

طرق التنبؤ الإحصائي

برأسطة R

(الجزء الأول)
الطبعة الثانية



تأليفه د. محمد نان ماجد عبد الرحمن بري
أستاذ الإحصاء وبحوث العمليات المشارك (سابقاً)

بسم الله الرحمن الرحيم

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

هذه هي الطبعة الثانية لكتاب طرق التنبؤ الإحصائي لطلاب مرحلة البكالوريوس. هذا الكتاب سوف أقوم بتطويره وتحسينه بشكل مستمر وسيظل بشكله الإلكتروني هذا لأنني أعتقد ان العلوم والتقنية تتطور يوميا وبشكل متسارع بحيث ان وضعها في كتاب جامد ستاتيكي لايتناسب مع ديناميكية الموضوع وخاصة في عصر ثورة المعلومات والإنترنت.

يغطي الجزء الأول من الكتاب الأساسيات الأولية للموضوع ويتطرق إلى موضوع التنبؤ الإحصائي بإستخدام نماذج ARIMA والتي كانت اول معالجة رياضية جادة ومحكمة للتنبؤ الإحصائي بإستخدام المتسلسلات الزمنية Time Series كما تطرقت في آخر الكتاب إلى بعض الطرق التقليدية الهورستكية للتنبؤ الإحصائي وفي جميع أجزاء الكتاب قمت بتوضيح الأمثلة والحالات الدراسية بإستخدام الحزمة الإحصائية R وهي برامج حاسب طورت لعلم الإحصاء بجميع فروعها وهذه الحزمة متوفرة 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 المتعددة Multivariate Time Series Models ونماذج المتسلسلات الزمنية الموجهة Vector Time Series Models ونماذج فضاء الحالة ومرشح كالمن State Space Models and Kalman Filtering ونماذج الحد Threshold Time Series Models ونماذج ARCH ونماذج GARCH وتطبيقاتها في التنبؤ المالي Finantial Time Series Forecasting كما سنتطرق 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/statisticalForecast1.pdf> والله الموفق.

المؤلف
د. عدنان ماجد عبد الرحمن بري

يناير 2018 م

المحتويات

مقدمة

10	1- الفصل الأول: مقدمة وتعريف.....
10	1-1 أمثلة على المتسلسلات الزمنية
10	2-1 الغرض من دراسة وتحليل المتسلسلات الزمنية
11	3-1 الخطوات المتخذة لبناء نموذج تنبؤ
11	1-3-1 تعيين النموذج
11	2-3-1 تطبيق النموذج
11	3-3-1 تشخيص واختبار النموذج
11	4-3-1 توليد التنبؤات
11	5-3-1 استخدام التنبؤات ووضع القرارات
12	4-1 تعريف ومبادئ أولية
12	1-4-1 تعريف ماضي أو تاريخ الظاهرة
12	2-4-1 تعريف الحاضر أو الآن
12	3-4-1 تعريف أخطاء التطبيق
13	4-4-1 تعريف أخطاء التنبؤ
13	5-4-1 تعريف الاستقرار
13	6-4-1 تعريف الضجة البيضاء
14	7-4-1 مثال 1 : المشي العشوائي
14	8-4-1 تعريف دالة التباين الذاتي
15	9-4-1 تعريف دالة الترابط الذاتي
15	10-4-1 مثال 2 : دالة الترابط الذاتي للضجة البيضاء
16	11-4-1 تعريف دالة الترابط الذاتي الجزئي
16	12-4-1 مثال 3: دالة الترابط الذاتي للضجة البيضاء
17	13-4-1 تعريف دالة الترابط الذاتي للعينة
17	14-4-1 تعريف دالة الترابط الذاتي الجزئي للعينة

15-4-1 مثال 4: دالة الترابط الذاتي والترابط الذاتي الجزئي للعينة 18

2- الفصل الثاني: نماذج الإنحدار الذاتي-المتوسط المتحرك ARMA

3- وإستخداماتها في التنبؤ..... 25

1-2 تعريف نماذج الإنحدار الذاتي-المتوسط المتحرك من الدرجة (p,q) 25

2-2 تعريف عامل الإزاحة الخلفي 25

3-2 تعريف عامل الإزاحة الأمامي 26

4-2 تعريف عامل التفريق 26

5-2 تعريف عامل التجميع 26

6-2 أمثلة 26

7-2 خصائص نماذج الإنحدار الذاتي-المتوسط المتحرك 28

1-7-2 نموذج ARMA(0,0) 28

2-7-2 نموذج AR(1) 32

3-7-2 نموذج AR(2) 37

4-7-2 نموذج MA(1) 43

5-7-2 نموذج MA(2) 47

6-7-2 نموذج ARMA(1,1) 51

7-7-2 خواص نماذج ARMA(p,q) 56

3- الفصل الثالث: نماذج المتسلسلات الزمنية غير المستقرة 58

1-3 عدم الإستقرار في المتوسط 58

2-3 عدم الإستقرار في التباين 59

3-3 نماذج الإنحدار الذاتي-التكاملي-المتوسط المتحرك من الدرجة (p,d,q) 62

1-3-3 نموذج ARIMA(1,1,0) 62

2-3-3 نموذج ARIMA(0,1,1) 62

3-3-3 نموذج المشي العشوائي بانجراف 63

4-3 دالة الأوزان $\psi(B)$ وتمثيل نماذج ARMA(p,q) 63

5-3 أمثلة لدالة الأوزان لبعض النماذج 64

1-5-3 دالة الأوزان لنموذج AR(1) 64

2-5-3 دالة الأوزان لنموذج MA(1) 65

66	3-5-3 دالة الأوزان لنموذج AR(2)
66	4-5-3 دالة الأوزان لنموذج MA(2)
67	5-5-3 دالة الأوزان لنموذج ARMA(1,1)
68	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)
72	1-4 نظرية 2: أخطاء التنبؤ
72	2-2 مجموعة المعلومات Information Sets
72	3-4 نظرية 3: المتنبئ ذا متوسط مربع الخطأ الأدنى
73	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)
74	2-6-4 شرط الإستمرار
75	3-6-4 دالة التنبؤ لنموذج AR(2)
76	4-6-4 دالة التنبؤ لنموذج ARIMA(0,1,1)
77	5-6-4 دالة التنبؤ لنموذج MA(1)
78	6-6-4 دالة التنبؤ لنموذج MA(2)
79	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
82	1-1-5 تثبيت التباين
82	2-1-5 إختيار درجة التفريق d
83	3-1-5 تحديد p,q
83	4-1-5 إضافة معلم إنجراف

85	2-5	تقدير النموذج
85	1-2-5	طريقة العزوم
86	2-2-5	تقدير العزوم لبعض النماذج
86	1-2-2-5	لنموذج $AR(1)$
87	2-2-2-5	لنموذج $MA(1)$
87	3-2-2-5	لنموذج $AR(2)$
88	4-2-2-5	لنموذج $MA(2)$
88	5-2-2-5	لنموذج $ARMA(1,1)$
89	3-2-5	طريقة المربعات الدنيا الشرطية
90	4-2-5	تقديرات المربعات الدنيا الشرطية لبعض النماذج
90	1-4-2-5	لنماذج $AR(1)$
91	2-4-2-5	لنماذج $MA(1)$
94	3-5	تشخيص واختبار النموذج
94	1-3-5	فحص البواقي
94	1-1-3-5	إختبار المتوسط للبواقي
95	2-1-3-5	إختبار العشوائية للبواقي
95	3-1-3-5	إختبار الترابط أو الإستقلال للبواقي
95	4-1-3-5	إختبار طبيعية البواقي
95	2-3-5	بعض المعايير الأخرى لإختيار نموذج مناسب
95	1-2-3-5	إحصائية كيو للجنق وبكس
96	2-2-3-5	معيار الإعلام الذاتي AIC
96	3-3-5	أمثلة وحالات دراسة
142	6-	الفصل السادس: نماذج الإنحدار الذاتي-التكاملي-المتوسط المتحرك الموسمية
143	1-6	دوال الترابط الذاتي والترابط الذاتي الجزئي لبعض النماذج الموسمية
144	1-1-6	لنموذج $SARMA(0,1)(1,1)_{12}$
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
148	دالة الترابط الذاتي الجزئي للنموذج الموسمي التضاعفي	3-6
149	أمثلة على المتسلسلات الزمنية الموسمية	4-6
157	إشتقاق دوال تنبؤ لبعض نماذج المتسلسلات الموسمية التضاعفية	5-6
158	دالة التنبؤ للنموذج SARIMA(0,0,0)(0,1,1) ₁₂	1-5-6
158	دالة التنبؤ للنموذج SARIMA(0,1,1)(0,1,1) ₁₂	2-5-6
159	أمثلة وحالات دراسة للمتسلسلات الزمنية الموسمية	6-6
الجزء العملي:		
7- الفصل السابع: ورقة تدريب عملي على التنبؤ بواسطة نماذج الإنحدار		
188	الذاتي-المتوسط المتحرك	
204	8- الفصل الثامن: مثال تحليل البواقي ومعيير إختيار نموذج مناسب	
212	9- الفصل التاسع: تحليل أو تفكيك المتسلسلة الزمنية إلى مركبات	
225	10- الفصل العاشر: التمهيد والتنبؤ بواسطة المتوسط المتحرك	
242	1-10 الوسيط الجاري	
245	11- الفصل الحادي عشر: التمهيد والتنبؤ بواسطة التمهيد الأسّي البسيط	
250	12- الفصل الثاني عشر: التمهيد والتنبؤ بواسطة التمهيد الأسّي المزدوج	
250	1-12 طريقة براون	
251	2-12 طريقة هولت	
251	3-12 أمثلة	
13- الفصل الثالث عشر: التمهيد الأسّي الثلاثي والتنبؤ بواسطة طريقة		
257	ونترز للمتسلسلات الموسمية المنجرفة	
258	1-13 النموذج الإضافي	
260	2-13 النموذج التضاعفي	
263	3-13 مثال لبناء نموذج تنبؤ	
270	4-13 مثال آخر لبناء نموذج تنبؤ	
278	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 اقفال 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 امكن ذلك.

الشكل التالي لمتسلسلة زمنية مشاهدة وهي عبارة عن عدد المسافرين جوا من احد المطارات



الخطوات المتخذة لبناء نموذج تنبؤ:

إن إيجاد نموذج مناسب لتطبيق على 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 إختيار 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 أو 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 لاحقاً.

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 بإعتمادة على انه النموذج النهائي ويستخدم لتوليد تنبؤات للقيم المستقبلية وإلا نعود للخطوة الأولى لتعيين نموذج جديد.

4- توليد التنبؤات Forecast Generation:

يستخدم النموذج النهائي لتوليد تنبؤات عن القيم المستقبلية ومن ثم حساب أخطاء التنبؤ Forecast Errors كلما استجدت قيم جديدة مشاهدة من المتسلسلة الزمنية ومراقبة هذه الأخطاء في ما يسمى بمخططات المراقبة Control Charts والتي توضع للقبول بنسبة خطأ معين إذا تجاوزت 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 إستخدامها بالشكل المناسب.

تعريف ومبادئ أولية:

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

تعريف 2:

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

والتاريخ مهم جدا في عملية النمذجة

تعريف 3 :

القيمة z_n تسمى الحاضر أو الآن

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 دفعة واحدة بعد تقدير النموذج.

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

أخطاء التنبؤ تعطى بالعلاقة

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

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

الآن سوف نعرف متسلسلة زمنية مهمة جدا 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 (واحيانا نفترض انها متتابعة من المتغيرات العشوائية التي تكون مستقلة ولها توزيعات متطابقة **(Independent, Identically Distributed (IID)**) بمتوسط صفري وتباين ثابت σ^2 أي:

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

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

مثال 1:

متسلسلة المشى العشوائى Random Walk :

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

$$Z_1 = a_1$$

$$Z_2 = a_1 + a_2$$

$\vdots$

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

أو

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

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

هي موقع ماشي 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 التباين 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 علي انه الفترة الزمنية التي تفصل بين Z_t وبين Z_{t-k} أو Z_{t+k} فإن

دالة التباين 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 نشق الآن دالة الترابط الذاتي لعملية الضجة البيضاء


دالة التغيرات 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) Partial Autocorrelation Function

وتعطي مقدار الترابط بين Z_t و Z_{t-k} بعد إزالت تأثير الترابط الناتج من المتغيرات $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$ الواقعة بينهما ويرمز لها عند التخلف k بالرمز ϕ_{kk} وأحد طرق حسابها تقوم علي 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 $E(Z_{t-1}a_t) = 0$ (بشكل عام $E(Z_{t-k}a_t) = 0, k = 1, 2, \dots$ كما سنبين لاحقا)

وبالقسمة علي γ_0 نجد

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

تعريف 11:

بشكل عام تعرف دالة الترابط الذاتي الجزئي كالتالي:

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

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 نشق 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:



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. لإختبار عدم الترابط بين قيم مشاهدة لمتغير عشوائي تستخدم دالة الترابط الذاتي لذلك.

تعريف 12 :

دالة الترابط الذاتي للعينة Sample Autocorrelation Function SACF لمسلسلة زمنية مشاهدة $z_1, z_2, \dots, z_{n-1}, z_n$ ويرمز لها بالرمز r_k , $k = 0, 1, 2, \dots$ 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 مُقدّر Estimator لدالة الترابط الذاتي أي $\hat{\rho}_k = r_k$, $k = 0, 1, 2, \dots$ وبما انها مُقدّر فهي إذا تتغير عشوائيا من عينة لآخرى ولهذا فإن لها الخواص العينية التالية:

1- إذا كانت $\rho_k = 0$, $k > q$ فإن

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

وفي الحالة الخاصة عندما $\rho_k = 0$, $k > 0$ فإن $V(r_k) \cong \frac{1}{n}$

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

$$H_0 : \rho_k = 0$$

$$H_1 : \rho_k \neq 0$$

وذلك باستخدام الإحصاءة:

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

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

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

4- تُقدَّر التباينات لدالة الترابط الذاتي للعينة كالتالي:

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

تعريف 13:

دالة الترابط الذاتي الجزئي للعينة **Sample Partial Autocorrelation Function**

SPACF لمسلسلة زمنية مشاهدة $z_1, z_2, \dots, z_{n-1}, z_n$ ويرمز لها بالرمز

r_{kk} , $k = 0, 1, 2, \dots$ تعطى بالعلاقة:

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

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 مقدر Estimator لدالة الترابط الذاتي الجزئي للعينة أي

$$\hat{\phi}_{kk} = r_{kk}, \quad k = 0, 1, 2, \dots$$

لها الخواص العينية التالية:

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

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

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

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

وذلك باستخدام الإحصائية:

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

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

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

4- تُقدّر التباينات لدالة الترابط الذاتي للعينة كالتالي:

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

مثال 4:

البيانات التالية تمثل الطلب علي منتج معين يوميا:

158 222 248 216 226 239 206 178 169

أحسب الترابط الذاتي والترابط الذاتي الجزئي للعينة وارسمهما:

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

ثانيا: نحسب الترابط الذاتي من العلاقة

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

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

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

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

$$r_8 = 0.230, r_7 = 0.104, r_6 = -0.242, r_5 = -0.387, r_4 = -0.183 \text{ وهكذا}$$

ثالثا: نحسب التباينات من

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

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

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

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

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

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

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

$$\begin{aligned} r_{22} &= \frac{r_2 - \sum_{j=1}^1 r_{1,j} r_{2-j}}{1 - \sum_{j=1}^1 r_{1,j} r_j} = \frac{r_2 - r_{11} r_1}{1 - r_{11} r_1} = \frac{(-0.212) - (0.265)(0.265)}{1 - (0.265)(0.265)} = \frac{-0.282225}{0.929775} \\ &= -0.30354 \end{aligned}$$

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

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


$$\begin{aligned}
r_{33} &= \frac{r_3 - \sum_{j=1}^2 r_{2,j} r_{3-j}}{1 - \sum_{j=1}^{k-1} r_{2,j} r_j} = \frac{r_3 - (r_{21} r_2 + r_{22} r_1)}{1 - (r_{21} r_1 + r_{22} r_2)} \\
&= \frac{(-0.076) - ((0.345)(-0.212) + (-0.303)(0.265))}{1 - ((0.345)(0.265) + (-0.303)(-0.212))} \\
&= 0.092
\end{aligned}$$

وهكذا نحسب باقي الترابطات الجزئية للعينة

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

$$1/9 = 0.1111 \text{ ولها جميعا التباينات تساوي تقريبا}$$

خامسا: رسم دوال الترابط الذاتي والترابط الذاتي الجزئي للعينة



الفصل الثاني

نماذج الإنحدار الذاتي المتوسط المتحرك Autoregressive-Moving Average

Models وإستخداماتها في التنبؤ:

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

تعريف 14:

نموذج الإنحدار الذاتي_المتوسط المتحرك من الدرجة (p, q) ويرمز له $ARMA(p, q)$

لمتسلسلة زمنية مشاهدة $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ 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 $a_t \sim WN(0, \sigma^2)$ متسلسلة ضجة بيضاء و $-\infty < \delta < \infty$ معلم ثابت يمثل المستوي

و $\phi_1, \phi_2, \dots, \phi_p$ هي معالم الإنحدار 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:

$$1 - Bz_t = z_{t-1}$$

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

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

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

تعريف 15 ب:

1- عامل الإزاحة الأمامي **Forewardshift 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 الي نموذج الإنحدار الذاتي_المتوسط المتحرك من الدرجة (p, q) ونكتبه علي الشكل:

$$\begin{aligned} z_t - \phi_1 z_{t-1} - \phi_2 z_{t-2} - \dots - \phi_p z_{t-p} &= \delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \\ z_t - \phi_1 B z_t - \phi_2 B^2 z_t - \dots - \phi_p B^p z_t &= \delta + a_t - \theta_1 B a_t - \theta_2 B^2 a_t - \dots - \theta_q B^q a_t \\ (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) z_t &= \delta + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \end{aligned}$$

أو

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

حيث $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ هو عامل الإنحدار الذاتي Autoregressive

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

Moving Average Operator

أمثلة:

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

علي 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 علي 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 علي 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 علي 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 (1و1) $ARMA(1,1)$ ونكتبه علي

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 علي احد هذه النماذج من عينة مشاهدة وذلك لتعيين او تحديد نموذج مناسب يصف المشاهدات.

أولاً: نموذج المتوسط الثابت ARMA(0,0):

ويكتب علي 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 نشق الخواص الإحصائية لهذا النموذج وذلك بإيجاد التوقع (المتوسط) ودالتي الترابط الذاتي والترابط الذاتي الجزئي كالتالي:

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

$$a_t \sim WN(0, \sigma^2) \text{ لأن}$$

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

$$z_t - \mu = a_t$$

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

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

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

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

ونحل هذه العلاقة تكرارياً:

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

لإيجاد الطرف الأيمن نضرب طرفي $z_t - \mu = a_t$ 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

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

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

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 علي شكل دالي:

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

وبالقسمة علي $\gamma_0 = \sigma^2$ نجد

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

ولها الشكل التالي:



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 علي 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 لايفترق عن نموذج الضجة البيضاء الا في ان له متوسط غير

صفر

ثانياً: نموذج الإنحدار الذاتي من الدرجة الاولى AR(1) = ARMA(1,0)

وهو علي 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 نوجد 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 علي المجموع اللانهائي يجب ان تكون المتسلسلة اللانهائية $\sum_{j=0}^{\infty} \phi_1^j B^j < \infty$

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

مركب Complex Variable له الشكل $B = a + ib$ وله القياس $|B| = 1$ في الحقيقة لابد ان

نتطلب ان تكون جزور او اصفار $(1 - \phi_1 B) = 0$ خارج دائرة الوحدة أي $|B| > 1$ أي

$$1 - \phi_1 B = 0$$

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

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

وهذا هو شرط الإستقرار. نعود الي العلاقة

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

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 $z_{t-k} - \mu$ 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 و تحل 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:

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

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

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

إذا

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

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

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 أن $\rho_0 = 1$ 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 $\rho_{-k} = \rho_k, \quad \forall k$ سوف ننظر من الآن وصاعداً للشق الموجب من ρ_k أي

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

هذه الدالة لها الشكل التالي:


1- عندما تكون $\phi_1 > 0$

Autocorrelation function of AR(1) Model



2- عندما تكون $\phi_1 < 0$

Autocorrelation function of AR(1) Model



نشتق الآن دالة الترابط الذاتي الجزئي

من تعريف 11 نجد

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

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

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

$\vdots$


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

محددة البسط تساوي صفرا لأن العاود الأخير يساوي العاود الأول مضروبا في ϕ_1 ونكتب دالة الترابط الذاتي الجزئي علي 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 $\phi_1 > 0$



2- عندما تكون $\phi_1 < 0$



ملاحظة: دائما لا ترسم أي من $\rho_0 = 1$ أو $\phi_{00} = 1$ في الأشكال البيانية.

مناقشة النموذج:

- 1- عندما تكون $|\phi_1| < 1$ (شرط الإستقرار) فإن $E(z_t) = \delta / (1 - \phi_1)$ وهوثابت لجميع قيم t
- 2- دالة الترابط الذاتي دالة للتخلف k فقط ولا تعتمد علي الزمن t
- 3- دالة الترابط الذاتي تتخامد اسيا في إتجاه واحد ابتداء من ρ_1 عندما تكون $\phi_1 > 0$ وتتخامد اسيا مترددة بين القيم الموجبة والسالبة عندما تكون $\phi_1 < 0$
- 4- دالة الترابط الذاتي الجزئي لها قيمة واحدة غير صفرية (مع عدم النظر الي ϕ_{00}) ويكون إتجاهها حسب إشارة ϕ_1 ومقدارها يساوي $|\phi_1|$

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

ويكتب علي الشكل:

$$\begin{aligned} \phi_2(B)z_t &= \delta + \theta_0(B)a_t \\ (1 - \phi_1 B + \phi_2 B^2)z_t &= \delta + a_t \\ z_t &= \delta + \phi_1 z_{t-1} + \phi_2 z_{t-2} + a_t, \quad a_t \sim WN(0, \sigma^2) \end{aligned}$$

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 لانهاضي 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

وفقط 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 بشروط الاستقرار (هذه الشروط تنتج ايضا من كون جزور او أصفار

$$(1 - \phi_1 B - \phi_2 B^2) = 0 \text{ خارج دائرة الوحدة }). \text{ إذا تحققت شروط الاستقرار فإن}$$

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

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

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

$$= \mu + \phi_1 (z_{t-1} - \mu) + \phi_2 (z_{t-2} - \mu) + a_t$$

$$(z_t - \mu) - \phi_1 (z_{t-1} - \mu) - \phi_2 (z_{t-2} - \mu) = a_t$$

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 علي γ_0 نجد

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

$$\rho_k - \phi_1 \rho_{k-1} - \phi_2 \rho_{k-2} = 0, \quad k = 1, 2, \dots$$

(ملاحظة: بوضع المعادلة السابقة علي الشكل (ملاحظة: بوضع المعادلة السابقة علي الشكل

نجد انها معادلة فروقية من الدرجة الثانية والتي يمكن حلها بشكل مغلق باستخدام طرق حل

المعادلات الفروقية ولكن هذا خارج نطاق المقرر الحالي)

سوف نحل العلاقة السابقة بالطريقة التكرارية والتي تحتاج الي قيمتين اوليتين:

$$1 - \rho_0 = 1$$

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

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 $AR(2)$

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


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

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


شكل (1)



شكل (2)



شكل (3)



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

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

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

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

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

$|| > 0$

وذلك لأن العمود الأخير في محددة البسط هو تركيب خطي من العمودين الأول والثاني، كذلك

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

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 $ARMA(0,1) = MA(1)$:

وتكتب علي الشكل:

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

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

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

الآن نوجد المتوسط ودالتي الترابط الذاتي والترابط الذاتي الجزئي:

$$E(z_t) = E(\delta + a_t - \theta_1 a_{t-1}) = \delta$$

$$\therefore \mu = \delta$$

ونكتب النموذج

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

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

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

أو

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

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 $E[(z_t - \mu)a_t]$ و $E[(z_t - \mu)a_{t-1}]$ كالآتي:

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

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

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

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

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

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 علي

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

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

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

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


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

وبشكل عام


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

ولها الشكل التالي:

$$\theta_1 = -0.8 \text{ عندما عندما } -1$$



2- عندما $\theta_1 = 0.8$



خامسا: نموذج المتوسط المتحرك من الدرجة الثانية $\text{ARMA}(0,2) = \text{MA}(2)$

وتكتب علي الشكل:

$$\phi_0(B)z_t = \delta + \theta_2(B)a_t$$

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

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

الآن نوجد المتوسط ودالتي الترابط الذاتي والترابط الذاتي الجزئي:

$$E(z_t) = E(\delta + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}) = \delta$$

$$\therefore \mu = \delta$$

ونكتب النموذج

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

بضرب هذه المعادلة في $z_{t-k} - \mu$ 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 علي 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 علي 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 $MA(2)$

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


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

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


شکل (7)



شکل (8)



شکل (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:

-10 الشكل (10) $\theta_1 = 0.4, \theta_2 = 0.4$


-11 الشكل (11) $\theta_1 = 1.5, \theta_2 = -0.8$

-12 الشكل (12) $\theta_1 = 0.5, \theta_2 = -0.6$


شكل (10)



شكل (11)



شكل (12)



سادسا: نموذج المتوسط المتحرك-الإنحدار الذاتي من الدرجة (1,1) ARMA(1,1):

ويكتب على الشكل:

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

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

$$z_t - \phi_1 z_{t-1} = \delta + a_t - \theta_1 a_{t-1}$$

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

شرط الإستقرار $|\phi_1| < 1$ وشرط الإنقلاب $|\theta_1| < 1$ وهناك شرط آخر يسمى شرط الإمتساخ

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

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

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

نوجد المتوسط كالتالي:

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

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

$$E(z_t) = \frac{\delta}{1 - \phi_1} + \frac{(1 - \theta_1 B)}{(1 - \phi_1 B)}E(a_t)$$

وذلك لأن $|\phi_1| < 1$ وهكذا

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

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

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

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

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 $E[(z_t - \mu)a_t]$ و $E[(z_t - \mu)a_{t-1}]$ 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 العلاقتين السابقتين نجد

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

ومن العلاقة

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

وبالقسمة على γ_0 نجد

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

ويمكن 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 متردد بين القيم الموجبة والسالبة وهي في هذا تشبه تماما دالة الترابط الذاتي لنموذج $AR(1)$ ماعدى ان

التخامد يبدأ من ρ_1 (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

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

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

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

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


وهكذا تحسب بقية القيم تكراريا.

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


$$\begin{array}{lll} \phi_{11} = 0.944186 & \phi_{22} = -0.384471 & \phi_{33} = 0.183710 \\ \phi_{44} = -0.908462 & \phi_{55} = 0.452979 & \phi_{66} = -0.226337 \\ \phi_{77} = 0.113154 & \phi_{88} = -0.565702 & \phi_{99} = 0.282834 \end{array}$$

ونرسم هذه القيم في شكل 15

شكل 15



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



نلاحظ ان دالة الترابط الذاتي الجزئي لنموذج $ARMA(1,1)$ تتخامد اسيا في إتجاه واحد أو متردد بين القيم الموجبة والسالبة وهي في هذا تشبه تماما دالة الترابط الذاتي الجزئي لنموذج $MA(1)$ ماعدى ان التخامد يبدأ بعد القيمة الأولية $\phi_{11} = \rho_1$.

ملخص خواص نماذج $ARMA(p,q)$:

أولاً: نموذج $AR(p)$

ويتميز بالتالي:

1- دالة ترابط ذاتي تمتد لانهايا وتتكون من خليط من التخامدات الاسية والتخامدات الجيبية.

2- دالة ترابط ذاتي جزئي تتكون من أصفار لقيم التخلفات $k > p$ 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 قطعاً في دالة الترابط الذاتي الجزئي بعد التخلف $k > p$.

ثانياً: نموذج $MA(q)$

ويتميز بالتالي:

1- دالة ترابط ذاتي تتكون من أصفار لقيم التخلفات $k > q$ 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 قطعاً في دالة الترابط الذاتي بعد التخلف $k > q$.

2- دالة ترابط ذاتي جزئي تمتد لانهايا وتتكون من خليط من التخامدات الاسية والتخامدات الجيبية.

لاحظ الإزدواجية Duality بين نموذجي AR و MA.

ثالثا: النموذج المختلط ARMA(p,q):

ويتميز بالتالي:

دوال الترابط الذاتي والترابط الذاتي الجزئي للنموذج المختلط تمتد لانهايا وتتكون 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

اولا: عدم الإستقرار في المتوسط:

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

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

نجد ان المتوسط هو

$$E(z)_t = b_0 + b_1 t$$

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

لنحاول التحويل ∇z_t وذلك بتطبيق عامل التفريق على النموذج نجد

$$w_t = \nabla z_t = z_t - z_{t-1} = b_0 + b_1 t + a_t - b_0 - b_1(t-1) - a_{t-1}$$

$$= b_1 + a_t - a_{t-1} = b_1 + c_t$$

$$\therefore w_t = b_1 + c_t, c_t \sim WN(0, \nu^2)$$

(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 $\nabla = (1-B)$ على المتسلسلة غير المستقرة (أي أخذ التفريق الأول للمتسلسلة) حولها إلى متسلسلة مستقرة.

كمثال آخر نموذج الإنجراف التربيعي

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

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

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

وهكذا

$$\begin{aligned}
w_t &= \nabla^2 z_t = b' + h_t, \quad h_t \sim WN(0, \tau^2) \\
E(w_t) &= b' = \text{constant} \quad \forall t
\end{aligned}$$

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

(تمرين: أوجد العلاقة بين σ^2 و τ^2).

بشكل عام إذا كان النموذج غير المستقر على الشكل

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

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

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

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

ثانياً: عدم الاستقرار في التباين:

من تعريف 6 لإستقرار متسلسلة زمنية، الشرط الثاني

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

يتطلب أن يكون التباين ثابت لجميع قيم t .

فمثلاً لنموذج المشي العشوائي

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

نجد من التعويض المتكرر

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

وبإخذ التوقع والتباين

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

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

ونلاحظ أن التباين يعتمد على الزمن t .

بأخذ التفريق الأول

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

وبإخذ التوقع والتباين

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

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

إذاً التفريق الأول حول المتسلسلة غير المستقرة في التباين إلى متسلسلة مستقرة.

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

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

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

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

$T(\cdot)$ لإستقرار التباين.

التحويل

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


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

القيم الأكثر إستخداما 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 (أ) 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 التفريق الأول $\nabla y_t = y_t - y_{t-1}$



لاحظ كيف أصبحت المتسلسلة مستقرة في كل من المتوسط والتباين.

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

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

يمكن نمذجة المتسلسلة المستقرة $w_t = \nabla^d z_t$ 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-التكاملي-المتوسط المتحرك من الدرجة (p, d, q)

حيث $\delta \in (-\infty, \infty)$ معلم الإنجراف.

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

أولاً: نموذج الإنحدار الذاتي-التكاملي من الدرجة (1,1) أو ARIMA(1,1,0) = ARI(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 التكاملي-المتوسط المتحرك من الدرجة (1,1)

أو ARIMA(0,1,1) = IMA(1,1)

ويكتب على الشكل

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

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

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

أي

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

ثالثا: نموذج المشى العشوائى بإنجراف Random Walk with Trend Model أو

: 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 $\psi(B)$ 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 بالقسمة على عامل الإنحدار الذاتي $\phi_p(B)$ 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 سلسلة متقاربة وذلك لأن جذور $\phi_p(B) = 0$

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

مناقشتنا التالية

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

السلسلة 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 $\psi_0 = 1, \psi_1, \psi_2, \psi_3, \dots$

ملاحظة: النموذج الذي على الشكل $z_t - \mu = \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad a_t \sim WN(0, \sigma^2)$ 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 نوجد 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 أن 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 أن 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) :

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

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

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

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

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

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

$\vdots$

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

أي ان الأوزان لنموذج 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 لنموذج MA(2) :

نموذج 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

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

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 نوجد 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 نوجد

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

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 $\psi(B)$:

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 تتقارب أي $\sum_{j=0}^{\infty} \psi_j^2 < \infty$ فإنه يمكن إثبات النظرية التالية:

نظرية 1:

لنموذج الإنحدار 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 الإنحدار الذاتي من الدرجة AR(1) وجدنا سابقا دالة الأوزان

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

دالة الترابط الذاتي

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

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

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

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 أيضا على نماذج $ARIMA(p,d,q)$ بشكل عام.

لمتسلسلة زمنية مشاهدة $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ التنبؤات $z_n(\ell), \ell \geq 1$ للقيم المستقبلية $z_{n+\ell}, \ell \geq 1$ يمكن ان تكتب على الشكل

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

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

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

متوسط مربع الخطأ يعطى بالعلاقة (أنظر 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 فقط 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

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

نظرية 2:

أخطاء التنبؤ تعطى بالعلاقة:

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

وتباين أخطاء التنبؤ تعطى بالعلاقة:

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

الصيغة $z_n(\ell) = \psi_\ell a_n + \psi_{\ell+1} a_{n-1} + \psi_{\ell+2} a_{n-2} + \dots, \ell \geq 1$ غير عملية لإيجاد التنبؤات للقيم المستقبلية $z_{n+\ell}, \ell \geq 1$ وذلك لأننا نحتاج إلى معرفة القيم $\{a_1, a_2, \dots, a_{n-1}, a_n\}$.

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.

نظرية 3 :

المتنبئ 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 $z_{n+\ell}, \ell \geq 1$ معطى $\{z_1, z_2, \dots, z_{n-1}, z_n\}$.

تستخدم نظرية 2 عمليا لإيجاد قيم التنبؤات بدلا من الصيغة

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

وذلك تبعا للملاحظة السابقة.

قاعدة 2:

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

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

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

تعريف 19:

الدالة $z_n(\ell)$, $\ell \geq 1$ كدالة لزمن التقدم $\ell \geq 1$ عند نقطة الاصل للزمن 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 تتبع

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 $z_{n+1}, z_{n+2}, z_{n+3}, \dots$ أو بشكل عام $z_{n+\ell}$, $\ell \geq 1$.

من نظرية 3 نجد

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

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

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

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

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

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

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:

شروط الإستمرار Continuity Condition يتطلب أنه عندما تكون $\ell = 1$ فإن

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

من نظرية 2 تبين أخطاء التنبؤ تعطي 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 اشتقنا دالة الأوزان لنموذج AR(1) وهي

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

وبالتعويض في صيغة التباين نجد

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

مثال: متسلسلة زمنية مشاهدته وجد انها 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 الملاحظة الأخيرة هي $z_{156} = 0.49$ ، أوجد تنبؤات للقيم المستقبلية $z_{157}, z_{158}, z_{159}$ وأوجد أخطاء التنبؤ لها.

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

$$\begin{aligned} z_{156}(1) &= 0.97 + 0.85(z_{156} - 0.97) \\ &= 0.97 + 0.85(0.49 - 0.97) = 0.56 \\ z_{156}(2) &= 0.97 + 0.85(z_{156}(1) - 0.97) \\ &= 0.97 + 0.85(0.56 - 0.97) = 0.62 \\ z_{156}(3) &= 0.97 + 0.85(z_{156}(2) - 0.97) \\ &= 0.97 + 0.85(0.62 - 0.97) = 0.68 \end{aligned}$$

والتباينات

$$\begin{aligned} V[e_n(\ell)] &= \sigma^2 \frac{1 - \phi_1^{2\ell}}{1 - \phi_1^2}, \ell \geq 1 \\ V[e_{156}(1)] &= 0.024 \\ V[e_{156}(2)] &= 0.024 \frac{1 - (0.85)^4}{1 - (0.85)^2} = 0.041 \\ V[e_{156}(3)] &= 0.024 \frac{1 - (0.85)^6}{1 - (0.85)^2} = 0.054 \end{aligned}$$

ثانياً: دالة التنبؤ لنموذج $AR(2)$:

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

نموذج $AR(2)$ والذي يكتب على الشكل

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

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

من نظرية 3 نجد

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

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

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 $ARIMA(0,1,1)$:

نفترض 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 $z_{n+1}, z_{n+2}, z_{n+3}, \dots$ أو بشكل عام $z_{n+\ell}$, $\ell \geq 1$.
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 MA(1) :

لنفترض اننا شاهدنا المتسلسلة الزمنية $\{z_1, z_2, \dots, z_{n-1}, z_n\}$ حتى الزمن n والتي نعتقد انها تتبع 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 $z_{n+1}, z_{n+2}, z_{n+3}, \dots$ أو بشكل عام $z_{n+\ell}$, $\ell \geq 1$.
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

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

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

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

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

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

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

خامسا : 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 نتنبأ عن القيم المستقبلية $z_{n+1}, z_{n+2}, z_{n+3}, \dots$ أو بشكل عام $z_{n+\ell}$, $\ell \geq 1$.

من نظرية 3 نجد

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

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

نحل هذه العلاقة تكراريا وباستخدام القاعدة 2

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

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

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

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

وهكذا بشكل عام

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

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

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

سادسا : 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

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

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

من نظرية 3 نجد

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

نحل هذه العلاقة تكراريا 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

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

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

تمرين:

أوجد دوال التنبؤ وتباين 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 لا يكفي 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 تأكدنا (أو احتمال) من أن القيمة المستقبلية المراد التنبؤ عنها تساوي القيمة المعطاة من دالة التنبؤ تساوي الصفر أي اننا غير متأكدين إطلاقا وبالتالي لافائدة من التنبؤ. للتغلب على ذلك والإستفادة من التنبؤات نستخدم مايسمى بتنبؤ الفترة Interval Forecast وهي عبارة عن فترة مثل $[a, b]$ على خط الأعداد الحقيقية بحيث يكون

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

وبهذا نستطيع أن نحدد درجة تأكدنا من أن القيمة المستقبلية المراد التنبؤ عنها تقع بين القيم a و b بدرجة تأكد أو احتمال $1 - \alpha$ (أو $100 \times (1 - \alpha) \%$) فمثلا لو كانت $\alpha = 0.05$ فإننا نكون متأكدين وبإحتمال 95% ان 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 $z_{n+\ell}$, $\ell \geq 1$ تعطى بالعلاقة

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

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

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

ملاحظة: في التعريف إفتراضنا أن متسلسلة الضجة البيضاء $a_t \sim N(0, \sigma^2)$ وهذا ممكن
إعتمادا على نظرية نهاية مركزية.

مثال: متسلسلة زمنية مشاهدده وجد انها 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 للقيم المستقبلية $z_{157}, z_{158}, z_{159}$
وأوجد أخطاء التنبؤ لها ومن ثم أوجد فترات تنبؤ 95% للقيم المستقبلية.
الحل: سبق أن حسبنا في مثال سابق التنبؤات و أخطاء التنبؤ كالتالي:
التنبؤات

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

والتباينات

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

فترات تنبؤ 95% للقيم 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 $z_{157} \in (0.256, 0.864)$ بإحتمال 0.95 وكذلك $z_{158} \in (0.223, 1.017)$ وكذلك أيضا
. $z_{159} \in (0.225, 1.135)$

الفصل الخامس

تصميم وبناء نظام تنبؤ إحصائي Designing and Building Statistical

: Forecasting System

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

: Model Identification (Specification) تحديد النموذج

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

: Variance-stabilizing Transformation الخطوة الاولى: تحويل تثبيت التباين

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

: الخطوة الثانية: إختيار 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 دالتي الترابط الذاتي العيني والترابط الذاتي الجزئي العيني SACF و SPACF .
 - 3- إجراء تفريق آخر إذا احتاج الأمر وإعادة الخطوات 1 و 2 السابقتين.
- المخططات الزمنية للمتسلسلات غير المستقرة تبين تغير في المستوى ودالة ترابط ذاتي عيني متخادمة ببطء كما ان دالة الترابط الذاتي الجزئي العيني تعطي قيمة واحدة قريبة من الواحد الصحيح (بغض النظر عن الإشارة) وبقية القيم قريبة جدا من الصفر.
- ملاحظة: درجة التفريق d غالبا 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:

النموذج	ACF	PACF
$AR(1)$ و $(1,d,0)$	تخامد اسي أو اسي متردد	$\phi_{kk} = 0, k > 1$
$AR(2)$ و $(2,d,0)$	تخامد اسي او تخامد جيبي	$\phi_{kk} = 0, k > 2$
$AR(p)$ و $(p,d,0)$	تخامد اسي و / او تخامد جيبي	$\phi_{kk} = 0, k > p$
$MA(1)$ و $(0,d,1)$	$\rho_k = 0, k > 1$	يسيطر عليها تخامد اسي
$MA(2)$ و $(0,d,2)$	$\rho_k = 0, k > 2$	يسيطر عليها تخامد اسي او جيبي
$MA(q)$ و $(0,d,q)$	$\rho_k = 0, k > q$	يسيطر عليها تخامد اسي و / او جيبي
$ARMA(1,1)$ و $(1,d,1)$	تتناقص وتتخامد اسيا	تتناقص ويسيطر عليها تخامد اسي
	من التخلف 1	من التخلف 1
$ARMA(p,q)$ و (p,d,q)	تتناقص بعد التخلف $p - q$ وتتخامد	تتناقص بعد التخلف
	اسيا و / او جيبي بعد التخلف $q - p$	$p - q$ ويسيطر عليها تخامد اسي
		و / او جيبي بعد
		التخلف $p - q$

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

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

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

$$H_0 : \delta = 0$$

$$H_1 : \delta \neq 0$$

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 $\phi_1, \dots, \phi_p$ و $\theta_1, \dots, \theta_q$ و σ^2 وذلك باستخدام البيانات التاريخية المتوفرة لدينا.

لنفترض ان لدينا المتسلسلة الزمنية المشاهدة $z_1, z_2, \dots, z_{n-1}, z_n$ والنموذج المقترح

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

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 $\phi_p(B) = 0$ تقع جميعها خارج دائرة الوحدة (شرط الإستقرار).

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 r_k بالعزوم النظرية مثل المتوسط μ ودالة الترابط الذاتي ρ_k وحل المعادلات الناتجة بالنسبة للمعالم المراد تقديرها.

سوف نستعرض الطريقة للنموذج $AR(p)$ كالتالي:

$$1- \text{يقدر المتوسط } \mu \text{ بالمقدر } \bar{z} \text{ أي } \hat{\mu} = \bar{z} = \sum_{i=1}^n z_i / n$$

$$2- \text{لتقدير } \phi_1, \dots, \phi_p \text{ نستخدم العلاقة:}$$

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

والتي تنتج من ضرب المعادلة المعرفة لنموذج $AR(p)$ بالحد $z_{t-k} - \mu$ وأخذ التوقع. في المعادلة السابقة بوضع $k = 1, 2, \dots, p$ نحصل على نظام المعادلات المسمى معادلات يول و وكر 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 بالمقدر r_k نحصل على مقدرات العزوم للمعالم $\hat{\phi}_1, \dots, \hat{\phi}_p$ كالتالي:

بوضع معادلات يول و ووكر على الشكل المصفوفي:

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

وبحل هذه المعادلة للمعالم

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

تقدر σ^2 كالتالي

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

حيث

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

هو تباين العينة.

تقدير العزوم لبعض النماذج:

1- نموذج AR(1)

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

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

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

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 $|\hat{\theta}_1| < 1$. فمثلا لو كانت $r_1 = -0.4$ فإن

$$(\hat{\theta}_1)_1 = -0.77 \text{ و } (\hat{\theta}_1)_2 = 3.27 \text{ وبالتالي يكون مقدر العزوم للمعلم } \theta_1 \text{ هو } \hat{\theta}_1 = -0.77.$$

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 للمعالم 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

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

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 للمعالم 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 للمعالم 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 $|\theta_2| < 1$, $\theta_2 + \theta_1 < 1$, $\theta_2 - \theta_1 < 1$.

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 للمعالم 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 للمعالم 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 نعوض 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 للمقدر $\hat{\theta}_1$ و نأخذ القيمة التي تحقق $|\hat{\theta}_1| < 1$.

تمارين: أوجد مقدرات العزوم لمعالم النماذج التالية

$$\text{ARIMA}(1,1,1), \quad \text{ARIMA}(2,1,0), \quad \text{ARIMA}(0,1,2), \quad \text{ARIMA}(1,2,0), \\ \text{ARIMA}(0,2,1), \text{ARIMA}(0,2,0).$$

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

ثانيا: طريقة المربعات الدنيا الشرطية Conditional Least Square Method :

لنماذج $\text{ARMA}(p,q)$ 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 الانقلاب). 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 المعالم $\phi = \{\phi_1, \phi_2, \dots, \phi_p\}$ و $\theta = \{\theta_1, \theta_2, \dots, \theta_q\}$ و μ

و يكتب

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

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.

$$\left. \frac{\partial}{\partial \boldsymbol{\varphi}} S_c(\boldsymbol{\varphi}, \boldsymbol{\theta}, \mu) \right|_{\substack{\boldsymbol{\varphi}=\hat{\boldsymbol{\varphi}} \\ \boldsymbol{\theta}=\hat{\boldsymbol{\theta}} \\ \mu=\hat{\mu}}} = \frac{\partial}{\partial \boldsymbol{\varphi}} \sum_{t=p+1}^n a_t^2(\boldsymbol{\varphi}, \boldsymbol{\theta}, \mu | \mathbf{z}) \Big|_{\substack{\boldsymbol{\varphi}=\hat{\boldsymbol{\varphi}} \\ \boldsymbol{\theta}=\hat{\boldsymbol{\theta}} \\ \mu=\hat{\mu}}} = 0$$

$$\left. \frac{\partial}{\partial \boldsymbol{\theta}} S_c(\boldsymbol{\varphi}, \boldsymbol{\theta}, \mu) \right|_{\substack{\boldsymbol{\varphi}=\hat{\boldsymbol{\varphi}} \\ \boldsymbol{\theta}=\hat{\boldsymbol{\theta}} \\ \mu=\hat{\mu}}} = \frac{\partial}{\partial \boldsymbol{\theta}} \sum_{t=p+1}^n a_t^2(\boldsymbol{\varphi}, \boldsymbol{\theta}, \mu | \mathbf{z}) \Big|_{\substack{\boldsymbol{\varphi}=\hat{\boldsymbol{\varphi}} \\ \boldsymbol{\theta}=\hat{\boldsymbol{\theta}} \\ \mu=\hat{\mu}}} = 0$$

$$\left. \frac{\partial}{\partial \mu} S_c(\boldsymbol{\varphi}, \boldsymbol{\theta}, \mu) \right|_{\substack{\boldsymbol{\varphi}=\hat{\boldsymbol{\varphi}} \\ \boldsymbol{\theta}=\hat{\boldsymbol{\theta}} \\ \mu=\hat{\mu}}} = \frac{\partial}{\partial \mu} \sum_{t=p+1}^n a_t^2(\boldsymbol{\varphi}, \boldsymbol{\theta}, \mu | \mathbf{z}) \Big|_{\substack{\boldsymbol{\varphi}=\hat{\boldsymbol{\varphi}} \\ \boldsymbol{\theta}=\hat{\boldsymbol{\theta}} \\ \mu=\hat{\mu}}} = 0$$

هذه المقدرات تسمى شرطية لأننا هنا نشترط ان 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

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

تقديرات المربعات الدنيا الشرطية لبعض النماذج:

1- نموذج AR(1)

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

لتبسيط الاشتقاقات سوف نستبدل μ بمقدرها $\bar{z}$

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

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

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

وتربيع 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 ، نشق 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 الاشتقاقات سوف نستبدل μ بمقدرها $\bar{z}$ 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 $a_0 = 0$ شرطيا نكتب الأخطاء

$$a_1 = x_1$$

$$a_2 = x_2 - \theta_1 a_1$$

$$a_3 = x_3 - \theta_1 a_2$$

$$\vdots$$

$$a_n = x_n - \theta_1 a_{n-1}$$

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 جاكبسون-نيوتن والتي تتلخص في تقريب $a_t = a_t(\theta_1)$ بدالة خطية للمعلم θ_1 حول قيمة أولية θ^* مثلا 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 تكراريا وذلك بإشتقاق طرفي المعادلة $a_t = x_t - \theta_1 a_{t-1}$ بالنسبة للمعلم 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 $\frac{da_0(\theta_1)}{d\theta_1} = 0$. 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

$$S_c(\theta_1) = \sum_{t=1}^n a_t^2$$

تحليليا لنحصل علي مقدر جديد وأفضل للمعلم θ_1 ونكرر هذه العملية بإستبدال θ^* بالمقدر الجديد ونستمر حتى يصبح الفرق بين مقدرين تالين صغير جدا أو النقص في مجموع المربعات صغير جدا. ممكن استخدام طريقة العزوم لإيجاد القيمة الأولية θ^* لكي نحصل على تقارب سريع. طبعا الطريقة السابقة لا تتم يدويا بل تحتاج إلى حاسب لذلك.

يلاحظ أن تقدير المعالم للنموذج في حالة نماذج المتوسط المتحرك أو النماذج المختلطة التي تحوي على متوسط متحرك تشكل تعقيدا لأنها تحوي معالم المتوسط المتحرك بشكل غير خطي ولهذا تحتاج إلى طرق عددية لحلها كما شاهدنا في حالة النموذج $MA(1)$ وهو أبسطها جميعا.

سوف نكتفي في مقررنا هذا على الطريقتين 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 واختبار النموذج : Model Checking and Diagnostics

بعد التعرف على نموذج مبدئي وتقدير معالم هذا النموذج نجري بعض التشخيصات على البواقي أو أخطاء التطبيق (انظر تعريف 4) لنرى مدى مطابقة النموذج للمتسلسلة المشاهدة ، ويفترض أن البواقي هي مقدرات لمتسلسلة الضجة البيضاء a_t والتي نفترض انها موزعة طبيعيا بمتوسط صفري وتباين σ^2 . البواقي تعطى بالعلاقة

$$e_t = z_t - \hat{z}_t = \hat{a}_t, \quad t = 1, 2, \dots, n$$

أي ان البواقي هي القيم المشاهدة ناقص القيم المطبقة.
يقوم التشخيص والاختبارات على فحص البواقي والنظر في مدى تحقيقها لفرضيات النموذج والتي هي:

- 1- متوسط صفري
- 2- العشوائية
- 3- عدم الترابط
- 4- موزعة توزيع طبيعي (مستقل ومتطابق بمتوسط صفري وتباين σ^2)
 $(a_t \sim IIDN(0, \sigma^2))$

لهذا فإننا نجري تشخيص وهو مجموعة من الاختبارات علي البواقي لنرى فيما إذا كانت تحقق هذه الشروط وفي هذه الحالة نعتبر النموذج المطبق مقبولا أما إذا فشل احد هذه الاختبارات فيجب علينا إعادة النظر وإقتراح نموذج آخر

أولا: اختبار المتوسط:

$$H_0 : E(a_t) = 0$$

$$H_1 : E(a_t) \neq 0$$

وهو اختبار بذيلين ونستخدم فيه الإحصائية $u = \frac{\bar{e}}{se(\bar{e})}$ والتي لها توزيع طبيعي قياسي فعند

مستوى معنوية $\alpha = 0.05$ نعتبر ان $E(a_t) = 0$ إذا كانت $|u| < 1.96$ (هذا علي إعتبار ان

حجم العينة اكبر من 30 وحدة وهذا دائما متحقق للمتسلسلات الزمنية التي ندرسها)

ثانيا: اختبار العشوائية:

نختبر عشوائية البواقي بواسطة اختبار الجري Runs test حول المتوسط وحول الصفر وهو احد الاختبارات اللامعلمية (يوجد كثير من الاختبارات للعشوائية يدرسها الطالب في المقرر 241 بحث ولكن نكتفي هنا بهذا الاختبار).

ثالثا: اختبار الترابط أو الإستقلال:

يختبر ترابط أو إستقلال البواقي بواسطة اختبار الترابط الذاتي Autocorrelation test وذلك بحساب ورسم الترابطات الذاتية العينية SACF للبواقي ومقارنتها مع دالة الترابط الذاتي لمتسلسلة الضجة البيضاء. الاختبار

$$H_0 : \rho_1 = 0$$

$$H_1 : \rho_1 \neq 0$$

حيث الإحصائية $u = \frac{r_1}{se(r_1)}$ لها توزيع طبيعي قياسي فعند مستوى معنوية $\alpha = 0.05$ نعتبر

ان $\rho_1 = 0$ إذا كانت $|u| < 1.96$.

رابعا: اختبار طبيعية البواقي:

نختبر في ما إذا كانت البواقي موزعة طبيعيا وذلك بعدة طرق مثل:

- 1- اختبار حسن التطابق Goodness of Fit Test ونستخدم الاختبار اللامعلمي كولموجوروف-سميرنوف Kolmogorov-Smirnov Test.
- 2- مخطط الإحتمال الطبيعي Normal Probability Plot.
- 3- مخطط الربيعات-الربيعات Q-Q Plot.

بعض المعايير الاخرى لإختيار نموذج المناسب:

(1) إحصائية كيو لـ لجنق-بوكس Ljung-Box Q statistic وتختصر LBQ وتستخدم لإختبار 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 وتختصر AIC وتعطى بالعلاقة:

$$AIC(m) = n \ln \sigma_a^2 + 2m$$

حيث m عدد المعالم المقدرة في النموذج ونختار النموذج الذي يعطي $\min_m AIC(m)$

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

اولا نرسم المتسلسلة في مخطط زمني Time Plot باستخدام الحزمة الإحصائية MINITAB كالتالي:

```
> plot.ts(z)
> title(main = " An observed time seies")
```



ثانيا نحسب ونرسم الترابط الذاتي العيني باستخدام الأمر


```
> zacf = acf(z)
> zacf = acf(z, plot=F)
> zacf
Autocorrelations of series 'z', by lag
```

0	1	2	3	4	5	6	7	8
9	10	11	12	13	14	15	16	17
18								

```

1.000  0.508  0.201 -0.001 -0.052 -0.084 -0.184 -0.191 -
0.141 -0.144 -0.086 -0.069 -0.076 -0.020  0.031  0.066
0.128  0.171  0.204
      19      20      21      22      23
0.123  0.062 -0.030 -0.151 -0.097
> plot(zacf)

```



ثالثاً نحسب ونرسم الترابط الذاتي الجزئي العيني باستخدام الأمر

```

> zpacf = pacf(z)
> zpacf


```

Partial autocorrelations of series 'z', by lag

```

1      2      3      4      5      6      7      8      9
10     11     12     13     14     15     16     17
18     19     20
0.508 -0.076 -0.097  0.003 -0.052 -0.165 -0.035 -0.008 -
0.115  0.011 -0.043 -0.095  0.028  0.022 -0.016  0.090
0.084  0.061 -0.032  0.036
      21     22     23
-0.068 -0.124  0.124

```



من أنماط الترابط الذاتي و الترابط الذاتي الجزئي العيني نلاحظ ان المتسلسلة تتبع نموذج AR(1) ولهذا نطبق النموذج المقترح علي المشاهدات باستخدام الأمر

```
> z.fit = arima(z, order = c(1,0,0))
> z.fit
```

Call:

```
arima(x = z, order = c(1, 0, 0))
```

Coefficients:

	ar1	intercept
	0.5126	59.7772
s.e.	0.0609	0.2664

```
sigma^2 estimated as 3.406: log likelihood = -406.49,
aic = 818.98
```

```
> predict(z.fit, 20)
```

```
$pred
```

Time Series:

```
Start = 201
```

```
End = 220
```

```
Frequency = 1
```

```

[1] 61.64051 60.73227 60.26673 60.02811 59.90579
59.84310 59.81096 59.79449 59.78604 59.78172 59.77950
59.77836 59.77778 59.77748 59.77732
[16] 59.77725 59.77721 59.77719 59.77717 59.77717

```

\$se

Time Series:

Start = 201

End = 220

Frequency = 1

```

[1] 1.845507 2.073825 2.129756 2.144209 2.147990
2.148983 2.149243 2.149312 2.149330 2.149335 2.149336
2.149336 2.149336 2.149336 2.149336
[16] 2.149336 2.149336 2.149336 2.149336 2.149336

```

ونستنتج التالي:

1- النموذج المقترح هو

$$z_t = 59.7772 + 0.5126(z_{t-1} - 59.7772) + a_t, \quad a_t \sim WN(0, 3.406)$$

2- المعالم المقدرة وإنحرافها المعياري وقيمة t لها هي:

$$\hat{\phi}_1 = 0.5126, \quad s.e.(\hat{\phi}_1) = 0.0609, \quad t = 8.417$$

$$\hat{\mu} = 59.7772, \quad s.e.(\hat{\mu}) = 0.2664$$

$$\hat{\sigma}^2 = 3.406, \quad \text{with } d.f. = 199$$

رابعاً نفحص البواقي:

1- إختبار متوسط البواقي

لانرفض الفرضية الصفرية بأن المتوسط يساوي الصفر

```
> t.test(z.fit$residuals)
```

One Sample t-test

```
data: z.fit$residuals
```

```
t = -0.0102, df = 199, p-value = 0.99
```

```
alternative hypothesis: true mean is not equal to 0
```

95 percent confidence interval:

-0.25931 0.25665

sample estimates:

mean of x

-0.0013303

2- إختبار عشوائية البواقي

```
> library(tseries)
> runs.test(z.fit$residuals)
```


Runs Test

```
data: z.fit$residuals
statistic = -1.42, runs = 91, n1 = 100, n2 = 100, n =
200, p-value = 0.16
alternative hypothesis: nonrandomness
```

لأنرفض الفرضية الصفرية بأن البواقي عشوائية


3- الترابط الذاتي للبواقي

```
> acf(z.fit$residuals)
```



4- الترابط الذاتي الجزئي للبواقي

```
> pacf(z.fit$residuals)
```




نلاحظ ان أنماط الترابط الذاتي والترابط الذاتي الجزئي تتبع أنماط متسلسلة الضجة البيضاء

5- إختبار طبيعية البواقي :

1- نرسم المضلع التكراري للبواقي


```
> hist(z.fit$residuals)
```



نلاحظ أنه متناظر وله شكل التوزيع الطبيعي تقريبا. وهذا لا يكفي بل يجب ان ننظر الى:

ب- رسم الاحتمال الطبيعي Normal Probability Plot

```
> qqnorm(z.fit$residuals, pch=20)
> qqline(z.fit$residuals, col="blue")
```



واضح من الرسم أن البواقي طبيعية وللتأكد نقوم:

ج- بإختبار K-S Test لطبيعية البواقي

```
> ks.test(z.fit$residuals, "pnorm")
```

One-sample Kolmogorov-Smirnov test

```
data: z.fit$residuals
D = 0.135, p-value = 0.0014
alternative hypothesis: two-sided
```

ونلاحظ التالي:

الإختبار هو

H_0 : Residuals is $N(0,3.406)$

H_1 : Residuals is not $N(0,3.406)$

إختبار كولموجوروف-سميرنوف اعطى

$D = 0.06$

الـ P-Value للاختبار هي 0.0014 وهي أقل من $\alpha = 0.05$ أي اننا نرفض الفرضية الصفرية.

توليد تنبؤات:


استخدمنا النموذج للتنبؤ عن 10 قيم مستقبلية

```
> library("forecast")
> z.f = forecast(z , model = z.fit)
> z.f
```

	Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
201		61.641	59.275	64.006	58.023	65.258
202		60.732	58.075	63.390	56.668	64.797
203		60.267	57.537	62.996	56.092	64.441
204		60.028	57.280	62.776	55.826	64.231
205		59.906	57.153	62.659	55.696	64.116
206		59.843	57.089	62.597	55.631	64.055
207		59.811	57.057	62.565	55.599	64.023
208		59.794	57.040	62.549	55.582	64.007
209		59.786	57.032	62.541	55.573	63.999
210		59.782	57.027	62.536	55.569	63.994

ونرسمها بالأمر التالي

```
> plot(z.f)
```



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

```
> z2 = read.csv(file.choose(), header=F)
> head(z2)
[1] 499.148 496.650 511.026 488.539 498.440 507.382
> z2 <- as.ts(z2)
> plot.ts(z2)
```

اولا : سوف نرسم المتسلسلة




ثانيا: نحسب ونرسم الترابط الذاتي العيني:

```
> z2acf = acf(z2, main = "SACF of z2")
> z2acf = acf(z2, plot=F)
> z2acf
```

Autocorrelations of series 'z2', by lag

0	1	2	3	4	5	6	7	8
9	10	11	12	13	14			
1.000	-0.530	-0.050	0.121	0.041	-0.129	0.112	-0.092	
0.097	-0.108	0.146	-0.181	0.107	0.048	-0.117		
15	16	17	18	19	20	21	22	
23								
0.052	-0.023	0.072	-0.101	0.065	-0.064	0.094	-0.058	
0.018								

SACF of z2




ثالثاً: نحسب ونرسم الترابط الذاتي الجزئي العيني:

```
> z2pacf = pacf(z2, main = "SPACF of z2")
> z2pacf = pacf(z2, plot=F)
> z2pacf
```

Partial autocorrelations of series 'z2', by lag

1	2	3	4	5	6	7	8	9
10	11	12	13	14	15			
-0.530	-0.460	-0.286	-0.068	-0.108	0.019	-0.086	0.041	-
0.069	0.123	-0.073	-0.045	0.075	-0.038	0.031		
16	17	18	19	20	21	22	23	
-0.132	0.064	-0.084	0.028	-0.131	0.016	0.022	0.016	



من الأنماط المشاهدة نلاحظ ان المتسلسلة قد تتبع نموذج MA(1) وبتطبيق هذا النموذج نجد

```
> z2.fit = arima(z2, order = c(0,0,1))
> z2.fit
```

Call:

```
arima(x = z2, order = c(0, 0, 1))
```

Coefficients:

	ma1	intercept
	-0.7880	499.9614
s.e.	0.0344	0.0523

```
sigma^2 estimated as 14.75: log likelihood = -691.61,
aic = 1389.23
```

```
> Box.test(z2.fit$residuals, lag=20, type="Ljung-Box")
```

Box-Ljung test

```
data: z2.fit$residuals
```

```
X-squared = 34.349, df = 20, p-value = 0.02386
```

ونستنتج التالي:

1- النموذج المقترح هو

$$z_t = 499.9614 + a_t - 0.788a_{t-1}, \quad a_t \sim WN(0, 14.75)$$

2- المعالم المقدرة وإنحرافها المعياري و قيمة t لها هي:

$$\hat{\theta}_1 = -0.788, \quad s.e.(\hat{\theta}_1) = 0.0344, \quad t = 22.91$$
$$\hat{\mu} = \hat{\delta} = 499.9614, \quad s.e.(\hat{\delta}) = 0.0523, \quad t = 9559.49$$
$$\hat{\sigma}^2 = 14.75, \quad \text{with } d.f. = 248$$

رابعاً نفحص البواقي:

1- إختبار متوسط البواقي

```
> t.test(z2.fit$residuals)

One Sample t-test

data:  z2.fit$residuals
t = -0.085807, df = 249, p-value = 0.9317
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 -0.5002108  0.4584451
sample estimates:
 mean of x
-0.02088285
```

لأنرفض الفرضية الصفرية بأن المتوسط يساوي الصفر

2- إختبار عشوائية البواقي

```
> library(tseries)
> library(randtests)
> runs.test(z2.fit$residuals)
```


Runs Test

```
data:  z2.fit$residuals
statistic = 0.88722, runs = 133, n1 = 125, n2 = 125, n =
250, p-value = 0.375
alternative hypothesis: nonrandomness
```

لأنرفض الفرضية الصفرية بأن البواقي عشوائية


3- الترابط الذاتي للبواقي

```
> acf(z2.fit$residuals, lag.max=20, main="ACF of
Residuals")
```



4- الترابط الذاتي الجزئي للبواقي

```
> pacf(z2.fit$residuals, lag.max=20, main="PACF of Residuals")
```



```
> Box.test(z2.fit$residuals, lag=20, type="Ljung-Box")
```

Box-Ljung test


```
data: z2.fit$residuals
X-squared = 34.349, df = 20, p-value = 0.02386
```

نلاحظ ان أنماط الترابط الذاتي والترابط الذاتي الجزئي تتبع أنماط متسلسلة الضجة البيضاء

5- إختبار طبيعية البواقي :

ا- نرسم المضلع التكراري للبواقي


```
> hist(z2.fit$residuals)
```



نلاحظ أنه متناظر وله شكل التوزيع الطبيعي تقريبا. وهذا لا يكفي بل يجب ان ننظر الى:

ب- رسم الاحتمال الطبيعي Normal Probability Plot

```
> qqnorm(z2.fit$residuals, pch=20)
> qqline(z2.fit$residuals, col="blue")
```



واضح من الرسم أن البواقي طبيعية وللتأكد نقوم:

ج- بإختبار K-S Test لطبيعية البواقي

```
> ks.test(z2.fit$residuals, "pnorm")
```

One-sample Kolmogorov-Smirnov test

```
data: z2.fit$residuals
D = 0.27256, p-value < 2.2e-16
alternative hypothesis: two-sided
```

إختبار كولموجوروف-سميرنوف اعطى


$D = 0.27256$

الـ P-Value للإختبار هي أقل من $2.2e-16$ وهي أقل من $\alpha = 0.05$ أي أننا نرفض الفرضية

أن البواقي موزعة طبيعياً.

أمر التالي يقوم بإعطاء إختصار رسمي (مخطط) لتشخيص النموذج

```
> tsdiag(z2.fit)
```

توليد تنبؤات:


استخدمنا النموذج للتنبؤ عن 20 قيمة مستقبلية

```
> library("forecast")
> z2.f = forecast(z2 , model = z2.fit, h=20)
> z2.f
```

Point	Forecast	Lo 80	Hi 80	Lo 95	Hi 95
251	502.2491	497.3275	507.1708	494.7221	509.7762
252	499.9614	493.6954	506.2274	490.3784	509.5444
253	499.9614	493.6954	506.2274	490.3784	509.5444
254	499.9614	493.6954	506.2274	490.3784	509.5444
255	499.9614	493.6954	506.2274	490.3784	509.5444
256	499.9614	493.6954	506.2274	490.3784	509.5444
257	499.9614	493.6954	506.2274	490.3784	509.5444
258	499.9614	493.6954	506.2274	490.3784	509.5444
259	499.9614	493.6954	506.2274	490.3784	509.5444
260	499.9614	493.6954	506.2274	490.3784	509.5444
261	499.9614	493.6954	506.2274	490.3784	509.5444
262	499.9614	493.6954	506.2274	490.3784	509.5444
263	499.9614	493.6954	506.2274	490.3784	509.5444
264	499.9614	493.6954	506.2274	490.3784	509.5444
265	499.9614	493.6954	506.2274	490.3784	509.5444
266	499.9614	493.6954	506.2274	490.3784	509.5444
267	499.9614	493.6954	506.2274	490.3784	509.5444
268	499.9614	493.6954	506.2274	490.3784	509.5444
269	499.9614	493.6954	506.2274	490.3784	509.5444
270	499.9614	493.6954	506.2274	490.3784	509.5444

والرسم التالي يعطي التنبؤات مع فترات 95% تنبؤ

```
> plot(z2.f)
```



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

اولا نرسم المتسلسلة في مخطط زمني Time Plot

```

z3 = read.csv(file.choose(), header=F)
z3 <- ts(z3)
plot.ts(z3)

```




ثانيا نحسب ونرسم الترابط الذاتي العيني

```
> z3acf = acf( z3, plot=F)
> z3acf = acf(z3, main = "SACF of z3")
> z3acf
```

Autocorrelations of series 'z3', by lag

	0	1	2	3	4	5	6	7
8	9	10	11	12	13	14	15	16
17	18							
	1.000	0.839	0.510	0.146	-0.159	-0.327	-0.326	-0.203
	0.020	0.141	0.233	0.228	0.151	0.018	-0.119	-0.205
	0.225	-0.181	-0.097					
	19	20	21	22	23			
	0.003	0.078	0.108	0.083	0.029			




ثالثا نحسب ونرسم الترابط الذاتي الجزئي العيني

```
> z3pacf = pacf( z3, plot=F)
> z3pacf = pacf( z3, main = "SPACF of z3")
> z3pacf
```

Partial autocorrelations of series 'z3', by lag

8	7	6	5	4	3	2	1
16	15	14	13	12	11	10	9
19	18	17					
- 0.067	0.014	- 0.138	0.113	0.063	- 0.072	- 0.657	- 0.839
0.059	- 0.042	0.011	0.153	- 0.057	0.075	- 0.046	0.071
0.091	0.072	- 0.038					
23	22	21	20				
0.083	0.081	- 0.034	0.088	-			



من أنماط الترابط الذاتي و الترابط الذاتي الجزئي العيني نلاحظ ان المتسلسلة تتبع نموذج AR(2) ولهذا نطبق النموذج المقترح علي المشاهدات

```
> z3.fit = arima( z3, order = c(2,0,0))
> z3.fit
```

Call:

```
arima(x = z3, order = c(2, 0, 0))
```

Coefficients:

	ar1	ar2	intercept
	1.4023	-0.6667	229.6376
s.e.	0.0468	0.0468	0.4521

```
sigma^2 estimated as 3.577: log likelihood = -515.27,
```

```
aic = 1038.54
```

```
>
```

ونستنتج التالي:

1- النموذج المقترح هو

$$z_t = 229.6376 + 1.4023z_{t-1} - 0.6667z_{t-2} + a_t, \quad a_t \sim WN(0, 3.577)$$

2- المعالم المقدرة وإنحرافها المعياري وقيمة t لها هي:

$$\hat{\phi}_1 = 1.4023, \quad s.e.(\hat{\phi}_1) = 0.0468, \quad t = 29.96$$

$$\hat{\phi}_2 = -0.667, \quad s.e.(\hat{\phi}_2) = 0.0468, \quad t = -14.25$$


$$\hat{\mu} = 229.638, \quad s.e.(\hat{\mu}) = 0.456$$

$$\hat{\sigma}^2 = 3.577, \quad \text{with } d.f. = 247$$

رابعاً نفحص البواقي:

رسم البواقي

```
> plot.ts( z3.fit$residuals)
```



1- إختبار متوسط البواقي

```
> t.test( z3.fit$residuals)
```

One Sample t-test

```
data: z3.fit$residuals
```

```
t = -0.030259, df = 249, p-value = 0.9759
```

```
alternative hypothesis: true mean is not equal to 0
```

```
95 percent confidence interval:
```

```
-0.2397015  0.2324477
```

```
sample estimates:
```

```
mean of x  
-0.003626923
```

لأنرفض الفرضية الصفرية بأن المتوسط يساوي الصفر

2- إختبار عشوائية البواقي

لأنرفض الفرضية الصفرية بأن البواقي عشوائية

```
> library(randtests)
```

```
Attaching package: 'randtests'
```

```
The following object is masked from 'package:tseries':
```

```
runs.test
```


```
> runs.test(z3.fit$residuals)
```

```
Runs Test
```

```
data: z3.fit$residuals  
statistic = 0.12675, runs = 127, n1 = 125, n2 = 125, n =  
250, p-value = 0.8991  
alternative hypothesis: nonrandomness
```


3- الترابط الذاتي للبواقي

```
> acf( z3.fit$residuals, lag.max=20, main="ACF of  
Residuals")
```

4- الترابط الذاتي الجزئي للبواقي

```
> pacf( z3.fit$residuals, lag.max=20, main="PACF of Residuals")
```




نلاحظ ان أنماط الترابط الذاتي والترابط الذاتي الجزئي تتبع أنماط متسلسلة الضجة البيضاء

5- إختبار طبيعية البواقي :

1- نرسم المضلع التكراري للبواقي


```
> hist( z3.fit$residuals)
```



نلاحظ أنه متناظر وله شكل التوزيع الطبيعي تقريبا. وهذا لا يكفي بل يجب ان ننظر الى:

ب- رسم الاحتمال الطبيعي Normal Probability Plot

```
> qqnorm( z3.fit$residuals, pch=20)
> qqline( z3.fit$residuals, col="blue")
```



واضح من الرسم أن البواقي طبيعية وللتأكد نقوم:

ج- باختبار K-S Test لطبيعية البواقي

```
> ks.test( z3.fit$residuals, "pnorm")
```

One-sample Kolmogorov-Smirnov test

```
data: z3.fit$residuals
D = 0.15626, p-value = 9.972e-06
alternative hypothesis: two-sided
```

إختبار كولموجوروف-سميرنوف اعطى الـ P-Value للإختبار هي 9.97×10^{-6} وهي أقل من $\alpha = 0.05$ أي اننا لانرفض فرضية طبيعية البواقي.

إختبار بوكس ليونج


```
> Box.test( z3.fit$residuals, lag=20, type="Ljung-Box")
```

Box-Ljung test

```
data: z3.fit$residuals
X-squared = 24.325, df = 20, p-value = 0.2285
```

الإختبار التشخيصي للتطبيق

```
> tsdiag( z3.fit)
```



توليد تنبؤات:

```
> library(tseries)
```

استخدمنا النموذج للتنبؤ عن 20 قيم مستقبلية


```
> z3.f = forecast( z3 , model = z3.fit, h=20)
```

```
> z3.f
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
251	224.9449	222.5210	227.3689	221.2378	228.6520
252	226.7514	222.5766	230.9263	220.3665	233.1363
253	228.7187	223.4884	233.9490	220.7196	236.7178
254	230.2731	224.6173	235.9289	221.6233	238.9229
255	231.1414	225.4117	236.8712	222.3785	239.9043
256	231.3228	225.5911	237.0544	222.5569	240.0886
257	230.9982	225.2083	236.7881	222.1433	239.8531
258	230.4221	224.5377	236.3065	221.4227	239.4216
259	229.8307	223.8738	235.7876	220.7205	238.9410
260	229.3854	223.3985	235.3724	220.2292	238.5417
261	229.1552	223.1641	235.1463	219.9927	238.3178
262	229.1293	223.1376	235.1210	219.9657	238.2928
263	229.2464	223.2485	235.2442	220.0735	238.4193
264	229.4279	223.4214	235.4343	220.2418	238.6140
265	229.6043	223.5918	235.6169	220.4089	238.7997
266	229.7308	223.7160	235.7456	220.5319	238.9296
267	229.7904	223.7754	235.8055	220.5913	238.9896
268	229.7898	223.7747	235.8050	220.5905	238.9892
269	229.7492	223.7334	235.7650	220.5488	238.9495
270	229.6926	223.6760	235.7092	220.4911	238.8942

والرسم التالي يعطي التنبؤات و 95% فترات تنبؤ

```
> plot( z3.f)
```



الشكل يبين المتسلسلة الزمنية بكاملها مع التنبؤات.

حالة دراسة:

المتسلسلة التالية المتوسط اليومي لعدد التلفزيونات المعيبة في خط إنتاج مصنع ما (اقرأ سطرا بسطر)

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					


ندخل البيانات

```
> Defects <- c(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)
```

نحولها لمتسلسلة زمنية ونرسمها

```
> dd <- ts(Defects)
> plot.ts(dd)
```

المخطط الزمني للمتسلسلة




الترابط الذاتي والذاتي الجزئي

```
> ddacf = acf( dd, plot=F)
> ddacf = acf(dd, main = "SACF of Defects")
> ddacf
```

Autocorrelations of series 'dd', by lag


	0	1	2	3	4	5	6	7
8	9	10	11	12	13	14	15	16
1.000	0.429	0.261	0.141	0.079	-0.085	-0.073	-0.207	-
0.110	-0.052	-0.007	-0.037	0.038	0.045	-0.003	-0.125	-
0.103								



```
> ddpacf = pacf( dd, plot=F)
> ddpacf = pacf(dd, main = "SPACF of Defects")
> ddpacf
```

Partial autocorrelations of series 'dd', by lag

	1	2	3	4	5	6	7	8
9	10	11	12	13	14	15	16	
	0.429	0.094	-0.001	0.000	-0.160	0.003	-0.177	0.066
	0.052	0.013	-0.034	0.021	0.022	-0.086	-0.145	-0.008



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 $\min_m AIC(m)$

سوف نطبق النماذج علي التوالي:

```
> m1 <- arima(dd, c(1,0,0))
> m1
```

Call:

```
arima(x = dd, order = c(1,0,0))
```

Coefficients:

	ar1	intercept
	0.4322	1.7799
s.e.	0.1340	0.1189

```
sigma^2 estimated as 0.2118: log likelihood = -29.04,
aic = 64.07
```



```
> m2 <- arima(dd, c(2,0,0))
```

```
> m2
```

```
Call:
```

```
arima(x = dd, order = c(2,0,0))
```

```
Coefficients:
```

	ar1	ar2	intercept
	0.3910	0.0945	1.7768
s.e.	0.1478	0.1473	0.1298

```
sigma^2 estimated as 0.2098: log likelihood = -28.83,
```

```
aic = 65.66
```

```
> m3 <- arima(dd, c(0,0,1))
```

```
> m3
```

```
Call:
```

```
arima(x = dd, order = c(0,0,1))
```

```
Coefficients:
```

	ma1	intercept
	0.3357	1.7848
s.e.	0.1170	0.0937

```
sigma^2 estimated as 0.2238: log likelihood = -30.23,
```

```
aic = 66.46
```

```
> m4 <- arima(dd, c(0,0,2))
```

```
> m4
```

```
Call:
```

```
arima(x = dd, order = c(0,0,2))
```

```
Coefficients:
```

	ma1	ma2	intercept
--	-----	-----	-----------

	0.3796	0.1765	1.7839
s.e.	0.1467	0.1263	0.1063

sigma^2 estimated as 0.2143: log likelihood = -29.28,
aic = 66.56

```
> m5 <- arima(dd, c(1,0,1))
> m5
```

Call:

```
arima(x = dd, order = c(1,0,1))
```

Coefficients:

	ar1	ma1	intercept
	0.5858	-0.1894	1.7765
s.e.	0.2417	0.2866	0.1306

sigma^2 estimated as 0.21: log likelihood = -28.85, aic
= 65.69

```
> m6 <- arima(dd, c(2,0,1))
> m6
```

Call:

```
arima(x = dd, order = c(2,0,1))
```

Coefficients:

	ar1	ar2	ma1	intercept
	0.4047	0.0886	-0.0138	1.7767
s.e.	1.1869	0.5313	1.1883	0.1300

sigma^2 estimated as 0.2098: log likelihood = -28.83,
aic = 67.66

```
> m7 <- arima(dd, c(1,0,2))
> m7
```

Call:

```
arima(x = dd, order = c(1,0,2))
```

Coefficients:

	ar1	ma1	ma2	intercept
	0.5430	-0.1543	0.0411	1.7767
s.e.	0.3397	0.3609	0.1855	0.1296

sigma^2 estimated as 0.2097: log likelihood = -28.82,
aic = 67.65

```
> m8 <- arima(dd, c(2,0,2))
```

Warning message:

```
In arima(dd, c(2,0,2)) :
```

possible convergence problem: optim gave code = 1

```
>
```

ونلخص ذلك بالجدول التالي:

<i>Model</i>	$\hat{\sigma}^2$	<i>m</i>	<i>AIC</i>
<i>AR</i> (1)	0.2118	3	64.07
<i>AR</i> (2)	0.2098	4	65.66
<i>MA</i> (1)	0.2238	3	66.46
<i>MA</i> (2)	0.2143	4	66.56
<i>ARMA</i> (1,1)	0.21	4	65.69
<i>ARMA</i> (2,1)	0.2098	5	67.66
<i>ARMA</i> (1,2)	0.2097	5	67.65
<i>ARMA</i> (2,2)	—	—	—

$$\min_m AIC(m) = 64.07$$

أي ان أفضل نموذج هو *AR*(1) .

سوف نستخدم الدالة `auto.arima()` من مكتبة `forecast` لإيجاد نموذج مناسب بطريقة
أوتوماتيكية

```
> m.aut <- auto.arima(dd)
```

```

> m.aut
Series: dd
ARIMA(1,0,0) with non-zero mean

Coefficients:
          ar1      mean
      0.4322  1.7799
s.e.  0.1340  0.1189

sigma^2 estimated as 0.2217:  log likelihood=-29.04
AIC=64.07   AICc=64.66   BIC=69.49

```

وهذا يتفق تماما مع الطريقة المطولة التي استخدمناها.

يترك للطالب كتمرين فحص البواقي 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

```

ندخل المتسلسلة

```

> sales <- c(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)


```

نحولها لمتسلسلة زمنية ونرسمها

```
> s <- as.ts(sales)
```

مخطط زمني للمتسلسلة

```
> plot.ts(s)
```



دوال الترابط الذاتي والذاتي الجزئي العينية

```
> acf(s, plot=F)
```


Autocorrelations of series 's', by lag

	1	2	3	4	5	6	7	8	9
10	11	12	13	14	15	16			

```

0.710 0.603 0.653 0.637 0.595 0.594 0.511 0.560 0.492
0.490 0.512 0.425 0.384 0.451 0.406 0.354
    17    18    19    20
0.308 0.295 0.360 0.311
>

```



```

> pacf(s, plot=F)


```

Partial autocorrelations of series 's', by lag

```


      1      2      3      4      5      6      7      8
9      10     11     12     13
0.710 0.199 0.353 0.149 0.092 0.103 -0.127 0.193 -
0.170 0.144 0.034 -0.152 0.025
      14     15     16     17     18     19     20
0.039 0.032 -0.096 -0.084 -0.010 0.143 -0.044
> pacf(s)
>

```



دالة الترابط الذاتي العيني تدل على تخامد بطيئ مما قد يدل على عدم إستقرار في المتوسط.
 لنجرب التفريق الأول للمتسلسلة $w_t = \nabla z_t$ ونرسمها



```
> ds <- diff(s)
> plot.ts(ds)
```



تبدو المتسلسلة مستقرة الآن. دوال الترابط الذاتي والذاتي الجزئي للمتسلسلة المستقرة

```
> acf(ds)
```

```
> pacf(ds)
```



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 $\min_m AIC(m)$

سوف نطبق النماذج علي التوالي:

```
> library(tseries)
> library(randtests)
> m1 <- arima(sales, c(1,1,0))
> m2 <- arima(sales, c(2,1,0))
> m3 <- arima(sales, c(0,1,1))
> m4 <- arima(sales, c(0,1,2))
> m5 <- arima(sales, c(1,1,1))
> m6 <- arima(sales, c(2,1,1))
> m7 <- arima(sales, c(1,1,2))
> m8 <- arima(sales, c(2,1,2))
> m1
```

Call:

```
arima(x = sales, order = c(1, 1, 0))
```

Coefficients:

```
          ar1
        -0.3081
s.e.      0.0968
```

```
sigma^2 estimated as 1.349:  log likelihood = -155.35,
```

```
aic = 314.71
```

```
> m2
```

Call:

```
arima(x = sales, order = c(2, 1, 0))
```

Coefficients:

	ar1	ar2
	-0.4485	-0.4560
s.e.	0.0909	0.0903

sigma^2 estimated as 1.07: log likelihood = -144.13,
aic = 294.26
> m3

Call:

arima(x = sales, order = c(0, 1, 1))

Coefficients:

	ma1
	-0.7569
s.e.	0.0617

sigma^2 estimated as 1.034: log likelihood = -142.55,
aic = 289.11
> m4

Call:

arima(x = sales, order = c(0, 1, 2))

Coefficients:

	ma1	ma2
	-0.5709	-0.2011
s.e.	0.1237	0.1212

sigma^2 estimated as 1.009: log likelihood = -141.33,
aic = 288.66
> m5

Call:

```
arima(x = sales, order = c(1, 1, 1))
```

Coefficients:

	ar1	ma1
	0.1306	-0.7979
s.e.	0.1222	0.0641

sigma^2 estimated as 1.022: log likelihood = -141.98,

aic = 289.95

> m6

Call:

```
arima(x = sales, order = c(2, 1, 1))
```

Coefficients:

	ar1	ar2	ma1
	0.0224	-0.3057	-0.6546
s.e.	0.1338	0.1137	0.1153

sigma^2 estimated as 0.9564: log likelihood = -138.76,

aic = 285.51

> m7

Call:

```
arima(x = sales, order = c(1, 1, 2))
```

Coefficients:

	ar1	ma1	ma2
	-0.3453	-0.2396	-0.4451
s.e.	0.2230	0.1935	0.1395

sigma^2 estimated as 0.9897: log likelihood = -140.38,

aic = 288.76

> m8

Call:

```
arima(x = sales, order = c(2, 1, 2))
```

Coefficients:

	ar1	ar2	ma1	ma2
	-0.0708	-0.2869	-0.5556	-0.0852
s.e.	0.4237	0.1456	0.4404	0.3710

sigma^2 estimated as 0.956: log likelihood = -138.73,
aic = 287.47

ونلخص ذلك بالجدول التالي:

<i>Model</i>	$\hat{\sigma}^2$	<i>m</i>	<i>AIC</i>
<i>ARI</i> (1,1)	1.349	2	314.71
<i>ARI</i> (2,1)	1.07	3	294.26
<i>IMA</i> (1,1)	1.034	2	289.11
<i>IMA</i> (1,2)	1.009	3	288.66
<i>ARIMA</i> (1,1,1)	1.022	3	289.95
<i>ARIMA</i> (2,1,1)	0.9564	4	285.51
<i>ARIMA</i> (1,1,2)	0.9897	4	288.76
<i>ARIMA</i> (2,1,2)	0.956	5	287.47

$$\min_m AIC(m) = 285.51$$

أي ان أفضل نموذج هو $ARIMA(2,1,1)$.

باستخدام `auto.arima()` من مكتبة forecast

```
> m.aut <- auto.arima(sales)
```

```
> m.aut
```

Series: sales

ARIMA(2,1,1)

Coefficients:

	ar1	ar2	ma1
	0.0224	-0.3057	-0.6546
s.e.	0.1338	0.1137	0.1153

sigma^2 estimated as 0.9863: log likelihood=-138.76
AIC=285.51 AICc=285.94 BIC=295.89

مما يتفق مع الطريقة المطولة السابقة.
يترك للطالب كتمرين فحص البواقي وتوليد تنبؤات.


الفصل السادس

نماذج الإنحدار الذاتي التكامل 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 الإنحدار الذاتي التكامل 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 التكاملي المتوسط المتحرك بالدرجة $(p, d, q)(P, D, Q)_s$ SARIMA($p, d, q)(P, D, Q)_s$ يكتب على الشكل

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

حيث $\phi_p(B)$ و $\theta_q(B)$ عامل الإنحدار الذاتي والمتوسط المتحرك غير الموسمية والتي مرت علينا سابقا 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 مفهوما ضمينا أن $a_t \sim WN(0, \sigma^2)$

دوال الترابط الذاتي والترابط الذاتي الجزئي لبعض النماذج الموسمية:

في الإشتقاق التالية سوف نستخدم المتسلسلة الموسمية المستقرة $w_t = (1 - B)^d(1 - B^s)^D z_t$

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

$$\begin{aligned} \gamma_{12} &= \Phi \gamma_0 - \Theta \sigma^2 + \theta \Theta(-\theta) \sigma^2 \\ &= \Phi \gamma_0 - \Theta \sigma^2 (1 + \theta^2) \end{aligned}$$

وبحل العلاقتين السابقتين نجد

$$\begin{aligned} \gamma_0 &= \sigma^2 (1 + \theta^2) \frac{1 + \Theta^2 - 2\Phi\Theta}{1 - \Phi^2} \\ \gamma_{12} &= \sigma^2 (1 + \theta^2) \left[\Phi - \Theta + \frac{\Phi(\Theta - \Phi)^2}{1 - \Phi^2} \right] \end{aligned}$$

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 العلاقتين 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

$$\begin{aligned}\gamma_2 &= \gamma_3 = \dots = \gamma_{10} = 0 \\ \gamma_{13} &= \gamma_{11} \\ \gamma_k &= \Phi \gamma_{k-12}, \quad k > 13\end{aligned}$$

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:

1- نموذج $\text{SARIMA}(0,d,0)(0,D,1)_s$ $w_t = (1 - \Theta B^s) a_t$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{\Theta}{1 + \Theta^2}, & k = s \\ 0, & \text{otherwise} \end{cases}$$

2- نموذج $\text{SARIMA}(0,d,0)(1,D,1)_s$ $(1 - \Phi B^s) w_t = a_t$

$$\rho_k = \begin{cases} 1, & k = 0 \\ \Phi^{k/s}, & k = s, 2s, \dots \\ 0, & \text{otherwise} \end{cases}$$

3- نموذج $\text{SARIMA}(0,d,1)(0,D,1)_s$ $w_t = (1 - \theta B)(1 - \Theta B^s) a_t$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{\theta}{1 + \theta^2}, & k = 1 \\ \frac{\theta \Theta}{(1 + \theta^2)(1 + \Theta^2)}, & k = s - 1 \\ -\frac{\Theta}{1 + \Theta^2}, & k = s \\ \rho_{s-1}, & k = s + 1 \\ 0, & \text{otherwise} \end{cases}$$

4- نموذج $\text{SARIMA}(0,d,0)(1,D,1)_s$ $(1 - \Phi B^s) w_t = (1 - \Theta B^s) a_t$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{(\Theta - \Phi)(1 - \Phi \Theta)}{1 + \Theta^2 - 2\Phi \Theta} \Phi^{k/s-1}, & k = s, 2s, \dots \\ 0, & \text{otherwise} \end{cases}$$

5- نموذج $\text{SARIMA}(0,d,1)(1,D,0)_s$ $(1 - \Phi B^s) w_t = (1 - \theta B) a_t$

$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{\theta}{1+\theta^2}, & k = 1 \\ 0, & k = 2, \dots, s-2 \\ -\frac{\theta\Phi}{1+\theta^2}, & k = s-1 \\ \Phi, & k = s \\ \rho_{s-1}, & k = s+1 \\ \Phi\rho_{k-s}, & k > s+1 \end{cases}$$

$$w_t = (1 - \theta_1 B - \theta_2 B^2)(1 - \Theta B^{12})a_t \quad \text{SARIMA}(0, d, 2)(0, D, 1)_s \text{ نموذج 6-}$$


$$\rho_k = \begin{cases} 1, & k = 0 \\ -\frac{\theta_1(1-\theta_2)}{1+\theta_1^2+\theta_2^2}, & k = 1 \\ -\frac{\theta_2}{1+\theta_1^2+\theta_2^2}, & k = 2 \\ \frac{\theta_2\Theta}{(1+\theta_1^2+\theta_2^2)(1+\Theta^2)}, & k = s-2 \\ \frac{\theta_1\Theta(1-\theta_2)}{(1+\theta_1^2+\theta_2^2)(1+\Theta^2)}, & k = s-1 \\ -\frac{\Theta}{1+\Theta^2}, & k = s \\ \rho_{s-1}, & k = s+1 \\ \rho_{s-2}, & k = s+2 \\ 0, & otherwise \end{cases}$$

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:


شكل (1)

$$\Phi = 0.6, \quad \theta = 0.5$$




شكل (2)

$$\Phi = 0.6, \quad \theta = -0.5$$




شكل (3)

$$\Phi = -0.6, \quad \theta = 0.5$$



شكل (4)

$$\Phi = -0.6, \quad \theta = -0.5$$




دالة الترابط الذاتي الجزئي للنموذج الموسمي التضاعفي:

من الصعوبة اشتقاق وتفسير أنماط دالة الترابط الذاتي الجزئي للنماذج الموسمية التضاعفية ولكنها وبشكل عام فإن أجزاء النموذج الموسمية وغير الموسمية والتي تتمزج المتوسط المتحرك تعطي تخامدات اسية وتخامدات جيبيية 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 $w_t = (1 - \Theta B^{12})a_t$

أ) $\Theta = 0.6$




ب) $\Theta = -0.6$




2- شكل دالة الترابط الذاتي الجزئي لنموذج $(1 - \Phi B^{12})w_t = a_t$

$\Phi = 0.6$ (أ)



$\Phi = -0.6$ (ب)



أمثلة: للمتسلسلة الزمنية الموسمية (في جميع الأمثلة التالية اقرأ سطرا 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		

```
> zs <- as.ts(zs)
> plot.ts(zs)
```

شكل المتسلسلة هو




دالة الترابط الذاتي

```
> acf(zs)
```

```
> acf(zs, plot=F)
```

Autocorrelations of series 'zs', by lag

	1	2	3	4	5	6	7	8
9	10	11	12	13				
0.773	0.325	-0.115	-0.384	-0.522	-0.564	-0.518	-0.378	-
0.116	0.288	0.691	0.882	0.682				
	14	15	16	17	18	19	20	21
22								
0.282	-0.115	-0.362	-0.491	-0.532	-0.495	-0.372	-0.137	
0.233								




والترابط الذاتي الجزئي

```
> pacf(zs)
> pacf(zs, plot=F)
```

Partial autocorrelations of series 'zs', by lag

	1	2	3	4	5	6	7	8
9	10	11	12	13				
0.773	-0.675	-0.062	0.006	-0.416	-0.184	-0.111	-0.222	
0.179	0.573	0.263	0.162	-0.421				
	14	15	16	17	18	19	20	21
22								
0.291	0.012	-0.069	0.071	-0.008	-0.086	-0.054	-0.083	
0.103								




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


> plot.ts(z)

شكل المتسلسلة




الترابط الذاتي

`> acf(z)`



والترابط الذاتي الجزئي

`> pacf(z)`




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					

```
> zts2a <- ts(zts2,frequency = 4)
> plot.ts(zts2a)
```

ولها الشكل




ودالة الترابط الذاتي

```
> acf(zts2a, plot = F)
```

Autocorrelations of series 'zts2a', by lag

0.25	0.50	0.75	1.00	1.25	1.50	1.75	2.00	
2.25	2.50	2.75	3.00	3.25	3.50	3.75		
0.814	0.427	-0.027	-0.430	-0.685	-0.775	-0.684	-0.427	-
0.044	0.381	0.714	0.843	0.713	0.372	-0.025		
4.00	4.25	4.50	4.75	5.00				
-0.375	-0.599	-0.669	-0.590	-0.368				

```
> acf(zts2a)
>
```



ودالة الترابط الذاتي الجزئي


```
> pacf(zts2a, plot = F)
```

Partial autocorrelations of series 'zts2a', by lag

0.25	0.50	0.75	1.00	1.25	1.50	1.75	2.00
2.25	2.50	2.75	3.00	3.25	3.50	3.75	
0.814	-0.697	-0.289	-0.222	-0.157	-0.320	-0.155	-0.030
0.185	0.268	0.176	0.072	-0.096	-0.147	0.187	
4.00	4.25	4.50	4.75	5.00			
0.081	0.107	0.038	-0.021	-0.028			

```
> pacf(zts2a)
```

```
>
```



وكل هذه المتسلسلات تبدي انماط موسمية واضحة.

إشتقاق 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 علي شكل النموذج وتقدير معالم النموذج والإختبارات التفحصية ومن ثم التنبؤ. جميع الطرق والمعادلات التي درسناها سابقا للنماذج غير الموسمية تنطبق هنا. سوف نشق دوال التنبؤ لبعض النماذج للتوضيح فقط.

1- دالة التنبؤ للنموذج $SARIMA(0,0,0)(0,1,1)_{12}$:

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

$$\begin{aligned}
z_n(1) &= z_{n-11} - \Theta a_{n-11} \\
z_n(2) &= z_{n-10} - \Theta a_{n-10} \\
&\vdots \\
z_n(12) &= z_n - \Theta a_n \\
z_n(\ell) &= z_n(\ell - 12), \quad \ell \geq 12
\end{aligned}$$

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

$$\begin{aligned}
z_n(1) &= z_n(13) = z_n(25) = \dots \\
z_n(2) &= z_n(14) = z_n(26) = \dots \\
&\vdots \\
z_n(12) &= z_n(24) = z_n(36) = \dots
\end{aligned}$$

تباين أخطاء التنبؤ

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

ودالة الأوزان تعطى بالعلاقة (برهن ذلك)

$$\psi_j = \begin{cases} 1 - \Theta, & j = 12, 24, \dots \\ 0, & otherwise \end{cases}$$

وبتعويض الأوزان في صيغة تباين 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

$$\begin{aligned}
z_n(1) &= z_n + z_{n-11} - z_{n-13} - \theta a_n - \Theta a_{n-11} + \theta \Theta a_{n-12} \\
z_n(2) &= z_n(1) + z_{n-10} - z_{n-11} - \Theta a_{n-10} + \theta \Theta a_{n-11} \\
&\vdots \\
z_n(12) &= z_n(11) + z_n - z_{n-1} - \Theta a_n + \theta \Theta a_{n-1} \\
z_n(13) &= z_n(12) + z_n(1) - z_n + \theta \Theta a_n
\end{aligned}$$

وعلاقة تكرارية

$$z_n(\ell) = z_n(\ell-1) + z_n(\ell-12) - z_n(\ell-13), \quad \ell > 13$$

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:

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
```


```
> zts <- ts(z, frequency = 12)
```

```
> head(zts)
```

```
Jan Feb Mar Apr May Jun
1 589 561 640 656 727 697
```

والمخطط الزمني للمشاهدات

```
> plot.ts(zts)
```




يلاحظ ان المتسلسلة غير مستقرة في التباين والمتوسط لذلك نثبت التباين أولاً بتحويل لوغاريتمي

أي $y_t = \ln(z_t)$ ونرسم المخطط الزمني لها


```
> lzts <- log(zts)
```

```
> plot.ts(lzts)
```


نلاحظ ان المتسلسلة استقرت في التباين ولكن لاتزال غير مستقرة في المتوسط لذلك نأخذ الفرق الأول $x_t = (1-B)y_t = (1-B)\ln(z_t)$ ولها الشكل التالي

```
> dlzts <- diff(lzts)
> plot.ts(dlzts)
```




المتسلسلة الآن مستقرة في كل من التباين والمتوسط. لننظر إلى دوال الترابط الذاتي والترابط الذاتي الجزئي لها

```
> acf(dlzts)
```



```
> pacf(dlzts)
```




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 $w_t = (1 - B^{12})(1 - B)\ln(z_t)$

```
> sdlzts <- diff(dlzts, 12)
```


```
> plot.ts(sdlzts)
```

ونرسمها بعد هذا التفريق




نوجد دوال الترابط الذاتي والترابط الذاتي الجزئي لها

```
> acf(sdlzts)
```



```
> pacf(sdlzts)
```



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 $SARIMA(0,1,0)(0,1,1)_{12}$ الأمر التالي في MINITAB يطبق هذا النموذج

ARIMA 0 1 0 0 1 1 12 'y(t)';

NoConstant.

لاحظ اننا استخدمنا $y_t = \ln(z_t)$ وللحصول على النتائج النهائية نجري التحويل $z_t = e^{y_t}$

النتائج:

باستخدام مكتبة forecast

```
> library(forecast)
> fit1<- arima(lzts, order = c(0,1,0), seasonal =
list(order = c(0,1,1), period = 12))
> fit1
```

Call:

```
arima(x = lzts, order = c(0, 1, 0), seasonal = list(order
= c(0, 1, 1), period = 12))
```

Coefficients:

```
      sma1
      -0.6313
s.e.    0.0619
```

```
sigma^2 estimated as 0.00011:  log likelihood = 483.41,
aic = -962.82
>
```

أي أن النموذج المقترح لهذه المتسلسلة هو

$$(1-B^{12})(1-B)\ln(z_t) = (1-0.6313B^{12})a_t, \quad a_t \sim N(0, 0.00011)$$

لاحظ ان

$$\Theta = -0.6313, \quad s.e.(\Theta) = 0.0619, \quad t = 10.1987$$

أي ان المعلم عالي المعنوية.

باستخدام مكتبة astsa

```
> library(astsa)
> fit2<- sarima(lzts, 0,1,0,0,1,1,12)
initial value -4.369567
iter 2 value -4.517683
iter 3 value -4.535746
iter 4 value -4.538267
iter 5 value -4.541397
iter 6 value -4.542312
iter 7 value -4.542341
iter 8 value -4.542341
iter 9 value -4.542341
iter 9 value -4.542341
iter 9 value -4.542341
final value -4.542341
converged
initial value -4.537628
iter 2 value -4.537685
```

```

iter    3 value -4.537726
iter    3 value -4.537726
iter    3 value -4.537726
final   value -4.537726
converged

> fit2
$fit

Call:
stats::arima(x = xdata, order = c(p, d, q), seasonal =
list(order = c(P, D,
      Q), period = S), include.mean = !no.constant,
optim.control = list(trace = trc,
      REPORT = 1, reltol = tol))

Coefficients:
      sma1
      -0.6313
s.e.    0.0619

sigma^2 estimated as 0.00011:  log likelihood = 483.41,
aic = -962.82

$degrees_of_freedom
[1] 154

$tttable
      Estimate      SE  t.value p.value
sma1  -0.6313 0.0619 -10.2011      0

$AIC
[1] -8.102899


$AICc

```

[1] -8.090562

\$BIC

[1] -9.084304




نفس النتائج

فحص البواقي:

رسم البواقي

```
> plot.ts(fit1$residuals)
```



إختبار المتوسط

```
> t.test(fit1$residuals)
```

One Sample t-test

```
data: fit1$residuals
t = -0.17798, df = 167, p-value = 0.859
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 -0.001703791  0.001422008
sample estimates:
 mean of x
-0.0001408914
```

لاحظ ان الـ $P\text{-value}=0.859$ وهي اكبر من 0.05 اي لانرفض أن متوسط البواقي صفرا

إختبار عشوائية البواقي

```
> runs.test(fit1$residuals)
```

Runs Test


```
data: fit1$residuals
statistic = -1.8572, runs = 73, n1 = 84, n2 = 84, n =
168, p-value = 0.06328
alternative hypothesis: nonrandomness
```

الإختبار معنوي عند 0.063 اي اننا لانرفض فرضية عشوائية البواقي


إختبار إستقلال البواقي:

دوال الترابط الذاتي والترابط الذاتي الجزئي

```
> acf(fit1$residuals)
```


```
> pacf(fit1$residuals)
```



نلاحظ انها تعطي انماط الضجة البيضاء أي انها غير مترابطة وإذا كانت طبيعية فهي مستقلة.


إختبار طبيعية البواقي:

```
> hist(fit1$residuals)
```



```
> qqnorm(fit1$residuals)
```

```
> qqline(fit1$residuals)
```



```
> ks.test(fit1$residuals, "pnorm")
```

One-sample Kolmogorov-Smirnov test

```
data: fit1$residuals
```

```
D = 0.48843, p-value < 2.2e-16
```

```
alternative hypothesis: two-sided
```

لاحظ ان الـ P-value لإختبار K-S يعطي $2.2e-16$ وهي اقل من 0.05 اذا الإختبار معنوي عند $\alpha = 0.05$ اي لانرفض فرضية طبيعية البواقي.

التنبؤ باستخدام النموذج:

في المخرجات السابقة قمنا بالتنبؤ عن 24 قيمة مستقبلية مع 95% فترات تنبؤ ونرسمها بالرسم التالي:

```
> library(forecast)
```

```
> f <- forecast(fit1, h = 24)
```

```
> f
```


	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 15	6.766688	6.753246	6.780131	6.746130	6.787247
Feb 15	6.707398	6.688388	6.726409	6.678324	6.736473
Mar 15	6.836941	6.813658	6.860225	6.801333	6.872550
Apr 15	6.851963	6.825078	6.878848	6.810845	6.893080
May 15	6.920604	6.890546	6.950663	6.874634	6.966575
Jun 15	6.891374	6.858447	6.924302	6.841016	6.941733
Jul 15	6.845372	6.809806	6.880938	6.790979	6.899765
Aug 15	6.799424	6.761402	6.837445	6.741275	6.857572
Sep 15	6.743518	6.703190	6.783846	6.681842	6.805194
Oct 15	6.749931	6.707422	6.792440	6.684919	6.814943
Nov 15	6.706580	6.661996	6.751164	6.638395	6.774765
Dec 15	6.759955	6.713389	6.806521	6.688738	6.831172
Jan 16	6.789676	6.739607	6.839746	6.713101	6.866251
Feb 16	6.730386	6.677043	6.783730	6.648805	6.811968
Mar 16	6.859930	6.803502	6.916357	6.773631	6.946228
Apr 16	6.874951	6.815599	6.934302	6.784181	6.965721
May 16	6.943592	6.881454	7.005730	6.848560	7.038624
Jun 16	6.914362	6.849558	6.979167	6.815252	7.013473
Jul 16	6.868360	6.800994	6.935726	6.765332	6.971388
Aug 16	6.822412	6.752578	6.892245	6.715610	6.929213

```

Sep 16      6.766506 6.694289 6.838723 6.656060 6.876952
Oct 16      6.772919 6.698395 6.847443 6.658945 6.886894
Nov 16      6.729568 6.652807 6.806330 6.612171 6.846965
Dec 16      6.782943 6.704007 6.861879 6.662221 6.903665


```

```
> plot.ts(f)
```



```
> library(astsa)
```

```
> f2 <- sarima.for(lzts,12, 0,1,0,0,1,1,12)
```



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

```
> zst <- ts(zs, frequency = 12)
> plot.ts(zst)
```




بأخذ الفرق الأول لإستقرار المتوسط $w_t = (1 - B)z_t$ نجد

```
> dzst <- diff(zst)
> plot.ts(dzst)
```




ولها دوال ترابط ذاتي وترابط ذاتي جزئي

> acf(dzst)




> pacf(dzst)




نرى انها تحتاج إلى تفريق موسمي من الرتبة 12 أي $w_t = (1 - B^{12})(1 - B)z_t$ وينتج المتسلسلة التالية

```
> dzstd12 <- diff(zst, 12)
> plot.ts(dzstd12)
```



ولها دوال ترابط ذاتي وترابط ذاتي جزئي

```
> par(mfrow=c(1,2))
> acf(dzstd12)
> pacf(dzstd12)
```

من الأنماط المشاهدة لدوال الترابط الذاتي والترابط الذاتي الجزئي قد يكون النموذج المناسب هو

SARIMA(1,1,1)(0,1,1)₁₂ أي

$$(1 - \phi B)(1 - B^{12})(1 - B)z_t = (1 - \theta B)(1 - \Theta B^{12})a_t$$

نطبق هذا النموذج على المتسلسلة كالتالي:

```
> fit1<- arima(zst, order = c(1,1,1), seasonal =
list(order = c(0,1,1), period = 12))
> fit1
```

Call:

```
arima(x = zst, order = c(1, 1, 1), seasonal = list(order
= c(0, 1, 1), period = 12))
```

Coefficients:

	ar1	ma1	sma1
	0.5479	-0.8928	-0.6625
s.e.	0.0882	0.0425	0.0813

```

sigma^2 estimated as 1.267:    log likelihood = -257.63,
aic = 523.26
> fit2<- sarima(zst,1,1,1,0,1,1,12)
initial  value 0.352273
iter    2 value 0.237092
iter    3 value 0.221567
iter    4 value 0.219136
iter    5 value 0.217742
iter    6 value 0.217122
iter    7 value 0.215590
iter    8 value 0.208130
iter    9 value 0.157765
iter   10 value 0.153144
iter   11 value 0.148290
iter   12 value 0.145769
iter   13 value 0.144290
iter   14 value 0.143715
iter   15 value 0.143655
iter   16 value 0.143653
iter   17 value 0.143651
iter   18 value 0.143650
iter   19 value 0.143650
iter   19 value 0.143650
iter   19 value 0.143650
final   value 0.143650
converged
initial  value 0.143989
iter    2 value 0.143371
iter    3 value 0.142508
iter    4 value 0.142451
iter    5 value 0.142450
iter    6 value 0.142449
iter    7 value 0.142449
iter    7 value 0.142449

```

```
iter    7 value 0.142449
```

```
final   value 0.142449
```

```
converged
```

```
> fit2
```

```
$fit
```

```
Call:
```

```
stats::arima(x = xdata, order = c(p, d, q), seasonal =  
list(order = c(P, D,  
      Q), period = S), include.mean = !no.constant,  
optim.control = list(trace = trc,  
      REPORT = 1, reltol = tol))
```

```
Coefficients:
```

	ar1	ma1	sma1
	0.5479	-0.8928	-0.6625
s.e.	0.0882	0.0425	0.0813

```
sigma^2 estimated as 1.267:  log likelihood = -257.63,  
aic = 523.26
```

```
$degrees_of_freedom
```

```
[1] 162
```

```
$ttable
```

	Estimate	SE	t.value	p.value
ar1	0.5479	0.0882	6.2097	0
ma1	-0.8928	0.0425	-21.0066	0
sma1	-0.6625	0.0813	-8.1496	0

```
$AIC
```


```
[1] 1.270646
```

```
$AICc
```

[1] 1.283181

\$BIC

[1] 0.3242715



أي أن النموذج المقترح لهذه المتسلسلة هو

$$(1 - 0.5479B)(1 - B^{12})(1 - B)z_t = (1 - 0.8928B)(1 - 0.6625B^{12})a_t, \quad a_t \sim N(0, 1.267)$$

لاحظ ان

$$\phi = 0.5479, \quad s.e.(\phi) = 0.0882, \quad t = 6.212$$

$$\theta = -0.8928, \quad s.e.(\theta) = 0.0425, \quad t = -21.007$$

$$\Theta = -0.6625, \quad s.e.(\Theta) = 0.0813, \quad t = -8.1488$$

أي ان المعالم عالية المعنوية.

فحص البواقي:

إختبار المتوسط

```
> t.test(fit1$residuals)
```

One Sample t-test

```

data: fit1$residuals
t = 1.6175, df = 177, p-value = 0.1075
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 -0.02879064  0.29045085
sample estimates:
mean of x
0.1308301

```

لاحظ ان الـ P-value=0.1075 وهي اكبر من 0.05 اي لانرفض أن متوسط البواقي صفرا

إختبار عشوائية البواقي

```
> runs.test(fit1$residuals)
```

Runs Test

```

data: fit1$residuals
statistic = -2.255, runs = 75, n1 = 89, n2 = 89, n = 178,
p-value = 0.02413
alternative hypothesis: nonrandomness

```

الإختبار غير معنوي عند 0.05 اي اننا نرفض فرضية عشوائية البواقي وهذا يحتاج إلى إجراء إختبار آخر أكثر قوة من إختبار الجري مثل إختبار الإشارة Sign Test على الوسيط التالي:

```

> library(BSDA)
> SIGN.test(fit1$residuals, md = 0, alternative =
"two.sided", conf.level = 0.95)

```

One-sample Sign-Test

```

data: fit1$residuals
s = 107, p-value = 0.008521
alternative hypothesis: true median is not equal to 0
95 percent confidence interval:
 0.008277848 0.179401945
sample estimates:

```

```
median of x
0.09993051
```

Achieved and Interpolated Confidence Intervals:

	Conf.Level	L.E.pt	U.E.pt
Lower Achieved CI	0.9394	0.0093	0.1787
Interpolated CI	0.9500	0.0083	0.1794
Upper Achieved CI	0.9573	0.0076	0.1799

والإختبار غيرمعنوي عند 0.0085 وللتأكد تجري إختبار ولكوكسون لإشارات الرتب على الوسيط التالي

```
> wilcox.test(fit1$residuals)
```

Wilcoxon signed rank test with continuity correction

```
data: fit1$residuals
```

```
V = 9433, p-value = 0.0331
```

```
alternative hypothesis: true location is not equal to 0
```

والإختبار ايضا غيرمعنوي عند 0.0331


إختبار إستقلال البواقي:

دوال الترابط الذاتي والترابط الذاتي الجزئي

```
> par(mfrow=c(2,1))
```

```
> acf(fit1$residuals)
```


```
> pacf(fit1$residuals)
```



نلاحظ انها تعطي انماط الضجة البيضاء أي انها غير مترابطة وإذا كانت طبيعية فهي مستقلة.


إختبار طبيعية البواقي:

```
> hist(fit1$residuals)
```



```
> qqnorm(fit1$residuals)
```

```
> qqline(fit1$residuals)
```



```
> ks.test(fit1$residuals, pnorm)
```

One-sample Kolmogorov-Smirnov test

```
data: fit1$residuals
D = 0.15033, p-value = 0.0006411
alternative hypothesis: two-sided
```

لاحظ ان الـ P-value لإختبار K-S أقل من 0.00064 اذا الإختبار غير معنوي عند $\alpha = 0.05$ اي نرفض فرضية طبيعية البواقي.

إذا النموذج المقترح غير مناسب و نبحث عن نموذج آخر.

لإمكانية وجود عدد كبير جدا من النماذج التي يمكن تجربتها عن طريق AIC لذلك نستخدم

التطبيق الاوتوماتيكي (`auto.arima()`) في مكتبة forecast

```
> fit3 <- auto.arima(zst)
> fit3
Series: zst
ARIMA(2,1,3) (1,1,2) [12]
```


Coefficients:

	ar1	ar2	ma1	ma2	ma3	sar1
sma1	sma2					
	1.4115	-0.4766	-1.7076	0.5451	0.1903	0.2851
	0.946	0.1473				
s.e.	0.1355	0.1282	0.1410	0.2392	0.1095	0.8292
	0.834	0.5709				

sigma^2 estimated as 1.244: log likelihood=-252.47

AIC=522.93 AICc=524.09 BIC=550.89

تمرين: يترك للطالب كتابة النموذج $(1, 1, 2)_{12}$ $ARIMA(2, 1, 3)$ بالشكل الرياضي

التنبؤ باستخدام النموذج:

سوف نستخدم النموذج المقترح اوتوماتيكيا لإيجاد التنبؤ عن 36 قيمة مستقبلية مع 95% فترات تنبؤ

```
> f <- forecast(fit3, h = 36)
```


```
> f
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Nov 15	58.94921	57.51951	60.37891	56.76267	61.13575
Dec 15	58.17776	56.42940	59.92611	55.50388	60.85164
Jan 16	57.49977	55.67947	59.32006	54.71587	60.28366
Feb 16	57.07466	55.23367	58.91565	54.25910	59.89022
Mar 16	57.41762	55.56718	59.26807	54.58761	60.24763
Apr 16	57.55346	55.69502	59.41189	54.71123	60.39569
May 16	58.17621	56.30772	60.04471	55.31860	61.03383
Jun 16	61.55859	59.67587	63.44131	58.67922	64.43796
Jul 16	70.56929	68.66681	72.47176	67.65970	73.47887
Aug 16	75.72269	73.79422	77.65117	72.77335	78.67204
Sep 16	75.33295	73.37210	77.29379	72.33410	78.33180
Oct 16	65.02770	63.02842	67.02697	61.97007	68.08533
Nov 16	60.87414	58.67907	63.06922	57.51707	64.23122
Dec 16	59.13223	56.79942	61.46504	55.56450	62.69995
Jan 17	57.98601	55.56603	60.40598	54.28497	61.68704

Feb 17	57.36241	54.87265	59.85217	53.55465	61.17017
Mar 17	57.62360	55.06885	60.17835	53.71645	61.53075
Apr 17	57.73292	55.11262	60.35321	53.72552	61.74031
May 17	58.38521	55.69659	61.07384	54.27331	62.49712
Jun 17	61.76678	59.00629	64.52727	57.54497	65.98858
Jul 17	70.74487	67.90904	73.58071	66.40783	75.08192
Aug 17	75.92563	73.01137	78.83989	71.46866	80.38260
Sep 17	75.63584	72.64067	78.63102	71.05512	80.21657
Oct 17	65.51706	62.43907	68.59505	60.80969	70.22444
Nov 17	61.36748	58.08138	64.65358	56.34183	66.39313
Dec 17	59.60895	56.16282	63.05508	54.33855	64.87935
Jan 18	58.47091	54.90907	62.03275	53.02355	63.91828
Feb 18	57.86675	54.20689	61.52660	52.26948	63.46402
Mar 18	58.14441	54.39307	61.89574	52.40724	63.88158
Apr 18	58.26608	54.42484	62.10732	52.39141	64.14075
May 18	58.93596	55.00421	62.86771	52.92287	64.94905
Jun 18	62.32073	58.29706	66.34440	56.16705	68.47440
Jul 18	71.29000	67.17287	75.40714	64.99339	77.58662
Aug 18	76.47760	72.26565	80.68954	70.03598	82.91921
Sep 18	76.21472	71.90694	80.52250	69.62654	82.80290
Oct 18	66.14734	61.74306	70.55161	59.41158	72.88310


> plot.ts(f)

ونرسمها بالرسم التالي:



الرسم التالي للمتسلسلة بكاملها مع التنبؤات وفترات التنبؤ باستخدام مكتبة `astsa`

```
> f2 <- sarima.for(zst,36, 2,1,3,1,1,2,12)
```



الفصل السابع

ورقة تدريب عملي على التنبؤ بواسطة نماذج المتوسط المتحرك-الانحدار الذاتي

Forecasting By ARMA Models


المشاهدات التالية لظاهرة عشوائية مسجلة علي 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				

```
> z <- ts(z)
```

ولها الشكل التالي:

```
> plot.ts(z)
```




اولا نوجد دوال الترابط الذاتي والترابط الذاتي الجزئي

```
> par(mfrow=c(2,1))
```

```
> acf(z)
```

```
> pacf(z)
```



نلاحظ من انماط الدالتين ان المشاهدات قد تكون من نموذج $ARMA(1,1)$

نطبق النموذج المقترح بمكتبة forecast

```
> zfit1 <- arima(z , order =c(1,0,1))
```

```
> zfit1
```

Call:

```
arima(x = z, order = c(1, 0, 1))
```

Coefficients:

	ar1	ma1	intercept
	0.4553	0.6887	23.2814
s.e.	0.1955	0.1817	2.0507

```
sigma^2 estimated as 16.12: log likelihood = -101.83,
aic = 211.66
```

بمكتبة astsa

```
> zfit2 <- sarima(z,1,0,1,0,0,0,-1)
```

```

initial value 1.762010
iter 2 value 1.398564
iter 3 value 1.342033
iter 4 value 1.332620
iter 5 value 1.331002
iter 6 value 1.329267
iter 7 value 1.328930
iter 8 value 1.328893
iter 9 value 1.328893
iter 10 value 1.328891
iter 11 value 1.328891
iter 11 value 1.328891
iter 11 value 1.328891
final value 1.328891

```

converged

```

initial value 1.418787
iter 2 value 1.411240
iter 3 value 1.409988
iter 4 value 1.409718
iter 5 value 1.409695
iter 6 value 1.409695
iter 6 value 1.409695
iter 6 value 1.409695
final value 1.409695

```

converged

```
> zfit2
```

```
$fit
```

Call:

```

stats::arima(x = xdata, order = c(p, d, q), seasonal =
list(order = c(P, D,
      Q), period = S), xreg = xmean, include.mean = FALSE,
optim.control = list(trace = trc,
      REPORT = 1, reltol = tol))

```

Coefficients:

	arl	ma1	xmean
	0.4553	0.6887	23.2814
s.e.	0.1955	0.1817	2.0507

sigma^2 estimated as 16.12: log likelihood = -101.83,
aic = 211.66

\$degrees_of_freedom

[1] 33

\$ttable

	Estimate	SE	t.value	p.value
arl	0.4553	0.1955	2.3291	0.0261
ma1	0.6887	0.1817	3.7894	0.0006
xmean	23.2814	2.0507	11.3527	0.0000

\$AIC

[1] 3.946593

\$AICc

[1] 4.03799

\$BIC

[1] 3.078553

النموذج المقترح هو:

$$z_t = 23.28 + 0.4553z_{t-1} + a_t - 0.6887a_{t-1}, \quad a_t \sim WN(0, 16.12) \forall t$$

حيث

$$\hat{\phi}_1 = 0.4553 \quad se(\hat{\phi}_1) = 0.1955 \quad t = 2.329$$

$$\hat{\theta}_1 = 0.6887 \quad se(\hat{\theta}_1) = 0.1817 \quad t = 3.789$$

$$\hat{\mu} = 23.2814 \quad se(\hat{\delta}) = 2.0507 \quad t = 11.3526$$

$$\hat{\sigma}^2 = 16.12 \quad df = 33$$

ونلاحظ ان جميع المقدرات معنوية عند $\alpha = 0.05$ فمثلا الفرضية

$$H_0 : \phi_1 = 0$$

$$H_1 : \phi_1 \neq 0$$

$$\text{نختبرها بالإحصائية } t = \frac{\hat{\phi}_1}{se(\hat{\phi}_1)} = \frac{0.4553}{0.1955} = 2.329 \text{ وهي معنوية عند } \alpha = 0.05 \text{ أي أننا}$$

نرفض ان $\phi_1 = 0$ وبالمثل لجميع المقدرات الاخرى

ثانيا فحص البواقي

إختبار متوسط البواقي:

الإختبار هو

$$H_0 : \mu_a = 0, \quad H_1 : \mu_a \neq 0$$

```
> t.test(zfit1$residuals)
```

One Sample t-test

```
data: zfit1$residuals
```

```
t = 0.32271, df = 35, p-value = 0.7488
```

```
alternative hypothesis: true mean is not equal to 0
```

```
95 percent confidence interval:
```

```
-1.156936 1.594271
```

```
sample estimates:
```

```
mean of x
```

```
0.2186678
```

لاحظ ان $t = 0.3227$ والـ $p\text{-value} = 0.7488$ وهي اكبر من $\alpha = 0.05$ أي ان

الإختبار غير معنوي أي يمكن إعتبار متوسط البواقي يساوي الصفر

إختبار عشوائية البواقي:


ونستخدم لذلك إختبار الجري Runs Test

لايمكننا رفض عشوائية البواقي عند $\alpha = 0.05$

إختبار ترابط البواقي:

ونستخدم لذلك إختبار الترابط الذاتي


```
> acf(zfit1$residuals)
> pacf(zfit1$residuals)
```



نلاحظ انه لا يوجد أي ترابط من أي درجة بين القيم المختلفة للبواقي أي انها تظهر انماط تتمشي مع كونها متسلسلة ضجة بيضاء

واخيرا نختبر طبيعية البواقي بالـ Normal Probability Plot

```
> par(mfrow=c(1,1))
> qqnorm(zfit1$residuals)
> qqline(zfit1$residuals)
```



```
> ks.test(zfit1$residuals, pnorm)
```

One-sample Kolmogorov-Smirnov test

```
data: zfit1$residuals
D = 0.38174, p-value = 3.157e-05
alternative hypothesis: two-sided
```

وهو مقبول (نوعاً)

إذا يمكن اعتبار النموذج المقترح مناسباً

الرسم التالي للتنبؤات لخمسة قيم مستقبلية وفترات 95% تنبؤ لها

```
> z.f <- sarima.for(z,5,1,0,1,0,0,0,-1)
> z.f
$pred
Time Series:
Start = 37
End = 41
Frequency = 1
[1] 15.17075 19.58858 21.60003 22.51586 22.93283

$se
```


Time Series:

Start = 37

End = 41

Frequency = 1

[1] 4.014701 6.100012 6.448458 6.518360 6.532758




مثال آخر:

المشاهدات التالية لظاهرة عشوائية مسجلة علي 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						

```
> z2ts <- ts(z2)
> plot.ts(z2ts)
```



نفحص دوال الترابط الذاتي والترابط الذاتي الجزئي

```
> par(mfrow=c(2,1))
> acf(z2ts)
> pacf(z2ts)
```



نلاحظ ان الأنماط تقترح نموذج إنحدار ذاتي من الدرجة الثانية $AR(2)$

```
> z2ts.fit <- arima(z2ts, c(2,0,0))
> z2ts.fit
```

Call:

```
arima(x = z2ts, order = c(2, 0, 0))
```

Coefficients:

	ar1	ar2	intercept
	1.0436	-0.2495	9.0473
s.e.	0.0983	0.1008	0.3319

```
sigma^2 estimated as 0.4788: log likelihood = -103.63,
aic = 215.27
```

```
> z2ts.fit2 <- sarima(z2ts,2,0,0,0,0,0,-1)
```

```
initial value 0.250791
```

```
iter 2 value 0.185366
```

```
iter 3 value -0.271691
```

```
iter 4 value -0.357021
```

```
iter 5 value -0.378607
```

```
iter 6 value -0.387054
```

```
iter 7 value -0.394441
```

```
iter 8 value -0.394802
```

```
iter 9 value -0.394816
```

```
iter 10 value -0.394842
```

```
iter 11 value -0.394859
```

```
iter 12 value -0.394864
```

```
iter 13 value -0.394866
```

```
iter 14 value -0.394867
```

```
iter 14 value -0.394867
```

```
iter 14 value -0.394867
```

```
final value -0.394867
```

```
converged
```

```
initial value -0.359931
```

```

iter    2 value -0.360669
iter    3 value -0.361161
iter    4 value -0.361339
iter    5 value -0.361439
iter    6 value -0.361454
iter    7 value -0.361457
iter    8 value -0.361457
iter    8 value -0.361457
final   value -0.361457

```

converged

```
> z2ts.fit2
```

```
$fit
```

Call:

```

stats::arima(x = xdata, order = c(p, d, q), seasonal =
list(order = c(P, D,
      Q), period = S), xreg = xmean, include.mean = FALSE,
optim.control = list(trace = trc,
      REPORT = 1, reltol = tol))

```

Coefficients:

	ar1	ar2	xmean
	1.0436	-0.2495	9.0473
s.e.	0.0983	0.1008	0.3319

```

sigma^2 estimated as 0.4788:  log likelihood = -103.63,
aic = 215.27

```

```
$degrees_of_freedom
```

```
[1] 95
```

```
$ttable
```

	Estimate	SE	t.value	p.value
ar1	1.0436	0.0983	10.6185	0.0000

```
ar2      -0.2495  0.1008 -2.4754   0.0151
xmean     9.0473  0.3319 27.2612   0.0000
```

\$AIC


```
[1] 0.3247953
```

\$AICc

```
[1] 0.3495923
```

\$BIC

```
[1] -0.5960731
```



النموذج المقترح هو

$$z_t = 9.047 + 1.044(z_{t-1} - 9.047) - 0.2495(z_{t-2} - 9.047) + a_t, \quad a_t \sim WN(0, 0.479) \quad \forall t$$

مقدرات المعالم وإنحرافات المعيارية وقيم t لها هي

$$\hat{\phi}_1 = 1.0436 \quad se(\hat{\phi}_1) = 0.0983 \quad t = 10.6185$$

$$\hat{\phi}_2 = -0.2495 \quad se(\hat{\phi}_2) = 0.1008 \quad t = -2.4754$$

$$\hat{\mu} = 9.0473 \quad se(\hat{\mu}) = 0.3319 \quad t = 27.2612$$

$$\hat{\sigma}^2 = 0.4788 \quad df = 95$$

نلاحظ ان جميع المقدرات معنوية عند $\alpha = 0.05$

لكي نقبل بهذا النموذج علي انه مناسب للتنبؤ نجري إختبارات علي البواقي

```
> rs <- fit1$residuals
> t.test(rs)
```

One Sample t-test

```
data:  rs
t = 1.6175, df = 177, p-value = 0.1075
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 -0.02879064  0.29045085
sample estimates:
mean of x
0.1308301
```

واضح جدا ان الأختبار غير معنوي (ملاحظة الـ P-Value هي إحتمال ان الفرضية الصفرية صحيحة)

نختبر عشوائية البواقي

```
> runs.test(rs)
```

Runs Test

```
data:  rs
statistic = -2.255, runs = 75, n1 = 89, n2 = 89, n = 178,
p-value = 0.02413
alternative hypothesis: nonrandomness
```



أي لايمكننا رفض فرضية عشوائية البواقي

نفحص الترابط الذاتي والترابط الذاتي الجزئي

```
> par(mfrow=c(2,1))
```

```
> acf(rs)
```


```
> pacf(rs)
```



واضح جدا انماط الضجة البيضاء


يبقي فحص طبيعية البواقي

```
> hist(rs)
```



```
> qqnorm(rs)
```

```
> qqline(rs)
```



```
> ks.test(rs, pnorm)
```

One-sample Kolmogorov-Smirnov test

```
data: rs
```

```
D = 0.15033, p-value = 0.0006411
```

```
alternative hypothesis: two-sided
```

توجد مشكلة مع توزيع البواقي و يترك إيجاد نموذج مناسب للبيانات ولكن نستطيع ان نقول ان

البواقي لها توزيع طبيعي (أي $a_t \sim IIDN(0, 0.4788)$)

الرسم التالي للتنبؤات لخمسة قيم مستقبلية وفترات 95% تنبؤ لها

```
> z2ts.f2 <- sarima.for(z2ts, 5, 2, 0, 0, 0, 0, 0, -1)
```

```
> z2ts.f2
```

```
$pred
```

```
Time Series:
```

```
Start = 99
```

```
End = 103
```

Frequency = 1

[1] 9.789559 9.594219 9.432885 9.313251 9.228652

\$se


Time Series:

Start = 99

End = 103

Frequency = 1

[1] 0.6919687 1.0001591 1.1566667 1.2326774 1.2686092



تمرين: طبق علي المشاهدات السابقة نموذج $AR(1)$ وقارن بين النتائج

الفصل الثامن

مثال على تحليل البواقي ومعايير اختيار النموذج المناسب

: Example on Residual Analysis and Model Selection Criteria

لقد عرفنا سابقا البواقي علي انها 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 البواقي:

$$e_i = z_i - \hat{z}_i, \quad i = 1, 2, \dots, n$$

والبواقي هي مقدرات الأخطاء في النموذج أي $\hat{a}_i = e_i, i = 1, 2, \dots, n$ ولهذا يجب ان تحقق الشروط المفروضة علي الأخطاء في هذا النموذج والتي منها:

1- متوسط الأخطاء يساوي الصفر

2- الأخطاء عشوائية و غير مترابطة أو مستقلة (وفي كثير من النماذج نفترض ان الأخطاء لها توزيع طبيعي مستقل ومتطابق بمتوسط صفري وتباين σ^2 أي $a_i \sim IIDN(0, \sigma^2)$)

لهذا فإننا نجري تحليلا وهو مجموعة من الإختبارات علي البواقي لنري فيما إذا كانت تحقق هذه الشروط وفي هذه الحالة نعتبر النموذج المطبق مقبولا أما إذا فشل احد هذه الإختبارات فيجب علينا إعادة النظر وإقتراح نموذج آخر
أولا: إختبار المتوسط

$$H_0 : E(a_i) = 0$$

$$H_1 : E(a_i) \neq 0$$

وهو إختبار بذيلين ونستخدم فيه الإحصائية $u = \frac{\bar{e}}{se(\bar{e})}$ والتي لها توزيع طبيعي قياسي فعند

مستوى معنوية $\alpha = 0.05$ نعتبر ان $E(a_i) = 0$ إذا كانت $|u| < 1.96$ (هذا علي إعتبار ان حجم العينة اكبر من 30 وحدة وهذا دائما متحقق للمتسلسلات الزمنية التي ندرسها)

مثال:


سوف نطبق متوسط متحرك من الدرجة الثالثة علي المتغير z_t وهي الدخل ربع السنوي لشركة Johnson and Johnson يوجد 84 ربع سنوي اي 21 سنة مقاسة من الربع الاول لسنة 1960 وحتى الربع الاخير لسنة 1980
سوف نطبق متوسطات متحركة من الدرجة 3 و 5

$$> k3 = c(1,1,1)$$

```

> k3 = k / sum(k3)
> fjj3 = filter(jj, sides=2, k3)
> plot(jj)
> lines(fjj3, col="red")

```




لاحظ ان المتسلسلة الأصلية باللون الاسود و المتسلسلة الممهدة بالمتوسط المتحرك من الدرجة 3 باللون الاحمر.

```

> k5 = c( rep(1,5) )
> k5 = k5 / sum(k5)
> fjj5 = filter(jj, sides=2, k5)
> plot(jj)
> lines(fjj5, col="blue")
> resid5 = jj - fjj5

```



المتسلسلة الأصلية باللون الاسود و المتسلسلة الممهدة بالمتوسط المتحرك من الدرجة 5 باللون الازرق.

الآن نختبر متوسط البواقي للتطبيقات

```
> t.test(resid3)
```

One Sample t-test

```
data: resid3
```

```
t = 0.1936, df = 81, p-value = 0.847
```

```
alternative hypothesis: true mean is not equal to 0
```

```
95 percent confidence interval:
```

```
-0.1632910 0.1984943
```

```
sample estimates:
```

```
mean of x
```

```
0.01760163
```

لاحظ ان $p\text{-value} = 0.847$ لانرفض الفرضية الصفرية.

```
> resid5 = jj -fjj5
```

```
> t.test(resid5)
```

One Sample t-test

```
data: resid5
t = 0.055478, df = 79, p-value = 0.9559
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 -0.1796211  0.1899211
sample estimates:
mean of x
 0.00515
```

لاحظ ان $p\text{-value} = 0.9559$ لانرفض الفرضية الصفرية.

ملاحظة: في R عندما يكون الانحراف المعياري (او التباين) غير معروف يستخدم Ttest.
ثانيا: نختبر عشوائية البواقي بواسطة اختبار الجري Runs test حول المتوسط وحول الصفر
تابع المثال:

```
> runs.test(resid3)
```

Runs Test

```
data: resid3
statistic = 3.5558, runs = 58, n1 = 41, n2 = 41, n = 82,
p-value = 0.0003768
alternative hypothesis: nonrandomness
> runs.test(resid5)
```



Runs Test

```
data: resid5
statistic = 0, runs = 41, n1 = 40, n2 = 40, n = 80, p-
value = 1
alternative hypothesis: nonrandomness
```


نلاحظ انه في كلتا الحالتين لانرفض عشوائية البواقي

ثالثاً: نختبر ترابط أو إستقلال البواقي بواسطة إختبار الترابط الذاتي Autocorrelation test
تابع المثال:

```
> library(tseries)
> res3 = na.remove(resid3)
> acf(res3)
> pacf(res3)
```



```
> res5 = na.remove(resid5)
> par(mfrow=c(2,1))
> acf(res5)
> pacf(res5)
```

يوجد ترابط بين البواقي

رابعاً: نختبر في ما إذا كانت البواقي موزعة طبيعياً

تابع المثال:

```
> ks.test(resid3, pnorm)
```

One-sample Kolmogorov-Smirnov test

```
data: resid3
```

```
D = 0.25262, p-value = 5.699e-05
```

```
alternative hypothesis: two-sided
```

```
Warning message:
```

```
In ks.test(resid3, pnorm) :
```

```
ties should not be present for the Kolmogorov-Smirnov
test
```

```
> ks.test(resid5, pnorm)
```

One-sample Kolmogorov-Smirnov test

```
data: resid5
D = 0.25199, p-value = 7.736e-05
alternative hypothesis: two-sided
```

Warning message:


```
In ks.test(resid5, pnorm) :
```

ties should not be present for the Kolmogorov-Smirnov test


لاحظ الـ P-Value الناتجة وهي اصغر من 0.05 أي نرفض فرضية التوزيع الطبيعي عند $\alpha = 0.05$ هناك ايضا إختبار آخر للطبيعية هو الـ Q-Q Plot والذي يبين مدى تطابق مشاهدات ما مع توزيع معين

```
> qqnorm(resid3)
```

```
> qqline(resid3)
```



```
> hist(resid3)
```



لاحظ ان في جميع الحالات فإننا نرفض ان البواقي لها توزيع طبيعي.
ملاحظة اخيرة: يبدو ان البواقي لا تحقق معظم الشروط وهذا يجعلنا نرفض جودة التطبيق لطريقة
المتوسط المتحرك من الدرجة الثالثة .
يترك كتمرين المتوسط المتحرك من الدرجة 5.

الفصل التاسع

تحليل أو تفكيك المتسلسلة الى مركبات :Decomposition Method

ينظر إلى المتسلسلة الزمنية على انها مكونة من عدة مركبات أو اجزاء متحدة مع بعضها لتكوين هذه المتسلسلة،

لنفترض ان 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 تنمذج الإتجاه العام الذي تنحي أو تنجرف اليه المتسلسلة و S_t مركبة موسمية وتنمذج التأثير الموسمي (إذا وجد) وهو التغير الذي يحدث للمتسلسلة نتيجة التأثيرات الموسمية مثل الشهرية والسنوية و C_t مركبة دورية (إذا وجدت) و تنمذج منحى أو إتجاه يتكرر بعد فترات زمنية طويلة غير موسمية و E_t مركبة الخطأ وتشمل جميع العوامل الاخرى التي تؤثر على المتسلسلة والتي لايمكن نمذجتها ضمناً أو التي لايمكن مشاهدتها او قياسها. النموذج السابق يسمى بالنموذج 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 الى 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 علي البنزين بملايين 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
```

أولا نرسم المتسلسلة في مخطط زمني

```
> GasDemand <-c(87695,86890,96442,...)
> gd <- ts(GasDemand, frequency = 12, start = 1960)
> plot.ts(gd)
```



نلاحظ ان المتسلسلة الزمنية موسمية ومنجرفة الى الاعلى

اولا: تطبيق النموذج الإضافي: $z_t = T_t + S_t + E_t, t = 1, 2, \dots, n$

```
> gdd <- decompose(gd)
```

```
> gdd
```

```
$x
```

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep
Oct	Nov	Dec							
1960	87695	86890	96442	98133	113615	123924	128924	134775	117357
	114626	107677	108087						
1961	92188	88591	98683	99207	125485	124677	132543	140735	124008
	121194	111634	111565						
1962	101007	94228	104255	106922	130621	125251	140318	146174	122318
	128770	117518	115492						
1963	108497	100482	106140	118581	132371	132042	151938	150997	130931
	137018	121271	123548						
1964	109894	106061	112539	125745	136251	140892	158390	148314	144148
	140138	124075	136485						
1965	109895	109044	122499	124264	142296	150693	163331	165837	151731
	142491	140229	140463						
1966	116963	118049	137869	127392	154166	160227	165869	173522	155828
	153771	143963	143898						
1967	124046	121260	138870	129782	162312	167211	172897	189689	166496
	160754	155582	145936						

1968 139625 137361 138963 155301 172026 165004 185861 190270 163903
 174270 160272 165614
 1969 146182 137728 148932 156751 177998 174559 198079 189073 175702
 180097 155202 174508
 1970 154277 144998 159644 168646 166273 190176 205541 193657 182617
 189614 174176 184416
 1971 158167 156261 176353 175720 193939 201269 218960 209861 198688
 190474 194502 190755
 1972 166286 170699 181468 174241 210802 212262 218099 229001 203200
 212557 197095 193693
 1973 188992 175347 196265 203526 227443 233038 234119 255133 216478
 232868 221616 209893
 1974 194784 189756 193522 212870 248565 221532 252642 255007 206826
 233231 212678 217173
 1975 199024 191813 195997 208684 244113 243108 255918 244642 237579
 237579 217775 227621

\$seasonal

	Jan	Feb	Mar	Apr	May
Jun	Jul	Aug	Sep	Oct	
1960	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1961	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1962	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1963	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1964	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1965	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1966	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1967	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1968	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1969	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	

1970	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1971	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1972	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1973	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1974	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	
1975	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
10941.689	23703.447	26071.681	4716.086	7575.258	

	Nov	Dec
1960	-4719.856	-3811.017
1961	-4719.856	-3811.017
1962	-4719.856	-3811.017
1963	-4719.856	-3811.017
1964	-4719.856	-3811.017
1965	-4719.856	-3811.017
1966	-4719.856	-3811.017
1967	-4719.856	-3811.017
1968	-4719.856	-3811.017
1969	-4719.856	-3811.017
1970	-4719.856	-3811.017
1971	-4719.856	-3811.017
1972	-4719.856	-3811.017
1973	-4719.856	-3811.017
1974	-4719.856	-3811.017
1975	-4719.856	-3811.017

\$trend

	Jan	Feb	Mar	Apr	May	Jun	Jul
Aug	Sep	Oct	Nov	Dec			
1960	NA	NA	NA	NA	NA	NA	110032.6
110290.7	110455.0	110593.1	111132.4	111658.4			
1961	111840.5	112239.7	112765.1	113315.9	113754.5	114064.2	114576.6
115179.0	115646.0	116199.6	116735.1	116973.0			
1962	117320.9	117871.5	118027.7	118272.9	118833.7	119242.5	119718.2
120290.9	120630.0	121194.4	121753.1	122109.0			
1963	122876.1	123561.2	124121.0	124823.6	125323.6	125815.7	126209.5
126500.2	126999.3	127564.4	128024.6	128555.0			

1964	129192.6	129349.6	129788.5	130469.2	130716.1	131372.0	131911.0
	132035.4	132574.7	132928.0	133118.1	133778.4		
1965	134392.6	135328.6	136374.7	136788.7	137559.8	138398.7	138858.9
	139528.6	140544.2	141315.0	141939.9	142831.8		
1966	143334.8	143760.7	144251.6	144892.3	145517.9	145816.6	146254.9
	146683.8	146859.3	147000.6	147439.6	148070.0		
1967	148653.8	149620.3	150738.4	151473.9	152249.0	152818.0	153552.0
	154872.0	155546.8	156614.0	158082.0	158394.8		
1968	158843.0	159407.4	159323.5	159778.7	160537.2	161552.6	162645.7
	162934.2	163364.9	163840.7	164149.9	164796.9		
1969	165704.1	166163.3	166605.0	167339.5	167371.0	167530.3	168238.2
	168878.4	169627.7	170569.6	170576.7	170738.9		
1970	171700.5	172202.4	172681.5	173366.2	174553.3	175756.7	176331.7
	176963.0	178128.5	179119.5	180567.0	182182.0		
1971	183203.3	184437.6	185782.4	186487.8	187370.6	188481.6	189084.0
	190023.9	190838.6	190990.1	191631.1	192791.8		
1972	193214.0	193975.6	194961.1	196069.2	197097.4	197327.8	198396.3
	199536.1	200346.3	202183.0	204096.6	205655.7		
1973	207188.8	208945.2	210587.3	211986.8	213854.8	215551.5	216467.8
	217309.5	217795.6	218070.7	219340.1	219740.7		
1974	220033.1	220799.7	220392.2	220005.2	219647.9	219578.8	220058.8
	220321.2	220510.0	220438.8	220078.8	220792.3		
1975	221827.8	221532.5	222382.0	223844.5	224238.0	224885.8	NA
NA	NA	NA	NA	NA			

\$random

	Jan	Feb	Mar	Apr
May	Jun	Jul	Aug	
1960	NA	NA	NA	NA
NA	NA	-4.812072e+03	-1.587389e+03	
1961	1.622236e+03	2.827325e+03	1.678269e+03	-2.715236e+03
	1.302986e+03	-3.289389e+02	-5.737072e+03	-5.156389e+02
1962	4.960903e+03	2.832533e+03	1.987728e+03	4.276389e+01
	1.359694e+03	-4.933231e+03	-3.103697e+03	-1.885972e+02
1963	6.895694e+03	3.396783e+03	-2.220647e+03	5.151097e+03
	3.380181e+03	-4.715356e+03	2.025011e+03	-1.574889e+03
1964	1.976194e+03	3.187367e+03	-1.489147e+03	6.669431e+03
	4.892639e+03	-1.421647e+03	2.775511e+03	-9.793056e+03
1965	-3.222847e+03	1.913667e+02	1.884686e+03	-1.131028e+03
	5.691389e+03	1.352644e+03	7.686361e+02	2.366944e+02

1966	-5.096972e+03	7.642833e+02	9.377769e+03	-6.106653e+03	-
	1.779472e+03	3.468686e+03	-4.089322e+03	7.665278e+02	
1967	-3.333056e+03	-1.884300e+03	3.891978e+03	-1.029819e+04	-
	3.645139e+02	3.451311e+03	-4.358489e+03	8.745278e+03	
1968	2.056778e+03	4.429617e+03	-4.600147e+03	6.916014e+03	
	1.061194e+03	-7.490272e+03	-4.881556e+02	1.264111e+03	
1969	1.752694e+03	-1.959300e+03	-1.912647e+03	8.052222e+02	
	1.994444e+02	-3.913022e+03	6.137344e+03	-5.877097e+03	
1970	3.851278e+03	-7.284250e+02	2.722853e+03	6.673472e+03	-
	1.870789e+04	3.477561e+03	5.505886e+03	-9.377722e+03	
1971	-3.761514e+03	-1.700592e+03	6.331019e+03	6.258472e+02	-
	3.859139e+03	1.845686e+03	6.172511e+03	-6.234597e+03	
1972	-5.653181e+03	3.199408e+03	2.267311e+03	-1.043453e+04	
	3.277069e+03	3.992478e+03	-4.000781e+03	3.393236e+03	
1973	3.077944e+03	-7.122175e+03	1.438144e+03	2.932889e+03	
	3.160653e+03	6.544811e+03	-6.052281e+03	1.175178e+04	
1974	-3.974347e+03	-4.567675e+03	-1.110986e+04	4.258472e+03	
	1.848953e+04	-8.988522e+03	8.879719e+03	8.614111e+03	
1975	-1.529056e+03	-3.243467e+03	-1.062456e+04	-3.766819e+03	
	9.447403e+03	7.280561e+03	NA	NA	

	Sep	Oct	Nov	Dec
1960	2.185956e+03	-3.542342e+03	1.264439e+03	2.396417e+02
1961	3.645914e+03	-2.580883e+03	-3.812278e+02	-1.596983e+03
1962	-3.028128e+03	3.666667e-01	4.847722e+02	-2.805942e+03
1963	-7.843778e+02	1.878325e+03	-2.033728e+03	-1.195983e+03
1964	6.857247e+03	-3.652167e+02	-4.323269e+03	6.517642e+03
1965	6.470664e+03	-6.399258e+03	3.008939e+03	1.442267e+03
1966	4.252622e+03	-8.048417e+02	1.243272e+03	-3.609833e+02
1967	6.233122e+03	-3.435217e+03	2.219856e+03	-8.647775e+03
1968	-4.177961e+03	2.854075e+03	8.419389e+02	4.628142e+03
1969	1.358247e+03	1.952117e+03	-1.065485e+04	7.580142e+03
1970	-2.276278e+02	2.919242e+03	-1.671144e+03	6.045058e+03
1971	3.133289e+03	-8.091383e+03	7.590731e+03	1.774225e+03
1972	-1.862378e+03	2.798700e+03	-2.281769e+03	-8.151650e+03
1973	-6.033711e+03	7.222075e+03	6.995772e+03	-6.036733e+03
1974	-1.840013e+04	5.216992e+03	-2.680978e+03	1.916833e+02
1975	NA	NA	NA	NA

\$figure

[1]	-21274.778	-26475.992	-15760.394	-11393.681	10427.556
	10941.689	23703.447	26071.681	4716.086	7575.258

```
[11] -4719.856 -3811.017
```

```
$type
```


```
[1] "additive"
```

```
attr(,"class")
```

```
[1] "decomposed.ts"
```

```
> plot(gdd)
```

```
>
```




forecast باستخدام الدالة `stl` من مكتبة `forecast`

```
> fit <-
```

```
stl(gd,t.window=15,s.window="periodic",robust=TRUE)
```


```
> plot(fit)
```



```

> gdadj <- seasadj(fit)
> plot(naive(gdadj), xlab="New orders index", main="Naive
forecasts of seasonally adjusted data")
> fcast <- forecast(fit, method="naive")
> plot(fcast, ylab="New orders index")

```



ثانياً: تطبيق النموذج التضاعفي: $z_t = T_t S_t + E_t, \quad t = 1, 2, \dots, n$

```

> gdm <- decompose(gd, type = c("multiplicative"), filter = NULL)
> gdm

```

\$x

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep
Oct	Nov	Dec							
1960	87695	86890	96442	98133	113615	123924	128924	134775	117357
114626	107677	108087							
1961	92188	88591	98683	99207	125485	124677	132543	140735	124008
121194	111634	111565							
1962	101007	94228	104255	106922	130621	125251	140318	146174	122318
128770	117518	115492							
1963	108497	100482	106140	118581	132371	132042	151938	150997	130931
137018	121271	123548							
1964	109894	106061	112539	125745	136251	140892	158390	148314	144148
140138	124075	136485							
1965	109895	109044	122499	124264	142296	150693	163331	165837	151731
142491	140229	140463							
1966	116963	118049	137869	127392	154166	160227	165869	173522	155828
153771	143963	143898							
1967	124046	121260	138870	129782	162312	167211	172897	189689	166496
160754	155582	145936							
1968	139625	137361	138963	155301	172026	165004	185861	190270	163903
174270	160272	165614							
1969	146182	137728	148932	156751	177998	174559	198079	189073	175702
180097	155202	174508							
1970	154277	144998	159644	168646	166273	190176	205541	193657	182617
189614	174176	184416							
1971	158167	156261	176353	175720	193939	201269	218960	209861	198688
190474	194502	190755							
1972	166286	170699	181468	174241	210802	212262	218099	229001	203200
212557	197095	193693							
1973	188992	175347	196265	203526	227443	233038	234119	255133	216478
232868	221616	209893							
1974	194784	189756	193522	212870	248565	221532	252642	255007	206826
233231	212678	217173							
1975	199024	191813	195997	208684	244113	243108	255918	244642	237579
237579	217775	227621							

\$seasonal

	Jan	Feb	Mar	Apr	May	Jun
Jul	Aug	Sep	Oct	Nov	Dec	
1960	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	

1961	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1962	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1963	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1964	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1965	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1966	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1967	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1968	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1969	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1970	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1971	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1972	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1973	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1974	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1975	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	

\$trend

	Jan	Feb	Mar	Apr	May	Jun	Jul
Aug	Sep	Oct	Nov	Dec			
1960	NA	NA	NA	NA	NA	NA	110032.6
	110290.7	110455.0	110593.1	111132.4	111658.4		
1961	111840.5	112239.7	112765.1	113315.9	113754.5	114064.2	114576.6
	115179.0	115646.0	116199.6	116735.1	116973.0		
1962	117320.9	117871.5	118027.7	118272.9	118833.7	119242.5	119718.2
	120290.9	120630.0	121194.4	121753.1	122109.0		

1963	122876.1	123561.2	124121.0	124823.6	125323.6	125815.7	126209.5
	126500.2	126999.3	127564.4	128024.6	128555.0		
1964	129192.6	129349.6	129788.5	130469.2	130716.1	131372.0	131911.0
	132035.4	132574.7	132928.0	133118.1	133778.4		
1965	134392.6	135328.6	136374.7	136788.7	137559.8	138398.7	138858.9
	139528.6	140544.2	141315.0	141939.9	142831.8		
1966	143334.8	143760.7	144251.6	144892.3	145517.9	145816.6	146254.9
	146683.8	146859.3	147000.6	147439.6	148070.0		
1967	148653.8	149620.3	150738.4	151473.9	152249.0	152818.0	153552.0
	154872.0	155546.8	156614.0	158082.0	158394.8		
1968	158843.0	159407.4	159323.5	159778.7	160537.2	161552.6	162645.7
	162934.2	163364.9	163840.7	164149.9	164796.9		
1969	165704.1	166163.3	166605.0	167339.5	167371.0	167530.3	168238.2
	168878.4	169627.7	170569.6	170576.7	170738.9		
1970	171700.5	172202.4	172681.5	173366.2	174553.3	175756.7	176331.7
	176963.0	178128.5	179119.5	180567.0	182182.0		
1971	183203.3	184437.6	185782.4	186487.8	187370.6	188481.6	189084.0
	190023.9	190838.6	190990.1	191631.1	192791.8		
1972	193214.0	193975.6	194961.1	196069.2	197097.4	197327.8	198396.3
	199536.1	200346.3	202183.0	204096.6	205655.7		
1973	207188.8	208945.2	210587.3	211986.8	213854.8	215551.5	216467.8
	217309.5	217795.6	218070.7	219340.1	219740.7		
1974	220033.1	220799.7	220392.2	220005.2	219647.9	219578.8	220058.8
	220321.2	220510.0	220438.8	220078.8	220792.3		
1975	221827.8	221532.5	222382.0	223844.5	224238.0	224885.8	NA
NA	NA	NA	NA	NA			

\$random

	Jan	Feb	Mar	Apr	May	Jun
Jul	Aug	Sep	Oct	Nov	Dec	
1960	NA	NA	NA	NA	NA	NA
	1.0154649	1.0455756	1.0266339	0.9903915	1.0008600	0.9925421
1961	0.9539934	0.9487674	0.9714236	0.9444431	1.0386618	1.0246523
	1.0025669	1.0454759	1.0361220	0.9966166	0.9878392	0.9779330
1962	0.9964291	0.9609213	0.9805149	0.9752280	1.0349610	0.9846678
	1.0157940	1.0397342	0.9797758	1.0152756	0.9970469	0.9697754
1963	1.0219287	0.9775132	0.9492373	1.0248088	0.9945135	0.9838233
	1.0433423	1.0213207	0.9961689	1.0263602	0.9784863	0.9854022
1964	0.9844794	0.9856145	0.9625157	1.0396974	0.9814348	1.0053642
	1.0406369	0.9611184	1.0506060	1.0073753	0.9628048	1.0460821

```

1965  0.9463956  0.9685647  0.9971025  0.9799851  0.9739840  1.0207066
1.0194066 1.0169583 1.0431651 0.9634981 1.0205269 1.0083329
1966  0.9444245  0.9870488  1.0609307  0.9484646  0.9975230  1.0300739
0.9828958 1.0121793 1.0252644 0.9995559 1.0086209 0.9964476
1967  0.9657771  0.9741898  1.0226466  0.9242748  1.0037998  1.0257229
0.9758532 1.0479828 1.0342715 0.9808058 1.0166421 0.9446878
1968  1.0173382  1.0357896  0.9681894  1.0485276  1.0089486  0.9574593
0.9903718 0.9991785 0.9694380 1.0163719 1.0085749 1.0304214
1969  1.0210122  0.9963311  0.9922954  1.0105001  1.0013495  0.9767615
1.0203905 0.9579446 1.0008565 1.0089195 0.9398721 1.0479721
1970  1.0399198  1.0121370  1.0262373  1.0493878  0.8969007  1.0143397
1.0102312 0.9363445 0.9906027 1.0115311 0.9964169 1.0379107
1971  0.9992010  1.0183984  1.0537060  1.0164712  0.9745734  1.0010312
1.0036043 0.9449493 1.0059981 0.9529640 1.0484535 1.0145049
1972  0.9960644  1.0577924  1.0332210  0.9586617  1.0070353  1.0083787
0.9527361 0.9819762 0.9800183 1.0045751 0.9975414 0.9656951
1973  1.0557165  1.0087476  1.0345510  1.0357036  1.0013926  1.0134806
0.9373373 1.0045530 0.9604094 1.0203855 1.0436966 0.9793865
1974  1.0245554  1.0330317  0.9747094  1.0437726  1.0655251  0.9457704
0.9949915 0.9903320 0.9062929 1.0109974 0.9982411 1.0085295
1975  1.0383880  1.0407758  0.9783426  1.0056969  1.0250202  1.0133910
NA      NA      NA      NA      NA      NA

```

```
$figure
```

```

[1]  0.8640319  0.8319237  0.9008633  0.9269912  1.0620604  1.0667441
1.1538448 1.1687321 1.0349234 1.0465218 0.9680746 0.9752888

```


```
$type
```

```
[1] "multiplicative"
```

```
attr(,"class")
```

```
[1] "decomposed.ts"
```

```
> plot(gdm)
```

```
> gdm <- decompose(gd, type = c("multiplicative"), filter = NULL)
```

```
> gdm
```

```
$x
```

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep
Oct	Nov	Dec							
1960	87695	86890	96442	98133	113615	123924	128924	134775	117357
	114626	107677	108087						
1961	92188	88591	98683	99207	125485	124677	132543	140735	124008
	121194	111634	111565						
1962	101007	94228	104255	106922	130621	125251	140318	146174	122318
	128770	117518	115492						
1963	108497	100482	106140	118581	132371	132042	151938	150997	130931
	137018	121271	123548						
1964	109894	106061	112539	125745	136251	140892	158390	148314	144148
	140138	124075	136485						
1965	109895	109044	122499	124264	142296	150693	163331	165837	151731
	142491	140229	140463						
1966	116963	118049	137869	127392	154166	160227	165869	173522	155828
	153771	143963	143898						
1967	124046	121260	138870	129782	162312	167211	172897	189689	166496
	160754	155582	145936						
1968	139625	137361	138963	155301	172026	165004	185861	190270	163903
	174270	160272	165614						

1969 146182 137728 148932 156751 177998 174559 198079 189073 175702
 180097 155202 174508
 1970 154277 144998 159644 168646 166273 190176 205541 193657 182617
 189614 174176 184416
 1971 158167 156261 176353 175720 193939 201269 218960 209861 198688
 190474 194502 190755
 1972 166286 170699 181468 174241 210802 212262 218099 229001 203200
 212557 197095 193693
 1973 188992 175347 196265 203526 227443 233038 234119 255133 216478
 232868 221616 209893
 1974 194784 189756 193522 212870 248565 221532 252642 255007 206826
 233231 212678 217173
 1975 199024 191813 195997 208684 244113 243108 255918 244642 237579
 237579 217775 227621

\$seasonal

	Jan	Feb	Mar	Apr	May	Jun
Jul	Aug	Sep	Oct	Nov	Dec	
1960	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1961	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1962	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1963	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1964	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1965	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1966	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1967	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1968	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1969	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1970	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	

1971	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1972	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1973	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1974	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	
1975	0.8640319	0.8319237	0.9008633	0.9269912	1.0620604	1.0667441
1.1538448	1.1687321	1.0349234	1.0465218	0.9680746	0.9752888	

\$trend

	Jan	Feb	Mar	Apr	May	Jun	Jul
Aug	Sep	Oct	Nov	Dec			
1960	NA	NA	NA	NA	NA	NA	110032.6
110290.7	110455.0	110593.1	111132.4	111658.4			
1961	111840.5	112239.7	112765.1	113315.9	113754.5	114064.2	114576.6
115179.0	115646.0	116199.6	116735.1	116973.0			
1962	117320.9	117871.5	118027.7	118272.9	118833.7	119242.5	119718.2
120290.9	120630.0	121194.4	121753.1	122109.0			
1963	122876.1	123561.2	124121.0	124823.6	125323.6	125815.7	126209.5
126500.2	126999.3	127564.4	128024.6	128555.0			
1964	129192.6	129349.6	129788.5	130469.2	130716.1	131372.0	131911.0
132035.4	132574.7	132928.0	133118.1	133778.4			
1965	134392.6	135328.6	136374.7	136788.7	137559.8	138398.7	138858.9
139528.6	140544.2	141315.0	141939.9	142831.8			
1966	143334.8	143760.7	144251.6	144892.3	145517.9	145816.6	146254.9
146683.8	146859.3	147000.6	147439.6	148070.0			
1967	148653.8	149620.3	150738.4	151473.9	152249.0	152818.0	153552.0
154872.0	155546.8	156614.0	158082.0	158394.8			
1968	158843.0	159407.4	159323.5	159778.7	160537.2	161552.6	162645.7
162934.2	163364.9	163840.7	164149.9	164796.9			
1969	165704.1	166163.3	166605.0	167339.5	167371.0	167530.3	168238.2
168878.4	169627.7	170569.6	170576.7	170738.9			
1970	171700.5	172202.4	172681.5	173366.2	174553.3	175756.7	176331.7
176963.0	178128.5	179119.5	180567.0	182182.0			
1971	183203.3	184437.6	185782.4	186487.8	187370.6	188481.6	189084.0
190023.9	190838.6	190990.1	191631.1	192791.8			
1972	193214.0	193975.6	194961.1	196069.2	197097.4	197327.8	198396.3
199536.1	200346.3	202183.0	204096.6	205655.7			

1973	207188.8	208945.2	210587.3	211986.8	213854.8	215551.5	216467.8
	217309.5	217795.6	218070.7	219340.1	219740.7		
1974	220033.1	220799.7	220392.2	220005.2	219647.9	219578.8	220058.8
	220321.2	220510.0	220438.8	220078.8	220792.3		
1975	221827.8	221532.5	222382.0	223844.5	224238.0	224885.8	NA
NA	NA	NA	NA	NA			

\$random

	Jan	Feb	Mar	Apr	May	Jun
Jul	Aug	Sep	Oct	Nov	Dec	
1960	NA	NA	NA	NA	NA	NA
	1.0154649	1.0455756	1.0266339	0.9903915	1.0008600	0.9925421
1961	0.9539934	0.9487674	0.9714236	0.9444431	1.0386618	1.0246523
	1.0025669	1.0454759	1.0361220	0.9966166	0.9878392	0.9779330
1962	0.9964291	0.9609213	0.9805149	0.9752280	1.0349610	0.9846678
	1.0157940	1.0397342	0.9797758	1.0152756	0.9970469	0.9697754
1963	1.0219287	0.9775132	0.9492373	1.0248088	0.9945135	0.9838233
	1.0433423	1.0213207	0.9961689	1.0263602	0.9784863	0.9854022
1964	0.9844794	0.9856145	0.9625157	1.0396974	0.9814348	1.0053642
	1.0406369	0.9611184	1.0506060	1.0073753	0.9628048	1.0460821
1965	0.9463956	0.9685647	0.9971025	0.9799851	0.9739840	1.0207066
	1.0194066	1.0169583	1.0431651	0.9634981	1.0205269	1.0083329
1966	0.9444245	0.9870488	1.0609307	0.9484646	0.9975230	1.0300739
	0.9828958	1.0121793	1.0252644	0.9995559	1.0086209	0.9964476
1967	0.9657771	0.9741898	1.0226466	0.9242748	1.0037998	1.0257229
	0.9758532	1.0479828	1.0342715	0.9808058	1.0166421	0.9446878
1968	1.0173382	1.0357896	0.9681894	1.0485276	1.0089486	0.9574593
	0.9903718	0.9991785	0.9694380	1.0163719	1.0085749	1.0304214
1969	1.0210122	0.9963311	0.9922954	1.0105001	1.0013495	0.9767615
	1.0203905	0.9579446	1.0008565	1.0089195	0.9398721	1.0479721
1970	1.0399198	1.0121370	1.0262373	1.0493878	0.8969007	1.0143397
	1.0102312	0.9363445	0.9906027	1.0115311	0.9964169	1.0379107
1971	0.9992010	1.0183984	1.0537060	1.0164712	0.9745734	1.0010312
	1.0036043	0.9449493	1.0059981	0.9529640	1.0484535	1.0145049
1972	0.9960644	1.0577924	1.0332210	0.9586617	1.0070353	1.0083787
	0.9527361	0.9819762	0.9800183	1.0045751	0.9975414	0.9656951
1973	1.0557165	1.0087476	1.0345510	1.0357036	1.0013926	1.0134806
	0.9373373	1.0045530	0.9604094	1.0203855	1.0436966	0.9793865
1974	1.0245554	1.0330317	0.9747094	1.0437726	1.0655251	0.9457704
	0.9949915	0.9903320	0.9062929	1.0109974	0.9982411	1.0085295

```
1975  1.0383880  1.0407758  0.9783426  1.0056969  1.0250202  1.0133910
NA      NA      NA      NA      NA      NA
```

```
$figure
```

```
[1]  0.8640319  0.8319237  0.9008633  0.9269912  1.0620604  1.0667441
1.1538448 1.1687321 1.0349234 1.0465218 0.9680746 0.9752888
```

```
$type
```

```
[1] "multiplicative"
```

```
attr(,"class")
```

```
[1] "decomposed.ts"
```


```
> plot(gdm)
```

```
> predict(gd)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 1976	209498.7	200385.0	218612.3	195560.5	223436.8
Feb 1976	205582.0	196553.6	214610.4	191774.2	219389.8
Mar 1976	216637.5	207052.2	226222.8	201978.0	231296.9
Apr 1976	221799.3	211904.3	231694.3	206666.2	236932.5
May 1976	244328.6	233388.9	255268.4	227597.7	261059.5
Jun 1976	245544.7	234448.1	256641.2	228574.0	262515.4
Jul 1976	259021.8	247256.0	270787.5	241027.6	277015.9
Aug 1976	262152.9	250141.5	274164.3	243783.0	280522.8
Sep 1976	241460.1	230170.4	252749.9	224194.0	258726.3
Oct 1976	245069.2	233518.4	256620.1	227403.7	262734.7
Nov 1976	233483.8	222271.3	244696.2	216335.8	250631.8
Dec 1976	235138.2	223742.0	246534.4	217709.2	252567.2
Jan 1977	218126.7	207260.0	228993.5	201507.4	234746.1
Feb 1977	214210.1	203370.3	225049.8	197632.1	230788.0
Mar 1977	225265.5	213893.1	236638.0	207872.9	242658.2
Apr 1977	230427.4	218736.9	242117.9	212548.3	248306.5
May 1977	252956.7	240294.6	265618.8	233591.6	272321.8
Jun 1977	254172.7	241326.8	267018.7	234526.6	273818.9
Jul 1977	267649.8	254160.1	281139.6	247019.0	288280.7
Aug 1977	270781.0	257027.3	284534.7	249746.6	291815.4
Sep 1977	250088.2	236937.5	263238.9	229976.0	270200.5
Oct 1977	253697.3	240269.5	267125.0	233161.3	274233.2
Nov 1977	242111.8	228938.8	255284.9	221965.5	262258.2
Dec 1977	243766.3	230385.0	257147.5	223301.4	264231.1

```
> pgd <- predict(gd)
```

```
> plot(pgd)
```



مناقشة النتائج:

عند تطبيق أكثر من نموذج للتمهيد يجب ان 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 الانحراف المطلق Mean Absolute Deviation أو MAD ويعطى بالعلاقة

$$MAD = \frac{\sum_{t=1}^n |z_t - \hat{z}_t|}{n}$$

3- متوسط الانحراف المربع (أو متوسط الخطأ المربع) MSD (أو MSE) 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 استخداما وشيوعا هو MSD أو MSE وهو الذي سوف هنا.

```
> MAPE <- (sum(abs(gd - pgd$fitted)/gd)/length(gd))*100
> MAPE
```

```
[1] 2.755263
> MAD <- sum(abs(gd - pgd$fitted))/length(gd)
> MAD
[1] 4559.612
> MSD <- sum((gd - pgd$fitted)^2)/length(gd)
> MSD
[1] 34682600
```

للمنموذج الإضافي مقاييس الدقة هي:

MAPE: 2.755263

MAD: 4559.612

MSD: 34682600

يترك للطالب كتمرين إيجاد مقاييس دقة التطبيق للنموذج التضاعفي.

توضيح طريقة تحليل أو تفكيك المتسلسلة إلى مركبات :Decomposition Method


سوف نوضح بالمثل التالي طريقة تحليل أو تفكيك المتسلسلة إلى مركبات. البيانات التالية إنتاج

168 يوما للحليب في أحد المزارع بالكيلو جرام

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:

```
> mp <- ts(MilkProd, frequency =12)
> plot.ts(mp)
```



اولا: تطبيق النموذج الإضافي:

لملاحظات $z_1, z_2, \dots, z_n$ نكتب النموذج على الشكل $z_t = T_t + S_t + E_t, t = 1, 2, \dots, n$ لكي نقوم بتفكيك هذه المتسلسلة الزمنية الي المركبات السابقة سوف نستعرض طريقتين ممكنة:
الطريقة الاولى:

1- نطبق إنحدار خطي بسيط للملاحظات علي الزمن لتقدير مركبة الانجراف T_t أي:

$$\hat{T}_t \equiv \hat{z}_t = a + bt, t = 1, 2, \dots, 168$$

أي:

```
> inx = c(1:168)
> trnd <- lm(mp ~ inx)
> trnd
```

Call:

```
lm(formula = mp ~ inx)
```


Coefficients:

(Intercept)	inx
611.682	1.693


2- نطرح مركبة الإنجراف من المشاهدات الاصلية فنحصل علي مايسمي بالمتسلسلة مزالة

$$\text{الإنجراف Detrended Series أي } z_t - \hat{z}_t = z_t - \hat{T}_t, t=1,2,...,168$$

```
> det_mp = mp - trnd$fitted
```

ولها الشكل التالي:

```
> plot.ts(det_mp)
```



نلاحظ انها اصبحت موسمية فقط لأن $z_t - \hat{T}_t = S_t + E_t, t=1,2,...,168$

3- لتقدير المركبة الموسمية نوجد المؤشرات الموسمية Seasonal Indices كالتالي:

لنرمز للمؤشرات الموسمية بالرمز $I_s, s=1,2,...,12$ حيث I_1 المؤشر الموسمي للشهر

الأول و I_2 المؤشر الموسمي للشهر الثاني وهكذا ولنرمز بـ $d_t = z_t - \hat{T}_t, t=1,2,...,168$

تقدر هذه المؤشرات كالتالي:

$$I_1 = \frac{1}{14}(d_1 + d_{13} + d_{25} + \dots + d_{157})$$

$$I_2 = \frac{1}{14}(d_2 + d_{14} + d_{26} + \dots + d_{158})$$

$$\vdots$$

$$I_{12} = \frac{1}{14}(d_{12} + d_{24} + d_{36} + \dots + d_{168})$$

ويتم ذلك بالتالي:

```
n <- length(det_mp)-11
s1 <- seq(1, n, by = 12)
> s <- data.frame(matrix(nrow = 12, ncol = 14))
> s[1,] = s1
> for (i in 2:12) {
  s[i,] = s1+i-1
}
> st =t(s)
> I <- data.frame(matrix(nrow = 12,ncol = 1))
> colnames(I) <- c("season Index")
> for (i in 1:12) {
  I[i,] = mean(det_mp[st[,i]])
}
> I
```

	season Index
1	-18.327521
2	-57.805851
3	34.715820
4	49.594633
5	110.616304
6	82.280831
7	32.516788
8	-9.747256
9	-52.297014
10	-48.775344

11 -79.753673

12 -43.017717

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 إنحدار خطي بسيط للملاحظات علي الزمن لتقدير مركبة الانجراف

T_t فنحصل على نفس النتيجة كما في الطريقة الاولى (1)

2- ايضا هنا نطرح مركبة الإنجراف من المشاهدات الاصلية فنحصل علي المتسلسلة مزالة

الإنجراف Detrended Series

3- نطبق الآن متوسط متحرك من درجة الموسم ونوسطه اذا احتاج الامر

4- نطرح المتوسطات المتحركة من نظيراتها في المتسلسلة مزالة الإنجراف فنحصل علي

متسلسلة تحوي المركبات الموسمية

5- تقدر المركبات الموسمية كالتالي:

$$\begin{aligned} I_1 &= \text{Median}(d_1, d_{13}, d_{25}, \dots, d_{157}) \\ I_2 &= \text{Median}(d_2, d_{14}, d_{26}, \dots, d_{158}) \\ &\vdots \\ I_{12} &= \text{Median}(d_{12}, d_{24}, d_{36}, \dots, d_{168}) \end{aligned}$$

6- تولد التنبؤات كالسابق


وسوف نستعرض هذا كالتالي:

```
> mp <- ts(MilkProd, frequency = 12)
> inx <- c(1:168)
> trnd <- lm(mp ~ inx)
> det_mp = mp - trnd$fitted
```

في الخطوة التالية نطبق متوسط متحرك من الدرجة 12 ونوسطه:

May 15	1002.5333	986.4278	1018.6388	977.9020	1027.1645
Jun 15	975.6267	958.2121	993.0414	948.9934	1002.2601
Jul 15	927.8921	909.2597	946.5245	899.3963	956.3879
Aug 15	887.5150	867.7394	907.2907	857.2707	917.7593
Sep 15	846.7471	825.8905	867.6038	814.8496	878.6447
Oct 15	851.7846	829.9000	873.6693	818.3149	885.2544
Nov 15	822.7503	799.8835	845.6172	787.7785	857.7221
Dec 15	860.8669	837.0581	884.6757	824.4545	897.2793
Jan 16	886.7523	862.0368	911.4679	848.9532	924.5515
Feb 16	848.6798	823.0897	874.2699	809.5431	887.8164
Mar 16	943.3123	916.8763	969.7483	902.8820	983.7426
Apr 16	959.9430	932.6871	987.1989	918.2587	1001.6273
May 16	1022.6266	994.5745	1050.6787	979.7247	1065.5286
Jun 16	995.7201	966.8936	1024.5467	951.6337	1039.8065
Jul 16	947.9855	918.4045	977.5665	902.7453	993.2257
Aug 16	907.6084	877.2915	937.9253	861.2427	953.9740
Sep 16	866.8405	835.8050	897.8761	819.3757	914.3053
Oct 16	871.8780	840.1398	903.6162	823.3387	920.4174
Nov 16	842.8437	810.4179	875.2695	793.2527	892.4347
Dec 16	880.9603	847.8609	914.0596	830.3392	931.5813

```
> plot(forecast(mp , h=24))
```



تمرين: ولد تنبؤات لإنتاج الحليب اليومي بإستخدام الطريقتين المعطاة وقارنها بالقيم الأخيرة الناتجة من البرنامج

الفصل العاشر

التمهيد و التنبؤ بواسطة المتوسط المتحرك Using Moving Average Smoothing for Forecasting

يستخدم المتوسط المتحرك لتمهيد المشاهدات وذلك بتقليل تباين الأخطاء فمثلا لو كان لدينا مشاهدات من متسلسلة زمنية $z_1, z_2, z_3, \dots, z_{n-2}, z_{n-1}, z_n$ فالمتوسط 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 $n - m + 1$.
فمثلا لو كانت $m=3$ فإن المتوسط المتحرك من الدرجة الثالثة هو

$$\begin{aligned} \hat{z}_3 &= \frac{1}{3} (z_3 + z_2 + z_1) \\ \hat{z}_4 &= \frac{1}{3} (z_4 + z_3 + z_2) \quad \text{or} \quad \hat{z}_4 = \hat{z}_3 + \frac{1}{3} (z_4 - z_1) \\ &\vdots \\ \hat{z}_n &= \frac{1}{3} (z_n + z_{n-1} + z_{n-2}) \quad \text{or} \quad \hat{z}_n = \hat{z}_{n-1} + \frac{1}{3} (z_n - z_{n-3}) \end{aligned}$$

ولكي نرى كيف يعمل التمهيد لتقليل تباين الأخطاء لنفترض ان المشاهدات تتبع النموذج

$$z_t = \mu + a_t, \quad a_t \sim WN(0, \sigma^2), \quad t = 1, 2, \dots, n$$

فيكون

$$V(z_t) = \sigma^2, \quad \forall t$$

وبالتالي

$$V(\hat{z}_t) = \frac{\sigma^2}{m}, \quad t = m, m+1, \dots, n$$

أي ان المشاهدات الممهدة اصبح تباينها أصغر بـ m ضعف من المشاهدات الأصلية وهذا التمهيد للأخطاء يظهر أي نمط في المتسلسلة كان مدفونا او مغطى من تأثير الأخطاء.

ملاحظة: تؤخذ m دائما فردية وذلك لنتجنب توسيط القيم الممهدة.

التنبؤ باستخدام المتوسط المتحرك:

يؤخذ كمتنبئ للقيم المستقبلية المتوسط المتحرك:

$$z_n(\ell) = \hat{z}_{n-1}, \quad \ell > 0$$

مثال:


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:

```
> mt <- ts(Metals)
> plot.ts(mt)
```




نطبق الآن تمهيدا لهذه المشاهدات بإستخدام المتوسط المتحرك من الدرجة $m=3$ ونوجد تنبؤات لـ 6 قيم مستقبليه:

```
> mt <- ts(Metals)
> plot.ts(mt)
> library(forecast)
> m3 <- ma(mt, order = 3)
> lines(m3)
> forecast(mt)
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
61	48.10011	47.25925	48.94097	46.81412	49.38610
62	48.10011	46.91101	49.28921	46.28154	49.91868
63	48.10011	46.64379	49.55643	45.87286	50.32736
64	48.10011	46.41851	49.78171	45.52833	50.67189
65	48.10011	46.22004	49.98018	45.22478	50.97544
66	48.10011	46.04060	50.15962	44.95036	51.24986

```
> plot(forecast(mt))
> lines(m3)
> plot(forecast(mt))
> lines(m3, col = "red")
```

المتسلسلة الأصلية باللون الأسود والقيم الممهدة بالمتوسط المتحرك باللون الأحمر مع التنبؤات.

ثانياً: مناقشة النتائج

في المثال الحالي

$$\hat{z}_{59} = \frac{50.3 + 49.2 + 48.1}{3} = \frac{147.6}{3} = 49.2$$

تؤخذ التنبؤات للقيم الـ 6 المستقبلية أي للقيم $z_{n+1}, z_{n+2}, \dots, z_{n+6}$ أو في هذا المثال

$z_{61}, z_{62}, \dots, z_{66}$ كالتالي:

$$z_{60}(1) = z_{60}(2) = \dots = z_{60}(6) = 49.2$$

لحساب فترات تنبؤ 95% نحسب الكميات $[z_n(\ell) \pm 1.96\hat{\sigma}]$, أي

$[49.2 \pm 1.96\hat{\sigma}]$ لجميع قيم التنبؤات المستقبلية، نأخذ القيمة $MSD = 0.76433$ كمقدر لـ

σ^2 أي $\hat{\sigma}^2 = 0.76433$ فيكون $\hat{\sigma} = 0.8743$ 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 كالآتي

$$MSD = \hat{\sigma}^2 = \frac{\sum_{i=2}^{n-1} (z_i - \hat{z}_i)}{n-2}$$

تمرين:


طبق متوسطات متحركة من الدرجات 5 و 7 علي المشاهدات السابقة وقرر ايها افضل للتنبؤ عن القيم المستقبلية؟.

الوسيط الجارى Running Median


المتوسط المتحرك يتأثر كثيرا بالمشاهدات الخارجة Outliers او المتطرفة فالقيمة المتطرفة الواحدة تؤثر علي m من المتوسطات المتحركة المتتالية فمثلا لو كانت لدين 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.
للتغلب على مثل هذه الصعوبات يستخدم الوسيط الجاري ذا الطول الفردي كممهد غير خطي
والذي لا يتأثر باقيم المتطرفة.

الوسيط الجاري ذا الطول الفردي $j = 2i + 1$ لمشاهدات $z_1, z_2, z_3, \dots, z_{n-2}, z_{n-1}, z_n$ يحسب
من العلاقة

$$\tilde{z}_i = \text{med}(z_{i-j}, \dots, z_i, \dots, z_{i+j}), j = 2i + 1$$


فمثلا لقيمة $j = 3$ تصبح العلاقة $\tilde{z}_i = \text{med}(z_{i-1}, z_i, z_{i+1})$ وبأخذ وسيط جاري ذا الطول 3
للمشاهدات السابقة نجد

```
> rm <- runmed(z, 3)
> lines(rm, col = "blue")
> plot(rm)
> plot.ts(rm)
```



وإذا كانت القيمة الحقيقية لـ z_9 هي 15 وليس 1500 فإن المشاهدات الحقيقية لها الشكل التالي

```
> z[9] <- 15
> plot.ts(z)
```



قارن بين النتيجتين.

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 نوعا تؤثر نفس التأثير كالقيم الحديثة وهذا قد لا يكون من الناحية العملية صحيحا، التمهيد الاسي على العكس يعطي القيم الأكثر حداثة أهمية أكبر والقيم الاخرى تعطى اهمية تتناقص اسيا مع قدمها. فمثلا لو كان لدينا مشاهدات من متسلسلة زمنية $z_1, z_2, z_3, \dots, z_{n-2}, z_{n-1}, z_n$ فالمتوسط المتحرك من الدرجة m للملاحظات 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 مايسمى 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:

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:

```
> mt <- ts(Metals)
> plot.ts(mt)
> library(forecast)
```




نطبق الآن تمهيدا لهذه المشاهدات باستخدام التمهيد الاسي البسيط ونوجد تنبؤات لـ 10 قيم مستقبلية:

```
> library(forecast)
> mt <- ts(Metals)
> library(ggplot2)
> mt.ets = ses(mt,model="ANA")
> mt.ets
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
61	48.10011	47.25925	48.94097	46.81412	49.38610
62	48.10011	46.91101	49.28921	46.28154	49.91868
63	48.10011	46.64379	49.55643	45.87286	50.32736

64	48.10011	46.41851	49.78171	45.52833	50.67189
65	48.10011	46.22004	49.98019	45.22478	50.97544
66	48.10011	46.04060	50.15962	44.95036	51.24986
67	48.10011	45.87559	50.32463	44.69800	51.50222
68	48.10011	45.72200	50.47822	44.46311	51.73712
69	48.10011	45.57775	50.62247	44.24249	51.95773
70	48.10011	45.44131	50.75891	44.03382	52.16640

> autoplot(mt.ets)



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 اسياً نحتاج الى القيمة الاولى s_0 والتي تحسب بعدة طرق، أحد هذه الطرق والتي سنستخدمها هي وضع s_0 مساوية للمتوسط

$$s_0 = \frac{\sum_{i=1}^m z_i}{m}, \quad m = 6 \text{ (or } n, \text{ if } n < 6)$$

ففي مثالنا

$$s_0 = \frac{44.2 + 44.3 + 44.4 + 43.4 + 42.8 + 44.3}{6} = 43.9$$

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 حتي آخر مشاهدة .

2- يؤخذ كمتنبئ للقيم المستقبلية آخر قيمة ممهدة أي:

$$z_n(\ell) = s_n, \quad \ell > 0$$

ففي المثال الحالي

$$z_{60}(\ell) = 49.7216, \quad \ell > 0$$

تؤخذ التنبؤات للقيم الـ 6 المستقبلية أي للقيم $z_{n+1}, z_{n+2}, \dots, z_{n+6}$ أو في هذا المثال $z_{61}, z_{62}, \dots, z_{66}$ كالتالي:

$$z_{60}(1) = z_{60}(2) = \dots = z_{60}(6) = 49.7216$$

3- لحساب فترات تنبؤ 95% نحسب الكميات $z_n(\ell) \pm 1.96\hat{\sigma}$ أي

$$[49.7216 \pm 1.96\hat{\sigma}] \text{ لجميع قيم التنبؤات المستقبلية ، نأخذ القيمة } MSD = 1.45392$$

كمقدر لـ σ^2 أي $\hat{\sigma}^2 = 1.45392$ 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:

$$z_{60+\ell} \in [47.3582, 50.0849], \quad \ell > 0 \quad \text{with probability } 0.95$$

ملاحظة: تحسب MSD كالاتي

$$MSD = \hat{\sigma}^2 = \frac{\sum_{i=1}^n (z_i - \hat{z}_i)^2}{n-1}$$

> accuracy(mt.ets)

		ME	RMSE	MAE	MPE
MAPE	MASE	ACF1			

Training set 0.06500805 0.6561284 0.505012 0.1300051
1.1188 0.9833566 0.03962642

تمرين:

طبق تمهيد اسي بسيط علي 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 Using Double Exponential

: Smoothing for Forecasting

أولاً: طريقة براون Brown's Method:

لملاحظات $z_1, z_2, \dots, z_{n-1}, z_n$ ولثابت تمهيد $0 < \alpha < 1$ نوجد 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 $s_t^{(1)} = s_t$ (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 للقيم المستقبلية $z_{n+\ell}$, $\ell > 0$ من

$$z_n(\ell) = a_n + b_n \ell, \quad \ell > 0$$

حساب القيم الاولى $s_0^{(1)}$ 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 علي الزمن $t = 1, 2, \dots, n$ ويكون $z_t = \alpha + \beta t + e_t$,

$$b_0 = \hat{\beta} \quad \text{و} \quad a_0 = \hat{\alpha}$$

ثانياً: طريقة هولت Holt's Method:

لملاحظات $z_1, z_2, \dots, z_{n-1}, z_n$ ولثابتي تمهيد $0 < \alpha < 1$ و $0 < \gamma < 1$ نوجد التالي:

$$s_t = \alpha z_t + (1 - \alpha)(s_{t-1} + b_{t-1}), \quad t = 1, 2, \dots, n$$

$$b_t = \gamma(s_t - s_{t-1}) + (1 - \gamma)b_{t-1}, \quad t = 1, 2, \dots, n$$

نحسب القيم المطبقة من

$$\hat{z}_t = s_t + b_t, \quad t = 1, 2, \dots, n$$

والتنبؤات للقيم المستقبلية من

$$z_n(\ell) = s_n + b_n \ell, \quad \ell > 0$$

نحسب القيم الأولية 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:

سوف نستخدم الملاحظات في المتغير Metals

```
> library(fpp2)
```

```
Loading required package: forecast
```

```
Loading required package: fma
```


```
Loading required package: expsmoother
```

```
Loading required package: ggplot2
```

نرسم هذه الملاحظات:

```
> mt = ts(Metals, frequency = 12)
```

```
> plot.ts(mt)
```



نطبق الآن تمهيدا لهذه المشاهدات بإستخدام التمهيد الاسي المزدوج بطريقة براون.

```
> mt.ets = ets(mt)
```

```
> mt.ets
```

```
ETS(A,N,N)
```

Call:

```
ets(y = mt)
```

Smoothing parameters:

```
alpha = 0.9999
```

Initial states:

```
l = 44.2007
```

```
sigma: 0.6561
```


	AIC	AICc	BIC
	201.0928	201.5214	207.3759

```
> accuracy(mt.ets)
```

```

              ME          RMSE          MAE          MPE
MAPE      MASE      ACF1
Training set 0.06499685 0.6561284 0.5050232 0.1299798
1.118825 0.209517 0.03962626
> mt.fcast <- forecast(mt.ets)
> mt.fcast
      Point Forecast      Lo 80      Hi 80      Lo 95      Hi 95
Jan 6      48.10011 47.25925 48.94097 46.81412 49.38610
Feb 6      48.10011 46.91101 49.28921 46.28154 49.91868
Mar 6      48.10011 46.64379 49.55643 45.87286 50.32736
Apr 6      48.10011 46.41851 49.78171 45.52833 50.67189
May 6      48.10011 46.22004 49.98018 45.22478 50.97544
Jun 6      48.10011 46.04060 50.15962 44.95036 51.24986
Jul 6      48.10011 45.87559 50.32463 44.69800 51.50222
Aug 6      48.10011 45.72200 50.47822 44.46311 51.73711
Sep 6      48.10011 45.57775 50.62247 44.24249 51.95773
Oct 6      48.10011 45.44131 50.75891 44.03383 52.16639
Nov 6      48.10011 45.31154 50.88868 43.83536 52.36486
Dec 6      48.10011 45.18755 51.01268 43.64573 52.55449
Jan 7      48.10011 45.06862 51.13160 43.46384 52.73638
Feb 7      48.10011 44.95418 51.24604 43.28883 52.91139
Mar 7      48.10011 44.84377 51.35645 43.11997 53.08025
Apr 7      48.10011 44.73698 51.46324 42.95664 53.24358
May 7      48.10011 44.63347 51.56675 42.79835 53.40187
Jun 7      48.10011 44.53297 51.66725 42.64464 53.55558
Jul 7      48.10011 44.43522 51.76500 42.49515 53.70507
Aug 7      48.10011 44.34002 51.86020 42.34955 53.85068
Sep 7      48.10011 44.24716 51.95306 42.20754 53.99268
Oct 7      48.10011 44.15649 52.04373 42.06887 54.13135
Nov 7      48.10011 44.06786 52.13236 41.93332 54.26690
Dec 7      48.10011 43.98114 52.21908 41.80069 54.39953
> plot(mt.fcast)

```



مثال:

تطبيق طريقة هولت

```
> mt.hw = HoltWinters(mt)
> mt.hw
Holt-Winters exponential smoothing with trend and
additive seasonal component.
```

Call:

```
HoltWinters(x = mt)
```

Smoothing parameters:

```
alpha: 0.7169118
beta : 0.2405206
gamma: 1
```

Coefficients:

```
      [,1]
a  48.3718678
b  -0.3138727
s1 -0.8677548
```

```

s2  -0.7982475
s3  -1.4982683
s4  -0.8699901
s5  -0.4451344
s6   0.4151617
s7   0.4272938
s8   1.2483201
s9   1.0705231
s10  0.9036051
s11  0.3672388
s12 -0.2718678

```


```
> mthw.fcast = forecast(mt.hw)
```

```
> mthw.fcast
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 6	47.19024	46.38693	47.99355	45.96169	48.41879
Feb 6	46.94587	45.87084	48.02091	45.30176	48.58999
Mar 6	45.93198	44.55969	47.30427	43.83324	48.03072
Apr 6	46.24639	44.55341	47.93936	43.65721	48.83557
May 6	46.35737	44.32194	48.39280	43.24445	49.47029
Jun 6	46.90379	44.50546	49.30213	43.23585	50.57173
Jul 6	46.60205	43.82147	49.38264	42.34951	50.85459
Aug 6	47.10921	43.92797	50.29044	42.24393	51.97449
Sep 6	46.61754	43.01806	50.21701	41.11262	52.12246
Oct 6	46.13675	42.10216	50.17133	39.96638	52.30711
Nov 6	45.28651	40.80057	49.77244	38.42586	52.14716
Dec 6	44.33353	39.38056	49.28649	36.75862	51.90843
Jan 7	43.42377	37.89109	48.95645	34.96226	51.88527
Feb 7	43.17940	37.15787	49.20093	33.97027	52.38854
Mar 7	42.16551	35.63982	48.69120	32.18532	52.14569
Apr 7	42.47991	35.43531	49.52452	31.70612	53.25371
May 7	42.59090	35.01313	50.16867	31.00170	54.18010
Jun 7	43.13732	35.01258	51.26206	30.71160	55.56304
Jul 7	42.83558	34.15046	51.52070	29.55283	56.11833
Aug 7	43.34273	34.08419	52.60128	29.18301	57.50246

Sep 7	42.85106	33.00638	52.69575	27.79491	57.90721
Oct 7	42.37027	31.92703	52.81351	26.39872	58.34183
Nov 7	41.52003	30.46611	52.57396	24.61452	58.42555
Dec 7	40.56705	28.89058	52.24353	22.70942	58.42468

```
> plot(mthw.fcast)
```



تمرين: تحقق من صحة الحسابات السابقة باتباع بعض القيم يدويا (ملاحظة: يتوقع عدم تطابق الحسابات تماما وذلك لإختلاف طريق تمثيل الأعداد بين الحاسب والآلة الحاسبة وكذلك في تخزين الأرقام في ذاكرت كل منهما)

الفصل الثالث عشر

التمهيد الاسي الثلاثي و التنبؤ بواسطة 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 تنفع لتحليل الظواهر الموسمية ماعدى طريقة التفكيك Decomposition Method وطريقة ونترز Winters' trend and seasonal smoothing التي سوف نستعرضها هنا طريقة ونترز للمتسلسلات الموسمية المنجرفة أولاً: تمهد المشاهدات تمهيدا كلياً بالعلاقة

$$s_t = \alpha \frac{z_t}{S_{t-s}} + (1 - \alpha)(s_{t-1} + b_{t-1}), \quad t = 1, 2, \dots, n$$

ثانياً: تمهيد الإنجراف

$$b_t = \gamma (s_t - s_{t-1}) + (1 - \gamma)b_{t-1}, \quad t = 1, 2, \dots, n$$

ثالثاً: تمهيد الموسمية

$$S_t = \beta \frac{z_t}{S_t} + (1 - \beta)S_{t-s}, \quad t = 1, 2, \dots, n$$

حيث S_i هي المركبة الموسمية عند الزمن i و s هي دورة الموسمية القيم المطبقة تعطي 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 جداً تتبع طريقة ونترز بالحسابات اليدوية حيث ان القيم الاولية تحسب بخوارزمات غير خطية بإستخدام الحاسب ولهذا لن نستعرضها هنا ونكتفي بالنتائج المخرجة من الحاسب.

مثال:


سوف نستخدم مشاهدات 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

```
> fd <- ts(food, frequency = 12)
> plot(fd)
```



نلاحظ ان الظاهرة موسمية بدورة 12 نطبق الآن طريقة ونترز كالتالي:

أولاً: للنموذج الإضافي Additive Model

$$z_t = b_t + S_t + e_t, \quad t = 1, 2, \dots, n$$

```
> fd.hw <- HoltWinters(fd, seasonal = c("additive"),
optim.start = c(alpha = 0.3, beta = 0.1, gamma = 0.1))
> fd.hw
Holt-Winters exponential smoothing with trend and
additive seasonal component.
```

Call:

```
HoltWinters(x = fd)
```

```
Smoothing parameters:
```

```
alpha: 0.3115394
```

```
beta : 0.07599714
```

```
gamma: 1
```

```
Coefficients:
```

```
      [,1]
```

```
a    61.9208719
```

```
b     0.1814075
```

```
s1   -4.5353101
```

```
s2   -5.2033181
```

```
s3   -4.9498151
```

```
s4   -5.3175252
```

```
s5   -4.8730207
```

```
s6   -1.5158184
```

```
s7     7.8010319
```

```
s8    12.4403294
```

```
s9    13.8076072
```

```
s10   4.3438583
```

```
s11  -1.5730961
```

```
s12  -4.2208719
```


```
> fd.fcast <- forecast(fd.hw)
```

```
> fd.fcast
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 6	57.56697	56.26230	58.87164	55.57165	59.56229
Feb 6	57.08037	55.70435	58.45639	54.97593	59.18481
Mar 6	57.51528	56.06178	58.96878	55.29234	59.73822
Apr 6	57.32898	55.79216	58.86579	54.97862	59.67933
May 6	57.95489	56.32925	59.58053	55.46869	60.44109
Jun 6	61.49350	59.77381	63.21318	58.86347	64.12353
Jul 6	70.99176	69.17309	72.81042	68.21035	73.77316
Aug 6	75.81246	73.89015	77.73477	72.87254	78.75238

Sep 6	77.36115	75.33077	79.39152	74.25596	80.46634
Oct 6	68.07881	65.93616	70.22145	64.80192	71.35569
Nov 6	62.34326	60.08436	64.60216	58.88857	65.79795
Dec 6	59.87689	57.49792	62.25586	56.23857	63.51521
Jan 7	59.74386	56.83417	62.65354	55.29388	64.19384
Feb 7	59.25726	56.23746	62.27705	54.63888	63.87564
Mar 7	59.69217	56.55801	62.82632	54.89889	64.48545
Apr 7	59.50587	56.25326	62.75848	54.53143	64.48030
May 7	60.13178	56.75677	63.50679	54.97014	65.29341
Jun 7	63.67039	60.16917	67.17161	58.31573	69.02504
Jul 7	73.16865	69.53755	76.79975	67.61536	78.72193
Aug 7	77.98935	74.22483	81.75387	72.23201	83.74669
Sep 7	79.53804	75.63666	83.43941	73.57140	85.50467
Oct 7	70.25570	66.21416	74.29723	64.07470	76.43669
Nov 7	64.52015	60.33524	68.70506	58.11988	70.92041
Dec 7	62.05378	57.72239	66.38517	55.42949	68.67807

```
> plot(fd.fcast)
```



ثانياً: للنموذج التضاعفي Multiplicative Model

$$z_t = b_t S_t + e_t, \quad t = 1, 2, \dots, n$$

```
> fd.hwm <-HoltWinters(fd, seasonal =
c("multiplicative"), optim.start = c(alpha = 0.3, beta =
0.1, gamma = 0.1))
> fd.hwm
Holt-Winters exponential smoothing with trend and
multiplicative seasonal component.
```

Call:

```
HoltWinters(x = fd, seasonal = c("multiplicative"),
optim.start = c(alpha = 0.3, beta = 0.1, gamma =
0.1))
```

Smoothing parameters:

```
alpha: 0.2967092
beta : 0.08107868
gamma: 1
```

Coefficients:


```
      [,1]
a  61.7341864
b   0.1762431
s1  0.9232411
s2  0.9114690
s3  0.9153468
s4  0.9087051
s5  0.9156775
s6  0.9716133
s7  1.1288416
s8  1.2077838
s9  1.2324774
s10 1.0774547
s11 0.9796223
s12 0.9346523
```

```
> fd.fcastm <- forecast(fd.hwm)
```

```
> fd.fcastm
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
Jan 6	57.15826	55.90323	58.41328	55.23886	59.07765
Feb 6	56.59008	55.27362	57.90653	54.57673	58.60342
Mar 6	56.99216	55.60557	58.37875	54.87156	59.11277
Apr 6	56.73878	55.27981	58.19775	54.50748	58.97008
May 6	57.33552	55.79195	58.87909	54.97483	59.69620
Jun 6	61.00920	59.33802	62.68038	58.45335	63.56505
Jul 6	71.08077	69.16838	72.99317	68.15602	74.00552
Aug 6	76.26446	74.15485	78.37407	73.03809	79.49083
Sep 6	78.04093	75.78118	80.30069	74.58494	81.49693
Oct 6	68.41473	66.24307	70.58639	65.09347	71.73599
Nov 6	62.37536	60.23073	64.51999	59.09543	65.65529
Dec 6	59.67671	52.78473	66.56870	49.13633	70.21710
Jan 7	59.11083	55.71171	62.50996	53.91232	64.30935
Feb 7	58.51776	54.97849	62.05702	53.10492	63.93060
Mar 7	58.92805	55.20250	62.65359	53.23031	64.62578
Apr 7	58.66062	54.77712	62.54411	52.72132	64.59991
May 7	59.27210	55.18241	63.36179	53.01746	65.52674
Jun 7	63.06408	58.57732	67.55084	56.20217	69.92599
Jul 7	73.46818	68.13963	78.79673	65.31887	81.61749
Aug 7	78.81882	72.90793	84.72972	69.77889	87.85876
Sep 7	80.64752	74.36562	86.92942	71.04019	90.25485
Oct 7	70.69346	64.89583	76.49108	61.82676	79.56016
Nov 7	64.44718	58.90646	69.98790	55.97337	72.92098
Dec 7	61.65343	50.27319	73.03366	44.24886	79.05799

```
> plot(fd.fcastm)
```



ملاحظات:

لتطبيق طريقة ونترز نحتاج الي إختيار قيم ثلاثة معالم هي α ثابت التمهيد الكلي و γ ثابت تمهيد الإنجراف و β ثابت تمهيد الموسمية وهذه عملية أفضلية Optimization في ثلاثة ابعاد (فضاء المعالم) إما أن نترك للبرنامج الإحصائي المستخدم حسابها تلقائيا بإستخدام خوارزمات غير خطية مبنية داخل البرنامج أو نقوم نحن بإمداد البرنامج بتلك القيم.

تمرين: في الأمثلة السابقة اخذنا $\alpha = \gamma = \beta = 0.2$. ثبت في كل مرة معلمين وغير الثالث

حتي تحصل علي أقل MSD

```
> accuracy(fd.fcastm)
```

		ME	RMSE	MAE	MPE	MAPE
MASE	ACF1					
Training set		0.1883733	0.9871876	0.6979998	0.2857943	1.147907
		0.5234998	0.1832898			

مثال عملي لبناء نموذج تنبؤ:

سوف نستخدم البيانات change

change

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

```
> cg <- ts(change)
```

```
> plot.ts(cg)
```




```
> par(mfrow=c(2,1))
```


```
> acf(cg)
```

```
> pacf(cg)
```

Series cg



Series cg




```
> acf(cg, plot = F)
```

Autocorrelations of series 'cg', by lag

```

0      1      2      3      4      5      6      7      8
9      10     11     12     13     14     15
 1.000  0.788  0.460  0.291  0.258  0.257  0.159 -0.019 -
0.159 -0.193 -0.177 -0.234 -0.342 -0.376 -0.349 -0.302
> pacf(cg, plot = F)
```

Partial autocorrelations of series 'cg', by lag

```

1      2      3      4      5      6      7      8      9
10     11     12     13     14     15
 0.788 -0.424  0.350 -0.042  0.076 -0.281 -0.051 -0.090
0.037 -0.109 -0.207 -0.006  0.036 -0.155  0.018
```

من انماط الترابطات الذاتية والترابطات الذاتية الجزئية العينية قد يكون النموذج ARMA(1,1) ينطبق على المتسلسلة، الأوامر التالية تطبق النموذج المقترح وتولد 5 تنبؤات للقيم المستقبلية

```
> cg.fit <- arima(cg, order = c(1,0,1))
> cg.fit
```

Call:

```
arima(x = cg, order = c(1, 0, 1))
```

Coefficients:

```

          ar1      ma1  intercept
          0.6236  0.9149         4.6776
s.e.    0.1339  0.0961         1.1596
```

```
sigma^2 estimated as 1.917:  log likelihood = -59.17,
aic = 126.33
```

أي ان النموذج المقترح 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 وإنحرافات المعيارية وقيمة إختبار 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 البواقي:


```
> res <- cg.fit$residuals
> par(mfrow=c(2,1))
> acf(res)
> pacf(res)
```



أنماط الترابط الذاتي والترابط الذاتي الجزئي للبواقي تدل على أن البواقي تتبع توزيع ضجة بيضاء أي غير مترابطة، لنفحص طبيعية البواقي:

رسم المدرج التكراري

```
> hist(res)
```




يبدو متناظر بعض الشيء.

لننظر إلى مخطط الإحتمال الطبيعي للبواقي:

```
> qqnorm(res)
```

```
> qqline(res)
```



نستطيع أن نقول ان البواقي طبيعية تقريبا.

الرسم التالي للمتسلسلة مع 5 تنبؤات للقيم المستقبلية.

```
> cg.fcast <- forecast(cg.fit)
```


```
> cg.fcast
```

Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
----------------	-------	-------	-------	-------

```

34      3.105091  1.3303014  4.879880   0.3907848   5.819396
35      3.696926  0.4409252  6.952926  -1.2826973   8.676549
36      4.066019  0.3918232  7.740216  -1.5531789   9.685218
37      4.296202  0.4716880  8.120717  -1.5528876  10.145292
38      4.439754  0.5583487  8.321160  -1.4963433  10.375852
39      4.529279  0.6259711  8.432588  -1.4403155  10.498874
40      4.585111  0.6733173  8.496905  -1.3974613  10.567683
41      4.619930  0.7048410  8.535019  -1.3676820  10.607542
42      4.641645  0.7252748  8.558015  -1.3479263  10.631216
43      4.655187  0.7383189  8.572055  -1.3351458  10.645520
> plot(cg.fcast)

```



دعنا نحاول تطبيق نموذج $AR(2)$ على المتسلسلة كالتالي:

```

> cg.fit <- arima(cg, order = c(2,0,0))
> cg.fit

```

Call:

```
arima(x = cg, order = c(2, 0, 0))
```

Coefficients:

	ar1	ar2	intercept
	1.1524	-0.4384	4.7602
s.e.	0.1522	0.1543	0.9873

sigma^2 estimated as 2.731: log likelihood = -64.13,
aic = 136.26

أي ان النموذج المقترح هو

$$z_t = 1.33 + 1.187z_{t-1} - 0.4657z_{t-1} + a_t, \quad a_t \sim N(0, 2.95)$$

مقدرات المعالم وإنحرافات المعيارية وقيمة إختبار t هي

$$\hat{\phi}_1 = 1.1872, \quad s.e.(\hat{\phi}_1) = 0.1625, \quad t = 7.31$$

$$\hat{\phi}_2 = -0.4657, \quad s.e.(\hat{\phi}_1) = 0.1624, \quad t = -2.87$$

$$\hat{\delta} = 1.327, \quad s.e.(\hat{\delta}) = 0.2996, \quad t = 4.43$$

$$\hat{\sigma}^2 = 2.954, \quad \text{with } d.f. = 30$$

لننظر إلى الإختبار

$$H_0 : \phi_2 = 0$$

$$H_1 : \phi_2 \neq 0$$

الإحصائية

$$t_0 = \frac{\hat{\phi}_2}{s.e.(\hat{\phi}_2)} = \frac{-0.4657}{0.1624} = -2.8676$$

نوجد الـ P-value لها بالأمر

```
> t <- -0.4384/0.1543
```

```
> t
```

```
[1] -2.841218
```

```
> dt(t, length(cg)-3)
```

```
[1] 0.009844429
```

أي الـ P-value لها تساوي 0.0098 وهي أقل من 0.05 أي لانرفض ان $\phi_2 = 0$

وبالتالي نرفض النموذج (2) AR.

تمرين:

حاول تطبيق نماذج اخرى مناسبة على المتسلسلة السابقة وإختار أفضل نموذج، أجري الإختبارات المناسبة واستخدم ايضا المعيار AIC.


مثال عملي 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:

```
> zt <- ts(z270)
> plot.ts(zt)
```



الترابطات الذاتية والترابطات الذاتية الجزئية هي:


```
> par(mfrow=c(2,1))
> acf(zt)
> pacf(zt)
```



واضح جدا ان المتسلسلة z_t غير مستقرة في المتوسط.

نأخذ الفروق الاولى $w_t = z_t - z_{t-1}$ ونرسمها



```
> dz_t <- diff(zt)
> par(mfrow=c(1,1))
> plot.ts(dz_t)
```



الترابطات الذاتية والترابطات الذاتية الجزئية للمتسلسلة المفرقة هي:

> acf(dzt)


> pacf(dzt)



واضح جدا ان المتسلسلة w_t لاتزال غير مستقرة في المتوسط.

نأخذ الفروق الاولى $y_t = w_t - w_{t-1}$ (لاحظ ان هذا الفرق الثاني للمتسلسلة الأصلية) و نرسمها



```
> plot.ts(ddzt)
```



الترابطات الذاتية والترابطات الذاتية الجزئية لهذه المتسلسلة المفرقة هي:

```
> acf(ddzt)
```

```
> pacf(ddzt)
```



نلاحظ من شكل المتسلسلة و الترابطات الذاتية والترابطات الجزئية انها اصبحت مستقرة في المتوسط اي ان $d=2$.

من انماط الترابطات الذاتية والترابطات الجزئية نرى انها تتخامد من التخلف الأول مما يرشح نموذج $ARIMA(1,2,1)$ للمتسلسلة الأصلية z_t وسوف نطبق هذا النموذج بالأمر

```
> zt.fit2 <- arima(zt, order = c(1,2,1))
> zt.fit2
```

Call:

```
arima(x = zt, order = c(1, 2, 1))
```

Coefficients:

	ar1	ma1
	0.8709	0.7225
s.e.	0.0350	0.0478

```
sigma^2 estimated as 1.077: log likelihood = -289.86,
aic = 585.73
```

النموذج المقترح هو

$$z_t = 0.875_{t-1}z + a_t - 0.859a_{t-1}, \quad a_t \sim N(0, 0.937)$$

ومقدرات المعالم وإنحرافات المعيارية وقيمة إختبار 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 البواقي:

```
> res <- zt.fit2$residuals
> par(mfrow=c(2,1))
> acf(res)
> pacf(res)
```




أنماط الترابط الذاتي والترابط الذاتي الجزئي للبواقي تدل على أن البواقي تتبع توزيع ضجة بيضاء أي غير مترابطة، لنفحص طبيعياً البواقي:
رسم المدرج التكراري



يبدو متناظر بعض الشيء.
لننظر إلى مخطط الإحتمال الطبيعي للبواقي:

```
> qqnorm(res)
> qqline(res)
```



نستطيع أن نقول ان البواقي طبيعية تقريبا.

الرسم التالي لـ 10 تنبؤات للقيم المستقبلية مع 95% فترات تنبؤ.


```
> zt.fcast <- forecast(zt.fit2)
```

```
> zt.fcast
```

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
201	-22615.04	-22616.37	-22613.71	-22617.08	-22613.01
202	-22756.85	-22761.81	-22751.89	-22764.44	-22749.27
203	-22899.68	-22910.91	-22888.45	-22916.86	-22882.51
204	-23043.40	-23063.75	-23023.05	-23074.53	-23012.27
205	-23187.89	-23220.34	-23155.44	-23237.52	-23138.26
206	-23333.05	-23380.63	-23285.47	-23405.82	-23260.28
207	-23478.80	-23544.55	-23413.04	-23579.36	-23378.24
208	-23625.05	-23712.00	-23538.11	-23758.02	-23492.08
209	-23771.75	-23882.87	-23660.63	-23941.70	-23601.81
210	-23918.84	-24057.07	-23780.62	-24130.24	-23707.45

```
> plot(zt.fcast)
```

Forecasts from ARIMA(1,2,1)



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 اسبوعيا لدي موزع ما

الاسبوع	1	2	3	4	5	6	7	8	9	10
العدد	75	75	79	83	69	78	71	80	77	85

اوجد تنبؤات لعدد السيارات التى ستباع فى الاسبوعين التاليين واوجد فترات تنبؤ 95% لهذه

التنبؤات كلما امكن ذلك باستخدام:

(ا) نموذج انحدار خطى للعدد المباع مع الزمن بالاسبوع.

(ب) التمهيد بواسطة متوسط متحرك من الدرجة الثالثة.

(ج) التمهيد الاسى البسيط مستخدما $\alpha = 0.3$.

السؤال الثانى:

للمنموذج $(1 - \phi_1 B - \phi_2 B^2)z_t = \delta + (1 - \theta B)a_t$ حيث $a_t \sim WN(0, \sigma^2)$ و $\phi_1, \phi_2, \delta, \theta$ هى معالم

النموذج و B هو عامل الازاحة الخلفى اوجد:

$$E(z_t) \forall t \quad (1)$$

(ب) دالة الترابط الذاتى $\rho_k \forall k \geq 0$

ج) دالة الترابط الذاتي الجزئي $\phi_{kk} \forall k \geq 0$

د) دالة الاوزان $\psi_j \forall j \geq 0$

السؤال الثالث:

للمنموذج $z_t = 38.5 + 1.2z_{t-1} - 0.7z_{t-2} + a_t - 0.4a_{t-1}$ حيث $a_t \sim WN(0,4)$ وإذا كانت $t = 10$ و

$z_9 = 77$ و $z_{10} = 85$ و $a_{10} = -1.6$ اوجد:

ا) دالة التنبؤ التي لها ادنى متوسط مربع اخطاء

ب) تبين دالة اخطاء التنبؤ حتى زمن التقدم $\ell = 3$

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.

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 اسبوعيا لدي 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 التى ستباع فى الاسبوعين التاليين واوجد فترات تنبؤ 95% لهذه التنبؤات كلما امكن ذلك باستخدام:

(ا) نموذج انحدار خطى للعدد المباع مع الزمن بالاسابيع.

(ب) التمهيد بواسطة متوسط متحرك من الدرجة الثالثة.

(ج) التمهيد الاسى البسيط مستخدما $\alpha = 0.3$.

السؤال الثانى:

للمنموذج $(1 - \phi_1 B - \phi_2 B^2)z_t = \delta + (1 - \theta B)a_t$ حيث $a_t \sim WN(0, \sigma^2)$ و $\phi_1, \phi_2, \delta, \theta$ هى معالم

النموذج و B هو عامل الازاحة الخلفى اوجد:

$$E(z_t) \forall t \quad (1)$$

(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:

للمودج $z_t = 38.5 + 1.2z_{t-1} - 0.7z_{t-2} + a_t - 0.4a_{t-1}$ حيث $a_t \sim WN(0,4)$ واذا كانت $t = 10$ و

$z_9 = 77$ و $z_{10} = 85$ و $a_{10} = -1.6$ اوجد:

(ا) دالة التنبؤ التى لها ادنى متوسط مربع اخطاء

(ب) تبين دالة اخطاء التنبؤ حتى زمن التقدم $\ell = 3$

(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 التنبؤ

بسم الله الرحمن الرحيم

قسم الإحصاء وبحوث العمليات
المادة : طرق التنبؤ الإحصائي 221 بحث
الاختبار الأول للأعمال الفصلية
الفصل الأول 1420-1421 هـ

الزمن : ساعتين

أجب علي جميع الأسئلة التالية:

السؤال الأول: لمتسلسلة زمنية $\{z_t\}$

- 1- أذكر شروط الاستقرار
- 2- عرف دالة الترابط الذاتي

السؤال الثاني: للمتسلسلة 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 تمهيد اسي بسيط $\alpha = 0.5$ ومن ثم أوجد z_{16}, z_{17}
- 4- إذا كانت $z_{16} = 56$ و $z_{17} = 49$ فأی من الطرق السابقة أكثر دقة وذلك بإستخدام معيار خطأ مناسب

السؤال الثالث:

للمنموذج $z_t = 20 - 0.9z_{t-1} + a_t$, $a_t \sim WN(0, 4)$

1- هل النموذج مستقر؟

2- أوجد μ

3- أوجد ρ_k و ϕ_{kk} لقيم $k = 0, 1, 2, \dots, 5$

بسم الله الرحمن الرحيم

قسم الإحصاء وبحوث العمليات

المادة : طرق التنبؤ الإحصائي 221 بحث

الاختبار النهائي للفصل الثاني 1420-1421 هـ

الزمن : أربع ساعات

أجب علي جميع الأسئلة التالية:

السؤال الأول: (20 علامة)

أكمل الفراغات التالية:

(1) لمتسلسلة زمنية $\{Z_t\}$ دالة التغير الذاتي تعطى بالعلاقة $\gamma_k = Cov(Z_t, Z_{t-k})$ ودالة

الترابط الذاتي بالعلاقة $\rho_k = \gamma_k / \gamma_0$ ولها الخواص $\rho_0 = 1$ و $|\rho_k| \leq 1$ و

$\rho_k = \rho_{-k}$ (5 علامات)

(2) لمتسلسلة زمنية مشاهدة $z_1, z_2, \dots, z_n$ دالة الترابط الذاتي للعينة تقدر من العلاقة

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

لدالة الترابط الذاتي للعينة تقدر من العلاقة $s.e(r_k) \approx 1/\sqrt{n}$ كما ان دالة الترابط الذاتي

$$r_{k+1,k+1} = \frac{r_{k+1} - \sum_{j=1}^k r_{kj} r_j}{1 - \sum_{j=1}^k r_j^2}$$

الجزئي للعينة تقدر من العلاقة و العلاقة المساعدة

$$r_{k+1,j} = r_{kj} - r_{k+1,k+1} r_{k,j}, j = 1, \dots, k$$

(8 علامات) $\pm \frac{1}{\sqrt{n}}$ ولها حدود حرجة

(3) نموذج $AR(\square)$ يعطى بالعلاقة

$$\left(1 - \phi_1 \square - \phi_2 \square^2\right) Z_t = a_t, a_t \sim WN(\square, \square)$$

$$Z_t = \delta + \phi_1 \square + \phi_2 \square + a_t \quad (7 \text{ علامات})$$

السؤال الثاني: (40 علامة)

البيانات التالية هي حجم المبيعات اليومية لشركة ما بآلاف الريالات: (اقرأ 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) باستخدام الأمرين %acf و %pacf في Minitab تعرف علي النموذج من عائلة النماذج $ARIMA(p, d, q)$ والذي تتبعه البيانات (7 علامات)
- (2) أوجد مقدرات أولية لمعالم النموذج المتعرف عليه بطريقة العزوم وطريقة المربعات الدنيا الشرطية (9 علامات)
- (3) باستخدام مقدرات المعالم بطريقة المربعات الدنيا الشرطية أو العزوم أكتب النموذج علي الشكل $Z_t = \delta + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$ حيث $a_t \sim WN(0, \sigma^2)$ (4 علامات)
- (4) أوجد دالة التنبؤ للنموذج ومن ثم أوجد تنبؤات للقيم المستقبلية Z_{99} و Z_{100} وإذا علمت أن $\sigma^2 = 10.83$ فاوجد فترات تنبؤ 95% للقيم المستقبلية Z_{99} و Z_{100} (10 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 ام بعد التجديد ؟ (5 علامات)
- (6) باستخدام الأمر arima p d q C1 والأوامر الفرعية forecast 5 C2 C3 C4 و gseries و gacf و gpacf و ghist و gnormal و gfit تحقق و قارن مع نتائجك في الفقرات السابقة. (5 علامات)

بسم الله الرحمن الرحيم

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 الحاسب في أحد الشركات شهريا (إقرأ من اليسار لليمين سطرًا 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 للبرنامج 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 المقترح.

د) أي نموذج من النماذج السابقة (في الفقرتين ب و ج) يصف المشاهدات بشكل أفضل؟

هـ) باستخدام النموذج الأفضل ولد تنبؤات للشهرين التاليين بفترات تنبؤ 95%

بسم الله الرحمن الرحيم

قسم الإحصاء وبحوث العمليات

المادة : طرق التنبؤ الاحصائي 221 بحث

الاختبار الاول الأعمال الفصلية

الفصل الثاني 1421/1422 هـ

الزمن : ساعتين

أجب علي جميع الأسئلة التالية:

السؤال الأول: شوهدت المتسلسة الزمنية التالية: (اقرأ من اليسار لليمين سطرا بسطر)

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 التفكيك 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 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 لخمس 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 اتجاه معين تتجه له المتسلسلة

(ج) يمكن استخدام طريقة التفكيك ولكنها تناسب أكثر المتسلسلات التي فيها مركبات إنجراف و موسمية

(د) يناسب التمهيد بالمتوسط المتحرك هذا النوع من المتسلسلات الزمنية أكثر من غيره من الطرق لأنه كما نرى هذه المتسلسلة تحتاج إلى تمهيد بسيط إذ ليس بها أي إنجراف أو موسمية
(هـ) التمهيد الاسي البسيط ينفع لمثل هذه المتسلسلات أيضا وخاصة إذا كانت تحوي إنجرافا بسيط

(و) التمهيد الاسي الثنائي يفيد أكثر في حالة المتسلسلات التي تحوي إنجرافا غير خطي والذي لا يبدو من تصرف المتسلسلة المشاهدة

(ز) طريقة ونترز تنفع للمتسلسلات الموسمية التي تحوي على مركبة إنجراف غير خطي
إجابة السؤال الثاني:

يبدو أن طريقة التمهيد بالمتوسط المتحرك هي الأكثر مناسبة لتحليل المتسلسلة المشاهدة. لنجرب عدة متوسطات متحركة لتمهيد المتسلسلة وإيجاد تنبؤات لها.

(1) لنجرب 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 متحرك 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

Moving Average



(3) لنجرب متوسط متحرك من الدرجة الرابعة (مركز):

```
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) أخيرا نجرب متوسط متحرك 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 تساوي
 التنبؤات للخمسة 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:

للمنموذج

$$(1 - 1.2B + 0.6B^2)(z_t - 65) = (1 - 0.4B)a_t, a_t \sim WN(0, 1)$$

(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 ψ_j لقيم $j = 1, 2, \dots, 5$.

السؤال الثاني:

للمنموذج 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 للقيم المستقبلية $z_{81}, z_{82}, z_{83}, z_{84}$.

(ب) أوجد فترات تنبؤ 95% للتنبؤات في الفقرة السابقة.

السؤال الثالث:

للمنموذج

$$(1 - 0.43B)(1 - B)z_t = a_t, a_t \sim WN(0, 1)$$

(أ) هل النموذج مستقر؟ ولماذا؟

(ب) إذا كانت $z_{49} = 33.4, z_{50} = 33.9$ فأحسب التنبؤات $z_{50}(\ell)$ لقيم $\ell = 1, 2, \dots, 5$.

(ج) أوجد فترات تنبؤ 95% للتنبؤات في الفقرة السابقة.

بسم الله الرحمن الرحيم

قسم الإحصاء وبحوث العمليات

كلية العلوم

جامعة الملك سعود

الإختبار النهائي للفصل الثاني 1421/1422 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 الأخيرة هي $z_{143} = 770, z_{144} = 800$

(أ) هل النموذج مستقر أم لا ولماذا؟

(ب) أوجد دالة الأوزان ψ_j لقيم $j = 1, 2, \dots, 5$.

(ج) احسب التنبؤات للثلاث (3) القيم المستقبلية التالية.

(د) اوجد فترات تنبؤ 95% للتنبؤات السابقة.

السؤال الثاني:

للمتسلسلة الزمنية التالية : (اقرأ من اليسار لليمين سطرا بسطر)

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 باستخدام Time Series Plot.

(ب) أقترح طريقة لتمهيد المتسلسلة بعد فحص الرسم.

(ج) لكل طريقة مقترحة قم بفحص البواقي Residuals وأختبر الفرضية فيما إذا كانت البواقي موزعة توزيع طبيعي وذلك باستخدام إختبار Kolmogorov-Smirnov Test .

(د) قارن معايير الدقة للأخطاء Mean Absolute Percentage Error

(MAPE) و (MAD) Mean Absolute Deviation و Mean

Squared Deviation (MSD) لكل طريقة مقترحة ومن ثم أستخدم الطريقة الأكثر

دقة لتوليد تنبؤات للخمسة القيم المستقبلية مع إيجاد فترات تنبؤ . 95%

السؤال الثالث:

للمتسلسلة الزمنية التالية: (اقرأ من اليسار لليمين سطرا بسطر)

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 اقترح نموذج مناسب من عائلة $ARIMA(p,d,q)$

وذلك بتعيين كل من p و d و q .

(ج) قدر المعالم للنموذج المقترح وأختبر الفرضيات فيما إذا كان أحد أو كل هذه المعالم مساويا للصفر.

(د) قم بفحص البواقي Residuals وأختبر الفرضية فيما إذا كانت البواقي موزعة توزيع

طبيعي وذلك باستخدام اختبار Kolmogorov-Smirnov Test.

(هـ) أحسب تنبؤات للخمسة القيم المستقبلية التالية مع إيجاد فترات تنبؤ . 95%

بسم الله الرحمن الرحيم

إجابات محتملة للاختبار النهائي للفصل الثاني 1422/1421 هـ

لمادة 221 بحث

إجابة السؤال الأول:

(أ) النموذج غير مستقر لأنه يحوى عامل التفريق $(1-B)$

(ب)

$$(1-0.7B)(1-B)z_t = a_t$$

$$(1-1.7B+0.7B^2)z_t = a_t$$

$$\begin{aligned}\therefore z_t &= \frac{1}{1-1.7B+0.7B^2} a_t \\ &= \psi(B)a_t\end{aligned}$$

$$\therefore \psi(B) = \frac{1}{1-1.7B+0.7B^2}$$

$$\therefore (1+\psi_1B+\psi_2B^2+\psi_3B^3+\dots)(1-1.7B+0.7B^2) \equiv 0$$

$$B: \psi_1 - 1.7 = 0 \Rightarrow \psi_1 = 1.7$$

$$B^2: \psi_2 - 1.7\psi_1 + 0.7 = 0 \Rightarrow \psi_2 = 1.7\psi_1 - 0.7 = 2.19$$

$$B^3: \psi_3 - 1.7\psi_2 + 0.7\psi_1 = 0 \Rightarrow \psi_3 = 1.7\psi_2 - 0.7\psi_1 = 2.53$$

$\vdots$

$$B^j: \psi_j - 1.7\psi_{j-1} + 0.7\psi_{j-2} = 0 \Rightarrow \psi_j = 1.7\psi_{j-1} - 0.7\psi_{j-2}, j = 2, 3, \dots$$

$$\therefore \psi_4 = 1.7\psi_3 - 0.7\psi_2 = 2.768$$

$$\psi_5 = 1.7\psi_4 - 0.7\psi_3 = 2.9346$$

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:

$$\begin{aligned}
& \therefore (1 - 1.7B + 0.7B^2)z_t = a_t \\
& \therefore z_t = 1.7z_{t-1} - 0.7z_{t-2} + a_t \\
& \therefore z_t(\ell) = E[z_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0 \\
& \quad = E[1.7z_{t+\ell-1} - 0.7z_{t+\ell-2} + a_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0 \\
& \quad = 1.7E[z_{t+\ell-1} | z_t, z_{t-1}, \dots] - 0.7E[z_{t+\ell-2} | z_t, z_{t-1}, \dots] + E[a_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0 \\
& \therefore \ell = 1: z_t(1) = 1.7E[z_t | z_t, z_{t-1}, \dots] - 0.7E[z_{t-1} | z_t, z_{t-1}, \dots] + E[a_{t+1} | z_t, z_{t-1}, \dots] \\
& \quad = 1.7z_t - 0.7z_{t-1} \\
& \ell = 2: z_t(2) = 1.7E[z_{t+1} | z_t, z_{t-1}, \dots] - 0.7E[z_t | z_t, z_{t-1}, \dots] + E[a_{t+2} | z_t, z_{t-1}, \dots] \\
& \quad = 1.7z_t(1) - 0.7z_t \\
& \ell = 3: z_t(3) = 1.7E[z_{t+2} | z_t, z_{t-1}, \dots] - 0.7E[z_{t+1} | z_t, z_{t-1}, \dots] + E[a_{t+3} | z_t, z_{t-1}, \dots] \\
& \quad = 1.7z_t(2) - 0.7z_t(1) \\
& \therefore \ell \geq 3: z_t(\ell) = 1.7z_t(\ell-1) - 0.7z_t(\ell-2) \\
& \therefore t = 144
\end{aligned}$$

$$\begin{aligned}
& \therefore z_{144}(1) = 1.7z_{144} - 0.7z_{143} = 1.7(800) - 0.7(770) = 821 \\
& z_{144}(2) = 1.7z_{144}(1) - 0.7z_{144} = 1.7(821) - 0.7(800) = 835.7 \\
& z_{144}(3) = 1.7z_{144}(2) - 0.7z_{144}(1) = 1.7(835.7) - 0.7(821) = 845.99
\end{aligned}$$

إذا التنبؤات للثلاث قيم المستقبلية هي:

$$z_{144}(1) = 821, \quad z_{144}(2) = 835.7, \quad z_{144}(3) = 845.99$$

(د) فترات $100\%(1-\alpha)$ 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: $V[e_t(\ell)] = \sigma^2(1 + \psi_1^2 + \psi_2^2 + \dots + \psi_{\ell-1}^2), \ell \geq 0$

$$V[e_t(1)] = \sigma^2 = 25$$

$$V[e_t(2)] = \sigma^2(1 + \psi_1^2) = 25(1 + (1.7)^2) = 97.25$$

$$V[e_t(3)] = \sigma^2(1 + \psi_1^2 + \psi_2^2) = 25(1 + (1.7)^2 + (2.19)^2) = 217.1525$$

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:

(أ)




(ب) من الرسم السابق نجد أن المتسلسلة غير موسمية ولذلك نستخدم في تمهيدها أحد الطرق التالية:

- 1- المتوسط المتحرك Moving Average Smoothing
- 2- التمهيد الأسّي البسيط Single Exponential Smoothing
- 3- التمهيد الأسّي الثنائي Double Exponential Smoothing

أولا 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 الأسّي 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 الأسّي 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 البواقي:


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	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 الأسّي 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

P	Percentile	95% CI	95% CI
		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 الأسّي الثنائي

Autocorrelation Function for RESI3




Lag	Corr	T	LBQ	Lag	Corr	T	LBQ
1	-0.22	-1.53	2.50	8	0.16	0.96	15.06
2	-0.29	-1.98	7.12	9	-0.16	-0.89	16.62
3	0.22	1.39	9.81	10	0.01	0.04	16.62
4	-0.07	-0.43	10.10	11	0.19	1.06	18.99
5	0.00	0.03	10.10	12	-0.15	-0.82	20.53
6	0.17	1.03	11.82				
7	-0.16	-0.95	13.38				


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 Lower Limit	Approximate 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 البواقي تحقق الفرضيات

1- غير مترابطة

2- لها تقريبا توزيع طبيعي بمتوسط صفري وتباين 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 الأسّي البسيط يعطي أفضل نتيجة.
التنبؤات باستخدام التمهيد الأسّي 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:

(أ)




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			

واضح من الشكل أن SACF تتخامد أسياً و SPACF لها قطع بعد $r_{1,1}$ وهذا يقترح نموذج

$ARIMA(1,0,0)$ أي أن $p=1$ و $d=0$ و $q=0$

(ج) تقدير المعالم:

```
MTB > ARIMA 1 0 0 'Defects' 'RESI1' '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	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= *)

Forecasts from period 45

95 Percent Limits

Period	Forecast	Lower	Upper Actual
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 المقترح هو

$$z_t = 0.9928 - 0.4421z_{t-1} + a_t, \quad a_t \sim WN(0, 0.22042)$$

$$\text{or } (z_t - 1.7795) = -0.4421(z_{t-1} - 1.7795) + a_t$$

حيث

$$\hat{\phi}_1 = 0.4421, s.e(\hat{\phi}_1) = 0.1365, \text{ with t-value} = 3.24$$



أي أن معامل الانحدار الذاتي معنوي

$$\hat{\delta} = 0.9928, s.e(\hat{\delta}) = 0.06999, \text{ with t-value} = 14.19$$




وأيضا المستوى δ معنوي

(د) فحص البواقي:

1- عدم الترابط



التوزيع الطبيعي:



```
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 Lower Limit	Approximate 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




نفحص أنماط البواقي مع القيم المطبقة

Residuals Versus the Fitted Values

(response is Defects)



والبواقي مع ترتيب البيانات



من الفحوصات السابقة نستنتج أن النموذج المقترح مناسب للتطبيق علي البيانات المعطاة
(هـ)

95% Forecasts from period 45 التنبؤات للخمس القيم المستقبلية وفترات تنبؤ

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 الإحصائي 221 بحث

الاختبار الأول للأعمال الفصلية

الفصل الأول 1420-1421 هـ

الزمن : ساعتين

أجب علي جميع الأسئلة التالية:

السؤال الأول:

ا- ضع النموذج التالي $z_{n+j} = \beta_0 + \beta_1 j + \varepsilon_{n+j}, j = 0, \pm 1, \dots$ علي الشكل

وذلك بتحديد كل من β و $f'(j)$ أوجد L وبرهن ان

$$f'(j+1) = Lf'(j)$$

ب- بوضع $y' = (z_1, \dots, z_n)$ و $X' = [f(-n+1), f(-n+2), \dots, f(1), f(0)]$ برهن ان

$$X'X = \sum_{j=0}^{n-1} f(-j)f'(-j) \text{ وان } X'y = \sum_{j=0}^{n-1} f(-j)z_{n-j} \text{ ومن ثم اوجد مقدر للمعلم } \beta$$

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 متنبئات لقيم المتسلسلة

$$z_{13}, z_{14}$$

ب- بأخذ $\alpha = 0.5$ طبق تمهيد اسي بسيط للمتسلسلة المعطاه ومن ثم اوجد متنبئات لقيم المتسلسلة

$$z_{13}, z_{14}$$

السؤال الثالث:

للمودج التالي $z_t = \delta + \phi_1 z_{t-1} + a_t$ حيث $0 < \delta < \infty$ مقدار ثابت و $|\phi_1| < 1$ و

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

ا- اوجد دالة الترابط الذاتي $\rho_k, \forall k$ وارسمها لقيم $k = 0, 1, \dots, 5$

ب- اوجد دالة الترابط الذاتي الجزئي $\phi_{k,k}, \forall k$ و وارسمها لقيم $k = 0, 1, \dots, 5$

بسم الله الرحمن الرحيم

جامعة الملك سعود – كلية العلوم

قسم الإحصاء وبحوث العمليات

إختبار أعمال فصل أول 1422/1423 هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي

الزمن: 2 ساعة

أجب على جميع الأسئلة التالية:

السؤال الأول:

للمنودج

$$z = \beta_0 + \beta_1 t + x_t$$

$$x_t = \phi_1 x_{t-1} + a_t, a_t \sim WN(0, \sigma^2)$$

على إفتراض أن المعالم $\beta_0, \beta_1, \phi_1, \sigma^2$ معلومة.

برهن أن المتنبئ الخطي ذا أدنى متوسط 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:

إعتامدا على متسلسلة طولها $n = 200$ مشاهدة طبق نموذج $AR(2)$ وحصلنا على الترابطات

الذاتية للبواقي التالية $r_1 = 0.13, r_2 = 0.13, r_3 = 0.12$ إذا كانت $\hat{\phi}_1 = 1.1, \hat{\phi}_2 = -0.8$

فهل الترابطات الذاتية للبواقي تدعم أن النموذج هو $AR(2)$ كل على حدة أو مجتمعة؟

السؤال الثالث:

للمتسلسلة المستقرة التالية 6, 5, 4, 6, 4 قدر μ, γ_0, ρ_1

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 للمعالم $\phi_1, \phi_2, \delta, \sigma^2$

بسم الله الرحمن الرحيم

جامعة الملك سعود – كلية العلوم

قسم الإحصاء وبحوث العمليات

الإختبار النهائي للفصل الأول 1423/1422 هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن: 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

للمنودج

$$z = \beta_0 + \beta_1 t + x_t$$

$$x_t = \phi_1 x_{t-1} + a_t, a_t \sim WN(0, \sigma^2)$$

على إفتراض أن المعالم $\beta_0, \beta_1, \phi_1, \sigma^2$ معلومة.

برهن أن المتنبئ الخطي ذا أدنى متوسط 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:

إعتمادا على متسلسلة طولها $n = 200$ مشاهدة طبق نموذج $AR(2)$ وحصلنا على الترابطات

الذاتية للبواقي التالية $r_1 = 0.13, r_2 = 0.13, r_3 = 0.12$ إذا كانت $\hat{\phi}_1 = 1.1, \hat{\phi}_2 = -0.8$

فهل الترابطات الذاتية للبواقي تدعم أن النموذج هو $AR(2)$ كل على حدة أو مجتمعة؟

السؤال الثالث:

للمتسلسلة المستقرة التالية $6, 5, 4, 6, 4$ قدر μ, γ_0, ρ_1

السؤال الرابع:

للمتسلسلة 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 للمعالم $\phi_1, \phi_2, \delta, \sigma^2$

السؤال الخامس:

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

1- أوجد تنبؤات لمبيعات 1422 و 1423 و 1424 هـ

2- أحسب الأوزان $\psi_j, j = 1, 2, 3, 4$

ج) أحسب فترات تنبؤ 95% للمبيعات للسنوات 1422 و 1423 و 1424 هـ.

بسم الله الرحمن الرحيم

جامعة الملك سعود – كلية العلوم

قسم الإحصاء وبحوث العمليات

الإختبار النهائي للفصل الأول 1423/1422 هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي)

الزمن: 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

للمنودج

$$z_t = \beta_0 + \beta_1 t + x_t$$

$$x_t = \phi_1 x_{t-1} + a_t, a_t \sim WN(0, \sigma^2)$$

على إفتراض أن المعالم $\beta_0, \beta_1, \phi_1, \sigma^2$ معلومة.

برهن أن المتنبئ الخطي ذا أدنى متوسط 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:

إعتمادا على متسلسلة طولها $n = 200$ مشاهدة طبق نموذج $AR(2)$ وحصلنا على الترابطات

الذاتية للبواقي التالية $r_1 = 0.13, r_2 = 0.13, r_3 = 0.12$ إذا كانت $\hat{\phi}_1 = 1.1, \hat{\phi}_2 = -0.8$

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 للمعالم $\phi_1, \phi_2, \delta, \sigma^2$

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% للمبيعات للسنوات 1422 و 1423 و 1424 هـ.

بسم الله الرحمن الرحيم

إجابات نموذجية للإختبار النهائي للفصل الأول 1423/1422 هـ

لمادة 221 بحث (طرق التنبؤ الإحصائي)

إجابة للسؤال الأول:

نضع المعادلات المعرفة للنموذج على الشكل

$$z_t = \beta_0 + \beta_1 t + \phi_1 x_{t-1} + a_t, a_t \sim WN(0, \sigma^2)$$

المتنبئ الخطي ذا أدنى متوسط مربع خطأ الخطوة ℓ إلى الأمام يعطى من العلاقة

$$z_t(\ell) = E(z_{t+\ell} | z_t, z_{t-1}, \dots), \ell \geq 0$$

$$\because x_t = z_t - \beta_0 - \beta_1 t$$

$$\therefore z_t - \beta_0 - \beta_1 t = \phi_1 [z_{t-1} - \beta_0 - \beta_1 (t-1)] + a_t, a_t \sim WN(0, \sigma^2)$$

$$z_t(\ell) - \beta_0 - \beta_1 (t + \ell) = E[\phi_1 [z_{t+\ell-1} - \beta_0 - \beta_1 (t + \ell - 1)] + a_{t+\ell} | z_t, z_{t-1}, \dots], \ell \geq 0$$

$$= E(\phi_1 [z_{t+\ell-1} - \beta_0 - \beta_1 (t + \ell - 1)] | z_t, z_{t-1}, \dots) + E(a_{t+\ell} | z_t, z_{t-1}, \dots), \ell \geq 0$$

$$\ell = 1 : z_t(1) - \beta_0 - \beta_1 (t + 1) = E(\phi_1 (z_t - \beta_0 - \beta_1 t) | z_t, z_{t-1}, \dots) + 0$$

$$= \phi_1 (z_t - \beta_0 - \beta_1 t)$$

$$\ell = 2 : z_t(2) - \beta_0 - \beta_1 (t + 2) = \phi_1 [z_t(1) - \beta_0 - \beta_1 (t + 1)] = \phi_1^2 (z_t - \beta_0 - \beta_1 t)$$

$$\ell = 3 : z_t(3) - \beta_0 - \beta_1 (t + 3) = \phi_1 [z_t(2) - \beta_0 - \beta_1 (t + 2)] = \phi_1^3 (z_t - \beta_0 - \beta_1 t)$$

$$\ell = 4 : z_t(4) - \beta_0 - \beta_1 (t + 4) = \phi_1 [z_t(3) - \beta_0 - \beta_1 (t + 3)] = \phi_1^4 (z_t - \beta_0 - \beta_1 t)$$

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 وبحوث العمليات

مادة 221 بحث (طرق التنبؤ الإحصائي)

الإختبار النهائي للفصل الثاني 1423/1422 هـ

الزمن 3 ساعات

أجب على جميع الأسئلة التالية:

السؤال الأول:

للمنموذج

$$z_t = 200 + 1.2z_{t-1} - 0.7z_{t-2} + a_t + 0.5a_{t-1}, a_t \sim N(0,1)$$

1- أوجد دالة الترابط الذاتي ρ_k لقيم $k = 1, 2, \dots, 5$ وارسمها.

2- أوجد دالة الترابط الذاتي الجزئي ϕ_{kk} لقيم $k = 1, 2, \dots, 5$ وارسمها.

3- أوجد دالة الأوزان ψ_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 سطرًا 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 بإستخدام

معياري المعلومات الذاتي AIC والذي يعطى بالعلاقة: $AIC(m) = n \ln \sigma_a^2 + 2m$

2- للنموذج المقترح قم بفحص البواقي مجريا عليها جميع الإختبارات المناسبة.

3- من النموذج المقترح ولد تنبؤات للقيم المستقبلية حتى 8 أزمنة تقدم مع فترات تنبؤ 95% .

بسم الله الرحمن الرحيم

إجابات محتملة للاختبار 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

$$\mu = \frac{\delta}{(1 - \phi_1 - \phi_2)} = \frac{200}{1 + 0.7 - 1.2} = 400 \text{ عن المتوسط}$$

$$z_t - 400 = 1.2(z_{t-1} - 400) - 0.7(z_{t-2} - 400) + a_t + 0.5a_{t-1}, a_t \sim N(0,1)$$

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

$$\gamma_k = 1.2\gamma_{k-1} - 0.7\gamma_{k-2}, k = 2, 3, \dots$$

$$\rho_k = 1.2\rho_{k-1} - 0.7\rho_{k-2}, k = 2, 3, \dots$$

$$\therefore \rho_2 = 1.2\rho_1 - 0.7\rho_0 = 1.2(0.74436) - 0.7(1) = 0.193232$$

$$\rho_3 = 1.2\rho_2 - 0.7\rho_1 = -0.289173$$

$$\rho_4 = -0.482271$$

$$\rho_5 = -0.376304$$

$$\rho_6 = -0.113975$$

$$\rho_7 = 0.126642$$


$$\rho_8 = 0.231754$$

$$\rho_9 = 0.189455$$

$$\rho_{10} = 0.651180$$

وترسم كالتالي:

ACF of the Model



2- نوجد 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



3- 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:

$$\psi(B) = \frac{(1 - 0.5B)}{(1 - 1.2B + 0.7B^2)} = 1 + \psi_1B + \psi_2B^2 + \psi_3B^3 + \dots$$

نوجد الأوزان كالتالي:

$$(1 + \psi_1B + \psi_2B^2 + \psi_3B^3 + \dots)(1 - 1.2B + 0.7B^2) \equiv (1 + 0.5B)$$

$$B : \psi_1 - 1.2 = 0.5 \Rightarrow \psi_1 = 1.7$$

$$B^2 : \psi_2 - 1.2\psi_1 + 0.7 = 0 \Rightarrow \psi_2 = 1.2\psi_1 - 0.7 = 1.34$$

$$B^3 : \psi_3 - 1.2\psi_2 + 0.7\psi_1 = 0 \Rightarrow \psi_3 = 1.2\psi_2 - 0.7\psi_1 = 0.418$$

⋮

$$B^j : \psi_j = 1.2\psi_{j-1} - 0.7\psi_{j-2}$$

$$\psi_4 = 1.2\psi_3 - 0.7\psi_2 = -0.4364$$

$$\psi_5 = -0.81628$$

$$\psi_6 = -0.674056$$

$$\psi_7 = -0.237471$$


$$\psi_8 = 0.186874$$

$$\psi_9 = 0.390478$$

$$\psi_{10} = 0.337762$$

ولها الشكل التالي:

Psi Weights of the Model



4- 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

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

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

إذا:


$$\begin{aligned} z_n(\ell) &= E(z_{n+\ell} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= E(200 + 1.2z_{n+\ell-1} - 0.7z_{n+\ell-2} + a_{n+\ell} + 0.5a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ &= 200 + 1.2E(z_{n+\ell-1} | z_n, z_{n-1}, \dots) - 0.7E(z_{n+\ell-2} | z_n, z_{n-1}, \dots) \\ &\quad + E(a_{n+\ell} | z_n, z_{n-1}, \dots) + 0.5E(a_{n+\ell-1} | z_n, z_{n-1}, \dots), \quad \ell \geq 1 \\ \ell = 1: z_n(1) &= 200 + 1.2z_n - 0.7z_{n-1} + 0.5a_n \\ \ell = 2: z_n(2) &= 200 + 1.2z_n(1) - 0.7z_n \\ \ell \geq 3: z_n(\ell) &= 200 + 1.2z_n(\ell-1) - 0.7z_n(\ell-2) \end{aligned}$$

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 انها مستقرة في التوقع والتباين


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

ونأخذ اقل قيمة للمعيار $AIC(m) = n \ln \sigma_a^2 + 2m$ كالتالي: $p = 0,1,2$ $q = 0,1,2$

1- $ARMA(1,0)$

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

$$= 64 \ln(4.272) + 2(3) = 64(1.452) + 6 = 98.928 \quad AIC(m) = n \ln \sigma_a^2 + 2m$$

2- $ARMA(2,0)$

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

$$= 64 \ln(1.998) + 2(4) = 64(0.692) + 8 = 52.288 \quad AIC(m) = n \ln \sigma_a^2 + 2m$$

3- $ARMA(0,1)$

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
 $= 64 \ln(4.075) + 2(3) = 64(1.40487) + 6 = 95.912$ $AIC(m) = n \ln \sigma_a^2 + 2m$
4- $ARMA(0,2)$

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
 $= 64 \ln(2.447) + 2(4) = 64(0.89486) + 8 = 65.271$ $AIC(m) = n \ln \sigma_a^2 + 2m$
5- $ARMA(1,1)$

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)

$$MS = 2.518 \quad DF = 61$$

$$= 64 \ln(2.518) + 2(4) = 64(0.92346) + 8 = 67.101 \quad AIC(m) = n \ln \sigma_a^2 + 2m$$

6- $ARMA(2,1)$

Model cannot be estimated with these data

7- $ARMA(1,2)$

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)

$$MS = 2.111 \quad DF = 60$$

$$= 64 \ln(2.111) + 2(5) = 64(0.74716) + 10 = AIC(m) = n \ln \sigma_a^2 + 2m$$

57.818

8- $ARMA(2,2)$

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

$$= 64 \ln(1.916) + 2(6) = 64(0.65) + 12 = 53.6 \quad AIC(m) = n \ln \sigma_a^2 + 2m$$


ونلخصها في الجدول التالي:

$ARMA(p, q)$	$AIC(m)$	$\min AIC(m)$
$ARMA(0, 0)$	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 البواقي:

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)




Histogram of the Residuals

(response is Observed)



Normal Probability Plot



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 البواقي تجتاز كل الإختبارات وهذا يعني ان النموذج المقترح مناسب.

3- تنبؤات للقيم 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 Ledoter, 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 أو الكتاب أن يرسل لي ملاحظة على البريد الإلكتروني:

abarry@ksu.edu.sa أو abarry@abarry.ws