\
& z_{144}(2) = 1.7z_{144}(1) - 0.7z_{144} = 1.7(821) - 0.7(800) = 835.7 \\
& z_{144}(3) = 1.7z_{144}(2) - 0.7z_{144}(1) = 1.7(835.7) - 0.7(821) = 845.99
\end{aligned}$$

إذا التنبؤات للثلاث قيم المستقبلية هي:

$$z_{144}(1) = 821, \quad z_{144}(2) = 835.7, \quad z_{144}(3) = 845.99$$

(د) فترات $(1 - \alpha)100\%$ تنبؤ تعطى بالعلاقة

$$\left[z_t(\ell) \pm u_{\alpha/2} \sqrt{V[e_t(\ell)]} \right], \ell \geq 0$$

حيث $u_{\alpha/2}$ هو المئين 95 للتوزيع الطبيعي القياسي وحيث ان $\alpha = 0.05$ فإن $u_{\alpha/2} = 1.96$ أي أن

$$z_{t+\ell} \in \left[z_t(\ell) \pm 1.96 \sqrt{V[e_t(\ell)]} \right] \text{ w.p. } 0.95, \ell \geq 0$$

أولا نحسب تباينات أخطاء التنبؤ من العلاقة:

$$V[e_t(1)] = \sigma^2 = 25$$

$$V[e_t(2)] = \sigma^2 (1 + \psi_1^2) = 25(1 + (1.7)^2) = 97.25$$

$$V[e_t(3)] = \sigma^2 (1 + \psi_1^2 + \psi_2^2) = 25(1 + (1.7)^2 + (2.19)^2) = 217.1525$$

ومنها نجد فترات التنبؤ المطلوبة:

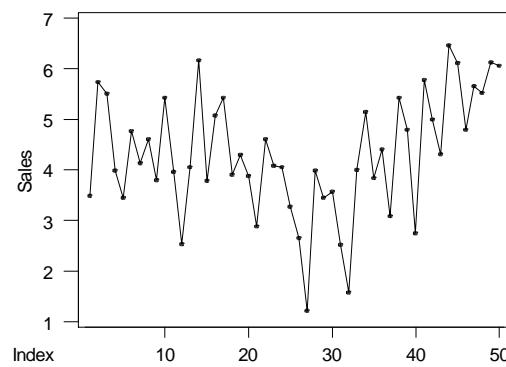
$$z_{145} \in [821 \pm 1.96\sqrt{25}] = [811.2, 830.8], w.p. 0.95$$

$$z_{146} \in [835.7 \pm 1.96\sqrt{97.25}] = [816.37, 855.03], w.p. 0.95$$

$$z_{145} \in [845.99 \pm 1.96\sqrt{217.1525}] = [817.11, 874.87], w.p. 0.95$$

إجابة للسؤال الثاني:

(ج)



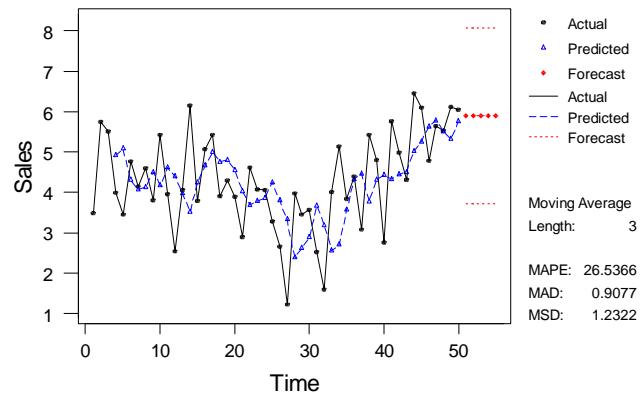
(ب) من الرسم السابق نجد أن المتسلسلة غير موسمية ولذلك نستخدم في تمهيدها أحد الطرق

التالية:

- 1- المتوسط المتحرك Moving Average Smoothing
- 2- التمهيد الأسوي البسيط Single Exponential Smoothing
- 3- التمهيد الأسوي الثنائي Double Exponential Smoothing

أولاً المتوسط المتحرك

Smoothing Sales Series by Moving Avg. of Order 3



```

MTB > %MA 'Sales' 3;
SUBC>   Forecasts 5;
SUBC>   Title "Smoothing Sales Series by Moving
          Avg. of Order 3";
SUBC>   Residuals 'RESI1'.
Executing from file: G:\MTBWIN\MACROS\MA.MAC

```

Macro is running ... please wait

Moving average

Data	Sales
Length	50.0000
NMissing	0

Moving Average
 Length: 3

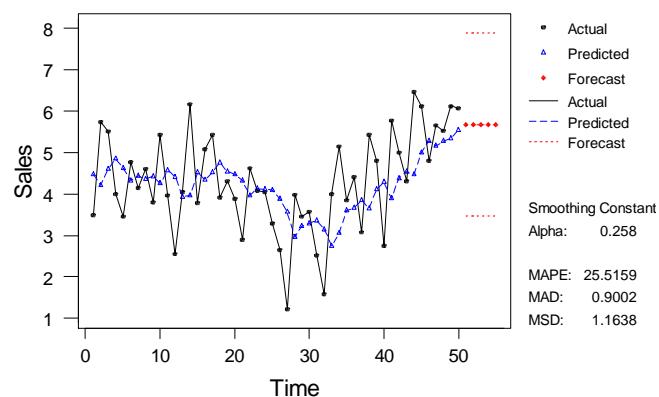
Accuracy Measures
 MAPE: 26.5366
 MAD: 0.9077

MSD: 1.2322

Row	Period	Forecast	Lower	Upper
1	51	5.9	3.72428	8.07572
2	52	5.9	3.72428	8.07572
3	53	5.9	3.72428	8.07572
4	54	5.9	3.72428	8.07572
5	55	5.9	3.72428	8.07572

ثانيا التمهيد الأسني البسيط

Smoothing Sales Series by Single Exponential Smoothing



```
MTB > %SES 'Sales';
SUBC>   Forecasts 5;
SUBC>   Title "Smoothing Sales Series by Single
          Exponential Smoothing";
SUBC>   Residuals 'RESI2'.
Executing from file: G:\MTBWIN\MACROS\SES.MAC
```

Macro is running ... please wait

Single Exponential Smoothing

Data Sales
Length 50.0000
NMissing 0

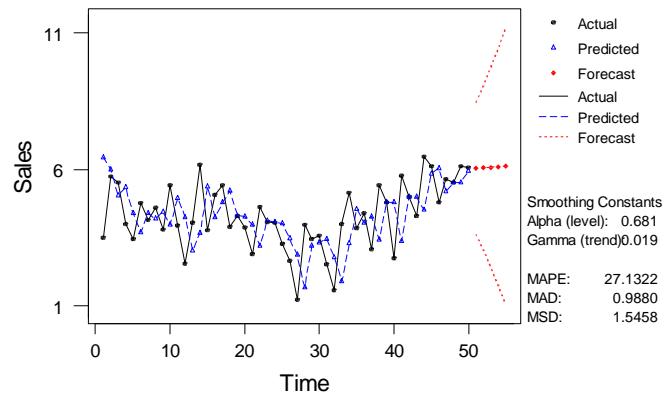
Smoothing Constant
Alpha: 0.257773

Accuracy Measures
MAPE: 25.5159
MAD: 0.9002
MSD: 1.1638

Row	Period	Forecast	Lower	Upper
1	51	5.67586	3.47035	7.88137
2	52	5.67586	3.47035	7.88137
3	53	5.67586	3.47035	7.88137
4	54	5.67586	3.47035	7.88137
5	55	5.67586	3.47035	7.88137

ثالثا التمهيد الأسوي الثنائي

Smoothing Sales Series by Double Exponential Smoothing



```

MTB > %DES 'Sales';
SUBC>   Forecasts 5;
SUBC>   Title "Smoothing Sales Series by Double
              Exponential Smoothing";
SUBC>   Residuals 'RESI3'.
Executing from file: G:\MTBWIN\MACROS\DES.MAC

```

Macro is running ... please wait

Double Exponential Smoothing

Data	Sales
Length	50.0000
NMissing	0

Smoothing Constants
 Alpha (level): 0.680728
 Gamma (trend): 0.019421

Accuracy Measures
 MAPE: 27.1322
 MAD: 0.9880

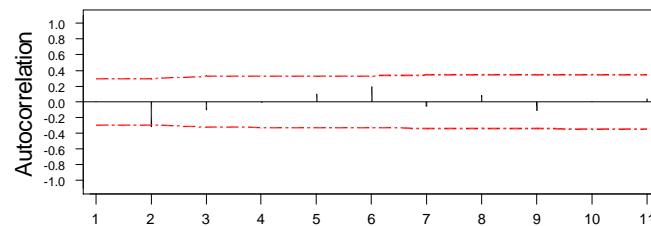
MSD: 1.5458

Row	Period	Forecast	Lower	Upper
1	51	6.04349	3.62298	8.4640
2	52	6.06254	3.04085	9.0842
3	53	6.08160	2.40519	9.7580
4	54	6.10065	1.74005	10.4613
5	55	6.11971	1.05736	11.1821

(ج) فحص الباقي:

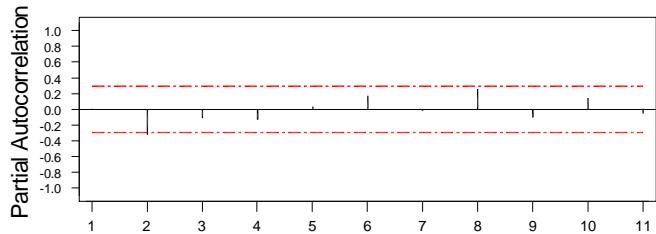
للمتوسط المتحرك

Autocorrelation Function for RESI1

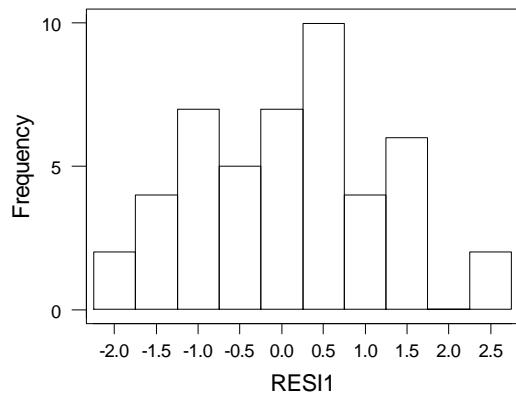


Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.01	0.05	0.00	8	0.08	0.47	9.66
2	-0.33	-2.26	5.55	9	-0.11	-0.66	10.43
3	-0.11	-0.69	6.19	10	0.00	0.02	10.43
4	-0.01	-0.06	6.19	11	0.04	0.25	10.55
5	0.10	0.64	6.79				
6	0.20	1.22	9.03				
7	-0.07	-0.39	9.28				

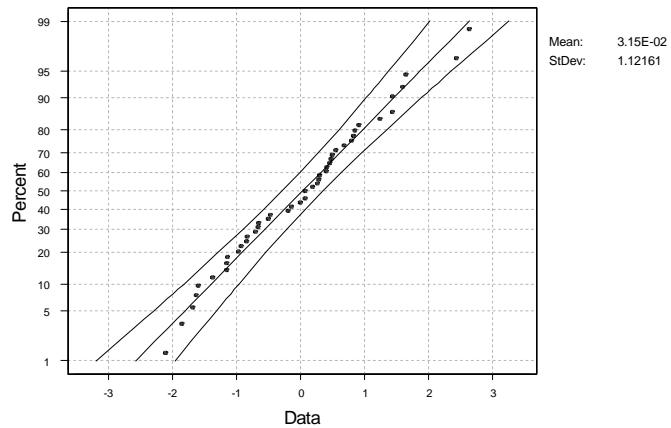
Partial Autocorrelation Function for RESI1



Lag	PAC	T	Lag	PAC	T
1	0.01	0.05	8	0.25	1.74
2	-0.33	-2.26	9	-0.11	-0.76
3	-0.12	-0.81	10	0.15	1.01
4	-0.14	-0.93	11	-0.06	-0.39
5	0.03	0.19			
6	0.17	1.14			
7	-0.02	-0.16			



Normal Probability Plot for RESI1



MTB > %Qqplot 'RESI1';

SUBC> Table;

```
SUBC> Conf 95;
SUBC> Ci.
Executing from file: G:\MTBWIN\MACROS\Qqplot.MAC
```

Distribution Function Analysis

Normal Dist. Parameter Estimates

Data : RESI1

Mean: 3.15E-02

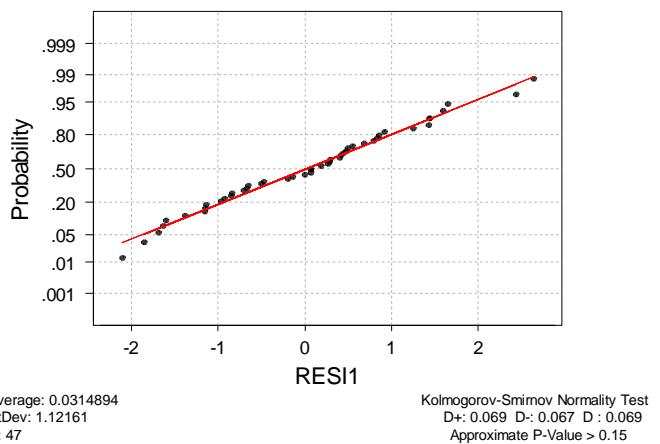
StDev: 1.12161

Percentile Estimates

P	Percentile	95% CI	
		Approximate	Approximate
		Lower Limit	Upper Limit
0.01	-2.57777	-3.19506	-1.96047
0.02	-2.27202	-2.83741	-1.70663
0.03	-2.07803	-2.61158	-1.54447
0.04	-1.93210	-2.44238	-1.42181
0.05	-1.81339	-2.30524	-1.32155
0.06	-1.71236	-2.18891	-1.23581
0.07	-1.62377	-2.08723	-1.16032
0.08	-1.54445	-1.99647	-1.09244
0.09	-1.47231	-1.91417	-1.03046
0.10	-1.40591	-1.83864	-0.97318
0.20	-0.91248	-1.28563	-0.53934

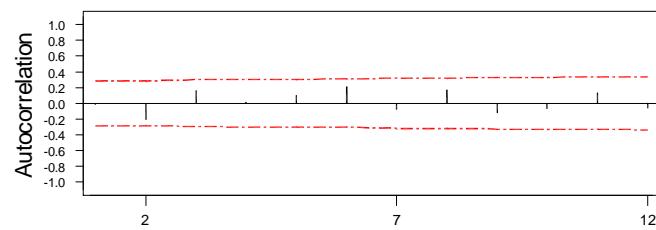
0.30	-0.55668	-0.89868	-0.21469
0.40	-0.25267	-0.57843	0.07309
0.50	0.03149	-0.28917	0.35215
0.60	0.31565	-0.01012	0.64141
0.70	0.61966	0.27767	0.96165
0.80	0.97546	0.60232	1.34860
0.90	1.46889	1.03616	1.90162
0.91	1.53529	1.09344	1.97715
0.92	1.60743	1.15542	2.05945
0.93	1.68675	1.22330	2.15021
0.94	1.77534	1.29879	2.25189
0.95	1.87637	1.38453	2.36822
0.96	1.99508	1.48479	2.50536
0.97	2.14101	1.60745	2.67456
0.98	2.33499	1.76961	2.90038
0.99	2.64074	2.02345	3.25804

Kolmogorov-Smirnov Test for Residuals of MA



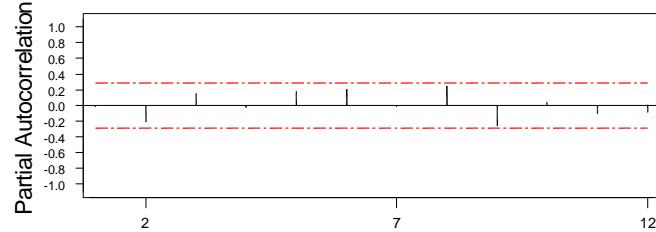
للتمهيد الأسوي البسيط

Autocorrelation Function for RESI2

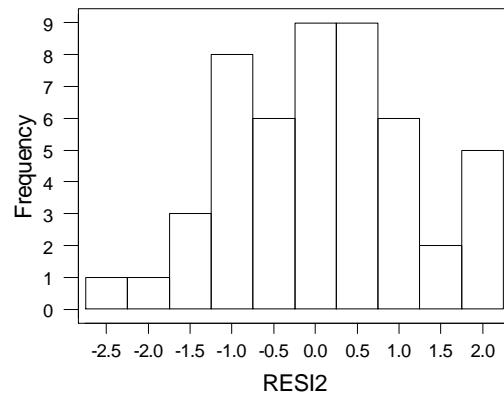


Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	-0.02	-0.16	0.03	8	0.17	1.05	9.33
2	-0.21	-1.51	2.48	9	-0.13	-0.79	10.37
3	0.16	1.07	3.87	10	-0.08	-0.47	10.76
4	0.01	0.07	3.87	11	0.13	0.81	11.95
5	0.10	0.68	4.47	12	-0.06	-0.38	12.24
6	0.21	1.40	7.18				
7	-0.08	-0.53	7.61				

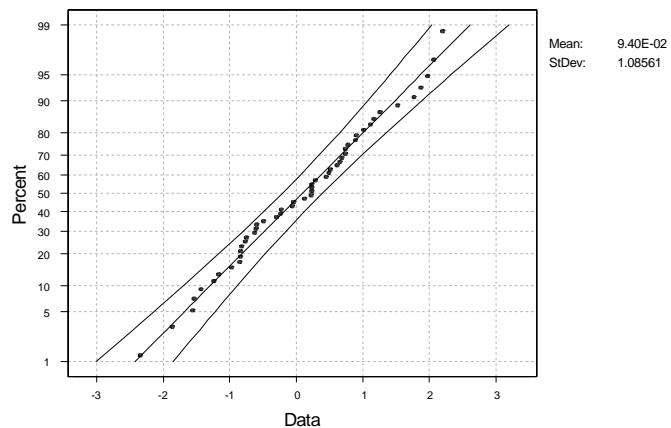
Partial Autocorrelation Function for RESI2



Lag	PAC	T	Lag	PAC	T
1	-0.02	-0.16	8	0.25	1.76
2	-0.21	-1.51	9	-0.27	-1.89
3	0.15	1.09	10	0.04	0.26
4	-0.03	-0.24	11	-0.11	-0.75
5	0.18	1.28	12	-0.09	-0.62
6	0.20	1.42			
7	-0.02	-0.14			



Normal Probability Plot for RESI2



```
MTB > %Qqplot 'RESI2';
SUBC> Table;
SUBC> Conf 95;
SUBC> Ci.
Executing from file: G:\MTBWIN\MACROS\Qqplot.MAC
```

Distribution Function Analysis

Normal Dist. Parameter Estimates

Data : RESI2

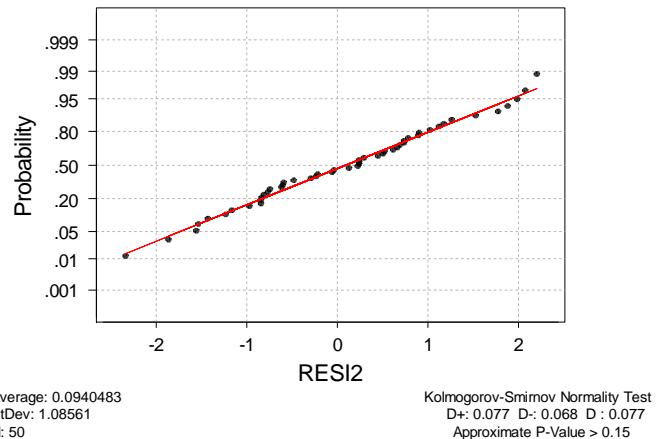
Mean: 9.40E-02
StDev: 1.08561

Percentile Estimates

95% CI 95% CI

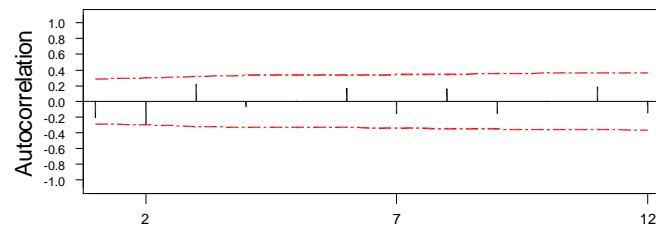
P	Percentile	Approximate Lower Limit	Approximate Upper Limit
0.01	-2.43146	-3.01074	-1.85218
0.02	-2.13552	-2.66609	-1.60495
0.03	-1.94776	-2.44846	-1.44706
0.04	-1.80651	-2.28537	-1.32766
0.05	-1.69162	-2.15318	-1.23006
0.06	-1.59383	-2.04103	-1.14663
0.07	-1.50809	-1.94300	-1.07317
0.08	-1.43131	-1.85549	-1.00713
0.09	-1.36149	-1.77614	-0.94684
0.10	-1.29722	-1.70330	-0.89113
0.20	-0.81962	-1.16979	-0.46946
0.30	-0.47525	-0.79618	-0.15431
0.40	-0.18099	-0.48669	0.12471
0.50	0.09405	-0.20686	0.39496
0.60	0.36908	0.06338	0.67479
0.70	0.66334	0.34241	0.98427
0.80	1.00772	0.65756	1.35789
0.90	1.48531	1.07923	1.89140
0.91	1.54959	1.13494	1.96423
0.92	1.61941	1.19523	2.04359
0.93	1.69618	1.26127	2.13110
0.94	1.78193	1.33473	2.22913
0.95	1.87972	1.41816	2.34128
0.96	1.99461	1.51575	2.47347
0.97	2.13586	1.63516	2.63655
0.98	2.32362	1.79305	2.85419
0.99	2.61955	2.04028	3.19883

Kolmogorov-Smirnov Test for Residuals of SES

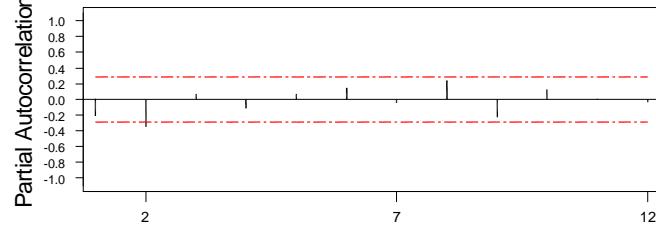


التمهيد الأسوي الثنائي

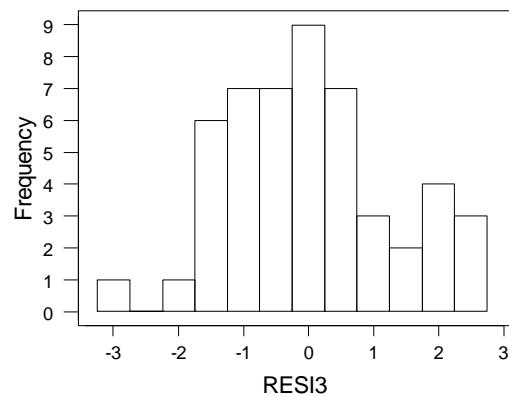
Autocorrelation Function for RESI3



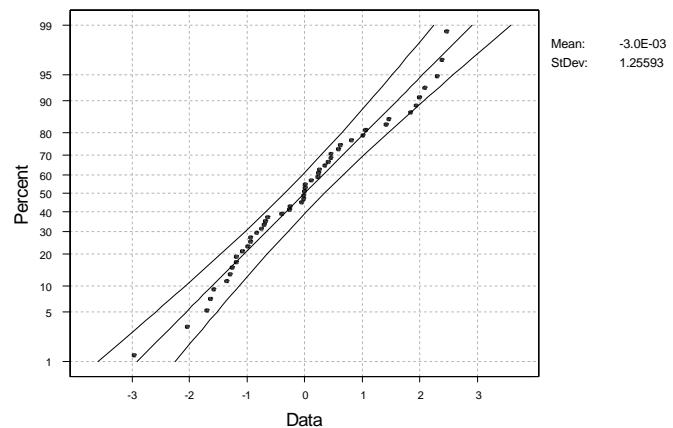
Partial Autocorrelation Function for RESI3



Lag	PAC	T	Lag	PAC	T
1	-0.22	-1.53	8	0.24	1.69
2	-0.36	-2.52	9	-0.23	-1.61
3	0.07	0.49	10	0.13	0.92
4	-0.11	-0.81	11	0.01	0.04
5	0.07	0.47	12	-0.03	-0.25
6	0.14	1.02			
7	-0.05	-0.34			



Normal Probability Plot for RESI3



```

MTB > %Qqplot 'RESI3';
SUBC> Table;
SUBC> Conf 95;
SUBC> Ci.
Executing from file: G:\MTBWIN\MACROS\Qqplot.MAC

```

Distribution Function Analysis

Normal Dist. Parameter Estimates

Data : RESI3

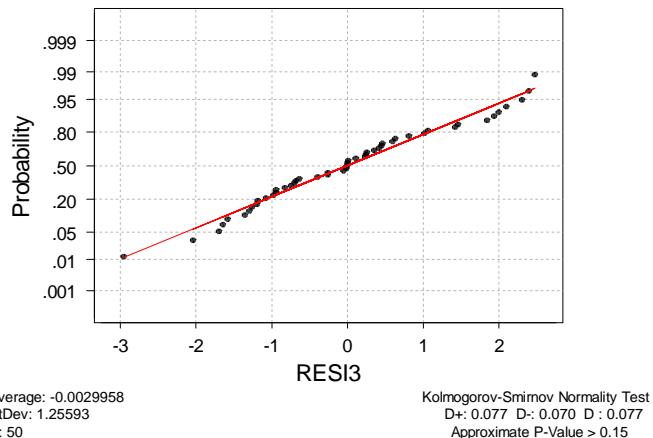
Mean: -3.0E-03
StDev: 1.25593

Percentile Estimates

P	Percentile	95% CI	95% CI
		Approximate	Approximate
		Lower Limit	Upper Limit
0.01	-2.92473	-3.59489	-2.25457
0.02	-2.58237	-3.19618	-1.96855
0.03	-2.36515	-2.94440	-1.78589
0.04	-2.20174	-2.75573	-1.64775
0.05	-2.06882	-2.60279	-1.53485
0.06	-1.95569	-2.47305	-1.43832
0.07	-1.85649	-2.35964	-1.35334
0.08	-1.76767	-2.25840	-1.27694
0.09	-1.68689	-2.16659	-1.20719
0.10	-1.61254	-2.08233	-1.14274
0.20	-1.06001	-1.46512	-0.65491
0.30	-0.66161	-1.03289	-0.29032
0.40	-0.32118	-0.67484	0.03248
0.50	-0.00300	-0.35112	0.34512
0.60	0.31519	-0.03847	0.66885
0.70	0.65562	0.28433	1.02690
0.80	1.05402	0.64892	1.45913
0.90	1.60655	1.13675	2.07634
0.91	1.68090	1.20120	2.16060
0.92	1.76168	1.27095	2.25241

0.93	1.85050	1.34735	2.35365
0.94	1.94969	1.43233	2.46706
0.95	2.06283	1.52886	2.59680
0.96	2.19575	1.64176	2.74973
0.97	2.35915	1.77990	2.93840
0.98	2.57637	1.96256	3.19019
0.99	2.91874	2.24858	3.58890

Kolmogorov-Smirnov Test for Residuals of DES



في كل الحالات السابقة نجد ان الباقي تحقق الفرضيات

- 1- غير مترابطة
 - 2- لها تقريرياً توزيع طبيعي بمتوسط صفر و تباين وحدة
- (د) الجدول التالي يلخص مقاييس الدقة للأخطاء

	MAPE	MAD	MSD
MA	26.5366	0.9077	1.2322
SES	25.5159	0.9002	1.1638

DES	27.1322	0.9880	1.5458
-----	---------	--------	--------

ويلاحظ أن التمهيد الأسني البسيط يعطي أفضل نتيجة.
التنبؤات باستخدام التمهيد الأسني البسيط وفترات 95% للتنبؤ

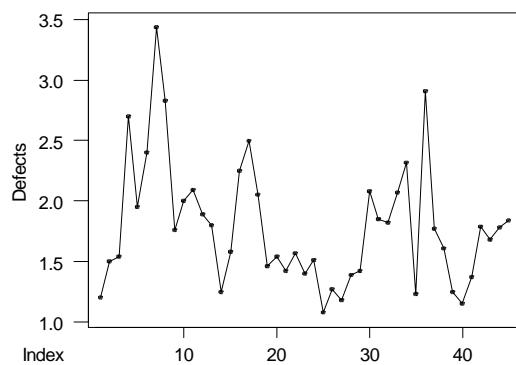
Period of

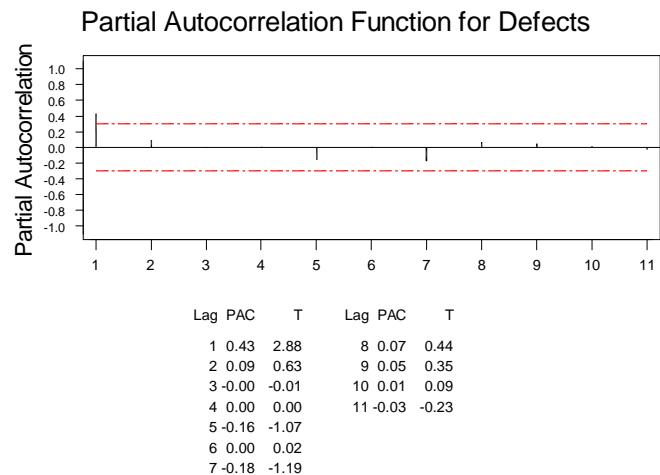
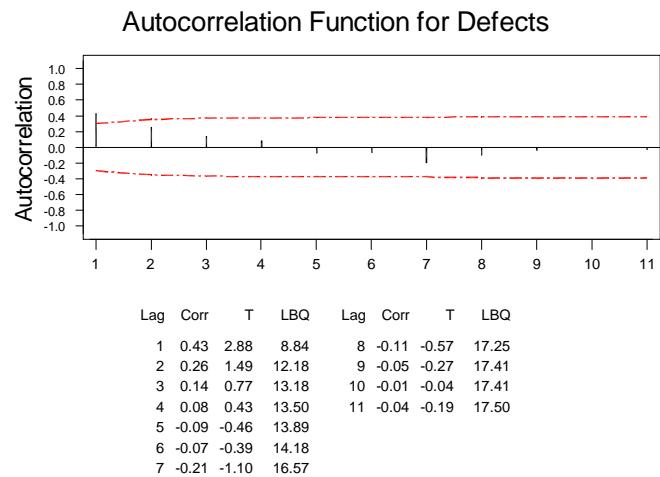
Forecast	Forecast	Lower	Upper
----------	----------	-------	-------

51	5.67586	3.47035	7.88137
52	5.67586	3.47035	7.88137
53	5.67586	3.47035	7.88137
54	5.67586	3.47035	7.88137
55	5.67586	3.47035	7.88137

إجابة للسؤال الثالث:

(٤)





واضح من الشكل أن SACF تتaxedم آسيا و SPACF لها قطع بعد $r_{1,1}$ وهذا يقترح نموذج

$q=0$ و $d=0$ و $p=1$ أي أن $ARIMA(1,0,0)$

(ج) تقدير المعالم:

```
MTB > ARIMA 1 0 0 'Defects' 'RES11' 'FITS1';
          SUBC> Constant;
          SUBC> Forecast 5 c3 c4 c5;
          SUBC> GACF;
          SUBC> GPACF;
          SUBC> GHistogram;
          SUBC> GNormalplot;
          SUBC> GFits;
          SUBC> GOrder.
```

ARIMA Model

ARIMA model for Defects

Estimates at each iteration

Iteration	SSE	Parameters	
0	11.2419	0.100	1.700
1	10.0858	0.250	1.393
2	9.5649	0.400	1.086
3	9.5316	0.436	1.006
4	9.5309	0.441	0.995
5	9.5309	0.442	0.993
6	9.5309	0.442	0.993

Relative change in each estimate less than
0.0010

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.4421	0.1365	3.24
Constant	0.99280	0.06999	14.19
Mean	1.7795	0.1254	

Number of observations: 45
Residuals: SS = 9.47811 (backforecasts
excluded)
MS = 0.22042 DF = 43

Modified Lag	Box-Pierce	(Ljung-Box)	Chi-Square statistic
		12	24
		36	48

Chi-Square	4.9 (DF=11)	8.9 (DF=23)
	30.9 (DF=35)	* (DF= *)

Period	Forecast	Forecasts from period 45	
		95 Percent Limits	
		Lower	Upper
46	1.80627	0.88588	2.72665
47	1.79135	0.78503	2.79767
48	1.78476	0.76248	2.80703
49	1.78184	0.75648	2.80721
50	1.78055	0.75459	2.80652

من المخرجات السابقة نجد أن النموذج المقترن هو

$$z_t = 0.9928 - 0.4421 z_{t-1} + a_t, \quad a_t \sim WN(0, 0.22042)$$

$$\text{or} \quad (z_t - 1.7795) = -0.4421(z_{t-1} - 1.7795) + a_t$$

حيث

$$\hat{\phi}_1 = 0.4421, s.e(\hat{\phi}_1) = 0.1365, \text{ with t-value} = 3.24$$

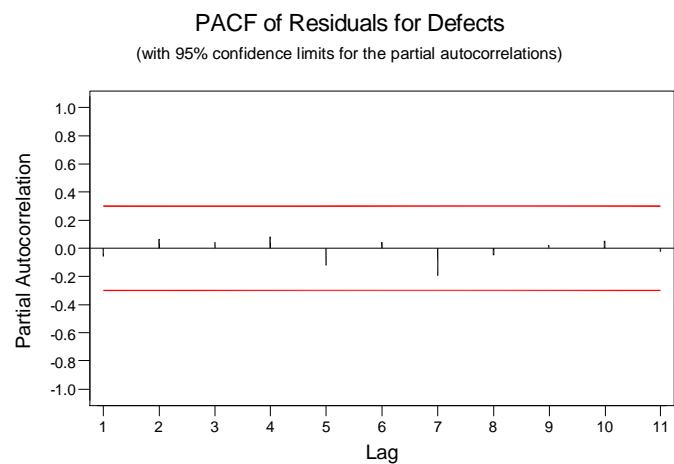
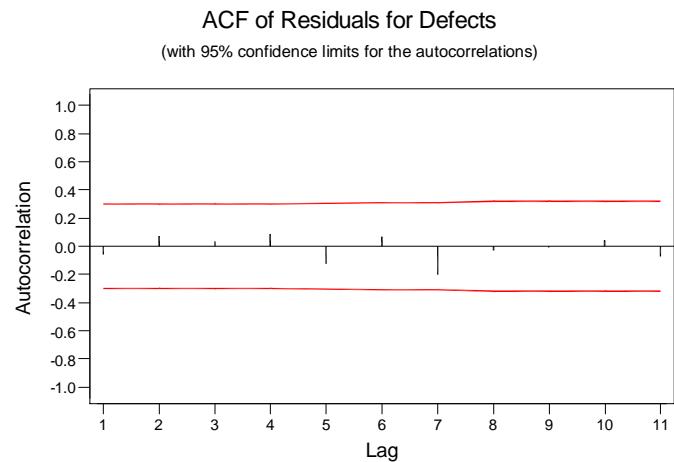
أي أن معامل الإنحدار الذاتي معنوي

$$\hat{\delta} = 0.9928, s.e(\hat{\delta}) = 0.06999, \text{ with t-value} = 14.19$$

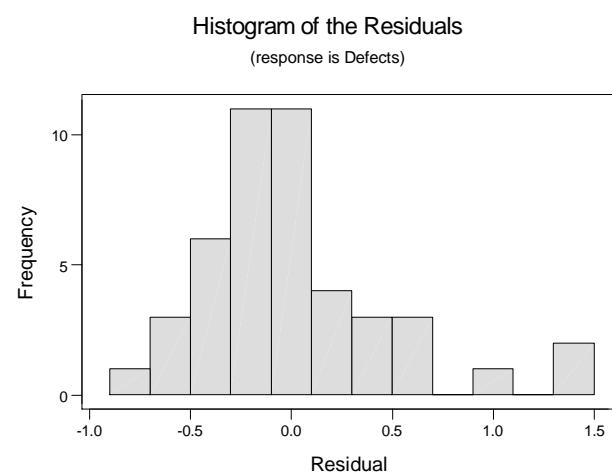
وأيضاً المستوى δ معنوي

(د) فحص البوافي:

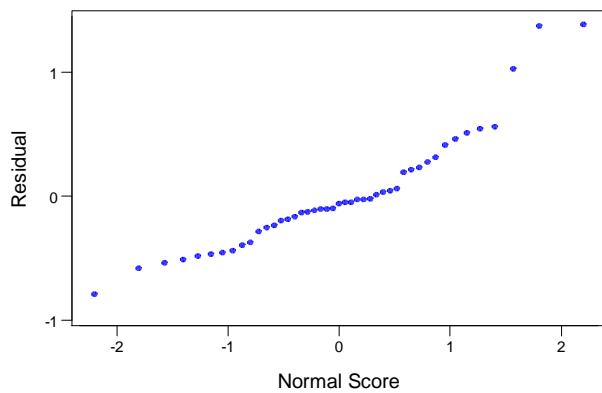
1- عدم الترابط



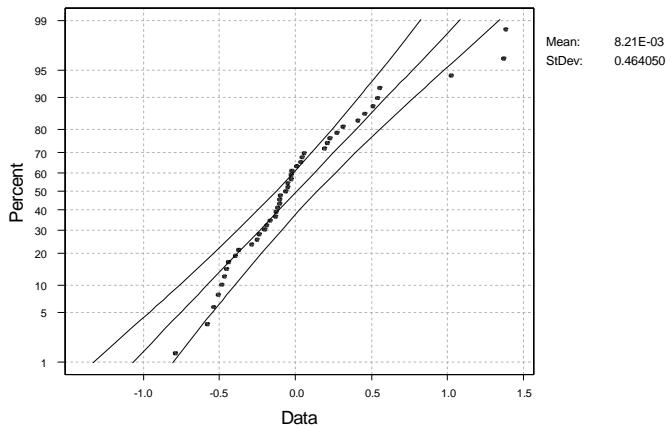
التوزيع الطبيعي:



Normal Probability Plot of the Residuals
(response is Defects)



Normal Probability Plot for RESI1



```

MTB > %Qqplot 'RESI1';
SUBC>   Table;
SUBC>   Conf 95;
SUBC>   Ci.
Executing from file: G:\MTBWIN\MACROS\Qqplot.MAC

```

Distribution Function Analysis

Normal Dist. Parameter Estimates

Data : RESI1

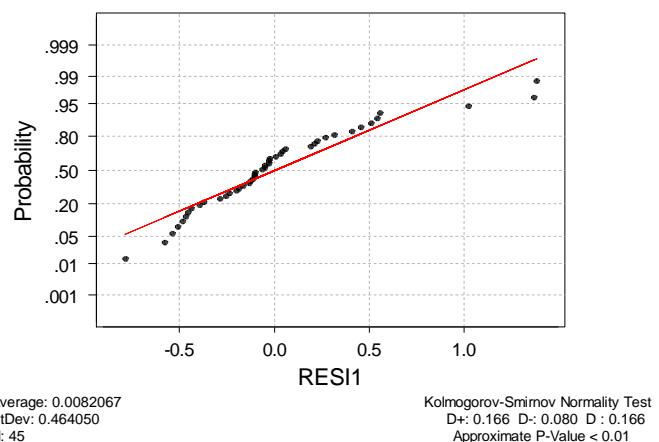
Mean: 8.21E-03
StDev: 0.464050

Percentile Estimates

P	Percentile	95% CI	95% CI
		Approximate	Approximate
		Lower Limit	Upper Limit
0.01	-1.07134	-1.33235	-0.81033
0.02	-0.94484	-1.18390	-0.70577
0.03	-0.86458	-1.09018	-0.63897
0.04	-0.80420	-1.01996	-0.58844
0.05	-0.75509	-0.96306	-0.54712
0.06	-0.71329	-0.91478	-0.51179
0.07	-0.67663	-0.87260	-0.48067
0.08	-0.64382	-0.83494	-0.45269
0.09	-0.61397	-0.80080	-0.42714
0.10	-0.58650	-0.76947	-0.40353
0.20	-0.38235	-0.54012	-0.22457
0.30	-0.23514	-0.37975	-0.09054
0.40	-0.10936	-0.24710	0.02838
0.50	0.00821	-0.12738	0.14379
0.60	0.12577	-0.01197	0.26351
0.70	0.25155	0.10695	0.39616
0.80	0.39876	0.24098	0.55654
0.90	0.60291	0.41994	0.78588
0.91	0.63038	0.44355	0.81721
0.92	0.66023	0.46911	0.85136
0.93	0.69305	0.49708	0.88901

0.94	0.72970	0.52820	0.93120
0.95	0.77150	0.56353	0.97947
0.96	0.82061	0.60485	1.03638
0.97	0.88099	0.65539	1.10659
0.98	0.96125	0.72219	1.20031
0.99	1.08775	0.82674	1.34876

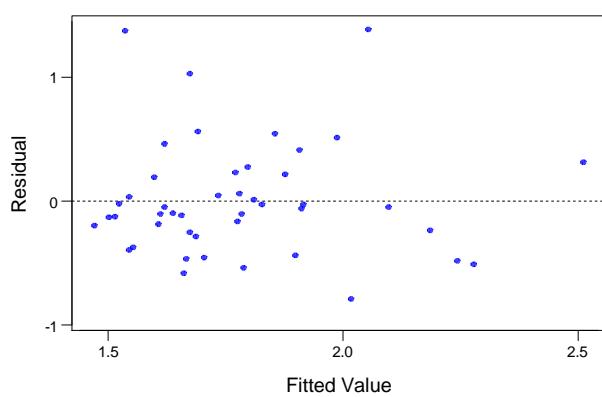
Normal Probability Plot



نحص أنماط الباقي مع القيم المطبقة

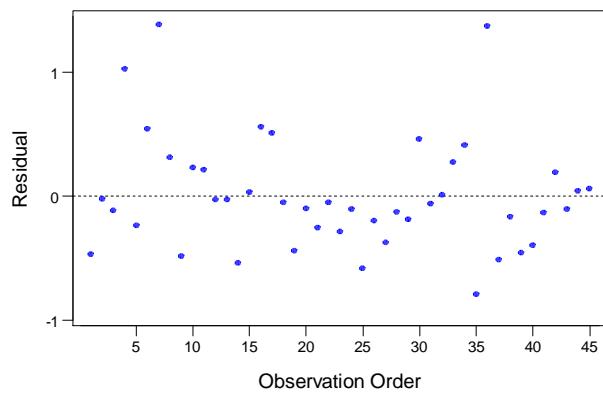
Residuals Versus the Fitted Values

(response is Defects)



والباقي مع ترتيب البيانات

Residuals Versus the Order of the Data
(response is Defects)



من الفحوصات السابقة نستنتج أن النموذج المقترن مناسب للتطبيق على البيانات المعطاة
(هـ)

95% Forecasts from period 45 to 50

Period	95 Percent Limits		
	Forecast	Lower	Upper
46	1.80627	0.88588	2.72665
47	1.79135	0.78503	2.79767
48	1.78476	0.76248	2.80703
49	1.78184	0.75648	2.80721
50	1.78055	0.75459	2.80652

بسم الله الرحمن الرحيم

قسم الإحصاء وبحوث العمليات
المادة : طرق التنبؤ الاحصائي 221 بحث
الاختبار الاول للأعمال الفصلية
الفصل الأول 1420-1421 هـ

الزمن : ساعتين

أجب على جميع الأسئلة التالية:

السؤال الأول:

ا- وضع النموذج التالي على الشكل $z_{n+j} = \beta_0 + \beta_1 j + \varepsilon_{n+j}, j = 0, \pm 1, \dots$ وذلك بتحديد كل من β و $f'(j)$ أوجد L وبرهن ان $f'(j+1) = Lf'(j)$

ب- بوضع $X' = [f(-n+1), f(-n+2), \dots, f(1), f(0)]$ و $y' = (z_1, \dots, z_n)$ وبرهن ان $X'y = \sum_{j=0}^{n-1} f(-j)z_{n-j}$ و $X'X = \sum_{j=0}^{n-1} f(-j)f'(-j)$

السؤال الثاني:

للمتسلسلة الزمنية التالية:

t	1	2	3	4	5	6	7	8	9	10	11	12
z_t	7	8	12	13	17	15	19	22	25	24	26	28

ا- طبق وسط متحرك من الدرجة 3 للمتسلسلة المعطاه ومن ثم اوجد متباينات لقيم المتسلسلة

$$z_{13}, z_{14}$$

ب- بأخذ $\alpha = 0.5$ طبق تمديد اسي بسيط للمتسلسلة المعطاه ومن ثم اوجد متباينات لقيم المتسلسلة

$$z_{13}, z_{14}$$

السؤال الثالث:

للنموذج التالي $| \phi_1 | < 1$ و $z_t = \delta + \phi_1 z_{t-1} + a_t$ حيث $0 < \delta < \infty$ مقدار ثابت و

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

ا- اوجد دالة الترابط الذاتي ρ_k وارسمها لقيم $k = 0, 1, \dots, 5$

ب- اوجد دالة الترابط الذاتي الجزئي $\phi_{k,k}$ وارسمها لقيم $k = 0, 1, \dots, 5$

بسم الله الرحمن الرحيم

جامعة الملك سعود – كلية العلوم
قسم الإحصاء وبحوث العمليات
اختبار أعمال فصل أول 1422/1423 هـ
لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن: 2 ساعة
أجب على جميع الأسئلة التالية:

السؤال الأول:
للنموذج

$$\begin{aligned} z &= \beta_0 + \beta_1 t + x_t \\ x_t &= \phi_1 x_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2) \end{aligned}$$

على إفتراض أن المعالم $\beta_0, \beta_1, \phi_1, \sigma^2$ معلومة.
برهن أن المتتبّع الخطّي ذا أدنى متّسق مربع خطأ للخطوة ℓ إلى الأمام يعطى بالعلاقة

$$z_t(\ell) = \beta_0 + \beta_1(t + \ell) + \phi_1^\ell(z_t - \beta_0 - \beta_1 t), \quad \ell \geq 0$$

السؤال الثاني:
إعتماداً على متسلسلة طولها $n = 200$ مشاهدة طبق نموذج $AR(2)$ وحصلنا على الترابطات الذاتية للبواقي التالية $\hat{\phi}_1 = 1.1, \hat{\phi}_2 = -0.8, r_1 = 0.13, r_2 = 0.13, r_3 = 0.12$ إذا كانت
فهل الترابطات الذاتية للبواقي تدعم أن النموذج هو $AR(2)$ كل على حدة أو مجتمعة؟

السؤال الثالث:
للمتسلسلة المستقرة التالية $\mu, \gamma_0, \rho_1, \dots$ قدر $6, 4, 6, 5, 4, 6$

السؤال الرابع:

لمتسلسلة زمنية طولها $n = 100$ مشاهدة حسبت الكميات التالية

$$r_1 = 0.8, r_2 = 0.5, r_3 = 0.4, \bar{z} = 2, s^2 = 5$$

إذا افترض ان المشاهدات من نموذج $AR(2)$ على الشكل

$$z = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t, a_t \sim WN(0, \sigma^2)$$

أوجد مقدرات العزوم للمعلم $\phi_1, \phi_2, \delta, \sigma^2$

بسم الله الرحمن الرحيم

جامعة الملك سعود – كلية العلوم
قسم الإحصاء وبحوث العمليات
الإختبار النهائي للفصل الأول 1422/1423 هـ
لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن: 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

للنموذج

$$z = \beta_0 + \beta_1 t + x_t$$

$$x_t = \phi_1 x_{t-1} + a_t, a_t \sim WN(0, \sigma^2)$$

على إفتراض أن المعالم $\beta_0, \beta_1, \phi_1, \sigma^2$ معلومة.

برهن أن المتتبّع الخطّي ذا أدنى متّسق مربع خطأ الخطوة ℓ إلى الأمام يعطى بالعلاقة

$$z_t(\ell) = \beta_0 + \beta_1(t + \ell) + \phi_1^\ell(z_t - \beta_0 - \beta_1 t), \quad \ell \geq 0$$

السؤال الثاني:

إنتماداً على متسلسلة طولها $n = 200$ مشاهدة طبق نموذج $AR(2)$ وحصلنا على الترابطات

الذاتية للبواقي التالية $\hat{\phi}_1 = 1.1, \hat{\phi}_2 = -0.8$ إذا كانت $r_1 = 0.13, r_2 = 0.13, r_3 = 0.12$

فهل الترابطات الذاتية للبواقي تدعم أن النموذج هو $AR(2)$ كل على حدة أو مجتمعة؟

السؤال الثالث:

للمتسلسلة المستقرة التالية $6, 4, 5, 6, 4, \dots$ قدر μ, γ_0, ρ_1

السؤال الرابع:

لمتسلسلة زمنية طولها $n = 100$ مشاهدة حسب الكميات التالية

$$r_1 = 0.8, r_2 = 0.5, r_3 = 0.4, \bar{z} = 2, s^2 = 5$$

إذا افترض ان المشاهدات من نموذج $AR(2)$ على الشكل

$$z = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t, a_t \sim WN(0, \sigma^2)$$

أوجد مقدرات العزوم للمعلم $\phi_1, \phi_2, \delta, \sigma^2$

السؤال الخامس:

وجد أن المبيعات السنوية بمليين الريالات لشركة ما تتبع النموذج

$$z_t = 5 + 1.1z_{t-1} - 0.5z_{t-2} + a_t, a_t \sim WN(0, 2)$$

إذا كانت المبيعات للسنوات 1419 و 1420 و 1421 هـ هي على التوالي 10 و 11 و 9 ملايين

ريال

- أوجد تنبؤات لمبيعات 1422 و 1423 و 1424 هـ

- أحسب الأوزان $\psi_j, j = 1, 2, 3, 4.$

ج) أحسب فترات تنبؤ 95% لمبيعات للسنوات 1422 و 1423 و 1424 هـ.

جامعة الملك سعود – كلية العلوم
قسم الإحصاء وبحوث العمليات
الإختبار النهائي للفصل الأول 1422/1423 هـ
لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن: 3 ساعات
أجب على جميع الأسئلة التالية:

السؤال الأول:
للنموذج

$$z_t = \beta_0 + \beta_1 t + x_t$$
$$x_t = \phi_1 x_{t-1} + a_t, a_t \sim WN(0, \sigma^2)$$

على إفتراض أن المعالم $\beta_0, \beta_1, \phi_1, \sigma^2$ معلومة.

برهن أن المتتبّع الخطّي ذا أدنى متّسق مربع خطأ الخطوة ℓ إلى الأمام يعطى بالعلاقة

$$z_t(\ell) = \beta_0 + \beta_1(t + \ell) + \phi_1^\ell(z_t - \beta_0 - \beta_1 t), \quad \ell \geq 0$$

السؤال الثاني:

إنتماداً على متسلسلة طولها $n = 200$ مشاهدة طبق نموذج $AR(2)$ وحصلنا على الترابطات

الذاتية للبواقي التالية $\hat{\phi}_1 = 1.1, \hat{\phi}_2 = -0.8$ إذا كانت $r_1 = 0.13, r_2 = 0.13, r_3 = 0.12$

فهل الترابطات الذاتية للبواقي تدعم أن النموذج هو $AR(2)$ كل على حدة أو مجتمعة؟

السؤال الثالث:

لمتسلسلة زمنية طولها $n = 100$ مشاهدة حسبت الكميات التالية

$$r_1 = 0.8, r_2 = 0.5, r_3 = 0.4, \bar{z} = 2, s^2 = 5$$

إذا افترض ان المشاهدات من نموذج $AR(2)$ على الشكل

$$z = \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t, a_t \sim WN(0, \sigma^2)$$

أوجد مقدرات العزوم للمعلم $\phi_1, \phi_2, \delta, \sigma^2$

السؤال الرابع:

وجد أن المبيعات السنوية بملايين الريالات لشركة ما تتبع النموذج

$$z_t = 5 + 1.1z_{t-1} - 0.5z_{t-2} + a_t, a_t \sim WN(0, 2)$$

إذا كانت المبيعات للسنوات 1419 و 1420 و 1421 هـ هي على التوالي 10 و 11 و 9 ملايين

ريال

3- أوجد تنبؤات لمبيعات 1422 و 1423 و 1424 هـ

4- أحسب الأوزان $\psi_j, j = 1, 2, 3, 4$.

ج) أحسب فترات تنبؤ 95% لمبيعات للسنوات 1422 و 1423 و 1424 هـ.

بسم الله الرحمن الرحيم

إجابات نموذجية لاختبار النهائي للفصل الأول 1423/1422 هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي)

إجابة للسؤال الأول:

نضع المعادلات المعرفة للنموذج على الشكل

$$z_t = \beta_0 + \beta_1 t + \phi_1 x_{t-1} + a_t, \quad a_t \sim WN(0, \sigma^2)$$

المتنبئ الخطى ذا أدنى متوسط مربع خطأ للخطوة ℓ إلى الأمام يعطى من العلاقة

$$z_t(\ell) = E(z_{t+\ell} | z_t, z_{t-1}, \dots), \ell \geq 0$$

$$\therefore x_t = z_t - \beta_0 - \beta_1 t$$

$$\therefore z_t - \beta_0 - \beta_1 t = \phi_1 [z_{t-1} - \beta_0 - \beta_1 (t-1)] + a_t, \quad a_t \sim WN(0, \sigma^2)$$

$$z_t(\ell) - \beta_0 - \beta_1 (t + \ell) = E[(\phi_1 [z_{t+\ell-1} - \beta_0 - \beta_1 (t + \ell - 1)] + a_{t+\ell}) | z_t, z_{t-1}, \dots], \ell \geq 0$$

$$= E(\phi_1 [z_{t+\ell-1} - \beta_0 - \beta_1 (t + \ell - 1)] | z_t, z_{t-1}, \dots) + E(a_{t+\ell} | z_t, z_{t-1}, \dots), \ell \geq 0$$

$$\ell = 1 : z_t(1) - \beta_0 - \beta_1 (t + 1) = E(\phi_1 (z_t - \beta_0 - \beta_1 t) | z_t, z_{t-1}, \dots) + 0$$

$$= \phi_1 (z_t - \beta_0 - \beta_1 t)$$

$$\ell = 2 : z_t(2) - \beta_0 - \beta_1 (t + 2) = \phi_1 [z_t(1) - \beta_0 - \beta_1 (t + 1)] = \phi_1^2 (z_t - \beta_0 - \beta_1 t)$$

$$\ell = 3 : z_t(3) - \beta_0 - \beta_1 (t + 3) = \phi_1 [z_t(2) - \beta_0 - \beta_1 (t + 2)] = \phi_1^3 (z_t - \beta_0 - \beta_1 t)$$

$$\ell = 4 : z_t(4) - \beta_0 - \beta_1 (t + 4) = \phi_1 [z_t(3) - \beta_0 - \beta_1 (t + 3)] = \phi_1^4 (z_t - \beta_0 - \beta_1 t)$$

وهكذا بشكل عام

$$z_t(\ell) - \beta_0 - \beta_1 (t + \ell) = \phi_1 [z_t(\ell - 1) - \beta_0 - \beta_1 (t + \ell - 1)] = \phi_1^\ell (z_t - \beta_0 - \beta_1 t)$$

أو بعد ترتيب الحدود

$$z_t(\ell) = \beta_0 + \beta_1 (t + \ell) + \phi_1^\ell (z_t - \beta_0 - \beta_1 t), \ell \geq 0$$

وهو المطلوب.

بسم الله الرحمن الرحيم

جامعة الملك سعود

قسم الإحصاء وبموجة العمليات

مادة 221 بحث (طرق التنبؤ الإحصائي)

الإختبار النهائي للفصل الثاني 1423/1422 هـ

الزمن 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

للنموذج

$$z_t = 200 + 1.2z_{t-1} - 0.7z_{t-2} + a_t + 0.5a_{t-1}, a_t \sim N(0, 1)$$

- 1- أوجد دالة الترابط الذاتي ρ_k لقيم $k = 1, 2, \dots, 5$ وارسمها.
- 2- أوجد دالة الترابط الذاتي الجزيئي ϕ_{kk} لقيم $k = 1, 2, \dots, 5$ وارسمها.
- 3- أوجد دالة الأوزان β_j لقيم $j = 1, 2, \dots, 5$ وارسمها.
- 4- أوجد دالة التنبؤ $z_n(\ell)$, $\ell \geq 0$.

السؤال الثاني:

المشاهدات التالية لمتسلسلة زمنية: (إقرأ من اليسار سطراً بسطر)

201	202	203	202	200	198	197	197
				198	200	201	199

196	193	195	197	199	201	201	201
				203	203	200	197
194	195	197	201	204	204	202	200
				201	200	198	198
198	198	196	193	194	199	204	206
				206	203	200	200
202	204	206	205	202	198	199	201
				201	201	204	205
				205	201	198	197

ادخل المشاهدات في برنامج MINITAB وأجب على التالي:

1- تعرف على نموذج مناسب من عائلة ARIMA يطبق على المشاهدات وذلك باستخدام

$$\text{معيار المعلومات الذاتي } AIC = n \ln \sigma_a^2 + 2m$$

2- للنموذج المقترن بفحص الباقي مجرياً عليها جميع الإختبارات المناسبة.

3- من النموذج المقترن ولد تنبؤات لقيم المستقبلية حتى 8 أزمنة تقدم مع فترات تنبؤ 95% .

إجابات محتملة لـاختبار النهائي للفصل الثاني 1423/1422 هـ

مادة 221 بحث (طرق التنبؤ الإحصائي)

إجابة للسؤال الأول:

نضع النموذج $z_t = 200 + 1.2z_{t-1} - 0.7z_{t-2} + a_t + 0.5a_{t-1}$, $a_t \sim N(0,1)$ على شكل إنحرافات

$$\text{عن المتوسط } \mu = \frac{\delta}{(1-\phi_1-\phi_2)} = \frac{200}{1+0.7-1.2} = 400$$

$$z_t - 400 = 1.2(z_{t-1} - 400) - 0.7(z_{t-2} - 400) + a_t + 0.5a_{t-1}, a_t \sim N(0,1)$$

- نوجد ρ_k كالتالي:

$$E\{(z_t - 400)(z_{t-k} - 400)\} - 1.2E\{(z_{t-1} - 400)(z_{t-k} - 400)\} + 0.7E\{(z_{t-2} - 400)(z_{t-k} - 400)\} = \\ E\{a_t(z_{t-k} - 400)\} + 0.5E\{a_{t-1}(z_{t-k} - 400)\}$$

$$\gamma_k - 1.2\gamma_{k-1} + 0.7\gamma_{k-2} = E\{a_t(z_{t-k} - 400)\} + 0.5E\{a_{t-1}(z_{t-k} - 400)\}$$

$$k=0: \gamma_0 - 1.2\gamma_1 + 0.7\gamma_2 = E\{a_t(z_t - 400)\} + 0.5E\{a_{t-1}(z_t - 400)\}$$

$$= \sigma^2 + 0.5(0.7\sigma^2) = 1.35\sigma^2$$

$$k=1: \gamma_1 - 1.2\gamma_0 + 0.7\gamma_1 = E\{a_t(z_{t-1} - 400)\} + 0.5E\{a_{t-1}(z_{t-1} - 400)\} \\ = 0.5\sigma^2$$

$$k=2: \gamma_2 - 1.2\gamma_1 + 0.7\gamma_0 = E\{a_t(z_{t-2} - 400)\} + 0.5E\{a_{t-1}(z_{t-2} - 400)\} \\ = 0$$

$$k \geq 2: \gamma_k - 1.2\gamma_{k-1} + 0.7\gamma_{k-2} = 0$$

من العلاقات السابقة نجد ان (بوضع $\sigma^2 = 1$)

$$\rho_1 = 0.74436$$

ومن العلاقة الأخيرة وبالقسمة على γ_0 نجد

$$\gamma_k = 1.2\gamma_{k-1} - 0.7\gamma_{k-2}, k=2,3,\dots$$

$$\rho_k = 1.2\rho_{k-1} - 0.7\rho_{k-2}, k=2,3,\dots$$

$$\therefore \rho_2 = 1.2\rho_1 - 0.7\rho_0 = 1.2(0.74436) - 0.7(1) = 0.193232$$

$$\rho_3 = 1.2 \rho_2 - 0.7 \rho_1 = -0.289173$$

$$\rho_4 = -0.482271$$

$$\rho_5 = -0.376304$$

$$\rho_6 = -0.113975$$

$$\rho_7 = 0.126642$$

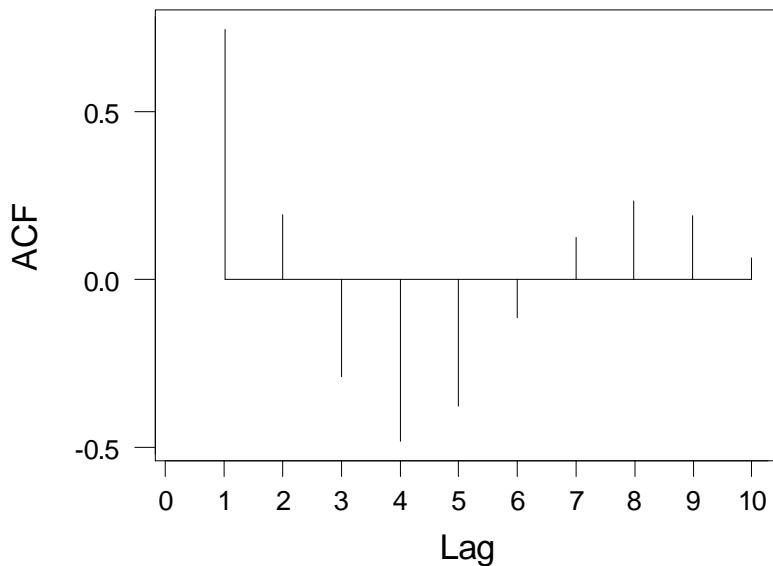
$$\rho_8 = 0.231754$$

$$\rho_9 = 0.189455$$

$$\rho_{10} = 0.651180$$

و ترسم كالتالي:

ACF of the Model



نوج 2 - ϕ_{kk}

$\phi_{00} = 1$, by definition

$\phi_{11} = \rho_1 = 0.744361$, by definition

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}, \quad k = 2, 3, \dots$$

$$\phi_{kj} = \phi_{k-1,j} - \phi_{kk} \phi_{k-1,k-1}, \quad j = 1, 2, \dots, k-1$$

$$\phi_{22} = \frac{\rho_2 - \phi_{11} \rho_1}{1 - \phi_{11} \rho_1} = \frac{0.193233 - (0.744361)(0.744361)}{1 - (0.744361)(0.744361)} = \frac{-0.3608402}{0.4459268} = -0.8091915$$

$$\phi_{33} = 0.343852$$

$$\phi_{44} = -0.165706$$

$$\phi_{55} = 0.821095$$

$$\phi_{66} = -0.409620$$

$$\phi_{77} = 0.204689$$

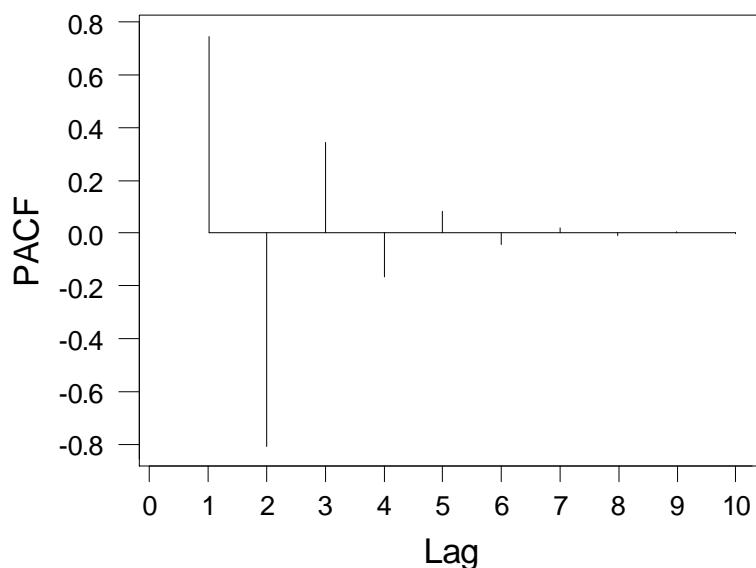
$$\phi_{88} = -0.102327$$

$$\phi_{99} = 0.511617$$

$$\phi_{10,10} = -0.255822$$

ونرسمها كالتالي:

PACF of the Model



- دالة الأوزان ψ_j

نضع النموذج على الشكل:

$$\begin{aligned}
 z_t &= 200 + 1.2z_{t-1} - 0.7z_{t-2} + a_t + 0.5a_{t-1} \\
 z_t - 1.2z_{t-1} + 0.7z_{t-2} &= 200 + a_t + 0.5a_{t-1} \\
 (1 - 1.2B + 0.7B^2)z_t &= 200 + (1 + 0.5B)a_t \\
 z_t &= \frac{200}{1 - 1.2 + 0.7} + \frac{(1 + 0.5B)}{(1 - 1.2B + 0.7B^2)}a_t \\
 &= 400 + \psi(B)a_t
 \end{aligned}$$

دالة الأوزان هي:

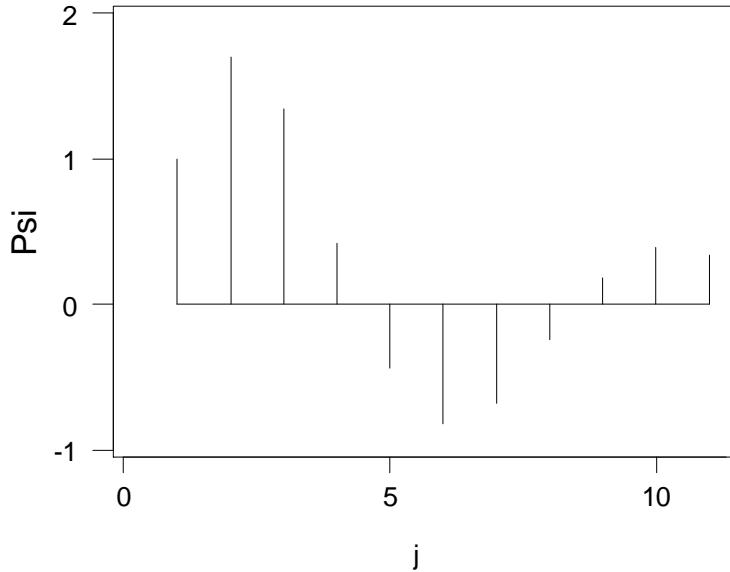
$$\psi(B) = \frac{(1 - 0.5B)}{(1 - 1.2B + 0.7B^2)} = 1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots$$

نوجد الأوزان كالتالي:

$$\begin{aligned}
 (1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots)(1 - 1.2B + 0.7B^2) &\equiv (1 + 0.5B) \\
 B : \psi_1 - 1.2 &= 0.5 \Rightarrow \psi_1 = 1.7 \\
 B^2 : \psi_2 - 1.2\psi_1 + 0.7 &= 0 \Rightarrow \psi_2 = 1.2\psi_1 - 0.7 = 1.34 \\
 B^3 : \psi_3 - 1.2\psi_2 + 0.7\psi_1 &= 0 \Rightarrow \psi_3 = 1.2\psi_2 - 0.7\psi_1 = 0.418 \\
 &\vdots \\
 B^j : \psi_j &= 1.2\psi_{j-1} - 0.7\psi_{j-2} \\
 \psi_4 &= 1.2\psi_3 - 0.7\psi_2 = -0.4364 \\
 \psi_5 &= -0.81628 \\
 \psi_6 &= -0.674056 \\
 \psi_7 &= -0.237471 \\
 \psi_8 &= 0.186874 \\
 \psi_9 &= 0.390478 \\
 \psi_{10} &= 0.337762
 \end{aligned}$$

ولها الشكل التالي:

Psi Weights of the Model



ـ دالة التنبؤ $z_n(\ell)$, $\ell \geq 0$ تعطى بالعلاقة:

$$z_n(\ell) = E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1$$

مع

$$E(a_{n+j} | z_n, z_{n-1}, \dots) = \begin{cases} a_{n+j}, & j \leq 0 \\ 0, & j > 0 \end{cases}$$

$$E(z_{n+j} | z_n, z_{n-1}, \dots) = \begin{cases} z_{n+j}, & j \leq 0 \\ z_n(j), & j > 0 \end{cases}$$

إذ:

$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= E(200 + 1.2z_{n+\ell-1} - 0.7z_{n+\ell-2} + a_{n+\ell} + 0.5a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= 200 + 1.2E(z_{n+\ell-1} | z_n, z_{n-1}, \dots) - 0.7E(z_{n+\ell-2} | z_n, z_{n-1}, \dots) \\ &\quad + E(a_{n+\ell} | z_n, z_{n-1}, \dots) + 0.5E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \end{aligned}$$

$$\ell = 1: z_n(1) = 200 + 1.2z_n - 0.7z_{n-1} + 0.5a_n$$

$$\ell = 2: z_n(2) = 200 + 1.2z_n(1) - 0.7z_n$$

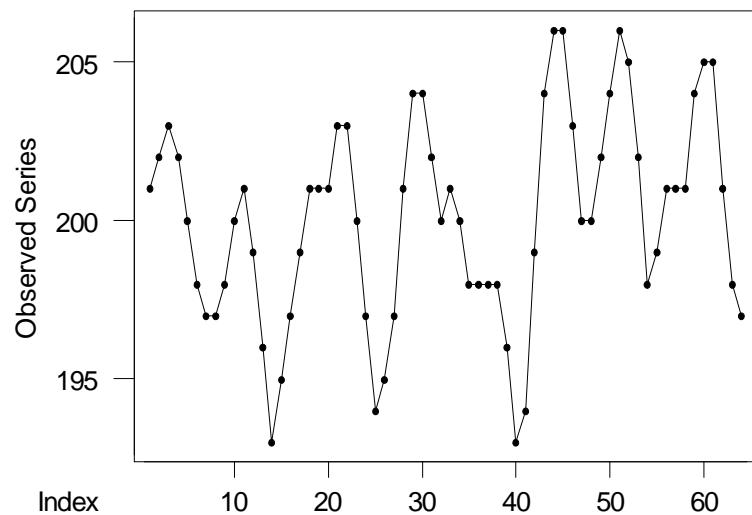
$$\ell \geq 3: z_n(\ell) = 200 + 1.2z_n(\ell-1) - 0.7z_n(\ell-2)$$

وبشكل دالة:

$$z_n(\ell) = \begin{cases} 200 + 1.2z_n - 0.7z_{n-1} + 0.5a_n, & \ell = 1 \\ 200 + 1.2z_n(1) - 0.7z_n, & \ell = 2 \\ 200 + 1.2z_n(\ell-1) - 0.7z_n(\ell-2), & \ell \geq 3 \end{cases}$$

إجابة للسؤال الثاني:

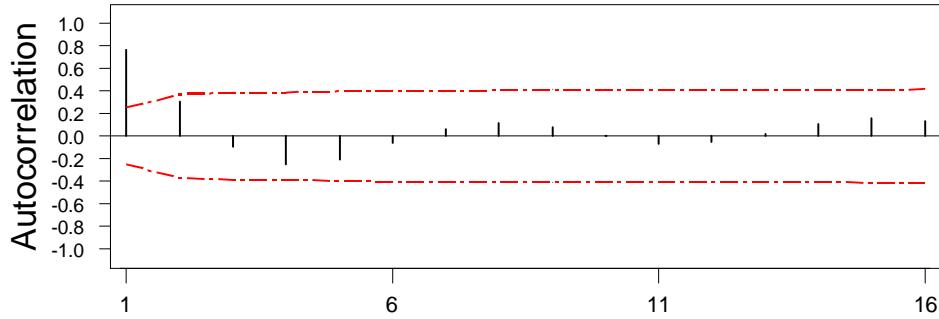
نرسم المتسلسلة



يبدو أنها مستقرة في التوقع والتبالغ

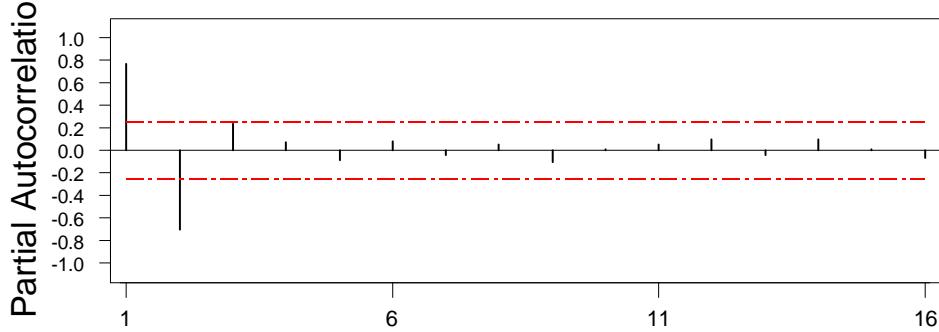
نرسم كلا من دالتي الترابط الذاتي والترابط الذاتي الجزئي

Autocorrelation Function for Observed



Lag	Corr	T	LBQ	Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	0.77	6.18	39.96	8	0.11	0.55	56.38	15	0.16	0.75	60.52
2	0.31	1.67	46.47	9	0.08	0.38	56.84	16	0.13	0.63	62.00
3	-0.09	-0.48	47.06	10	-0.00	-0.01	56.84				
4	-0.26	-1.33	51.72	11	-0.07	-0.33	57.21				
5	-0.21	-1.06	54.89	12	-0.06	-0.27	57.47				
6	-0.06	-0.32	55.19	13	0.02	0.08	57.49				
7	0.06	0.29	55.45	14	0.11	0.52	58.44				

Partial Autocorrelation Function for Observed



Lag	PAC	T	Lag	PAC	T	Lag	PAC	T
1	0.77	6.18	8	0.05	0.44	15	0.01	0.04
2	-0.71	-5.68	9	-0.11	-0.87	16	-0.07	-0.56
3	0.24	1.91	10	0.01	0.06			
4	0.07	0.56	11	0.05	0.42			
5	-0.08	-0.67	12	0.10	0.77			
6	0.08	0.62	13	-0.04	-0.35			
7	-0.04	-0.34	14	0.09	0.74			

كلا من الدالتين تبين ان المتسلسلة مستقرة وهي على الشكل $ARMA(p,q)$ نطبق مجموعة من

النماذج لقيم

: $AIC(m) = n \ln \sigma_a^2 + 2m$ ونأخذ اقل قيمة للمعيار $p = 0, 1, 2$ $q = 0, 1, 2$

ARMA(1,0) 1-

Type	Coef	StDev	T
AR 1	0.7841	0.0803	9.77
Constant	43.1776	0.2587	166.90
Mean	199.954		1.198

Number of observations: 64

Residuals: SS = 264.844 (backforecasts excluded)

MS = 4.272 DF = 62

$$= 64 \ln(4.272) + 2(3) = 64(1.452) + 6 = 98.928 AIC(m) = n \ln \sigma_a^2 + 2m$$

ARMA(2,0) 2-

Type	Coef	StDev	T
AR 1	1.3568	0.0870	15.60
AR 2	-0.7422	0.0872	-8.51
Constant	77.0740	0.1768	435.96
Mean	200.013		0.459

Number of observations: 64

Residuals: SS = 121.868 (backforecasts excluded)

MS = 1.998 DF = 61

$$= 64 \ln(1.998) + 2(4) = 64(0.692) + 8 = 52.288 AIC(m) = n \ln \sigma_a^2 + 2m$$

ARMA(0,1) 3-

Type	Coef	StDev	T
MA 1	-0.8772	0.0775	-11.32
Constant	200.032	0.464	430.96
Mean	200.032		0.464

Number of observations: 64

Residuals: SS = 252.640 (backforecasts excluded)

MS = 4.075 DF = 62

$$= 64 \ln(4.075) + 2(3) = 64(1.40487) + 6 = 95.912 AIC(m) = n \ln \sigma_a^2 + 2m$$

ARMA(0,2)4-

Type	Coef	StDev	T
MA 1	-1.3321	0.1042	-12.78
MA 2	-0.6491	0.1032	-6.29
Constant	200.038	0.580	344.69
Mean	200.038	0.580	

Number of observations: 64

Residuals: SS = 149.291 (backforecasts excluded)

MS = 2.447 DF = 61

$$= 64 \ln(2.447) + 2(4) = 64(0.89486) + 8 = 65.271 AIC(m) = n \ln \sigma_a^2 + 2m$$

ARMA(1,1)5-

Type	Coef	StDev	T
AR 1	0.6823	0.1023	6.67
MA 1	-0.6832	0.1054	-6.48
Constant	63.5287	0.3342	190.09
Mean	199.954		1.052

Number of observations: 64

Residuals: SS = 153.610 (backforecasts excluded)

MS = 2.518 DF = 61

$$= 64 \ln(2.518) + 2(4) = 64(0.92346) + 8 = 67.101 AIC(m) = n \ln \sigma_a^2 + 2m$$

ARMA(2,1)6-

Model cannot be estimated with these data

ARMA(1,2) 7-

Type		Coef	StDev	T
AR	1	0.5112	0.1492	3.43
MA	1	-1.0134	0.1518	-6.68
MA	2	-0.4821	0.1482	-3.25
Constant		97.7668	0.4536	215.55
	Mean		200.014	0.928

Number of observations: 64

Residuals: SS = 126.688 (backforecasts excluded)

MS = 2.111 DF = 60

$$= 64 \ln(2.111) + 2(5) = 64(0.74716) + 10 = AIC(m) = n \ln \sigma_a^2 + 2m \\ 57.818$$

ARMA(2,2) 8-

Type		Coef	StDev	T
AR	1	1.1047	0.2011	5.49
AR	2	-0.5789	0.1608	-3.60
MA	1	-0.4394	0.2275	-1.93
MA	2	-0.1918	0.1973	-0.97
Constant		94.8688	0.2824	335.90
	Mean		200.041	0.596

Number of observations: 64

Residuals: SS = 113.051 (backforecasts excluded)

MS = 1.916 DF = 59

$$= 64 \ln(1.916) + 2(6) = 64(0.65) + 12 = 53.6 AIC(m) = n \ln \sigma_a^2 + 2m$$

ونلخصها في الجدول التالي:

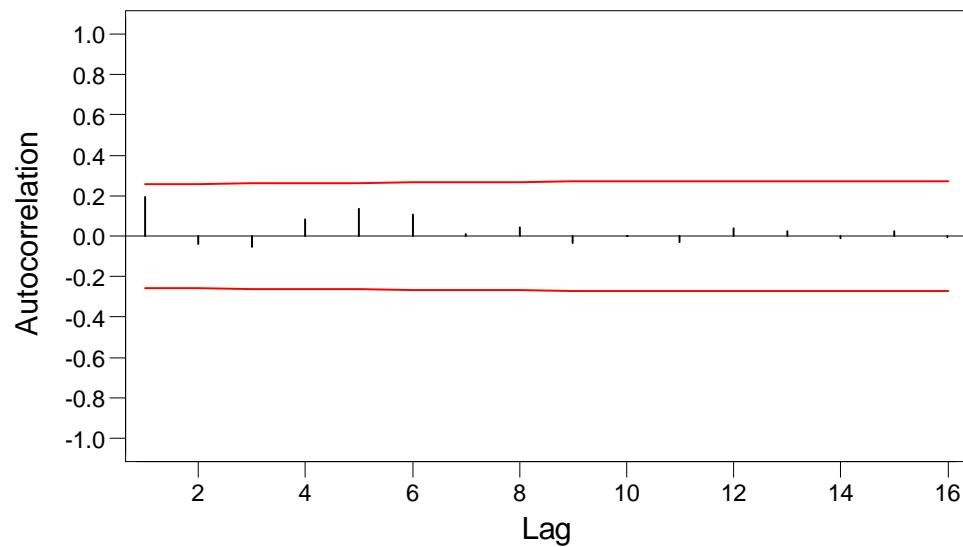
<i>ARMA(p,q)</i>	<i>AIC(m)</i>	<i>min AIC(m)</i>

$ARMA(0,0)$	NA	
$ARMA(1,0)$	98.928	
$ARMA(2,0)$	52.288	*
$ARMA(0,1)$	95.912	
$ARMA(0,2)$	65.271	
$ARMA(1,1)$	67.101	
$ARMA(2,1)$	NA	
$ARMA(1,2)$	57.818	
$ARMA(2,2)$	53.6	

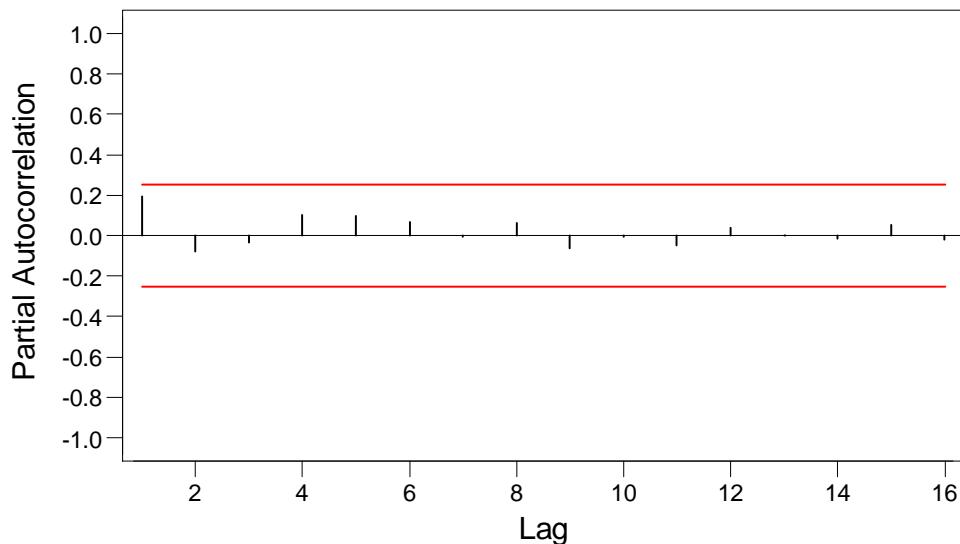
نلاحظ ان أقل قيمة لمعيار المعلومات الذاتي AIC للنموذج $ARMA(2,0)$

2- فحص وإختبار الباقي:

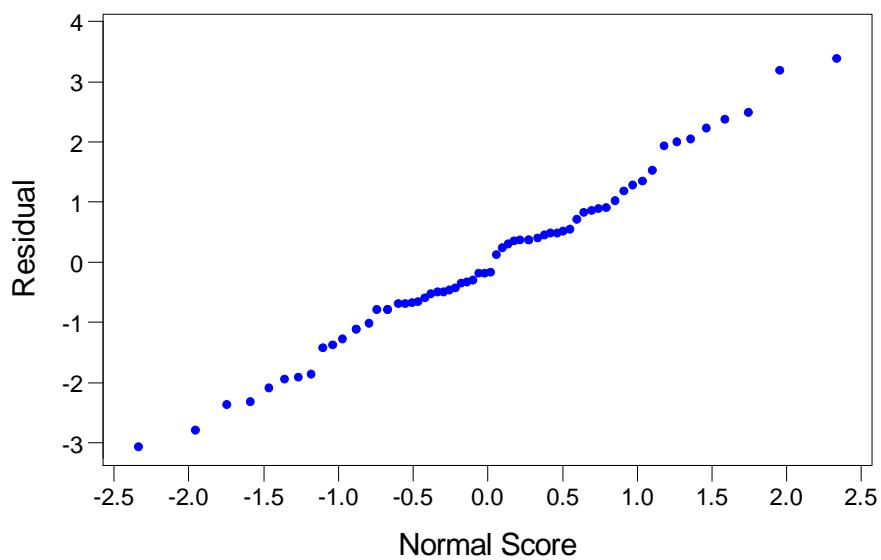
ACF of Residuals for Observed
(with 95% confidence limits for the autocorrelations)

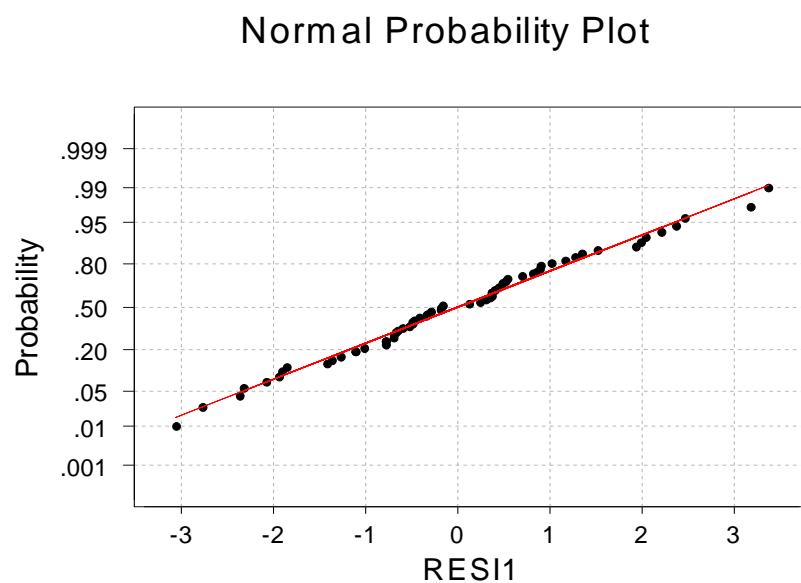
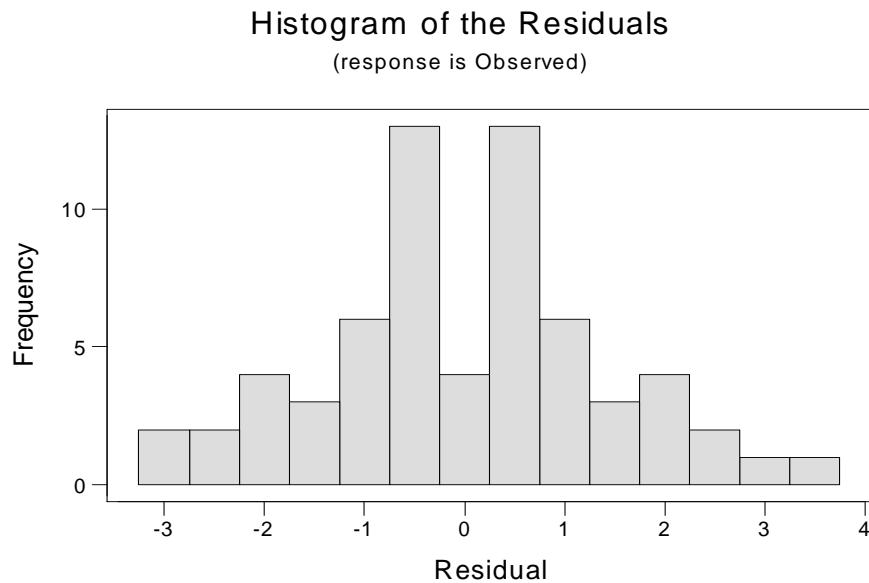


PACF of Residuals for Observed
(with 95% confidence limits for the partial autocorrelations)



Normal Probability Plot of the Residuals
(response is Observed)





Average: 0.0042206
StDev: 1.39083
N: 64

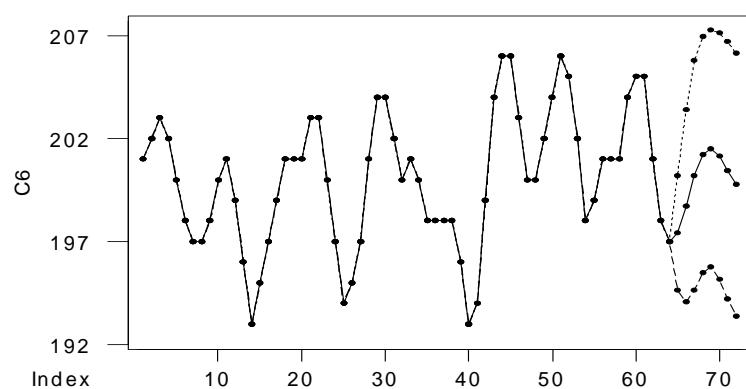
Kolmogorov-Smirnov Normality Test
D+: 0.067 D-: 0.068 D : 0.068
Approximate P-Value > 0.15

نلاحظ أن الباقي تجذاز كل الاختبارات وهذا يعني ان النموذج المقترن مناسب.

3- تنبؤات لقييم المستقبلية حتى 8 أزمنة تقدم مع فترات تنبؤ 95%

Forecasts from period 64
95 Percent Limits

Period	Forecast	Lower	Upper
			Actual
65	197.419	194.648	200.190
66	198.729	194.059	203.400
67	200.196	194.621	205.772
68	201.215	195.480	206.949
69	201.507	195.756	207.258
70	201.148	195.181	207.116
71	200.445	194.202	206.687
72	199.756	193.378	206.134



المراجع:

- 1- Abraham, B. and Ledotter, J. (1983). *Statistical Methods for Forecasting*, John Wiley, New York.
- 2- Anderson, T. W. (1971). *The Statistical Analysis of Time Series*, John Wiley, New York.
- 3- Box, G. E. P. and Jenkins, G. M. (1976). *Time Series Analysis Forecasting and Control*, 2nd ed., Holden-Day, San Francisco.
- 4- Montgomery, D. C., Johnson, L. A. and Gardiner, J. S. (1990). *Forecasting and Time Series Analysis*, 2nd ed., McGraw-Hill International Edition.
- 5- Makridakis, S., Wheelwright, S. C. and McGee, V. E. (1983). *Forecasting Methods and Applications*, 2nd ed., John Wiley, New York.
- 6- Wei, W. W. S. (1990). *Time Series Analysis Univariate and Multivariate Methods*, Addison Wesley.
- 7- *Minitab Reference Manual*, Release 11 for Windows. (1998).

للأسف الشديد لا توجد حسب علمي مراجع عربية تغطي كل أو جزء من محتوى المادة المغطاة في هذا الكتاب وأرجوا من أي طالب أو باحث أو مدرس يعلم بمثل هذا المرجع او الكتاب أن يرسل لي ملاحظة على البريد الإلكتروني:

abarry@ksu.edu.sa أو abarry@abarry.ws