

مقارنة بعض المقدرات الموجية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج (ARFIMA)

أ.م. باسم شليبة مسلم / قسم الإحصاء / كلية الإدارة والإقتصاد / جامعة واسط
الباحث / عمار مؤيد صابر / قسم الإحصاء / كلية الإدارة والإقتصاد / جامعة بغداد

تاريخ التقديم: 2017/10/3

تاريخ القبول: 2017/10/24

المستخلص

يهدف البحث إلى تقدير معلمات أنموذج الإنحدار الخطي بأخطاء تتبع أنموذج ARFIMA بالإسلوب الموجي المعتمد على طريقتي الإمكان الأعظم والمربعات الصغرى العامة التقريبية فضلا عن طريقة المربعات الصغرى الإعتيادية وقد تم تطبيق المقدرات عملياً على بيانات حقيقية تمثلت بالبيانات الشهرية لمعدل التغير في الرقم القياسي لسعر المستهلك (التضخم) (Inflation) ومدى تأثيره في معدل سعر صرف الدولار (Dollar exchange rate) والتي تم الحصول عليها من التقارير السنوية للأرقام القياسية لأسعار المستهلك الصادرة من الجهاز المركزي للإحصاء – مديرية الأرقام القياسية للمدة من 2005/1 ولغاية 2015/12، وقد أثبتت طريقة التقدير الموجي المعتمد على طريقة الإمكان الأعظم كفاءتها على بقية الطرائق وإملاك مقدرات الأنموذج أقل التباينات، كذلك أثبتت النتائج إن إختلاف قيم معلمة الفروق الكسرية في أنموذج ARFIMA لا تؤثر في تلك الطريقة.

المصطلحات الرئيسية للبحث / الموجيات، التحويل الموجي، أنموذج الإنحدار الخطي، أنموذج ARFIMA.



مجلة العلوم

الاقتصادية والإدارية

العدد 104 المجلد 24

الصفحات 374-387

*البحث مستل من رسالة ماجستير



مقارنة بعض المقدرات المويجية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

1. المقدمة (Introduction)

إن إجراء التحليل الإحصائي لظاهرة تحت الدراسة باستعمال تحليل الإنحدار الخطي يفرض على الباحث التحقق من توفر الفرضيات الأساسية لأنموذج الإنحدار الخطي الذي يؤدي إلى ظهور مشاكل في حالة عدم تحققها ومن تلك الفرضيات إنعدام الارتباط الذاتي بين الأخطاء العشوائية ولكن في الواقع التطبيقي قد لا تتحقق هذه الفرضية بحسب طبيعة بيانات الظاهرة المدروسة وعند ذاك يكون $(E(U_t U_s) \neq 0, t \neq s)$ مما يدل على وجود مشكلة الارتباط الذاتي.

ومن ناحية أخرى قد تتبع تلك الأخطاء أنموذجاً من نماذج السلسلة الزمنية عندما تأخذ بياناتها سلسلة زمنية كما في هذا البحث وكل ذلك يجعل من طريقة المربعات الصغرى (Ordinary Least Squares) أو طريقة الإمكان الأعظم (Maximum Likelihood) غير كفوءتين في عملية التقدير وعند ذاك يصبح التنبؤ للظاهرة غير جيد ومن تلك النماذج الأنموذج المختلط (الإنحدار الذاتي - الأوساط المتحركة) (Auto ARMA (Regressive Moving Averages model) وتبعاً لهذا الأنموذج فإن السلسلة غالباً ما تكون غير مستقرة في الواقع التطبيقي وهذا يؤدي إلى أن الارتباط الذاتي (Auto Correlation) للعينة سيتلاشى بشكل بطيء جداً وتكون مركبات التكرارات المنخفضة مهيمنة بشكل كلي على السلسلة الزمنية فتظهر أهمية أخذ الفروق (Differences) لجعل أنموذج ARMA مستقراً فيظهر أنموذج جديد هو إنموذج الإنحدار الذاتي والأوساط المتحركة التكاملية ARIMA (Auto Regressive Integrated Moving Averages) model، إن أخذ الفروق الأولى تؤدي إلى زيادة سرعة تلاشي الارتباط الذاتي للسلسلة الزمنية في حين يبقى السلوك الاتجاهي لها، كما وإن قوة الطيف تقترب من التكرار الصفري وهذا يوجب أخذ الفروق مرة أخرى وتكون لدينا الفروق الثانية مما يظهر مشكلة جديدة إن قوة الطيف لا تكون قريبة من التكرار الصفري لأن مركبات التكرار المنخفض لا تمثل التكرارات الضعيفة إذ تضاف إليها التكرارات التي تم إزالتها من الفروق الأولى هذا من ناحية وإن قوة الطيف المنخفض القريبة من التكرار الصفري ليس بالضرورة أن تدل على إن الفروق الثانية غير انعكاسية (Non Invertible) وهذا إشارة على إن البيانات من الممكن أن تكون فوق الفروق (Over Differenced) كل ذلك يدل على إن الفروق لا يمكن أن تؤخذ بعدد صحيح وقد يكون عدداً حقيقياً فينتج لنا أنموذج جديد هو أنموذج الإنحدار الذاتي والوسط المتحرك المتكامل كسرياً (Auto ARFIMA (Regressive Fractionally Integrated Moving Average model) وهو أحد نماذج الذاكرة الطويلة موضوع البحث.

فعندما تتبع الأخطاء العشوائية في أنموذج الإنحدار الخطي أنموذج ARFIMA يستوجب تقدير معلماته تبعاً لهذه الحالة ومن هنا جاءت فكرة البحث باستعمال الأسلوب المويجي لكي تتناسب وطبيعة هذا الأنموذج.

2. تعاريف (Definitions)

2.1. أنموذج الإنحدار الذاتي والوسط المتحرك المتكامل كسرياً (ARFIMA)

Auto Regressive Fractionally Integrated Moving Average model (ARFIMA) في عام 1976 قدم الباحثان Box & Jenkins أنموذج ARIMA (Auto Regressive Integrated Moving Average) وهو أنموذج مستقر ومنعكس (Stationary and Invertible) والذي ينتج من أخذ الفروق لأنموذج الإنحدار الذاتي والوسط المتحرك ARMA(p, q) المعروف أدناه⁽¹¹⁾:

$$Y_t = \phi_0 + \sum_{i=1}^p \phi_i Y_{t+i} + e_t - \sum_{j=1}^q \theta_j e_{t-j} \quad \dots (1)$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Y_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t \quad \dots (2)$$



مقارنة بعض المقدرات المويجية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

وفي ضوء ما تقدم يمكن تعريف أنموذج ARIMA بالشكل ARIMA(p, d, q) إذ أن (d) يمثل الفروق التي تكون أعداداً صحيحة وغالبا ما يتعامل معها الباحثون على وفق هذا الفرض والصيغة العامة لأنموذج بعد أخذ الفروق هي (11):

$$\phi(L)(1-L)^d Y_t = \theta(L)e_t \quad \dots (3)$$

وللحصول على أنموذج خاصية الذاكرة الطويلة ARFIMA تؤخذ قيمة (d) أي عدد حقيقي (Real number) وعند ذلك تكون حالة موسعة لأنموذج ARIMA وتتميز نماذج ARFIMA بالإستقرارية والإنعكاسية (11).

وفي ضوء مما تقدم يمكن درج عدة حالات من قيمة (d) كالآتي (4):

1. تعتمد قيم (d) على العلاقة بينها وبين أس هرست والموضحة بالصيغة (12).

2. عندما $(-\frac{1}{2} < d < 0)$ فإن السلسلة تكون غير مستمرة (متناوبة) (Anti-persistent).

3. عندما تكون $(0 < d < \frac{1}{2})$ تظهر خاصية الذاكرة الطويلة لأنموذج.

4. عندما تكون $(\frac{1}{2} < d < 1)$ تكون العملية غير مستقرة.

5. عندما تكون $(d = 1)$ تتخذ السلسلة أنموذج ARIMA من درجة الفروق الأولى.

6. عندما تكون $(d = 0)$ تتخذ السلسلة أنموذج ARMA.

علماً أن السلسلة تكون مستقرة في التباين المشترك (Covariance stationary) عندما $(-\frac{1}{2} < d < \frac{1}{2})$ وتكون معاملات الارتباط الذاتي (Autocorrelation coefficients) تتناقص بشكل

بطيء جدا على شكل قطع زائد (Hyperbolic decay)

تحدد المعلمة (d) في نماذج ARFIMA(p, d, q) سلوك الذاكرة الطويلة في حين تحدد المعلمتين (p, q) سلوك الذاكرة القصيرة ويمكن تمثيل أنموذج ARFIMA(p, d, q) بالصيغة الآتية (11):

$$\phi(L)(1-L)^d Y_t = \theta(L)e_t \quad \left\{ \begin{array}{l} |d| < 1/2 \\ e_t \underset{\sim}{\text{i. i. d}} N(0, \sigma_e^2) \end{array} \right. \quad \dots (4)$$

$$(1-L)^d = \sum_{s=0}^{\infty} \frac{\Gamma(s-d)L^s}{\Gamma(-d)\Gamma(s+1)} \quad \dots (5)$$

أذ أن:

L: يمثل معامل الإزاحة (Backshift operator).

$\phi(L)$: متعددة حدود الذاكرة القصيرة (سلسلة زمنية من نوع AR من الدرجة p) تمتلك جذور تقع خارج

دائرة الوحدة (Unit circle).

$\theta(L)$: متعددة حدود الذاكرة القصيرة (سلسلة زمنية من نوع MA من الدرجة q) تمتلك جذور تقع خارج

دائرة الوحدة (Unit circle).

e_t : تمثل التشويش الأبيض (White noise).



مقارنة بعض المقدرات الموجية لمعلمة انحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

وبالإعتماد على العلاقة ما بين معلمة (d) والإرتباط الذاتي ($\gamma = 2d = 2H - 1$) يمكن كتابة دالة الكثافة الطيفية لأنموذج ARFIMA(0, d, 0) التي تكون قريبة من المقدار $\left(\frac{1}{f}\right)$ بالصيغة الآتية (5):

$$S(f) = \sigma_e^2 |2 \sin(\pi f)|^{-2d} \propto_{f \rightarrow 0} \frac{\sigma_e^2}{f^{2d}} \quad \dots (6)$$

أذ أن: (f) يمثل التردد (Frequency).

2.2 نظرية الموجات (Wavelets Theory)

أول من تطرق إلى الموجات هو عالم الرياضيات الفرد هار (Alfrd Haar) في العام 1909 أذ إقترح موجة هار (Haar's wavelet)، ومن البحوث أستنتج إن الموجات (هي عبارة عن موجات صغيرة قيمتها (سعتها) (Amplitude) تبدأ من الصفر وبمدة زمنية محددة ووسط صفري)، علما إن هناك عدة أنواع من الموجات بالإعتماد على نوع البيانات من حيث كونها متقطعة (Discrete) أو مستمرة (Continuous) (10).

يتم إنشاء الموجات من دالة التدرج $\varphi(t)$ (Scaling function) أو تسمى أيضا الدالة الأم (Mother function) والدالة الموجية $\psi(t)$ (Wavelet function) وتسمى أيضا الدالة الأب (Father function).

من خلال عمليات التوسيع (Scaling) والإنتقال (Translate) لكل من $\varphi(t)$ و $\psi(t)$ تنتج مجموعة من الدوال ذات بعدين (دوال التحويل الموجي للمراحل المتقدمة) كما موضح بالصيغ الآتية (3):

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad \dots (7)$$

$$\varphi_{a,b}(t) = \frac{1}{\sqrt{a}} \varphi\left(\frac{t-b}{a}\right) \quad \dots (8)$$

أذ أن:

$a \in \mathbb{R}_+$: يمثل معلمة القياس (Scaling parameter).

$b \in \mathbb{R}$: يمثل معلمة الإنتقال (Translation parameter).

$\Psi_{a,b}(t)$: يمثل دالة الموجية أو التفصيلية (Detailed or wavelet function).

$\varphi_{a,b}(t)$: يمثل الدالة التقريبية أو التدرج (Approximation or scaling function).

لذا يمكن تعريف التحويل الموجي على إنه مجموعة من الدوال الأساسية (Basis functions) $\Psi_{jk}(x)$ المشتقة من دالة واحدة $\psi(x)$ من خلال توسيع القيمة والإزاحة خلال الزمن (Dilations and Shifts) للإشارة، وينقسم التحويل الموجي إلى التحويل الموجي المتقطع والتحويل الموجي المستمر تبعاً لنوعية البيانات (10).


هناك الكثير من الدوال الأساسية المختلفة في التحويل الموجي منها موجة هار (Haar wavelet) والتي تعد أبسط أنواع الموجات وتأخذ شكل دالة خطوة (Step function) (وهي تمثل موجة دوجز ذات الدرجة الأولى (Daubechies order 1 wavelet) والموضحة بالشكل (1) من حيث دالة الموجة (Wavelet function) ودالة القياس (Scaling function) (2).

¹ رسم من قبل الباحث بإستعمال برنامج الماتلاب.



مقارنة بعض المقدرات المويجية لمعاملات نموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

شكل (1) يوضح موجية هار ودالة القياس التابعة لها.



يعمل التحويل المتقطع على تحويل البيانات الأصلية أو متجه الإدخال من مجال الزمن (Time domain) إلى المجال المويجي (Wavelet domain)، والنتيجة متجة بنفس الحجم. يمكن تمثيل التحويل المويجي المتقطع كدالة خطية ويكتب بشكل مصفوفة تأخذ الأبعاد $(n \times n)$.

تتم عملية التحويل المويجي بعدد (J) من المراحل بعملية تدعى التحليل المتعدد المراحل (MRA) (Multi Resolution Analysis) حيث إن حجم العينة يجب أن يساوي $n = 2^J$ ويتم تقسيم البيانات أو الإشارة الأصلية إلى قسمين عن طريق المرشحات ويتم تقليل الحجم (2^J) بعملية إختزال (Down sampling) بمقدار (J-1) وفي المرحلة الثانية يتم تقسيم المعاملات التقريبية فقط الناتجة من المرحلة الأولى (السابقة) إلى قسمين أيضا من خلال المرشحات وتقليل الحجم وهكذا مع بقية المراحل وناتج العملية سيضم المعاملات التفصيلية لأخر مرحلة وأخر قيمة من المعاملات التقريبية (8).

يتم الحصول على معاملات التحويل لمتجه بيانات (\underline{y}) بضرب المتجه بمصفوفة التحويل المويجي (W) وتم استخدام موجية هار كما موضح بالصيغة الآتية (2):

$$\underline{w}_y = W \cdot \underline{y} \quad \dots (9)$$

أذ أن:

$$\underline{w}_y' = [T_J \ w_J \ w_{J-1} \ \dots \ w_1]$$

(Coefficients).

T_J : أخر قيمة لمعاملات التحويل التقديرية (Approximation).

w_J : أخر قيمة لمعاملات التحويل المويجية (Wavelet).

$(w_{J-1} \ \dots \ w_1)$: معاملات التحويل المويجية.

تتألف موجية هار من دالتين أساسيتين $\psi(t)$ و $\phi(t)$ والتي تعطى بالصيغ الآتية (8):

$$\psi_{ij}(t) = 2^{i/2} \psi(2^i t - j) \quad , \quad i = 0, \dots, I-1 \quad \text{and} \quad j = 0, \dots, 2^i - 1 \quad \dots (10)$$

$$\phi_{ij}(t) = 2^{i/2} \phi(2^i t - j) \quad \dots (11)$$



مقارنة بعض المقدرات الموجية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

أذ أن:

$$\psi(t) = \begin{cases} +1 & 0 \leq t < 1/2 \\ -1 & 1/2 < t \leq 1 \\ 0 & \text{O.W.} \end{cases}$$
$$\phi(t) = \begin{cases} 1 & 0 \leq t \leq 1 \\ 0 & \text{O.W.} \end{cases}$$

كما في جميع التحويلات الموجية يقوم تحويل هار بتحليل الإشارة المتقطعة الأصلية إلى نصفين متساويين بالطول كإشارتين فرعيتين أحدهما ناتجة من المعدل (Average) وتمثل الاتجاه (Trend) والأخرى ناتجة من الفروق (Difference) وتمثل التذبذب (Fluctuation).

2.3 أس هيرست (Hurst exponent)

وهو يمثل معلمة الذاكرة الطويلة التي اكتشفها الباحث (Hurst) في عام 1951 عند دراسته لمستوى نهر النيل ضمن أبحاثه في مجال الري إذ اكتشف ظاهرة الاعتمادية الطويلة بين مشاهدات السلسلة الزمنية وقد وجد علاقة بين معلمة الذاكرة الطويلة ومعلمة التكامل الكسري (d) (Fractional Integrated) إذ إن⁽⁷⁾:

$$H = d + \frac{1}{2} \Rightarrow d = H - \frac{1}{2} \quad \dots (12)$$

وعليه فإن $(\gamma = 2d = 2H - 1)$.

وتتراوح قيمة أس هيرست $(0 < H < 1)$ فكلما إقترب أس هيرست من الصفر زادت عدم إستقرارية السلسلة وعندما يكون (0.5) تكون السلسلة غير مرتبطة وعندما يكون (1) تكون السلسلة مرتبطة وتظهر خاصية الذاكرة الطويلة.

3. أنموذج الإنحدار الخطي بأخطاء ذات ذاكرة طويلة

(Linear regression model with long range memory errors)

لنفرض لدينا أنموذج الإنحدار الخطي الآتي⁽⁹⁾:

$$Y = X\beta + u \quad \dots (13)$$

أذ أن:

X: تمثل مصفوفة المتغيرات المستقلة بحجم $(n \times p)$ وإن $(X_{ij} \forall i = 1, \dots, n, j = 1, \dots, p)$.

Y: المتغير المعتمد. $Y = (Y_1, \dots, Y_n)'$

$\beta \in \mathbb{R}^p$: متجه المعلمات (Parameters).

u: متجه الأخطاء العشوائية $u \sim N(0, \Sigma)$ بحجم $(n \times 1)$.

نفترض إن الأخطاء (u) لأنموذج الإنحدار الخطي في الصيغة (15) تأخذ شكل عملية مستقرة ذات خاصية الذاكرة الطويلة وتتبع أنموذج ARFIMA و إن $(0 < d < \frac{1}{2})$ وسيتم تقدير أنموذج الإنحدار وفق ثلاث طرائق.



مقارنة بعض المقدرات الموجبية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

3.1. مقدرات المربعات الصغرى الإعتيادية

(Ordinary Least Square Estimators) OLS

إن مقدرات المربعات الصغرى للمتجه (β) للأنموذج في الصيغة (13) بتجاهل مشكلة خاصية الذاكرة الطويلة للأخطاء تعطى بالصيغة الآتية⁽¹⁾:

$$\hat{\beta} = (X'X)^{-1}X'Y \quad \dots (14)$$

وإن مصفوفة التباين والتباين المشترك المقدر للصيغة (14) يعطى بالصيغة الآتية:

$$\text{var} - \text{cov}(\hat{\beta}) = \sigma_e^2(X'X)^{-1}X'\Omega X(X'X)^{-1} \quad \dots (15)$$

أذ أن:

Ω : تمثل مصفوفة التباين والتباين المشترك للأخطاء العشوائية التي تتبع أنموذج ARFIMA(p, d, q).

3.2. مقدرات المربعات الصغرى العامة التقريبية

(Approaching general least square estimators) AGLS

من ناحية أخرى فإن المقدر (BLUE) للمتجه (β) يأخذ الصيغة الآتية⁽¹⁾:

$$\hat{\beta} = (X'\Omega^{-1}X)^{-1}X'\Omega^{-1}Y \quad \dots (16)$$

وتباينه يعطى بالصيغة الآتية:

$$\text{Var}(\hat{\beta}) \approx \sigma_e^2(X'\Omega^{-1}X)^{-1} \quad \dots (17)$$

ولسهولة التعامل مع أنموذج ARFIMA(p, d, q) نأخذ أبسط أنواعه ARFIMA(0,d,0) والذي تكون صيغته كالتالي:

$$(1 - B)^d u_t = e_t \quad \dots (18)$$

ولإيجاد مصفوفة التباين والتباين المشترك للأخطاء (u_t) يتم إيجاد الأخطاء المرتدة زمنيا فنحصل على قيمة الأخطاء العشوائية (u_t) في أنموذج الإنحدار (13) بصورة تشابه الصيغة الآتية:

$$u_t = e_t + d_1 e_{t-1} + \frac{d_2}{2!} e_{t-2} + \frac{d_3}{3!} e_{t-3} \dots \quad \dots (19)$$

أذ أن: $d_1 = d$, $d_2 = d(d - 1)$, $d_t = f(d)$, $t = 3, \dots, \infty$

ومن الصيغة (19) نستنتج أن قيم البسط المعتمدة على قيم (d) تتغير نتيجة التعويض ولكنها تضمحل مع التقدم في الزمن بحيث نستطيع أن نفترض امكانية الاستعانة بمصفوفة (Ω) المستعملة في طريقة

المربعات الصغرى العامة (GLS) لتقدير معلمات أنموذج الإنحدار التي تكون أخطاؤه تتبع أنموذج AR(1) كحالة تقريبية كما في الصيغة الآتية⁽¹⁾:

$$\Omega_d \approx \begin{bmatrix} 1 & d & d^2 & \dots & d^{n-1} \\ d & 1 & d & \dots & d^{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ d^{n-1} & d^{n-2} & d^{n-3} & \dots & 1 \end{bmatrix} \quad \dots (20)$$

$$\Omega_d^{-1} \approx \frac{1}{1 - d^2} \begin{bmatrix} 1 & -d & 0 & 0 & \dots & 0 \\ -d & 1 + d^2 & -d & 0 & \dots & 0 \\ 0 & -d & 1 + d^2 & -d & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad \dots (21)$$



مقارنة بعض المقدرات الموجية لمعاملات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

ومن ثم تكون مصفوفة التباين والتباين المشترك للأخطاء العشوائية لأنموذج الإنحدار بأخطاء تتبع أنموذج ARFIMA(0,d,0) بشكل تقاربي بالصيغة الآتية:

$$Euu' \approx \sigma_u^2 \Omega_d \quad \dots (22)$$

وإعتماداً على الصيغة (22) نعرف صيغة تقاربية لتقدير معاملات أنموذج الإنحدار كما في الصيغة (16).

3.3 المقدرات الموجية المعتمدة على دالة الإمكان الأعظم

Wavelet Generalized Maximum Likelihood (WML)

إن كون الأخطاء العشوائية (u) (Random errors) في الأنموذج (13) لها خاصية ذاكرة طويلة (Long memory) ومن ثم فإن التباين المشترك للأخطاء لها بنية الذاكرة الطويلة والتي تُعلم بوحدة من رموز التشويش الكسري (H or d) فيكون $u \sim (0, \Sigma(H))$ ، وبالإعتماد على خاصية التعامد للتحويل الموجي المتقطع يمكن إفتراض إن قيم العناصر غير القطرية لمصفوفة التباين والتباين المشترك (Σ) هي قيم صفرية وهذا يجعل إيجاد معكوس المصفوفة (Σ^{-1}) أسهل (5).

يمكن إعادة كتابة الأنموذج (13) بالمجال الموجي (Wavelet domain) بعد عملية التحويل كالاتي:

$$Y_W = X_W \beta + \epsilon_W \quad \dots (23)$$

أذ أن:

$$Y_W = W \cdot Y$$

$$X_W = W \cdot X$$

β : معاملات الأنموذج.

$u_w = W \cdot u$: تمثل متجه الأخطاء العشوائية بعد إجراء التحويل الموجي المتقطع على الأخطاء العشوائية

$$(u_w \sim N(0, \Sigma_{u_w}), \Sigma_{u_w} = \sigma^2 \Sigma_w)$$

W : تمثل مصفوفة التحويل الموجي المتقطع (مصفوفة هار).

يمكن كتابة دالة الإمكان للأنموذج في الصيغة (23) ضمن المجال الموجي وأخذ اللوغارتم لها كما بالصيغة الآتية (5):

$$\log L(\theta) = -\frac{1}{2} \left[n \log(2\pi\sigma^2) + \log(S_{a_j}) + \sum_j n(j) \log(S_{d_j}) \right] - \frac{1}{2\sigma^2} \left[\frac{(Y_{j,0} - \sum_{s=1}^p X_{j,0}^s \beta_s)^2}{S_{a_j}} + \sum_{j,1} \frac{(Y_{j,1} - \sum_{s=1}^p X_{j,1}^s \beta_s)^2}{S_{d_j}} \right] \quad \dots (24)$$

أذ أن: $n(j) = n/2^j$



مقارنة بعض المقدرات الموجية لمعاملات نموذج إنحدار خطي
بأخطاء تتبع نموذج [ARFIMA]

ومصفوفة التباين والتباين المشترك للأخطاء تكون قطرية وكما في الصيغة الآتية:

$$\Sigma_{u_w} = \sigma^2 \begin{bmatrix} S_{a_j}(\gamma) & & & & \\ & S_{d_j}(\gamma) & & & \\ & & \ddots & & \\ & & & \begin{pmatrix} S_{d_2}(\gamma) & & \\ & \ddots & \\ & & S_{d_2}(\gamma) \end{pmatrix} & \\ & & & & \begin{pmatrix} S_{d_1}(\gamma) & & \\ & \ddots & \\ & & S_{d_1}(\gamma) \end{pmatrix} \end{bmatrix} \quad \dots (25)$$

$$\Sigma_{u_w} = \sigma^2 \Sigma_w \quad \dots (26)$$

أذ أن:

$S_{a_j}(\gamma)$: يمثل تباين معامل التدرج (Scaling coefficient).

$S_{d_j}(\gamma)$: يمثل تباين معاملات الموجة (Wavelet coefficients).

أذ يمكن كتابة عناصر القطر الرئيس بدلالة المعلمة (d) التي تمثل معلمة الذاكرة الطويلة كالآتي:

$$S_{a_j}(\gamma) = \frac{C_f}{[1 - 2d]} \pi^{-2d} 2^{2jd} = S_{a_j}(d) \quad \dots (27)$$

$$S_{d_j}(\gamma) = \frac{C_f}{[1 - 2d]} \pi^{-2d} 2^{2jd} [2^{1-2d} - 1] = S_{d_j}(d) \quad \dots (28)$$

أذ أن: $0 < C_f$

ومن ثم فإن معكوس مصفوفة (Σ_{u_w}) يعطى بالصيغة الآتية:

$$\Sigma_{u_w}^{-1} = \frac{1}{\sigma^2} \begin{bmatrix} \frac{1}{S_{a_j}(d)} & & & & \\ & \frac{1}{S_{d_j}(d)} & & & \\ & & \ddots & & \\ & & & \begin{pmatrix} \frac{1}{S_{d_2}(d)} & & \\ & \ddots & \\ & & \frac{1}{S_{d_2}(d)} \end{pmatrix} & \\ & & & & \begin{pmatrix} \frac{1}{S_{d_1}(d)} & & \\ & \ddots & \\ & & \frac{1}{S_{d_1}(d)} \end{pmatrix} \end{bmatrix} \quad \dots (29)$$



مقارنة بعض المقدرات الموجبية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

في ضوء تعريف المصفوفة $(\Sigma_{u_w}^{-1})$ يمكن كتابة دالة الإمكان كالآتي:

$$L(\theta) = (2\pi)^{-\frac{n}{2}} (\sigma^2)^{-\frac{n}{2}} |\Sigma_w|^{-\frac{1}{2}} e^{-\frac{1}{2\sigma^2} (Y_w - X_w \beta)' \Sigma_w^{-1} (Y_w - X_w \beta)} \quad \dots (30)$$

وبأخذ اللوغارتم للدالة السابقة نحصل على الآتي:

$$\log L(\theta) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2} \left[\log S_{a_j}(d) + \sum_j \frac{n}{2j} \log S_{d_j}(d) \right] - \frac{1}{2\sigma^2} [(Y_w - X_w \beta)' \Sigma_w^{-1} (Y_w - X_w \beta)] \quad \dots (31)$$

وبأخذ الاشتقاق بالنسبة (β) نحصل على تقديرها كما في الصيغة الآتية:

$$\hat{\beta} = (X_w' \Sigma_w^{-1} X_w)^{-1} X_w' \Sigma_w^{-1} Y_w \quad \dots (32)$$

وتبايناتها تعطى بالصيغة الآتية:

$$v - \text{cov}(b) = (X_w' \Sigma_w^{-1} X_w)^{-1} = \sigma_e^2 (X_w' \Sigma_w^{-1} X_w)^{-1} \quad \dots (33)$$

وبأخذ الاشتقاق بالنسبة (σ^2) نحصل على تقديرها كما في الصيغة الآتية:

$$\hat{\sigma}_{ML}^2 = \frac{1}{n} \left[\frac{a_{j,0}^2}{S_{a_j}} + \sum_{j,l} \frac{d_{j,l}^2}{S_{d_j}} \right] \quad \dots (34)$$

4. التطبيق العملي (Practical application)

تم تطبيق ما جاء في الجانب النظري على بيانات حقيقية بالإستعانة ببرنامج الماتلاب بنسخته (MATLAB R2014a).

إستعملت البيانات الشهرية لمعدل التغير في الرقم القياسي لسعر المستهلك (التضخم) (Inflation) كمتغير معتمد ومعدل سعر صرف الدولار (Dollar exchange rate) كمتغير مستقل والتي تم الحصول عليها من التقارير السنوية للأرقام القياسية لأسعار المستهلك الصادرة من الجهاز المركزي للإحصاء - مديرية الأرقام القياسية للمدة من 2005/1 ولغاية 2015/12.

يعد التضخم من أبرز الظواهر الإقتصادية غير المرغوب فيها التي تعاني منها أغلب إقتصاديات دول العالم، لما له من تأثير على مجمل المجالات الإقتصادية والإجتماعية فضلاً عن تماسها مع حياة المواطن اليومية، ويمثل التضخم الإرتفاع المستمر والمتواصل في المستوى العام للأسعار، أذ تنجم هذه الظاهرة من عدم التوافق بين نمو أو حجم السيولة النقدية وبين نمو أو وفرة السلع والخدمات المتاحة في السوق، أو إنه ناجم عن إرتفاع تكاليف الإنتاج أو عن وجود فائض في الطلب أذ ان التضخم نتاج لعوامل متعددة تؤدي إلى إختلال في أسعار السلع والخدمات الإستهلاكية والإنتاجية وبين مستوى الأرباح ومستوى الأجور.

يعرف سعر الصرف بأنه النسبة التي يحصل على أساسها مبادلة النقد الأجنبي بالنقد الوطني، ويتم تحديده تبعاً للطلب والعرض عليها في سوق الصرف في لحظة زمنية ما، ولهذا يمكن أن يتغير سعر الصرف تبعاً لتغير الطلب والعرض، وينقسم على سعر الصرف الرسمي (السعر المعمول به فيما يخص التبادلات التجارية الرسمية) وسعر الصرف الموازي (السعر المعمول به في الأسواق الموازية).

يمكن توضيح العلاقة بين التضخم وسعر صرف الدولار بأنه كلما زادت الكمية المعروضة من النقد بالدينار كلما انخفضت قيمة الدينار مقابل الدولار وهذا يعني كمية أكثر من الدينار يجب دفعها للحصول على الدولار وذلك يعني زيادة في أسعار السلع أو ما يعرف بالتضخم ومن ثم انخفاض مستوى الدخل الحقيقي للأفراد.



مقارنة بعض المقدرات المويجية لمعلمات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

أفترضت معادلة الإنحدار كما في الصيغة الآتية:

$$Y_i = \beta_0 + \beta_1 X_i + U_i, \quad i = 1, \dots, 128 \quad \dots (36)$$

أذ أن:

Y_i : يمثل التضخم (معدل التغير في الرقم القياسي لأسعار المستهلك).

X_i : يمثل معدل سعر صرف الدولار.

U_i : يمثل الأخطاء العشوائية وعلى إفتراض إنها تتبع أنموذج ARFIMA.

ولتقدير معلمات الأنموذج المقترح تم تطبيق عدة إختبارات من حيث كونه خالي من المشاكل ومن خرق فرضياته ومن ثم تطبيق طرائق التقدير المذكورة في الجانب النظري للحصول على معادلة إنحدار ذات فاعلية في عملية التنبؤ المستقبلي وكذلك لإظهار إن طرائق التقدير المويجية هي الأفضل من طرائق التقدير التقليدية. بعد ثبوت عدم إستقرارية سلسلة الأخطاء للأنموذج المقترح ووجود مشكلة الإرتباطات بينها يتم تحديد قيمة معلمة الفروق الكسرية (d) على إفتراض أن سلسلة الأخطاء تتبع أنموذج ARFIMA وذلك من خلال إيجاد قيمة المعلمة هرست (H) بالطرائق المذكورة للحصول على قيم (d) بالإستعانة بالصيغة (12) وكما مبين في الجدول (1).

جدول (1) يبين قيم أس هرست وقيم معلمة الفروق الكسرية.

ت	الطريقة لإيجاد قيمة (H)	قيمة (H)	قيمة (d)
1	طريقة هيكوشي	0.841342331	0.341342331
2	طريقة العزوم	0.864617891	0.364617891
3	طريقة التباينات التجميعية	0.87270343	0.37270343
4	طريقة المدى المقيس	1.120432945	0.620432945

وتم إستعمال قيم (d) من كل الطرائق في عملية التقدير بإستثناء قيمة (d) المستخرجة بطريقة المدى المقيس (R/S analysis) كونها لا تقع ضمن المدى (0 < d < 0.5) أي إنها طريقة غير فعالة لتقدير معلمة التكامل الكسري (d) في هذه الحالة ولنوعية البيانات المستعملة.

بعد الإنتهاء من تقدير قيمة معلمة الفروق الكسرية بالإعتماد على قيمة أس هرست يتم إجراء التحويل المويجي للبيانات الأصلية (المتغير المعتمد والمتغيرات التوضيحية) لحجم العينة المستعملة (n=256) وعليه تكون عدد مراحل التحويل المويجي (J) هي (J = 8) بحسب العلاقة (n = 2^J).

تم تطبيق طرائق تقدير معلمات أنموذج الإنحدار (β) المذكورة آنفاً في الجانب النظري وكانت النتائج كما مبينة بالجدول (2)، علماً بأن المعلمة (σ_e²) في طريقة (WML) تستخدم الصيغة المعرفة (34)، في حين أن الطريقتين (OLS) و (AGLS) نقدرها بإعتماد آلية (SSE / (n-p)) كل بحسب فرضية الأنموذج علماً بأن الطريقة الثانية تعطي قيمة تقاربية وكما موضح بالجدول (2).

جدول (2) يبين مقدرات (β) وتقدير تبايناتها لكل الطرائق وحسب قيم (d).

قيمة معلمة (d)	المعلمات المقدره	طريقة OLS	طريقة AGLS	طريقة WML
0.341342331	b0	-164.702629	-160.1728838	-125.2349215
	v(b0)	402.9187075	243.9241124	10.55432482
	b1	0.142021356	0.138374317	0.110695361
	v(b1)	0.00025203	0.000152532	6.27813*10 ⁻⁶
	σ _e ²	158.755417	97.20963874	3.805919671
	R ²	0.557108288	0.669684094	0.98303616



مقارنة بعض المقدرات الموجية لمعلمة أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

0.364617891	b0	-164.702629	-159.5688445	-122.2087728
	v(b0)	423.8065312	249.8095916	9.942125426
	b1	0.142021356	0.137889678	0.10829347
	v(b1)	0.000265071	0.00015619	5.82139*10 ⁻⁶
	$\hat{\sigma}_e^2$	158.755417	94.85363343	3.256521886
	R ²	0.557108288	0.663265484	0.984538306
0.37270343	b0	-164.702629	-159.3433336	-121.1499559
	v(b0)	431.3990849	252.0235179	9.746139411
	b1	0.142021356	0.137708807	0.107453075
	v(b1)	0.000269811	0.000157566	5.66713*10 ⁻⁶
	$\hat{\sigma}_e^2$	158.755417	94.08773962	3.084788569
	R ²	0.557108288	0.660869736	0.985048525

نلاحظ من الجدول (2) أن طريقة (WML) قد حققت أقل تباينات لجميع مقدرات (β) مقارنة بالطرائق المستعملة الأخرى وقد جاءت بعدها طريقة (AGLS) وطريقة (OLS) على التوالي، كما ويلاحظ إن هذا التسلسل في الأسبقية هو نفسه عند تقدير معلمة (σ_e^2)، علماً بأن الفارق كان كبيراً بين المقدرات الموجية والمقدرات التقليدية.

وإعتماداً على ما تقدم فإن المعادلة التقديرية للأنموذج المعرف بالصيغة (36) تعتمد على مقدرات (WML) إذ كانت قيمة معامل التحديد (R^2) تساوي ما نسبته 98% وهذا يعني قبول الأنموذج والمتبقي تعزى إلى أسباب غير محددة تفسر بالأخطاء.

ويلاحظ إن تغير قيم (d) لم يؤثر في ما تمت ملاحظته في الجدول (2) ومن ثم تكون طريقة (WML) هي الطريقة التي تعتمد في تقدير أنموذج الإنحدار بالصيغة (36)، علماً بأنه كلما صغرت قيمة (d) كلما تحسنت تقديرات المعلمة (β) و(σ_e^2) للأنموذج.

وعليه فإن الأنموذج المقترح للبيانات الحقيقية المستعملة في الجانب العملي يأخذ الصيغة الآتية:

$$Y_i = -125.2349215 + 0110695361X_i + U_i$$

علماً إن قيمة معلمة الفروق الكسرية لهذا الأنموذج (0.341342331) وهي الأصغر بين القيم الأخرى والنتيجة من طريقة هيكوشي لتقدير معلمة أس هرسست وعليه تعد هذه الطريقة الأفضل في تقدير (d) لهذا النوع من البيانات.

5. الاستنتاجات (Conclusion)

من أهم الاستنتاجات التي توصل إليها الباحث هي:

1- إن آلية التحويل الموجي المنقطع تتوافق من حيث الرؤية الأولية مع آليات طرائق معالجة مشاكل الإنحدار الخطي المعلمي (مشكلة عدم تجانس التباين ومشكلة الارتباط الذاتي) عند إجراء عملية التقدير لمعلمة أنموذج الإنحدار الخطي المعلمي إذ أن أنموذج الإنحدار الخطي المعلمي يضرب بمصفوفة تحويل ذات مواصفات خاصة لكلا طرفي الأنموذج من جهة اليسار إلا إن الإختلاف في التحويل الموجي يقوم بتحويل بيانات المتغير المعتمد والمتغيرات التوضيحية والأخطاء العشوائية وتنعيمها والتي تكون بالحجم نفسه (توليد بيانات جديدة من البيانات الأصلية أي تحويلها من مجال الزمن إلى المجال الموجي) وهذه آلية المعالجة عند الطرائق الشائعة ومنها طريقة المربعات الصغرى الموزونة وطريقة الإمكان الأعظم ومن ثم تجرى عملية التقدير وفي كلتا الآليتين تستعمل الطرائق الشائعة مع إختلاف إن التقديرات الموجية تعتمد البيانات الجديدة في المجال الموجي في حين تعتمد التقديرات الأخرى على البيانات الأصلية.



مقارنة بعض المقدرات الموجية لمعاملات أنموذج إنحدار خطي بأخطاء تتبع أنموذج [ARFIMA]

- 2-بالإعتماد على نتائج الجانب التطبيقي نستنتج أن طريقة (WML) أثبتت كفاءتها على بقية الطرائق لإملاك مقدرات الأنموذج أقل التباينات المستخرجة بواسطة هذه الطريقة، ولذا يتم إعتماد مقدراتها في المعادلة التقديرية للأنموذج المعرف بالصيغة (23).
- 3-إن إختلاف قيم معلمة الفروق الكسرية لا تؤثر في أفضلية طريقة (MLE).

المصادر (References)

1. كاظم، أموري هادي و شليبة، باسم، (2002)، "القياس الإقتصادي المتقدم النظرية والتطبيق" مكتبة الامل، بغداد، شارع الصناعة.
2. Addison, Paul S, (1997), "Fractals and Chaos An Illustrated Course", British Library Cataloguing-in-Publication Data, ISBN 0 7503 0399 9 (hbk).
3. Bouden, Toufik and Mokhtar, Nibouche, (2012), "The Wavelet Transform for Image Processing Applications", INTECH Open Access Publisher, ISBN:9535104942, 9789535104940.
4. Dark, Onathan, (2007), "Estimation of the fractional differencing parameter using wavelets and temporal aggregation", Monash University, Australia.
5. Fadili, M., J. and Bullmore E.T., (2002), "Wavelet-Generalized Least Squares: A New BLUE Estimator of Linear Regression Models with 1/f Errors", NeuroImage 15, 217-232.
6. In, Francis and Kim, Sangbae, (2013), "An Introduction to Wavelet Theory in Finance, a Wavelet Multiscale Approach", World Scientific Publishing Co. Pte. Ltd.
7. Kale, Malhar and Butar, Ferry, (2011), "Fractal Analysis of Time Series and Distribution Properties of Hurst Exponent", Journal of Mathematical Sciences & Mathematics Education, Vol. 5 No. 1.
8. Nason, G., 2008, "Wavelet methods in statistics with R", X, 259 p., ISBN:978-0-387-75960-9.
9. Palma, Wilfredo, (2007), "Long memory time series – theory and methods", Pontificia Universidad Catolica de Chile.
10. Vaidyanathan, P. P. and Djokovic, Igor, (1994), "An Introduction to Wavelet Transform", California Institute of Technology, August.
11. Vacha, Lukas and Barunik, Jozef, (2012), "Long Memory II ARFIMA and Estimation", Summer Semester.



مقارنة بعض المقدرات المويجية لمعاملات أنموذج إنحدار خطي
بأخطاء تتبع أنموذج [ARFIMA]

Compare some wavelet estimators for parameters in the linear regression model with errors follows ARFIMA model.

Abstract

The aim of this research is to estimate the parameters of the linear regression model with errors following ARFIMA model by using wavelet method depending on maximum likelihood and approaching general least square as well as ordinary least square. We use the estimators in practical application on real data, which were the monthly data of Inflation and Dollar exchange rate obtained from the (CSO) Central Statistical organization for the period from 1/2005 to 12/2015. The results proved that (WML) was the most reliable and efficient from the other estimators, also the results provide that the changing of fractional difference parameter (d) doesn't effect on the results.

Keyword: wavelet, wavelet transformation, linear regression model , ARFIMA model.