



جمهورية العراق
وزارة التعليم العالي والبحث العلمي
جامعة القادسية
كلية علوم الحاسوب وتكنولوجيا المعلومات
قسم الإحصاء والمعلوماتية

دراسة ظاهرة التشوهات الخلقية في محافظة الديوانية خلال السنوات

(2007-2016) باستخدام بعض طرائق السلاسل الزمنية

مؤثر مؤثر

الكلية كلية علوم الحاسوب وتكنولوجيا المعلومات / قسم الإحصاء والمعلوماتية وهو جزء
من متطلبات فيل درجة البكالوريوس في علوم الإحصاء والمعلوماتية

من قبل الطالبتين

نزهة كاظم أسود

نور فراس تركي

إشراف

أ.د. طاهر ريسان دجيل

بسم الله الرحمن الرحيم

((وَبَسِّمُكَ عَنِ الرُّوحِ قُلِ الرُّوحُ مِنْ أَمْرِ رَبِّي وَمَا أُوتِيتُمْ مِنْ

الْعِلْمِ إِلَّا قَلِيلًا (85)))

صدق الله العلي العظيم

سورة الاسراء

الاهداء

إلى أبي الغائب عن عيون محبيه الحاضر في قلوبهم، إليك
أيها القائد الذي لطالما ذكرتني بدعائك ولم تنس لحظة
إلى من نعيش بركة وجوده الشريف إلى من نعيش مرارة غيبته
ونحن معه مقصرون إلى من يرعانا برعايته الدائمة إلى
صاحب الأمر وسultan العصر وإمام الزمان إلى من يملأ
الأرض قسطاً وعدلاً بعد ما ملأت ظلماً وجوراً مولانا وسيدنا الإمام المهدي
المنتظر عجل الله تعالى فرجه الشريف
، بركتك يا سيدي أتمت هذه السنين الدراسية وبخيرك وفقك للتخرج
أهدي لك هذا القليل عسى أن تقبله .

شكر وتقدير

لأبد من كلمة شكر أقولها بحق معلمي ومشرفي الأستاذ طاهر ريسان
،الذي وجدت في شخصه الكريم صدرا رحبا وقلبا مفتوحا ،ويدا كريمة كان إنسانا
عالما ،فتح أمامي نورا أضاء طريقي .

إليه أقدم خالص شكري وتقديري ،فهو الذي منحني فرصة الخوض في هذا
العنوان المهم ،فهو كل الشكر والعرفان لإشرافه النبيل بنصائحه المتواصلة ،ومتابعته القيمة
،له الشكر بعد الله تعالى وجزاه الله خير الجزاء .

كما إن الشكر موصول إلى أساتذتي في قسم الإحصاء والمعلوماتية .
وأخر دعوانا الحمد لله رب العالمين والصلاة والسلام على سيد المرسلين وعلى
آله أجمعين .

الفصل الأول

المقدمة

الصفحة	الموضوع
2	- المقدمة
2	- أقسام العيوب الولادية
2	- أسباب حدوث التشوهات الولادية
3	- هدف البحث

الفصل الثاني

الجانب النظري

الصفحة	الموضوع
5	- مفهوم السلاسل الزمنية
5	- مكونات السلاسل الزمنية
6	- نماذج السلاسل الزمنية: Time Series Models
7	- نماذج بوكس و جنكينز
8	- النماذج المختلطة (Mixed Models)
9	- الاستقرارية وعدم الاستقرارية في السلاسل الزمنية

الفصل الثالث

الجانب العملي

الصفحة	الموضوع
23	نموذج هولت ووتر الجمعي Additive Holt - winter Model
28	نموذج هولت ووتر الضربي: Multiplicative Holt - Winter Model
32	معادلة خط الاتجاه العام الخطي: The Linear Trend Equaiont
36	نماذج بوكس جنكنز

الفصل الأول

المقدمة

- المقدمة
- أقسام العيوب الولادية
- أسباب حدوث التشوهات الولادية
- هدف البحث

المقدمة :

ان التشوهات الخلقية أو العيوب الولادية هي عبارة عن تخلق غير طبيعي في احد أعضاء الجسم أو الأنسجة في مرحلة تخلق الجنين، تحدث أكثر هذه العيوب أثناء الشهور الثلاثة الأولى من الحمل وتكون نسبة حدوثها بين 1-3%. يكون العيب الولادي قد يشمل على عيب في شكل جسم الطفل، أو عيب في وظائف الجسم، أو كلاهما. هناك بعض العيوب الولادية التي تتعارض مع القدرة على الحياة مثل عدم تخلق (تشكل) الكليتين أو عدم وجود أنسجة الدماغ وهناك عيوب ولادية يمكن أن تحتاج إلى علاج جراحي أو طبي مثل الشفة المشقوقة .

أقسام العيوب الولادية:

- 1- عيوب خلقية منفردة: يكون المولود سليم ولكن يوجد به عيب خلقي في عضو واحد فقط مثل القلب
- 2- العيوب الخلقية المتعددة: وتحدث عند ولادة طفل بأكثر من عيب خلقي واحد

أسباب حدوث التشوهات الولادية:

هناك عيوب خلقية ناتجة عن الجينات الموروثة وتنقسم الى :

- 1- أمراض سائدة حينما يكون احد الأبوين لديه عيب خلقي وتكون نسبه حدوث المرض السائد 50% مع كل حمل. أي 50% يكون طبيعي و50% يكون مريض كقصر القامة الشديد .
- 2- أمراض متنحية ويكون احد الأبوين ناقل فقط وليس مصاب ويكون نسبة حدوثه 25% وتزداد نسبة حدوثه في زواج الأقارب .
- 3- زواج الأقارب يزيد نسبة حدوث العيوب الخلقية 2-6%.

هدف البحث

إن الهدف من هذا البحث هو دراسة وتحليل السلسلة الزمنية المتعلقة بأعداد الأطفال الذين لديهم تشوهات خلقية وإمكانية الحصول على القيم التنبؤية أو التنبؤ مستقبلا لهذه القيم لغرض اتخاذ الإجراءات اللازمة للحد من هذه الظاهرة .

الفصل الثاني

الجانب النظري

- مفهوم السلاسل الزمنية
- مكونات السلاسل الزمنية
- نماذج السلاسل الزمنية: Time Series Models
- نماذج بوكس و جنكنز
- النماذج المختلطة (Mixed Models)
- الاستقرار وعدم الاستقرار في السلاسل الزمنية

مفهوم السلاسل الزمنية:

السلسلة الزمنية هي قيم ظاهره مرتبه حسب الزمن أو مجموعه القيم التي تأخذها الظاهرة في فترات زمنية متتالية ومتساوية وتحليل السلسلة الزمنية يعني تحديد مكوناتها الرئيسية وهي الاتجاه العام للتغير في قيمة الظاهرة على المدى الطويل والاتجاه الموسمي وهي التغيرات التي تحصل على قيم الظاهرة في فترات قصيرة (أقل من سنة) كالتغيرات الفصلية والشهرية واليومية والتغيرات الدورية التي تحصل على قيمة الظاهرة بشكل دوري في فترات زمنية تتراوح بين (3-10) سنوات والتي تعود للتطورات الاقتصادية والسياسية والتغيرات العرضية أو العشوائية وهي التغيرات التي تطرأ على قيمة الظاهرة بشكل غير منتظم نتيجة حدوث الكوارث الطبيعية أو الحروب أو الإضرابات العمالية.

مكونات السلاسل الزمنية:

يقصد بتحليل السلسلة الزمنية تحديد المكونات الرئيسية للتغيرات الحاصلة على قيمة الظاهرة مع الزمن وهذه المكونات هي:

1-الاتجاه العام للسلسلة الزمنية: Time Series Trend

الاتجاه العام للسلسلة الزمنية هو الاتجاه العام للتغير في قيمة الظاهرة على المدى الطويل ويرمز له بالرمز T والاتجاه العام للسلسلة الزمنية يمكن تمثيله بخط مستقيم إذا كان التغير في قيمة الظاهرة يسير بنسبه ثابتة مع الزمن أو بخط غير مستقيم إذا كان التغير في قيمة الظاهرة متغيرا وليس ثابتا ،حيث لا يمكن تمثيله بخط مستقيم وإنما بخط منحنى .

2-التغيرات الموسمية: Seasonal Variation

التغيرات التي تحصل على قيمة الظاهرة في فترات زمنية أقل من سنة كالتغيرات الفصلية والشهرية واليومية ويرمز للتغيرات الموسمية بالرمز S.

3-التغيرات الدورية: Cyclical Variation

وهي التغيرات التي تحصل على قيمة الظاهرة بصوره دوريه كل (3-10) سنوات كفترات الركود والكساد الاقتصادي والأزمات الاقتصادية التي تحدث بصوره دوريه ويرمز لهذه التغيرات بالرمز C والدورة هي المسافة بين تحديدين أو تعريين في منحنى السلسلة الزمنية.

4-التغيرات العرضية (غير المنتظمة): Irregular Variations

وهي التغيرات التي تحدث بصوره عرضيه أو عشوائية والتي تنتج عن حوادث غير متوقعه والتي تحدث حركات واتجاهات لا يمكن تمييزها لأنها لا تحدث بانتظام ويرمز للتغيرات العرضية بالرمز I .

نماذج السلاسل الزمنية: Time Series Models

يمكن التعبير عن قيمة الظاهرة التي تحدث بفترات متعاقبة من الزمن كدالة للزمن حيث يعبر عن ذلك بالعلاقة الدالية التالية:

$$Y=f(t)$$

حيث: t : يمثل متغير الزمن (المتغير المستقل)

Y قيمة الظاهرة (المتغير المعتمد)

f علاقة دالية

في السلاسل الزمنية يمكن التعبير عن قيمة الظاهرة بدلالة مكوناتها الرئيسية بشكلين رئيسيين هما النموذج الجمعي والنموذج الضربي .

أولاً//النموذج الجمعي: Additive Model:

وفيه يعبر عن قيمة الظاهرة كحاصل جمع لمكوناتها الرئيسية الأربعة وهي الاتجاه العام والأثر الموسمي والأثر الدوري والأثر غير المنتظم حيث يمكن التعبير عن قيمة الظاهرة y_t بالصيغة :

$$Y_t = T+S+C+I$$

حيث: Y_t : قيمة الظاهرة في الفترة الزمنية t

T اثر الاتجاه العام، S الأثر الموسمي، C التأثير الدوري، I ، التأثيرات غير المنتظمة .

ثانياً//النموذج الضربي: Multiplicative model:

في هذا النموذج يفترض أن المركبات المكونة للسلسلة الزمنية تتفاعل مع بعضها ولا تتحرك مستقلة، وإنما تكون مترابطة في هذه الحالة يعبر عن قيمة الظاهرة كحاصل ضرب لمكوناتها الرئيسية الأربعة، أي

$$T \times S \times C \times I$$

$$Y_t =$$

في النموذج الضربي يعبر عن قيمة T بالوحدات الأصلية، بينما C, S, I يعبر عنها كنسب

$$\text{Log } Y_t = \text{Log } T + \text{Log } S + \text{Log } C + \text{Log } I$$

مئوية

نماذج بوكس وجنكينز:

1- نموذج الانحدار الذاتي: (Autoregressive Model)

هو القيمة الحالية للسلسلة الزمنية في نموذج الانحدار الذاتي (Autoregressive Model) بدلالة المجموع الموزون للقيم السابقة للسلسلة الزمنية ($Z_{t-1}, Z_{t-2}, \dots$) مضافا إليه قيمة الخطأ العشوائي. لذا فان الصيغة العامة للنموذج ومن الرتبة p والذي يرمز له $AR(p) = ARMA(p, 0)$ كما يأتي :

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$
$$\phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$
$$Z_t =$$
$$t=p+1, p+2$$

حيث أن a_t تمثل سلسلة الأخطاء العشوائية المستقلة وتسمى التشويش الأبيض وتمثل متغيرا عشوائيا مستقلا والتي تتبع التوزيع الطبيعي بوسط حسابي مقداره صفر وتباين قدره σ^2 أي أن :

$$a_t \sim N(0, \sigma_a^2)$$

ϕ_i :يمثل المعلمات وبضرب الصيغة رقم (1) بالمقدار ϕ_i واخذ التوقع لها مع ملاحظة أن $E(Z_{t-k} a_t) = 0$ نحصل على التباين المشترك الذاتي وكما يأتي:

$$\gamma_K = \phi_1 \gamma_{K-1} + \dots + \phi_p \gamma_{K-p} ; K > 0$$

وللحصول على دالة الارتباط الذاتي وكالاتي :

$$= \phi_1 p_k$$

أما تباين السلسلة Z_t فيساوي :

حيث أن σ_a^2 تمثل تباين الخطأ للسلسلة الزمنية Z_t إما دالة الارتباط الذاتي الجزئي للنموذج $AR(p)$ فيتم باستخدام معادلات (Yule walker) فعندما ϕ_{kj} تمثل المعامل رقم j في النموذج ولكل من $(j=1, 2, \dots, k)$

$$p_{j-k+1} \phi_{k(k-1)} + \phi_{kk}$$

$$p_k = p_{j-1} \phi_{kj} + \dots + p_{j-k} \phi_{kk}$$

النماذج المختلطة (Mixed Models)

وهي النماذج التي تحتوي على خصائص النوعين (انحدار ذاتي AR_وسط متحرك MA) ان مثل هذه النماذج تسمى بالنماذج المختلطة (Auto Regressive_Moving Average) ويرمز لها (ARMA).

إذا كان الانحدار الذاتي من الرتبة (P) والأوساط المتحركة من الرتبة (q) فتسمى بالشكل $ARMA(q,p)$.

إن من المسائل المهمة والمرغوب بها تقليص عدد المعلمات في النموذج المختلط عند عمليه التقدير للنموذج وقد أكد الكثير من الباحثين مثل بوكس وغيره .

إن النماذج التي تحتوي على اقل عدد من المعلمات تكون أسهل وأكثر وضوحا للفهم، ونتيجة لهذه الاعتبارات فإنه يتم اختيار النموذج الملائم الذي يسهم في تمثيل الظاهرة المدروسة بأقل عدد ممكن من المعلمات

فإذا كانت $t=0 \pm 1 \pm 2; \dots$ سلسلة زمنية مستقرة احادية المتغير فان صيغة الانموذج المختلط $ARMA(p,q)$ ستكون كالآتي:

$$Z_t - Z_{t-1}\phi_1 - Z_{t-2}\phi_2 - \dots - Z_{t-p}\phi_p = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

$$\Phi(B)Z_t = \Theta(B)a_t \quad \text{أي أن:}$$

$$\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

حيث إن:

B تمثل عامل الارتداد الخلفي

$$B^j a_t = a_{t-j}$$

a_t : تمثل سلسلة الأخطاء العشوائية المستقلة وتمثل متغيرا عشوائيا مستقلا والتي تتبع التوزيع الطبيعي بوسط حسابي مقداره صفر وتباين قدره σ_a^2 أي ان:

$$a_t \sim N(0, \sigma_a^2)$$

$\Phi(B)$: تمثل متعددة حدود في (B) لمعلمات نموذج الانحدار الذاتي

الاستقرارية وعدم الاستقرارية في السلاسل الزمنية

Stationary and Non Stationary in Time Series

السلاسل الزمنية المستقرة تعرف على انها السلاسل التي تكون في حالة خاصة من الموازنة الاحصائية أي امتلاكها وسطاً حسابياً وتبايناً ثابتين مع استمرار الزمن، عندها يقال إن السلسلة الزمنية مستقرة في الوسط والتباين. وحتى يمكن تطبيق نماذج (B-j) يجب ان تكون السلسلة الزمنية مستقرة اذ تعد السلسلة الزمنية المستقرة (Stationary Time Series) من العمليات التصادفية المقامة على افتراض إن العملية لها حالة خاصة من الموازنة اما السلسلة الزمنية التامة الاستقرارية

(Stationary and Non Stationary in Time Series)

فأنها السلسلة التي تتصف بكون الخصائص الاحتمالية فيها لا تتأثر بتغير الزمن، أي ان السلسلة الزمنية مستقرة اذا لم يكن هناك اتجاه الى الأعلى او الى الاسفل في المعدل عبر الزمن او عدم ظهور اختلاف حول الوسط عبر الزمن. وكذلك تكون السلسلة الزمنية مستقرة بشكل تام (strictly stationary) اذا كانت عزومها لا تتأثر بتغير الزمن وعلى هذا الاساس تعد دراسة الاستقرارية من المراحل الاولى في بناء السلسلة الزمنية وتحليلها.

الكشف عن استقراريه او عدم استقراريه السلسلة الزمنية

تستخدم دالة الارتباط الذاتي للكشف عن استقرارية او عدم استقرارية السلسلة الزمنية ولإجراء اختبار لمعنوية معاملات الارتباط الذاتي نستخدم احصائية Price and Box وهي كالآتي:

$$Q = T \sum_{k=1}^k (P_k^2 - \chi_k^2) \dots (1)$$

حيث ان:

Q : تمثل احصاءة

p : تمثل معامل الارتباط

T : الفترة الزمنية

K : فترة الابطاء

χ^2 : قيمة مربع كاي

حيث ان Q لها توزيع مربع كاي بدرجات حرية K تساوي K فاذا كانت القيمة المحسوبة عند فترة ابطاء K معينة ومستوى ثقة معين اكبر من القيمة المجدولة (جداول مربع كاي) عند ذلك نرفض فرضية العدم أي: ان جميع معاملات الارتباط الذاتي مساوي للصفر وهذا يعني بان السلسلة غير مستقرة وبالعكس تقبل الفرضية البديلة اذا كانت القيمة المحسوبة اصغر من القيمة الجدولية اي ان السلسلة تكون مستقرة وفي الغالب يكون لدالة الارتباط الذاتي شكل خاص حيث انها تتناقص كلما زادت فترات الابطاء حتى تصل الى الصفر.

ولتحويل السلاسل الزمنية غير المستقرة الى سلاسل مستقرة نقوم بعملية التفاضل (أخذ الفروق) differencing للسلسلة الاصلية وذلك من خلال طرح قيم Z_t من Z_{t-1} و Z_{t-1} من Z_{t-2} وهكذا حتى نحصل على سلسلة زمنية جديدة ونختبر السلسلة الزمنية الجديدة فاذا اصبحت مستقرة تكون درجة التفاضل d مساوياً الى واحد اي تم اخذ فرق واحد واذا كانت السلسلة لازالت تعاني من

عدم الاستقرارية تقوم بالتفاضل مرة ثانية وهكذا حتى نصل الى سلسلة زمنية مستقرة، وعملية الفروق تجعل السلسلة الجديدة اقل من السلسلة القديمة بنقطة واحدة اذا كان الفرق واحد ويمكن إجراء عدة فروق للبيانات وبشكل عام ان عدد الفروق تكون اما واحد او اثنين ولكن عادة فرق واحد يكفي، وهناك عمليات التحويل للسلاسل الزمنية منها:

- 1- طرح متوسط السلسلة الزمنية من جميع البيانات وبذلك تتحول السلسلة الى سلسلة ذات وسط يساوي صفراً ويعتمد هذا الاسلوب على نوع البيانات وبرنامج الحاسوب المستعمل.
- 2- اما اذا كانت البيانات تحتوي على مركبة اتجاهية واضحة فيمكن عمل نموذج رياضي للمركبة الاتجاهية مثلاً معادلة خطية او معادلة من الدرجة الثانية او منحني وهكذا وبعد ذلك يتم طرحها من السلسلة الاصلية والمتبقي هو سلسلة زمنية بدون مركبة اتجاهية وتكون مستقرة.
- 3- في حالة ان وجدت السلسلة الزمنية لها تباين غير ثابت عند ذلك من الممكن تحول البيانات الى الصيغة اللوغاريتمية او يؤخذ لها الجذر التربيعي وهذا قد يؤدي الى ثبات التباين.
- 4- ان وجدت هناك بيانات سالبة ويراد اجراء تحويل عن طريق اخذ الجذر التربيعي عند ذلك يمكن اضافة حد ثابت يجعل السلسلة الزمنية موجبة، وهذا الثابت يساوي أكبر قيمة مطلقة للأعداد السالبة ويساوي أكبر قيمة مطلقة للأعداد السالبة مضافاً اليه واحد بالنسبة للتحويل اللوغاريتمي ويمكن حذف هذا الثابت من البيانات بعد اجراء التحليل وإعادة البيانات الى صيغتها الاصلية.

وبالرغم أن المركبة الفصلية قد تعتبر غير مستقرة ولكنها تعتبر مركبة من مركبات السلسلة الزمنية ومن الناحية العملية فمن النادر الحصول على عملية مستقرة بشكل تام، إضافة على ان فروض الطريقة المستخدمة للوصول الى الهدف المرجو من التطبيق العملي قد لا تتطلب الاستقرارية التامة للسلسلة الزمنية بل تتطلب استقرارية بدرجة أو بأخرى.

واستناداً الى ما تقدم يمكننا وصف العملية $Z(t)$ بأنها مستقرة من الدرجة الاولى اذا كان متوسطها ثابتاً ومستقلاً عن الزمن، وتكون مستقرة من الدرجة الثانية او ضعيفة الاستقرارية (Weakly Stationary) اذا كان كل من متوسطها وتباينها ثابتين ومستقلين عن الزمن وكذلك دالة التباين المشترك الذاتي γ_k (Covariance Function Auto) ايضاً مستقلة عن الزمن ، حيث ان دالة التباين الذاتي المشترك للمتغيرين Z_1, Z_{1+k} هي:

$$\gamma_k = \text{cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad \dots (2)$$

اما تباين السلسلة فيكون عبارة عن:

$$\text{Var}(Z_t) = \text{Var}(Z_{t+k}) = \gamma_0 \quad \dots (3)$$

ولتقدير دالة التباين الذاتي المشترك من سلسلة المشاهدات

$Z_1, Z_2, \dots, Z_T$ فنستخدم الصيغة:

$$\gamma = \frac{1}{T} \sum_{t=1}^{T-k} (Z_t - Z)(Z_{t+k} - Z) \quad \dots (4)$$

حيث أن:

$$Z = \sum_{t=1}^T Z_t / T$$

دالة الارتباط الذاتي ACF

(Auto-Correlation Function)

دالة الارتباط الذاتي (Auto-Correlation Function) والتي يرمز لها (ACF) تعتبر واحدة من الأساليب المهمة في معرفة استقرارية السلسلة الزمنية فضلاً عن الوسط الحسابي والتباين الثابتين. وكذلك لها دور كبير في تشخيص نماذج السلسلة الزمنية حيث من خلالها ومن خلال دالة الارتباط الذاتي الجزئي يتم تحديد نوع النموذج. ولأن التعريف الرياضي لدالة الارتباط الذاتي هو عبارة عن حاصل قسمة التباين المشترك مقسوماً على التباين لـ Z_t لنا من تعريف التباين المشترك وكالاتي:

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu)$$

$$\gamma_k = E(Z_t Z_{t+k})$$

علماً أن $E(Z_1) = 0$ في العملية المستقرة، فإن دالة الارتباط الذاتي P_k ستكون:

$$P = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \dots \dots \dots (11)$$

حيث أن:

$$Var(Z_t) = Var(Z_{t+k}) = \gamma_0 \dots \dots (12)$$

أما دالة الارتباط الذاتي للعينه PK

$$P_k = \frac{\gamma_k}{\gamma_0} = \frac{\sum_{t=1}^{n-k} (Z_t - Z)(Z_{t+k} - Z)}{\sum_{t=1}^n (Z_t - Z)^2} \dots \dots \dots (13)$$

حيث أن Z تمثل متوسط العينة للسلسلة الزمنية Z_t

$$Z = \frac{\sum_{t=1}^n Z_t}{n} \dots \dots \dots (14)$$

وكذلك يمكن ايجاد التباين لـ P و لـ m من فترات الازاحة وكما يأتي:

$$Var(P_k) = \frac{1}{n} (1 + 2p_1^2 + \dots + 2p_m^2)$$

$$; m = 0, 1, \dots, k \dots \dots \dots (15)$$

وللنماذج المستقرة فان γ_k و p_k لها الخواص الاتية :

$$1. \gamma_0 = var(z_t) \quad ; \quad p_0 = 1$$

$$2. |\gamma_k| \leq \gamma \quad ; \quad |P_k| \leq 1$$

$$3. \gamma_k = \gamma_{-k} \quad ; \quad P_k = P_{-k}$$

وتعني الخاصية رقم (3) بأن γ_k , p_k دوال زوجية ومتماثلة *Even Symmetric Functions* حول نقطة الاصل $K = 0$ ، وهذا نتيجة أن فرق الزمن بين Z_{t+k} , Z_t هو الفرق نفسه بين Z_{t-k} , Z_t وبذلك فإن دالة الارتباط الذاتي (ACF) ترسم بالاتجاه الموجب.

تعتبر دالة الارتباط الذاتي ذات اهمية كبيرة في عملية تحديد النموذج ولكنها لا تمكننا دائماً من تحديد النموذج المناسب. ان هناك دالة اخرى تسهم في تشخيص النموذج المناسب ، تعرف هذه الدالة بدالة الارتباط الذاتي الجزئي *(Function Partial Autocorrelation)* ويشار اليها اختصاراً (PACF) وتكشف هذه الدالة الارتباط بين Z_1 , Z_{1+k} بثبوت المتغيرات الاخرى.

دالة الارتباط الذاتي الجزئي (PACF)

Partial Auto – Correlation Function

دالة الارتباط الذاتي الجزئي والتي يرمز لها اختصاراً (PACF) تستخدم في تحديد النموذج المناسب للسلسلة الزمنية المستقرة. وتعرف دالة الارتباط الذاتي الجزئي بأنها معاملات ϕ_{kk} المتأثية من الارتباط الذاتي بين Z_t, Z_{t+k} بعد إزالة تأثير $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$

أي أن:

$$\text{Corr}(Z_t, Z_{t+k} / Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}) \dots \dots \dots (16)$$

ويتم حسابها على وفق الصيغة الآتية:

$$; i = 1, 2, \dots, k \dots \dots \dots (17)$$

$$P_i = \phi_{k1} P_{i-1} + \phi_{k2} P_{i-2} + \dots + \phi_{kk} P_{i-k}$$

ويتم الحصول على مجموعة معاملات Yule-Walker باستخدام قاعدة كريمر Gramers Rule للمعاملات الخاصة بالارتباطات الذاتية وتكون معاملات الارتباط الذاتي الجزئي ϕ_{kk} بالشكل الآتي:

$$\phi_{kk} = P_k^{-1} P_k \dots \dots \dots (18)$$

حيث أن:

ϕ_{kk} : يمثل متجه بقيم معاملات P.A.C ذات الرتبة (kX1).

P : مصفوفة بقيم معاملات $A.C$ ذات الرتبة $k \times k$ علماً أن عناصر قطرها مساوية الى الواحد.

P_k : يمثل متجه بقيم معاملات $A.C$ ذات الرتبة $(k \times 1)$.

وفي حالة $(k = 1)$ فإن الصيغة رقم (2-16) تساوي: $\phi_{11} = P_1$

أما بالنسبة للعينة فإن ϕ_{kk} تمثل دالة الارتباط الجزئي للعينة

Sample Partial Auto – Correlation Function

ويرمز لها اختصاراً $(SPACE)$ ولحساب ϕ_{kk} تستخدم الصيغة المعطاة من قبل $Durbin (1960)$ كما يأتي:

$$\phi_{k+1,k+1} = \frac{P - \sum_{j=1}^k \phi P_{k+1-j}}{1 - \sum_{j=1}^k \phi P_j}; j = 1, 2, \dots, k; \dots \dots \dots (19)$$

$$\phi = \phi - \phi \phi \dots \dots \dots (20)$$

وأن:

وباستخدام قاعدة كرامر لحل المعادلات اعلاه سنحصل على:

$$\phi = P$$

$$\phi = \frac{\begin{vmatrix} 1 & P \\ P & P \end{vmatrix}}{\begin{vmatrix} 1 & p \\ P & 1 \end{vmatrix}} \dots \dots \dots (21)$$

$$\phi = \frac{\begin{vmatrix} 1 & P & P & . & . & . & P & P \\ P & 1 & p & . & . & . & p & p \\ . & . & . & . & . & . & . & . \\ . & . & . & . & . & . & . & . \\ P & p & . & . & . & . & p & p \end{vmatrix}}{\begin{vmatrix} 1 \\ P \\ . \\ . \\ P \end{vmatrix}}$$

معيار معلومة اكيكي (AIC)

AKaike Information Criterion

في عام (1973) قام الباحث Akaike بأيجاد المعيار (AIC) معيار معلومة اكيكي *AKaike Information Criterion* ويعرف:

$$AIC(M) = -2 (\text{maximum Like lihood}) + 2M$$

فإذا كان النموذج بمعلومات M وفق للبيانات، تكون صيغة المعيار AIC كما يأتي:

$$AIC(M) = n \quad \dots \dots \dots (34)$$

وبالنسبة للنموذج ARMA ولعدد n من المشاهدات فإن Log-likelihood Function يكون :

$$1nL = -\frac{n}{2} 1n2\pi\sigma_a^2 - \frac{1}{2\sigma_a^2} S(\phi, \mu, \theta) \quad \dots \dots \dots (35)$$

وتعظيمها بالنسبة الى $\phi, \mu, \theta, \sigma_a^2$ تكون لدينا الصيغة :

$$1nL = -\frac{n}{2} 1n\hat{\sigma}_a^2 - \frac{n}{2} (1 + 1n2\pi)$$

..... (36)

ولان الحد الثاني ثابت فأن المعيار AIC يكون :

$$AIC(M) = n1n\hat{\sigma}_a^2 + 2M$$

..... (37)

او

$$AIC(p, q) = 1n\hat{\sigma}_a^2 + 2(p + q)/n$$

..... (38)

حيث ان:

M : هي دالة لرتبة النموذج p, q

n : عدد المشاهدات .

$\hat{\sigma}_a^2$: مقدر تباين الخطأ

ويمكن ان يكون المعيار AIC بشكل معياري من خلال قسمة المعيار على حجم العينة وصيغته:

$$NAIC(M) = AIC(M)/n$$

$$= 1n\hat{\sigma}_a^2 + \frac{2M}{n}$$

..... (39)

وفي العام (1977) اقترح الباحثان Downhen, Bhans استخدام المعيار AIC من خلال استبدال الحد الثاني وصيغته:

$$AIC_{\alpha}(M) = n1n1n\hat{\sigma}_a^2 + \alpha M$$

(40)

حيث $\alpha > 0$ وتأخذ القيم (3,4) .

كما أوجد الباحثان Tsai , Hurich عام (1989) معيارا جديدا أطلق عليه اسم معيار معلومات اكيكي المصحح AICC وصيغته .

$$AIC_c = n \ln \hat{\sigma}_a^2 + n \frac{1 + np}{1 - (p + 2)/n}$$

(41)

ويكون مقدرا غير متحيز لمعلومات kullback- leibler

وفي العام (1991) اقترح الباحثان Davis , Brocwell معيارا جديدا بالاعتماد على AIC ، AICC ، ويرمز له بالرمز AIC_C^{BD} وصيغته :

$$AIC_C^{BD} = n(1n\hat{\sigma}_a^2 + 1) + \frac{2(p + 1)n}{n - p - 2}$$

(42)

وان عملية تحديد التربة تكون باختيار النموذج الذي يقابل القيمة الاقل معيار .

ويرى الباحث ان المعيار AIC يمكن ان يعد اداة من أدوات التشخيص اضافة الى كونه معيارا لتحديد الرتبة للنموذج . فعلى سبيل المثال إذا كنا نريد ان نوفق واحدا من النماذج

AR, MA, ARMA ولكننا غير متأكدين من النوع الواجب استعماله فنبدأ بتوفيق النموذج $ARMA(p, q)$ ، ونستخدم المعيار AIC حيث من خلاله نحدد قيمة p, q .

فاذا كانت $p=0$ فإن النموذج يكون $MA(q)$.

واذا كانت $q=0$ فإن النموذج يكون $AR(p)$.

وإذا كانت $p \neq 0$ و $q \neq 0$ فإن النموذج يكون $ARMA(p,q)$

3- معيار معلومة بيز $Bayesian Information Criterion$

لقد اظهر الباحث Shibata عام (1976) ان معيار AIC يميل الى المغالاة في التقدير $Overestimate$ (يقصد بـ $Overestimate$ بأن المعيار AIC يتجه احيانا الى اخذ رتبة اعلى من الرتبة المحددة للانحدار الذاتي). لرتبة الانحدار الذاتي وللدقة فقد طور مؤخرًا الباحث Akaike عام (1978,1979) توسيع بيزي $Bayesian Extension$ لطريقة AIC في الحد الأدنى له ويدعى بمعيار معلومة بيز $Bayesian Information Criterion$ ويرمز بـ BIC ويأخذ الصيغة الآتية :

$$BIC = nL1n\hat{\sigma}_a^2 - (n - p)Ln \left(1 - \frac{p}{n}\right) + PLnn + PLn \left[\frac{\left| \frac{\hat{\sigma}_z^2}{\hat{\sigma}_a^2} - 1 \right|}{p} \right] \dots \dots (43)$$

وباستخدام المحاكاة Simuhltion توصل الباحث Akaike ان معيار BIC له اقل احتمالية في المغالاة لتقدير رتبة الانحدار الذاتي: وبعد اهمال بعض الحدود فإن الصيغة (43) تكتب:

$$BIC(P) = nL\hat{\sigma}_a^2 + PLnn \dots \dots (44)$$

كما يمكن ان يؤخذ المعيار BIC بشكل معياري وكما يأتي :

$$NBC(p) = \frac{BIC(P)}{n} \dots \dots (45)$$

ويتم اختيار الرتبة للنموذج التي تقابل اقل قيمة للمعيار اي :

$$\hat{P} = k \rightarrow MBIC(P)$$

ولقد اقترح الباحث Schwartz عام (1978) معيارا على غرار معيار BIC
ويتضمن اقتراح المعيار البيزي في اختيار النموذج ويدعى Schwartz
Bayesian Criterion ويرمز به SBC

$$SBC(P) = nL\hat{\sigma}_a^2 + PLnn$$

الفصل الثالث الجانب التطبيقي

الجانب التطبيقي

تمت عملية تحليل البيانات باستخدام البرنامجين الاحصائيين QSB و gretl وباستخدام طريقة هولت ونتر وهذه الطريقة قادرة على التعامل مع البيانات والسلاسل الزمنية ذات الطابع الموسمي والاتجاهي. ان نموذج هولت ونتر واسع الاستخدام من قبل الباحثين وذلك لدقة النتائج التي يعطيها وكذلك مرونته في التعامل مع البيانات والظاهر المدروسة ولقد تم وصف نموذجين يمكن ان يمثل أحدهما الظاهرة المدروسة بحيث يتم اختياره ليجعل متوسط مربعات الاخطاء اقل ما يمكن وهذان النموذجان هما :-

1) نموذج هولت ونتر الجمعي Additive Holt-winter Model

ان هذا النموذج يفترض بان عامل الموسمية يكون مضافا الى بقية العوامل حيث ان المعادلة التنبؤية باستخدام هذا النموذج هي كما في المعادلة الاتية :-

$$=l_t+hT_t+S_{t+h}-cf_{t+h}$$

حيث ان :-

f_{t+h} : هي القيمة التنبؤية عند الزمن $t+h$ هذا يعني ان h هي فتره في المستقبل وان c هي طول الدورة الموسمية

L_t : لتمثل القيمة الممهدة عند الزمن t

MAPE (%)	MAD	Forecast Error	Actual HWA	Data	Month
				1	1
				5	2
				4	3
				2	4
				2	5
				1	6
				2	7
				2	8
				3	9
				5	10
				3	11
				5	12
52.37754	1.097363	-1.047551	3.047551	2	13
61.62549	6.827486	-3.543672	8.543672	5	14
92.93647	11.81118	-4.666753	7.666753	3	15
69.70845	8.858389	1.22E-03	4.998781	5	16
166.2632	13.19145	-5.524824	6.524824	1	17
190.9198	12.63826	-3.142028	4.142028	1	18
182.9451	11.87572	-2.701936	4.701936	2	19
165.5616	10.60783	-1.316298	4.316298	3	20
165.5616	12.79968	-5.507669	5.507669	0	21
156.1231	12.10461	-2.418465	5.418465	3	22
156.1231	11.64009	-2.644785	2.644785	0	23
148.5886	10.88759	-1.615569	3.615569	2	24
147.9217	11.43138	4.237563	-1.23756	3	25
146.4276	11.09766	-2.599855	4.599855	2	26
139.2242	10.82215	2.639136	2.360864	5	27
132.2366	10.41356	2.069945	2.930055	5	28
124.6852	9.834849	0.7586317	3.241368	4	29
118.625	9.395205	1.386091	3.613909	5	30
117.447	9.361227	-2.957974	5.957974	3	31
120.0582	9.434023	-3.288944	5.288944	2	32
115.7149	9.045169	-1.126093	4.126093	3	33
112.9556	8.900481	-2.421166	6.421166	4	34
109.731	8.833831	2.714318	3.285682	6	35
116.0534	9.497645	-4.976481	6.976481	2	36
114.0054	9.593147	3.447492	1.552508	5	37
110.6715	9.295285	-1.359682	5.359682	4	38
111.4663	9.20347	-2.610801	4.610801	2	39
108.3033	8.902237	0.8768957	2.123104	3	40
106.6827	8.724565	1.936419	1.063581	3	41
104.4837	8.494788	1.35325	1.64675	3	42
101.3371	8.225847	0.3970182	2.602982	3	43
99.18778	8.074921	1.842872	3.157128	5	44
96.67969	7.852506	-0.857467	4.857467	4	45
97.85681	8.099325	-4.030429	7.030429	3	46

94.98892	7.868389	-0.128661	4.128661	4	47
96.10954	7.846632	-2.661792	4.661792	2	48
93.41251	7.634593	3.43E-02	1.965726	2	49
92.04176	7.454122	-0.881309	2.881309	2	50
91.01907	7.38352	2.1681	1.8319	4	51
89.22562	7.210698	0.686034	2.313966	3	52
87.90125	7.038271	-0.37575	1.37575	1	53
87.43713	6.91648	1.386739	0.613261	2	54
86.72641	6.826766	1.748929	1.251071	3	55
85.47009	6.682096	-0.679212	2.679212	2	56
83.98649	6.537782	-0.433505	2.433505	2	57
82.84616	6.485127	2.028718	3.971282	6	58
81.05537	6.347418	0.1130524	4.886948	5	59
80.87798	6.314813	-2.18686	5.18686	3	60
80.72617	6.23033	-1.474848	3.474848	2	61
79.24731	6.10876	0.3896625	3.610337	4	62
77.64088	5.988989	2.13E-02	3.978725	4	63
76.80227	5.935125	1.785512	3.214488	5	64
76.19649	5.922553	2.295387	2.704613	5	65
74.80638	5.81333	0.1564264	3.843574	4	66
73.96402	5.767177	1.809679	4.190321	6	67
74.05164	5.763721	-2.360863	5.360863	3	68
73.6122	5.701891	-1.496469	4.496469	3	69
72.69218	5.624618	-1.104545	6.104545	5	70
71.42945	5.529307	-3.58E-02	5.035843	5	71
70.313	5.439009	0.3337817	4.666218	5	72
69.35716	5.357784	0.6959195	4.30408	5	73
68.62086	5.336813	2.014344	5.985656	8	74
68.24136	5.334151	-2.273561	7.273561	5	75
67.43039	5.263406	-0.898054	5.898054	5	76
66.43291	5.18295	-0.183576	4.183576	4	77
65.57975	5.107813	0.4732304	3.52677	4	78
64.64525	5.032135	-0.193478	4.193478	4	79
64.18793	5.001799	1.723156	3.276844	5	80
64.11765	5.549699	6.542695	4.457305	11	81
64.7409	5.875483	-5.324903	10.3249	5	82
65.12711	5.980948	-3.655612	7.655612	4	83
65.44389	5.993147	-2.61902	5.61902	3	84
64.87839	5.932959	1.264696	3.735304	5	85
66.60243	6.045889	-3.780187	5.780187	2	86
65.71062	5.965305	4.50E-02	2.955006	3	87
65.47643	5.963811	2.419045	2.580955	5	88
64.87555	5.891228	0.6123013	2.387699	3	89
64.08778	5.815828	-0.100107	2.100107	2	90
64.7965	5.760033	-1.186592	2.186592	1	91
65.04047	6.004242	5.029594	0.970405	6	92
64.91702	5.964079	-1.658617	4.658617	3	93
64.42717	5.911529	1.286462	3.713538	5	94


65.09132	5.907664	-2.364482	4.364482	2	95
65.2272	7.00656	9.910343	3.089657	13	96
68.38401	7.428069	-6.544831	8.544831	2	97
70.00047	7.535575	-4.083331	6.083331	2	98
69.60678	7.462769	-1.096111	4.096111	3	99
68.85499	7.378411	0.1981277	3.801872	4	100
68.70919	7.384134	2.808513	2.191487	5	101
68.23724	7.315219	1.087119	2.912881	4	102
67.60431	7.237325	0.4762328	3.523767	4	103
66.92898	7.159924	0.3412418	4.658758	5	104
67.72169	7.166116	-2.781332	4.781332	2	105
70.10988	7.177773	-2.874346	3.874346	1	106
70.15575	7.311846	4.462588	1.537412	6	107
69.97216	7.282317	-2.115913	6.115913	4	108
69.94674	7.376625	4.053418	1.946582	6	109
69.47904	7.311597	-1.001907	5.001907	4	110
68.82072	7.23854	-0.281064	5.281064	5	111
70.10011	7.317012	-3.884036	5.884036	2	112
69.91206	7.339042	3.089014	2.910986	6	113
69.93325	7.287437	-1.440609	3.440609	2	114
69.79746	7.327154	3.373165	2.626835	6	115
69.1423	7.256912	-0.14851	5.14851	5	116
69.64619	7.243614	-2.420871	4.420871	2	117
69.20402	7.180031	-0.709812	3.709812	3	118
69.53282	7.153151	-2.074569	4.074569	2	119
68.88156	7.086922	-2.00E-02	4.019951	4	120
			2.028255		121
			1.822259		122
			2.466538		123
			2.217955		124
			2.49187		125
			0.439303		126
			1.184791		127
			1.090071		128
			-0.33217		129
			0.290095		130
			0.588237		131
			1.932231		132
			-39.3689	CFE	
			2.040909	MAD	
			7.086922	MSE	
			68.88156	MAPE	
			-19.2899	Trk.Signal	
			0.951733	R-square	

c=12

Alpha=0.47

Beta=0.12

Gamma=0.39
 F(0)=2.9167
 T(0)=2.0476
 S(1)=-1.916667
 S(2)=2.083333
 S(3)=1.083333
 S(4)=-0.916667
 S(5)=-0.916667
 S(6)=-1.916667
 S(7)=-0.916667
 S(8)=-0.916667
 S(9)=8.333325E-02
 S(10)=2.083333
 S(11)=8.333325E-02
 S(12)=2.083333



2) نموذج هولت ونتر الضربي: Multiplicative Holt-Winter Model

ان هذا النموذج يفترض بان عامل الموسمية يكون مضروباً في بقية العوامل حيث انه يفترض ان تكون المعادلة التنبؤية بالشكل التالي :

$$=(L_t+hT_t)S_{t+h-c}f_{t+h}$$

حيث ان : $h=1,2,\dots,c$

MAPE (%)	Mad	Forecast by error	Actual HWM	Data	Month
				1	1
				5	2
				4	3
				2	4
				2	5
				1	6
				2	7
				2	8
				3	9
				5	10
				3	11
				5	12
50	1		1	1	2
25	0.5		0	5	5
27.77778	0.666667		-1	4	3
35.83333	2.75		3	2	5
48.66666	2.4		-1	2	1
40.55555	2	5.96E-08		1	1
2.333334	34.7619		2	2	2
34.58333	1.625		1	2	3
4.29E-07	34.58333		-3	3	0
38.14815	2.6		-2	5	3
38.14815	3.181818		-3	3	0
49.33333	3.666667		-3	5	2
50.27273	3.631085		1.79	1.21	3
58.58333	4.014578		-3	5	2
55.93846	3.844547		1.21	3.79	5
55.32858	3.955319		2.37	2.63	5
55.32334	4.009953		2.21	1.79	4
56.86563	4.676067		4	1	5
		1			
0.893985	55.48137	1.580001		2	3
52.98241	4.260665		-0.21	2.21	2


51.29912	4.076676	0.63	2.37	3	33
49.45917	3.906664	-0.58	4.579999	4	34
49.98492	4.309718	3.63	2.37	6	35
53.09924	4.364183	-2.37	4.37	2	36
53.75936	4.655859	3.4141	1.5859	5	37
51.9048	4.482053	-0.37	4.37	4	38
53.91681	4.470805	-2.0441	4.0441	2	39
52.00681	4.311716	-0.1277	3.1277	3	40
51.00149	4.18222	0.7459	2.2541	3	41
50.56096	4.087667	1.16	1.84	3	42
49.72553	3.975939	0.79	2.21	3	43
49.95741	4.102695	2.8341	2.1659	5	44
49.5537	4.046343	1.4977	2.5023	4	45
49.52411	3.989873	-1.4582	4.4582	3	46
48.68073	3.897388	0.8677	3.1323	4	47
50.00232	3.886502	-1.8723	3.8723	2	48
49.00634	3.783941	-0.30286	2.302861	2	49
50.82881	3.822643	-2.2923	4.2923	2	50
49.7153	3.728431	0.385161	3.614839	4	51
48.49549	3.635474	-0.10088	3.100883	3	52
50.8693	3.595345	-1.41074	2.410739	1	53
49.70207	3.509908	-8.36E-02	2.0836	2	54
48.99722	3.437341	0.6241	2.3759	3	55
48.73665	3.372383	-0.76106	2.761061	2	56
48.55302	3.312268	-0.81682	2.816817	2	57
48.14955	3.314505	1.848022	4.151978	6	58
47.82867	3.304427	1.685483	3.314517	5	59
47.1361	3.240368	-0.47912	3.479117	3	60
46.38773	3.175406	-0.23926	2.23926	2	61
45.5198	3.112613	0.189083	3.810917	4	62
44.74607	3.053397	0.304277	3.695723	4	63
44.61927	3.065592	1.920302	3.079698	5	64
44.87596	3.164849	2.885516	2.114484	5	65
44.94275	3.175503	1.933956	2.066044	4	66
45.19321	3.339609	3.493039	2.506961	6	67
44.60244	3.282813	0.398762	2.601238	3	68
44.00647	3.227427	0.354715	2.645285	3	69
43.3849	3.175429	0.459938	4.540062	5	70
43.09097	3.151659	1.331532	3.668468	5	71
42.90715	3.142952	1.621498	3.378502	5	72
43.13279	3.220963	2.810985	2.189015	5	73
43.27837	3.446711	4.149376	3.850624	8	74
42.97557	3.416422	1.240379	3.759621	5	75
42.77178	3.399	1.517039	3.482961	5	76
42.60062	3.371897	1.279558	2.720442	4	77
42.5318	3.356175	1.527825	2.472175	4	78
42.16957	3.314692	0.759501	3.240499	4	79
42.23217	3.34476	2.315022	2.684978	5	80

42.72534	4.289939	8.280225	2.719775	11	81
42.20389	4.230541	0.36335	4.63665	5	82
41.61105	4.170993	5.19E-02	3.94809	4	83
41.359	4.120244	-0.71902	3.719017	3	84
41.40202	4.131355	2.220678	2.779322	5	85
42.71727	4.175651	-2.72199	4.721993	2	86
42.5979	4.133851	-1.0201	4.020101	3	87
42.34616	4.098356	1.19846	3.80154	5	88
41.78637	4.045133	1.09E-02	2.989149	3	89
41.75827	4.001334	-0.79302	2.793018	2	90
44.33283	4.023596	-2.39999	3.399994	1	91
44.36892	4.073332	2.828867	3.171133	6	92
44.42274	4.04931	-1.45862	4.458623	3	93
43.93922	4.000933	0.287047	4.712953	5	94
44.60601	3.998966	-1.95899	3.958991	2	95
44.94683	5.010433	9.431976	3.568023	13	96
45.1557	4.969741	-1.24567	3.245665	2	97
45.89812	4.965723	-2.15037	4.150374	2	98
45.67418	4.91611	-0.80588	3.805879	3	99
45.15855	4.860277	-5.32E-02	4.053216	4	100
45.10123	4.850997	2.008572	2.991428	5	101
44.97892	4.818059	1.373516	2.626484	4	102
44.78365	4.778507	1.104004	2.895996	4	103
44.56045	4.74314	1.234805	3.765195	5	104
45.25336	4.74195	-2.15231	4.152312	2	105
48.86282	4.842964	-3.77323	4.773233	1	106
48.77691	4.855293	2.452397	3.547603	6	107
48.6699	4.829703	-1.54874	5.548739	4	108
48.6867	4.873683	3.015925	2.984075	6	109
48.25798	4.824877	0.301204	3.698796	4	110
48.04158	4.794917	1.363355	3.636645	5	111
48.59322	4.788667	-2.04204	4.042041	2	112
48.53786	4.807506	2.586772	3.413228	6	113
48.50994	4.768579	-0.91492	2.914923	2	114
48.5036	4.802373	2.872164	3.127836	6	115
48.21935	4.765347	0.975496	4.024504	5	116
48.5766	4.747497	-1.70033	3.700326	2	117
48.4239	4.711785	-0.98085	3.980854	3	118
48.94491	4.70751	-2.06261	4.062606	2	119
48.77173	4.677783	-1.2235	5.223504	4	120
			3.617419		121
			3.762049		122
			3.922949		123
			3.613212		124
			3.95645		125
			2.722789		126
			3.730991		127
			4.229358		128

3.343258	129
3.774874	130
3.629459	131
4.966568	132

48.90179	CFE
1.623986	MAD
4.677783	MSE
48.77173	MAPE
30.1122	Trk.Signal
0.331177	R-square

c=12
 Alpha=0
 Beta=0
 Gamma=0.21
 F(0)=2.9167
 T(0)=0
 S(1)=0.3428571
 S(2)=1.714286
 S(3)=1.371428
 S(4)=0.6857142
 S(5)=0.6857142
 S(6)=0.3428571
 S(7)=0.6857142
 S(8)=0.6857142
 S(9)=1.028571
 S(10)=1.714286
 S(11)=1.028571
 S(12)=1.714286



معادلة خط الاتجاه العام الخطي: The Linear Trend Equaiont:

في حالة الاتجاه العام للسلسلة الزمنية يتبع الاتجاه المستقيم فأن الاتجاه العام للسلسلة الزمنية خطي ومعادلة خط الاتجاه العام المستقيم هي :

$$Y=A+Bx$$

حيث A;B ثوابت المعادلة

A=قيمة Y عندما $x=0$ او بعد نقطة تقاطع خط الاتجاه العام المستقيم مع المحور العمودي عند نقطة الأصل.

B=ميل خط الاتجاه العام المستقيم =معدل التغير في قيمة الظاهرة y نسبة للتغير في وحدة الزمن x

في حالة $B>0$ فأن الاتجاه العام للسلسلة الزمنية متزايدا مع الزمن وفي حالة $B<0$ فأن الاتجاه العام للسلسلة الزمنية يتناقص مع الزمن .

جدول: LR

MAD	MAPE	Forecast	Actual			
		Error	LR	Data	Month	
3.232566	1.797934	-1.79793	2.797934	1	1	
4.010318	1.99305	2.188166	2.811834	5	2	
3.133179	1.720122	1.174266	2.825734	4	3	
2.52613	1.5	-0.83963	2.839635	2	4	
2.166609	1.370707	-0.85353	2.853535	2	5	
2.386726	1.453495	-1.86744	2.867435	1	6	
2.15673	1.371758	-0.88134	2.881335	2	7	
1.98732	1.312193	-0.89524	2.895236	2	8	
1.767424	1.176489	9.09E-02	2.909136	3	9	
2.022059	1.266537	2.076964	2.923036	5	10	
1.838597	1.15713	6.31E-02	2.936937	3	11	
2.035303	1.231466	2.049163	2.950837	5	12	
1.950335	1.210949	-0.96474	2.964737	2	13	
2.102876	1.268835	2.021363	2.978637	5	14	
1.962688	1.184744	7.46E-03	2.992537	3	15	
2.088413	1.235295	1.993562	3.006438	5	16	
2.205669	1.281474	-2.02034	3.020338	1	17	
2.313028	1.323294	-2.03424	3.034238	1	18	
2.24911	1.308812	-1.04814	3.048139	2	19	
2.136847	1.246474	-0.06204	3.062039	3	20	
2.485636	1.333591	-3.07594	3.075939	0	21	
		-8.98E-02				
2.373019	1.277057	02	3.089839	3	22	
2.688679	1.356478	-3.10374	3.10374	0	23	


2.628697	1.346527	-1.11764	3.11764	2	24
2.524242	1.297927	-0.13154	3.13154	3	25
2.477618	1.292062	-1.14544	3.145441	2	26
2.511337	1.31238	1.840659	3.159341	5	27
2.540827	1.330751	1.826759	3.173241	5	28
2.475996	1.312893	0.812859	3.187141	4	29
2.501338	1.329095	1.798958	3.201042	5	30
2.42214	1.293155	-0.21494	3.214942	3	31
2.393637	1.291145	-1.22884	3.228842	2	32
2.322888	1.259375	-0.24274	3.242743	3	33
2.27082	1.244198	0.743357	3.256643	4	34
2.418795	1.286634	2.729457	3.270543	6	35
2.397434	1.286573	-1.28444	3.284443	2	36
2.410899	1.297792	1.701656	3.298344	5	37
2.359902	1.281738	0.687756	3.312244	4	38
2.344485	1.282877	-1.32614	3.326144	2	39
2.288764	1.259306	-0.34004	3.340044	3	40
2.235996	1.237224	-0.35394	3.353945	3	41
2.18598	1.216524	-0.36784	3.367845	3	42
2.138532	1.197111	-0.38175	3.381745	3	43
2.148428	1.206367	1.604355	3.395645	5	44
2.108433	1.19268	0.590454	3.409546	4	45
2.066495	1.175957	-0.42345	3.423446	3	46
2.029263	1.162908	0.562654	3.437346	4	47
2.030864	1.168915	-1.45125	3.451247	2	48
2.033227	1.174961	-1.46515	3.465147	2	49
2.036314	1.181042	-1.47905	3.479047	2	50
2.001427	1.167827	0.507053	3.492947	4	51
1.967879	1.155116	-0.50685	3.506848	3	52
2.050639	1.180882	-2.52075	3.520748	1	53
2.056278	1.187434	-1.53465	3.534648	2	54
2.024362	1.175817	-0.54855	3.548548	3	55
2.031806	1.182721	-1.56245	3.562449	2	56
2.039755	1.189627	-1.57635	3.576349	2	57
2.104706	1.210664	2.409751	3.590249	6	58
2.102057	1.213803	1.39585	3.60415	5	59
2.073389	1.203873	-0.61805	3.61805	3	60
2.083059	1.210891	-1.63195	3.63195	2	61
2.051484	1.197073	0.35415	3.64585	4	62
2.020758	1.183472	0.340249	3.659751	4	63
2.016671	1.185705	1.326349	3.673651	5	64
2.012146	1.187655	1.312449	3.687551	5	65
1.98301	1.174183	0.298549	3.701451	4	66
2.031317	1.190757	2.284648	3.715352	6	67
2.009265	1.18397	-0.72925	3.729252	3	68
1.98815	1.177582	-0.74315	3.743152	3	69
1.981818	1.178516	1.242948	3.757052	5	70
1.97518	1.179227	1.229047	3.770953	5	71

1.968255	1.179726	1.215147	3.784853	5	72
1.96106	1.180021	1.201247	3.798753	5	73
2.171504	1.220661	4.187346	3.812654	8	74
2.16091	1.220031	1.173446	3.826554	5	75
2.150168	1.219235	1.159546	3.840454	5	76
2.122519	1.205293	0.145646	3.854354	4	77
2.09553	1.191529	0.131745	3.868255	4	78
2.06918	1.177938	0.117845	3.882155	4	79
2.058549	1.177013	1.103945	3.896055	5	80
2.653737	1.250014	7.090044	3.909956	11	81
2.635497	1.247893	1.076144	3.923856	5	82
2.603791	1.233608	6.22E-02	3.937756	4	83
2.583575	1.230252	-0.95166	3.951656	3	84
2.565769	1.227948	1.034443	3.965557	5	85
2.581495	1.236687	-1.97946	3.979457	2	86
2.563165	1.23389	-0.99336	3.993357	3	87
2.545237	1.231149	0.992743	4.007257	5	88
2.528356	1.22879	-1.02116	4.021158	3	89
2.546279	1.237748	-2.03506	4.035058	2	90
2.620453	1.257652	-3.04896	4.048958	1	91
2.632758	1.265038	1.937141	4.062859	6	92
2.616916	1.263013	-1.07676	4.076759	3	93
2.597873	1.259251	0.909341	4.090659	5	94
2.61715	1.268149	-2.10456	4.104559	2	95
3.411573	1.347455	8.88154	4.11846	13	96
3.423278	1.355546	-2.13236	4.13236	2	97
3.435351	1.363615	-2.14626	4.14626	2	98
3.414246	1.36156	-1.16016	4.160161	3	99
3.380407	1.349685	-0.17406	4.174061	4	100
3.353466	1.344362	0.812039	4.187961	5	101
3.320989	1.333161	-0.20186	4.201861	4	102
3.289198	1.322312	-0.21576	4.215761	4	103
3.263277	1.317005	0.770339	4.229661	5	104
3.280137	1.325829	-2.24356	4.243562	2	105
3.349297	1.344052	-3.25746	4.257462	1	106
3.345922	1.347646	1.728638	4.271362	6	107
3.315694	1.337809	-0.28526	4.285263	4	108
3.311815	1.34114	1.700837	4.299163	6	109
3.282599	1.331794	-0.31306	4.313063	4	110
3.257107	1.325859	0.673037	4.326963	5	111
3.276951	1.334921	-2.34086	4.340864	2	112
3.271905	1.337668	1.645236	4.354764	6	113
3.29242	1.346711	-2.36866	4.368664	2	114
3.286539	1.349066	1.617435	4.382565	6	115
3.261347	1.342638	0.603535	4.396465	5	116
3.283129	1.351764	-2.41037	4.410365	2	117
3.272496	1.352379	-1.42427	4.424265	3	118
3.294952	1.361503	-2.43817	4.438166	2	119

3.269197	1.353925	-0.45207	4.452066	4	120
			4.465966		121
			4.479867		122
			4.493767		123
			4.507667		124
			4.521567		125
			4.535468		126
			4.549368		127
			4.563268		128
			4.577168		129
			4.591069		130
			4.604969		131
			4.618869		132

7.63E-06	CFE
1.353925	MAD
3.269197	MSE
48.48026	MAPE
5.64E-06	Trk.Signal
6.62E-02	R-square

Y-
intercept=2.7840
Slope=0.0139



AR(1)

Model 19: ARMA, using observations 2007:01-2016:12 (T = 120)


Dependent variable: v1


Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.62338	0.184848	19.6020	<0.00001	***
phi_1	0.0794842	0.0913445	0.8702	0.38421	

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.001738	S.D. of innovations	1.865188
Log-likelihood	-245.0792	Akaike criterion	496.1584
Schwarz criterion	504.5209	Hannan-Quinn	499.5545

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
AR				
Root 1	12.5811	0.0000	12.5811	0.0000





AR(2)

Model 20: ARMA, using observations 2007:01-2016:12 (T = 120)



Dependent variable: v1

Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.61899	0.217245	16.6586	<0.00001	***
phi_1	0.0644228	0.0902869	0.7135	0.47551	
phi_2	0.165879	0.0905578	1.8318	0.06699	*

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.003397	S.D. of innovations	1.839252
Log-likelihood	-243.4266	Akaike criterion	494.8532
Schwarz criterion	506.0032	Hannan-Quinn	499.3812

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
AR				
Root 1	2.2688	0.0000	2.2688	0.0000
Root 2	-2.6571	0.0000	2.6571	0.5000



MA(1)


Model 21: ARMA, using observations 2007:01-2016:12 (T = 120)


Dependent variable: v1

Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.62389	0.18048	20.0792	<0.00001	***
theta_1	0.05959	0.0791062	0.7533	0.45128	
Mean dependent var	3.625000	S.D. dependent var		1.878952	
Mean of innovations	0.001266	S.D. of innovations		1.866684	
Log-likelihood	-245.1740	Akaike criterion		496.3480	
Schwarz criterion	504.7105	Hannan-Quinn		499.7441	

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
MA				
Root 1	-16.7813	0.0000	16.7813	0.5000





AM(2)

Model 22: ARMA, using observations 2007:01-2016:12 (T = 120)



Dependent variable: v1

Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.62156	0.200656	18.0486	<0.00001	***
theta_1	0.0658698	0.0933602	0.7055	0.48047	
theta_2	0.127343	0.0770087	1.6536	0.09820	*

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.002566	S.D. of innovations	1.846165
Log-likelihood	-243.8639	Akaike criterion	495.7278
Schwarz criterion	506.8778	Hannan-Quinn	500.2559

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
MA				
Root 1	-0.2586	-2.7903	2.8023	-0.2647
Root 2	-0.2586	2.7903	2.8023	0.2647





ARMA(1,1)

Model 23: ARMA, using observations 2007:01-2016:12 (T = 120)



Dependent variable: v1

Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.57215	0.345959	10.3254	<0.00001	***
phi_1	0.939218	0.0812029	11.5663	<0.00001	***
theta_1	-0.867313	0.11718	-7.4015	<0.00001	***

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.033992	S.D. of innovations	1.830320
Log-likelihood	-242.8930	Akaike criterion	493.7860
Schwarz criterion	504.9360	Hannan-Quinn	498.3141

		<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
AR					
	Root 1	1.0647	0.0000	1.0647	0.0000
MA					
	Root 1	1.1530	0.0000	1.1530	0.0000



ARMA(1,2)

Model 24: ARMA, using observations 2007:01-2016:12 (T = 120)


Dependent variable: v1


Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.57793	0.333238	10.7369	<0.00001	***
phi_1	0.923015	0.111784	8.2571	<0.00001	***
theta_1	-0.878357	0.144565	-6.0758	<0.00001	***
theta_2	0.0381846	0.0935984	0.4080	0.68330	

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.027650	S.D. of innovations	1.829065
Log-likelihood	-242.8088	Akaike criterion	495.6176
Schwarz criterion	509.5551	Hannan-Quinn	501.2777

		<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
AR					
	Root 1	1.0834	0.0000	1.0834	0.0000
MA					
	Root 1	1.2012	0.0000	1.2012	0.0000
	Root 2	21.8017	0.0000	21.8017	0.0000





ARMA(2,1)

Model 25: ARMA, using observations 2007:01-2016:12 (T = 120)



Dependent variable: v1

Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.57905	0.330826	10.8185	<0.00001	***
phi_1	0.865681	0.207849	4.1650	0.00003	***
phi_2	0.0497884	0.111264	0.4475	0.65453	
theta_1	-0.826119	0.189262	-4.3649	0.00001	***

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.026558	S.D. of innovations	1.828813
Log-likelihood	-242.7919	Akaike criterion	495.5838
Schwarz criterion	509.5213	Hannan-Quinn	501.2439

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
AR				
Root 1	1.0872	0.0000	1.0872	0.0000
Root 2	-18.4744	0.0000	18.4744	0.5000
MA				
Root 1	1.2105	0.0000	1.2105	0.0000



ARMA(2,2)

Model 26: ARMA, using observations 2007:01-2016:12 (T = 120)


Dependent variable: v1


Standard errors based on Hessian

	<i>Coefficient</i>	<i>Std. Error</i>	<i>z</i>	<i>p-value</i>	
Const	3.58039	0.327279	10.9398	<0.00001	***
phi_1	0.172355	0.233965	0.7367	0.46132	
phi_2	0.681028	0.21624	3.1494	0.00164	***
theta_1	-0.153818	0.263275	-0.5842	0.55905	
theta_2	-0.546766	0.238472	-2.2928	0.02186	**

Mean dependent var	3.625000	S.D. dependent var	1.878952
Mean of innovations	0.024983	S.D. of innovations	1.819535
Log-likelihood	-242.1913	Akaike criterion	496.3825
Schwarz criterion	513.1075	Hannan-Quinn	503.1746

	<i>Real</i>	<i>Imaginary</i>	<i>Modulus</i>	<i>Frequency</i>
AR				
Root 1	1.0918	0.0000	1.0918	0.0000
Root 2	-1.3449	0.0000	1.3449	0.5000
MA				
Root 1	1.2190	0.0000	1.2190	0.0000
Root 2	-1.5003	0.0000	1.5003	0.5000






ARMA(1,1)

Residual autocorrelation function

LAG	ACF	PACF	Q-stat.	[p-value]
1	-0.0347	-0.0347	0.1482	[0.700]
2	0.0750	0.0739	0.8464	[0.655]
3	-0.0806	-0.0761	1.6584	[0.646]
4	0.0905	0.0814	2.6926	[0.611]
5	-0.1056	-0.0919	4.1135	[0.533]
6	-0.0296	-0.0523	4.2261	[0.646]
7	0.1535 *	0.1834 **	7.2783	[0.400]
8	0.1143	0.1085	8.9854	[0.344]
9	-0.1151	-0.1342	10.7325	[0.294]
10	-0.2405 ***	-0.2628 ***	18.4309	[0.048]
11	0.0816	0.0814	19.3263	[0.055]
12	-0.0742	-0.0185	20.0724	[0.066]
13	0.0418	0.0540	20.3120	[0.088]
14	0.0194	0.0398	20.3639	[0.119]
15	0.2503 ***	0.1477	29.1022	[0.016]
16	-0.0443	-0.0083	29.3785	[0.022]
17	0.0173	0.0848	29.4209	[0.031]
18	-0.1061	-0.0739	31.0378	[0.028]
19	0.0281	-0.0893	31.1519	[0.039]
20	-0.0134	0.0077	31.1781	[0.053]



Model estimation range: 2007:01 - 2016:12

Standard error of residuals = 1.83032

residual	Fitted	v1	
-2.57215	3.57215	1.00000	2007:01
1.70655	3.29345	5.00000	2007:02
0.521546	3.47845	4.00000	2007:03
-1.53184	3.53184	2.00000	2007:04
-1.40200	3.40200	2.00000	2007:05
-2.29648	3.29648	1.00000	2007:06
-1.12973	3.12973	2.00000	2007:07
-1.06863	3.06863	2.00000	2007:08
-0.0176119	3.01761	3.00000	2007:09
1.95001	3.04999	5.00000	2007:10
-0.226849	3.22685	3.00000	2007:11
1.76890	3.23110	5.00000	2007:12
-1.38153	3.38153	2.00000	2008:01

1.70770	3.29230	5.00000	2008:02
-0.433472	3.43347	3.00000	2008:03
1.58953	3.41047	5.00000	2008:04
-2.53531	3.53531	1.00000	2008:05
-2.35439	3.35439	1.00000	2008:06
-1.19773	3.19773	2.00000	2008:07
-0.134132	3.13413	3.00000	2008:08
-3.15109	3.15109	0.000000	2008:09
0.0502396	2.94976	3.00000	2008:10
-2.99121	2.99121	0.000000	2008:11
-0.811249	2.81125	2.00000	2008:12
0.200873	2.79913	3.00000	2009:01
-0.860564	2.86056	2.00000	2009:02
2.15809	2.84191	5.00000	2009:03
1.95848	3.04152	5.00000	2009:04
0.785374	3.21463	4.00000	2009:05
1.70716	3.29284	5.00000	2009:06
-0.432583	3.43258	3.00000	2009:07
-1.40996	3.40996	2.00000	2009:08
-0.318426	3.31843	3.00000	2009:09
0.689050	3.31095	4.00000	2009:10
2.62363	3.37637	6.00000	2009:11
-1.57693	3.57693	2.00000	2009:12
1.53675	3.46325	5.00000	2010:01
0.419630	3.58037	4.00000	2010:02
-1.61004	3.61004	2.00000	2010:03
-0.491969	3.49197	3.00000	2010:04
-0.461467	3.46147	3.00000	2010:05
-0.435012	3.43501	3.00000	2010:06
-0.412068	3.41207	3.00000	2010:07
1.60783	3.39217	5.00000	2010:08
0.481281	3.51872	4.00000	2010:09
-0.556573	3.55657	3.00000	2010:10
0.482501	3.51750	4.00000	2010:11
-1.55552	3.55552	2.00000	2010:12
-1.44468	3.44468	2.00000	2011:01
-1.34854	3.34854	2.00000	2011:02
0.734832	3.26517	4.00000	2011:03
-0.336665	3.33666	3.00000	2011:04
-2.32677	3.32677	1.00000	2011:05
-1.17438	3.17438	2.00000	2011:06
-0.114110	3.11411	3.00000	2011:07
-1.13375	3.13375	2.00000	2011:08
-1.07887	3.07887	2.00000	2011:09
2.96872	3.03128	6.00000	2011:10
1.72238	3.27762	5.00000	2011:11
-0.419369	3.41937	3.00000	2011:12
-1.39850	3.39850	2.00000	2012:01
0.691505	3.30849	4.00000	2012:02
0.625757	3.37424	4.00000	2012:03


	1.56873	3.43127	5.00000	2012:04
	1.44737	3.55263	5.00000	2012:05
	0.342110	3.65789	4.00000	2012:06
	2.32272	3.67728	6.00000	2012:07
	-0.837904	3.83790	3.00000	2012:08
	-0.761501	3.76150	3.00000	2012:09
	1.30476	3.69524	5.00000	2012:10
	1.21843	3.78157	5.00000	2012:11
	1.14354	3.85646	5.00000	2012:12
	1.07860	3.92140	5.00000	2013:01
	4.02227	3.97773	8.00000	2013:02
	0.757698	4.24230	5.00000	2013:03
	0.743949	4.25605	5.00000	2013:04
	-0.267976	4.26798	4.00000	2013:05
	-0.206414	4.20641	4.00000	2013:06
	-0.153019	4.15302	4.00000	2013:07
	0.893290	4.10671	5.00000	2013:08
*	6.86155	4.13845	11.0000	2013:09
	0.402588	4.59741	5.00000	2013:10
	-0.564043	4.56404	4.00000	2013:11
	-1.46320	4.46320	3.00000	2013:12
	0.696175	4.30382	5.00000	2014:01
	-2.30941	4.30941	2.00000	2014:02
	-1.09854	4.09854	3.00000	2014:03
	1.01245	3.98755	5.00000	2014:04
	-1.03511	4.03511	3.00000	2014:05
	-1.93254	3.93254	2.00000	2014:06
	-2.77167	3.77167	1.00000	2014:07
	2.43975	3.56025	6.00000	2014:08
	-0.736401	3.73640	3.00000	2014:09
	1.32653	3.67347	5.00000	2014:10
	-1.76269	3.76269	2.00000	2014:11
*	9.37564	3.62436	13.0000	2014:12
	-2.29535	4.29535	2.00000	2015:01
	-2.08634	4.08634	2.00000	2015:02
	-0.905070	3.90507	3.00000	2015:03
	0.180245	3.81976	4.00000	2015:04
	1.18233	3.81767	5.00000	2015:05
	0.112241	3.88776	4.00000	2015:06
	0.123354	3.87665	4.00000	2015:07
	1.13299	3.86701	5.00000	2015:08
	-1.93055	3.93055	2.00000	2015:09
	-2.76995	3.76995	1.00000	2015:10
	2.44125	3.55875	6.00000	2015:11
	0.264892	3.73511	4.00000	2015:12
	2.25575	3.74425	6.00000	2016:01
	0.104010	3.89599	4.00000	2016:02
	1.11622	3.88378	5.00000	2016:03
	-1.94510	3.94510	2.00000	2016:04
	2.21743	3.78257	6.00000	2016:05

-1.92923	3.92923	2.00000	2016:06
2.23120	3.76880	6.00000	2016:07
1.08272	3.91728	5.00000	2016:08
-1.97416	3.97416	2.00000	2016:09
-0.807771	3.80777	3.00000	2016:10
-1.73537	3.73537	2.00000	2016:11
0.399336	3.60066	4.00000	2016:12

Note: * denotes a residual in excess of 2.5 standard errors

For 95% confidence intervals, $z(0.025) = 1.96$

95% interval	std. error	prediction	v1	Obs
(0.0402839, 7.21501)	1.83032	3.62764	undefined	2017:01
(0.0276486, 7.22089)	1.83505	3.62427	undefined	2017:02
(0.0163299, 7.22588)	1.83920	3.62110	undefined	2017:03
(0.00617962, 7.23008)	1.84286	3.61813	undefined	2017:04
(-0.00293229, 7.23360)	1.84609	3.61533	undefined	2017:05
(-0.0111206, 7.23654)	1.84893	3.61271	undefined	2017:06
(-0.0184865, 7.23897)	1.85143	3.61024	undefined	2017:07
(-0.0251195, 7.24097)	1.85363	3.60793	undefined	2017:08
(-0.0310985, 7.24260)	1.85557	3.60575	undefined	2017:09
(-0.0364937, 7.24391)	1.85728	3.60371	undefined	2017:10
(-0.0413670, 7.24495)	1.85879	3.60179	undefined	2017:11
(-0.0457734, 7.24575)	1.86012	3.59999	undefined	2017:12



يتضح ان افضل طريقة هي (The Linear Trend Equaiont) لان حققت اقل مقدار للخطأ

MSE=3.269197

الاستنتاجات والتوصيات

1- نماذج بوكس – جنكنز ظهرت بمقارنة قيم AIC و PIC نستنتج بأن نموذج $ARMA(1,1)$ كان هو النموذج الأفضل لتمثيل الظاهرة .

2- باستخدام نموذج هولت ونتر الضربي و الجمعي (HWM & HWA) ومقارنة نتائج ال MSE مع بقية النماذج كانت هي الأكبر من ناحية ال MSE .

3- بمقارنة مجمل الطرائق السابقة أتضح ان النموذج الخطي (LR) حققت اقل مقدار للخطأ نستنتج بأن هذا النموذج هو النموذج الأفضل للتنبوء بالقيم .

المصادر

اولاً:- المصادر العربية

- 1-المشهداني،د. محمود حسن،من طرق الاحصاء/الارقام القياسية والسلاسل الزمنية، وزارة التعليم العالي –جامعة بغداد 1985.
- 2-حامد،جمال (2003)،"اساليب التنبؤ"، المعهد العربي للتخطيط، العدد الرابع عشر، شباط السنة الثانية،الصفاء،الكويت.
- 3-عبد الرحمن ، د. عدنان ماجد،التنبؤ الاحصائي،جامعة الملك سعود، 2005 .
- 4-عزيز، د.منعم محمد، المدخل الى تحليل السلاسل الزمنية والارقام القياسية، مطبعة جامعة بغداد 1987.
- 5-فاندل ، والتر (1992)،"السلاسل الزمنية من الوجهة التطبيقية ونماذج بوكس جنكنز "تعريب عبد المرضي حامد عزام،دار المريخ للنشر،الرياض،المملكة العربية السعودية.

ثانياً :- المصادر الاجنبية

- 1-Box,G.E.P.& Jenkins,G.M. (1976):"Time Series Analysis,Forecasting and Control"2nd Revised Edition Holden-Day, San Francisco,USA.
- 2-Box,G.E.P. & Jenkins,G.M.(1976):" Time Series Aalysis ,Forecasting and Control " Revised Edition Holden-Day,San Francisco,USA.
- 3-Chatfield ,C.(1980)."The Analysis of Time Series:An Introduction "Bath Univerity ,2nd Ed.UK.
- 4-Cryer,Jonathan,(1986):"Time Series Analysis "Duxbury press,Boston.
- 5-Pankratz,Alan(1983)"Forecasting with Univariate Box-Jenkins, Concept and Cases",copyright by Wiley &Sons Inc.,printed in USA.