



A Geometric Integer – Valued GARCH Model Hala Fadal Hussian Alhakem (*)

أنموذج GARCH بقيمة صحيحة في حالة التوزيع الهندسي
(*) هالة فاضل حسين الحكيم

Abstract

In this paper, the modeling of integer - valued time series with over dispersion is discussed. A particularly flexible model for time series of counts is the Geometric integer - valued Generalized Autoregressive conditional heteroscedastic (GED - GARCH) model which properly accounts for the over dispersion and non - negativity. This model is proposed and the autocorrelation function are given. The main goal of this paper is to study the properties of model and some results from simulation study to estimate the unknown parameters by using Maximum Likelihood method.

Keywords: Geometric Integer, GARCH Model.

المستخلص:

في هذا البحث نوقشت نمذجة السلاسل الزمنية ذات قيم حقيقية غير سالبة وذلك في حالة عدم تجانس التباين. وان الانموذج الخاص للسلاسل الزمنية المعدودة يمكن وصفه بانموذج الانحدار الذاتي المشروط بعدم تجانس التباين الهندسي. تم اقتراح هذا الانموذج فضلاً عن ايجاد دالة الارتباط الذاتي له. ان الهدف الاساس لهذا البحث هي دراسة خصائص الانموذج وعرض بعض النتائج لتقدير معلمته بطريقة الامكان الاعظم وباستخدام دراسة المحاكاة.
1. المقدمة:

لقد تناول العديد من الباحثين نماذج الانحدار الذاتي المشروط بعد تجانس التباين للخطأ في حالة التوزيعات المستمرة، إلا أن استخدام هذا الانموذج لا يقتصر على هذه التوزيعات بل تم توسيع استخدامها ليشمل التوزيعات المتقطعة ايضاً بقيمة صحيحة وغير سالبة. وقد اطلق على هذه النماذج بالسلاسل الزمنية المعدودة (Count Time Series) او القابلة للعد. لقد اصبح لهذا النوع من السلاسل تطبيقات واسعة، لاسيما في مجال التأمين الصناعي، الاقتصاد، الطب، الاتصالات، أنظمة الانتظار، وغيرها، حيث ان قيم السلسلة الزمنية المعدودة ممكن ان تكون عدد من الحوادث، اعداد المرضى، عدد المنتجات الصناعية. ولتحليل السلسلة الزمنية المعدودة فقد تم اقتراح عدد من النماذج وذلك لوصف توزيعاتها الحدية (Marginal Distribution) ومركبات الارتباط الذاتي. لقد ناقش كل من (Zeger, (1988)⁽⁷⁾ و (Davis et al, 2000, 2003)⁽¹⁾⁽²⁾ نماذج الانحدار اللوغارتمي في حالة

(*) lecturer, Baghdad University, Higher Institute of science Accounting and financial.

بواسون، اضافة الى ما قدمه الباحثان (Kedem & Fokianas, 2002)⁽⁶⁾ في استخدام هذا النوع من السلاسل بشكل واسع.

كما قام (Fokianos, 2011)⁽⁵⁾ بدراسة وعرض نماذج الانحدار للسلاسل الزمنية المعدودة حيث ناقش الصيغة التي تعتمد على النماذج الخطية العامة واحد اصناف عمليات الانحدار الذاتي ذات القيم الصحيحة.

وقد ناقش (Zhu, 2011)⁽¹⁰⁾ هذا الانموذج عندما تكون قيم السلسلة الزمنية معدودة وغير سالبة وتعاني من مشكلة عدم التجانس، وان مشاهدات هذه السلسلة تتبع توزيع ثنائي الحد السالب (Negative Binomial) والذي يرمز له اختصاراً (NBINGARCH) وقد بين الباحث ان هذا النوع من السلاسل تكون تغيراتها اكبر من المتوسط وان السبب الرئيس لوجود حالة عدم التجانس هو وجود ارتباط موجب بين مشاهداتها.

ان دراسة انموذج (GARCH) في حالة التوزيع الهندسي يعد حالة خاصة من الانموذج (NBINGARCH). كما اقترح (Davis and wn, 2009)⁽³⁾ انموذج انحدر ثنائي الحد السالب للسلاسل الزمنية المعدودة والتي تعد تعميماً لنماذج انحدر بواسون الخطية اللوغارتمية. ان الانموذج الشائع الاستخدام للسلاسل الزمنية المعدودة بوجود عدم التجانس هو انموذج الانحدار الذاتي المشروط بعدم تجانس التباين العام بقيم صحيحة ويرمز له اختصاراً (INGARCH) بمتغيرات بواسون. وقد عرف (Ferland et al, 2006)⁽⁴⁾ هذا الانموذج بالصيغة الآتية:

$$\begin{cases} X_i / F_{i-1} : P(\lambda_i) \\ \lambda_i = \alpha_0 + \sum_{i=1}^p \alpha_i X_{i-i} + \sum_{j=1}^q \beta_j X_{i-j} \end{cases} \dots (1)$$

إذ أن $\alpha_0 > 0$, $\alpha_i > 0$, $\beta_j > 0$ عندما $i = 1, 2, \dots, p$ ، $j = 1, 2, \dots, q$ وأن $p \geq 1$ و $q \geq 0$

و F_{i-1} تمثل (σ - field) تولد بالمتسلسلة $\{X_{i-1}, X_{i-2}, \dots\}$.

ولقد درس هذا الانموذج العديد من الباحثين منهم (Zhu et al, 2008)⁽⁸⁾ و (Zhu & wang, 2010)⁽⁹⁾. كما قام (Weib, 2009)⁽¹¹⁾ باشتقاق مجموعة من المعادلات لدالة التباين والارتباط الذاتي للحالة العامة للانموذج. فضلاً عن ذلك فقد بين (Zhu, 2011)⁽¹⁰⁾ ان انموذج بواسون يكون فيه المتوسط المشروط مساوياً للتباين المشروط وان ذلك ممكن ان يؤدي الى ضعف الاداء في ظل وجود مشاهدات متطرفة محتملة، وبذلك فقد اقترح انموذج بديل هو انموذج ثنائي السالب الذي يتعامل مع عدم التجانس والمشاهدات المتطرفة في آن واحد.

2. مشكلة البحث:

في كثير من التطبيقات تكون الظاهرة المدروسة تخضع لأحد التوزيعات الاحتمالية المتقطعة وان بناء الانموذج لهذه الظاهرة يتطلب دراسة نظرية شاملة لخصائص العينة المدروسة بما في ذلك الاعتمادية وحالة عدم التجانس والقيم المتطرفة. وان دراسة هذه الخصائص في حقل السلاسل الزمنية يتطلب دراسة نماذج (INGARCH) الملائمة وبالتالي امكانية التنبؤ بالقيم المستقبلية.

3. هدف البحث:

يهدف بحثنا الى اقتراح ودراسة انموذج الانحدار الذاتي المشروط بعدم تجانس التباين (GARCH) في حالة اتباع السلسلة الزمنية التوزيع الهندسي والذي سيرمز له اختصاراً (GEO - GARCH).

4. الجانب النظري:

أنموذج (GEO - GARCH):

على فرض أن $\{X_t\}$ تمثل سلسلة زمنية ذات قيم متقطعة (معدودة)، مشروطة بـ (F_{t-1}) ، وأن المتغيرات العشوائية X_1, \dots, X_n مستقلة والتوزيع الشرطي لـ (X_t) يتمثل بالتوزيع الهندسي. وذلك فإن الانموذج الذي يصف هذه المتغيرات يكون:

$$X_t / F_{t-1} : G(P_t)$$

أذاً F_{t-1} هي (σ -field) وتتولد بالمتغيرات $(X_{t-1}, X_{t-2}, \dots)$ وأن (P_t) يحقق الانموذج التالي بفرض أن $(\lambda_t = \frac{1-P_t}{P_t})$:

$$\frac{1-P_t}{P_t} = \lambda_t = \alpha_0 + \sum_{i=1}^p \alpha_i X_{t-i} + \sum_{j=1}^q \beta_j X_{t-j} \quad \dots (2)$$

إذاً $\alpha_0 > 0$ ، $\alpha_i > 0$ ، $\beta_j > 0$ عندما $i = 1, 2, \dots, p$ ، $j = 1, 2, \dots, q$ و $p \geq 1$ و $q \geq 0$.

وأن الانموذج (2) سوف يرمز له اختصاراً (GEO – GARCH) أن دالة الاحتمال المشروطة للسلسلة (X_t) تأخذ الصيغة الآتية:

$$P(X_t = x_t / F_{t-1}) = p_t (1 - p_t)^{x_t}, \quad x_t = 0, 1, \dots \quad \dots (3)$$

إذاً:

$$P_t = \frac{1}{1 + \lambda_t}, \quad q_t = 1 - P_t = \frac{\lambda_t}{1 + \lambda_t}$$

وبذلك فإن المتوسط والتباين المشروطين للسلسلة X_t تعطى بالشكل الآتي:

$$E[X_t / F_{t-1}] = \frac{1 - p_t}{p_t} = \lambda_t$$

$$Var[X_t / F_{t-1}] = \frac{1 - p_t}{p_t^2} = \lambda_t (1 + \lambda_t)$$

على التوالي. وأن ذلك يشير الى ان

$$Var[X_t / F_{t-1}] > E[X_t / F_{t-1}]$$

علاوة على ذلك:

$$\begin{aligned} Var(X_t) &= E[Var(X_t / F_{t-1})] + Var[E(X_t / F_{t-1})] \\ &= E[\lambda_t (1 + \lambda_t)] + Var(\lambda_t) \\ &= E(\lambda_t) + E(\lambda_t)^2 + Var(\lambda_t) > E(\lambda_t) = E(X_t) \end{aligned}$$

كما يمكن كتابة الآتي:

$$X_t = \lambda_t + (X_t - \lambda_t)$$

وعلى فرض أن:

$$\epsilon_t = X_t - \lambda_t$$

$$\therefore X_t = \lambda_t + \epsilon_t$$

وبأخذ التوقع الرياضي لـ X_t ينتج أن:

$$E(X_t) = E[E(X_t / F_{t-1})] = E(\lambda_t)$$

خصائص السلسلة ϵ_t :

1.

$$\begin{aligned} E(\epsilon_t) &= E[E(\epsilon_t / F_{t-1})] = E[E\{(X_t - \lambda_t) / F_{t-1}\}] \\ &= E[E(X_t / F_{t-1})] - E[\lambda_t / F_{t-1}] = E(\lambda_t) - E(\lambda_t) = 0 \end{aligned}$$

2.

$$\begin{aligned} \text{Var}(\epsilon_t) &= \text{var}[E(\epsilon_t / F_{t-1})] + E[\text{var}(\epsilon_t / F_{t-1})] \\ &= 0 + E[\text{var}(\epsilon_t / F_{t-1})] \\ &= E[\text{Var}\{(X_t - \lambda_t) / F_{t-1}\}] \\ &= E[\text{Var}(X_t / F_{t-1})] + E[\text{Var}(\lambda_t / F_{t-1})] \end{aligned}$$

ان المعلمة λ_t بدلالة الزمن $(t-1)$ وهي معلومة لذلك يكون تباينها مساوياً للصفر:

$$\text{Var}(\epsilon_t) = E[\text{Var}(X_t / F_{t-1})] = E[\lambda_t(1 + \lambda_t)] = E(\lambda_t) + E(\lambda_t^2)$$

3.

$$\text{cov}(\epsilon_t, \epsilon_{t+h}) = 0$$

وبذلك يكون (ϵ_t) متغير عشوائي ويعرف بـ (white noise).

وبأخذ التوقع الرياضي للمعادلة (2) فإن المتوسط للسلسلة (X_t) يكون:

$$E(\lambda_t) = \alpha_0 + \sum_{i=1}^p \alpha_i E(X_{t-i}) + \sum_{j=1}^q \beta_j E(\lambda_{t-j})$$

وعندما تكون X_t مستقرة فإن:

$$E(\lambda_t) = \alpha_0 + \sum_{i=1}^p \alpha_i E(X_t) + \sum_{j=1}^q \beta_j E(\lambda_t)$$

ولكن:

$$E(X_t) = E(\lambda_t)$$

$$\therefore E(X_t) = \alpha_0 + \sum_{i=1}^p \alpha_i E(X_t) + \sum_{j=1}^q \beta_j E(X_t)$$

$$E(X_t) - \sum_{i=1}^p \alpha_i E(X_t) - \sum_{j=1}^q \beta_j E(X_t) = \alpha_0$$

$$\therefore E(X_t) = \frac{\alpha_0}{1 - \sum_{i=1}^p \alpha_i - \sum_{j=1}^q \beta_j} \quad \dots (4)$$

وبتعويض $E(X_t)$ بالمعادلة (2) ينتج ان:

$$X_t - \epsilon_t = E(X_t) \left(1 - \sum_{i=1}^p \alpha_i - \sum_{j=1}^q \beta_j\right) + \sum_{i=1}^p \alpha_i X_{t-i} + \sum_{j=1}^q \beta_j (X_{t-j} - \epsilon_{t-j})$$

$$X_t - E(X_t) = \sum_{i=1}^p \alpha_i [X_{t-i} - E(X_t)] + \sum_{j=1}^q \beta_j [X_{t-j} - E(X_t)] + \epsilon_{t-j} - \sum_{j=1}^q \beta_j \epsilon_{t-j}$$

$$= \sum_{i=1}^m (\alpha_i + \beta_i) [X_{t-j} - E(X_t)] + \epsilon_t - \sum_{j=1}^q \beta_j \epsilon_{t-j} \quad \dots (5)$$

حيث ان $m = \max(p, q)$. ان الصيغة رقم (5) تمثل نموذج $ARMA(m, q)$

بالمعلمات $\theta_j = \beta_j$ ، $\phi_i = (\alpha_i + \beta_i)$

وعندما $m = p = 1$ فإن الصيغة رقم (5) ستكون:

$$X_t - E(X_t) = (\alpha_1 + \beta_1)(X_{t-1} - E(X_{t-1})) + \epsilon_t - \beta_1 \epsilon_{t-1}$$

وأن خصائص الانموذج ستكون كما يأتي:

1.

$$E(X_t) = \frac{\alpha_0}{1 - \alpha_1 - \beta_1} = \mu$$

2.

$$\text{cov}(X_t, X_{t-h}) = \begin{cases} \frac{1 - (\alpha_1 + \beta_1)^2 + \alpha_1^2}{1 - (\alpha_1 + \beta_1)^2 - \alpha_1^2} [\mu + \mu^2] & , h = 0 \\ \frac{\alpha_1 [1 - \beta_1(\alpha_1 + \beta_1)]}{1 - (\alpha_1 + \beta_1)^2 - \alpha_1^2} (\alpha_1 + \beta_1^{h-1}) [\mu + \mu^2] & , h \geq 1 \end{cases}$$

3.

$$\rho_x = \text{corr}(X_t, X_{t-h}) = (\alpha_1 + \beta_1^{h-1}) \frac{\alpha_1 [1 - \beta_1(\alpha_1 + \beta_1)]}{1 - (\alpha_1 + \beta_1)^2 - \alpha_1^2} [\mu + \mu^2] \quad , h \geq 1$$

اما تباين (ϵ_t) فيكون بالصيغة الآتية:

$$\lambda_t = \alpha_0 + \alpha_1 X_{t-1} + \beta_1 \lambda_{t-1}$$

$$\begin{aligned} E(\lambda_t)^2 &= E[\alpha_0 + \alpha_1 X_{t-1} + \beta_1 \lambda_{t-1} + \alpha_1 \lambda_{t-1} - \alpha_1 \lambda_{t-1}]^2 \\ &= E[\{\alpha_0 + (\alpha_1 + \beta_1) \lambda_{t-1}\} + \alpha_1 (X_{t-1} - \lambda_{t-1})]^2 \\ &= E[\{\alpha_0 + (\alpha_1 + \beta_1) \lambda_{t-1}\} + \alpha_1 \epsilon_{t-1}]^2 \\ &= E[\{\alpha_0 + (\alpha_1 + \beta_1) \lambda_{t-1}\}^2 + \alpha_1^2 \epsilon_{t-1}^2 + 2\alpha_1 \epsilon_{t-1} \{\alpha_0 + (\alpha_1 + \beta_1) \lambda_{t-1}\}] \end{aligned}$$

وحيث خاصية الاستقرارية تؤدي الى ان $E(\lambda_t) = E(\lambda_{t-1})$

$$\begin{aligned} E(\lambda_t^2) &= \alpha_0^2 + (\alpha_1 + \beta_1) E(\lambda_t^2) + 2\alpha_0(\alpha_1 + \beta_1) E(\lambda_t) + \alpha_1^2 \mu - \alpha_1^2 E(\lambda_t^2) \\ &= \frac{\alpha_0^2 + 2\alpha_0(\alpha_1 + \beta_1)\mu + \alpha_1^2 \mu}{1 - (\alpha_1 + \beta_1)^2 + \alpha_1^2} \end{aligned}$$

وبالتعويض عن $\alpha_0 = \mu(1 - \alpha_1 - \beta_1)$ يكون:

$$E(\lambda_t^2) = \frac{\mu^2 [1 - (\alpha_1 + \beta_1)^2] + \alpha_1^2 \mu}{1 - (\alpha_1 + \beta_1)^2 + \alpha_1^2}$$

وبما أن $\text{Var}(\epsilon_t) = E\lambda_t + E\lambda_t^2$ فان:

$$\text{var}(\epsilon_t) = \frac{1 - (\alpha_1 + \beta_1)^2}{1 - (\alpha_1 - \beta_1)^2 + \alpha_1^2} (\mu - \mu^2)$$

تقدير المعلمات:

بالامكان تقدير معلمات الانموذج باستخدام الطرائق التقليدية (yull - walker)، المربعات الصغرى الشرطية، وطريقة الامكان الاعظم. وفي هذا البحث سيتم التركيز على الطريقة الاخيرة.

طريقة الامكان الاعظم: Maximum Likelihood Method
على فرض أن

$$\alpha = (\alpha_0, \alpha_1, \dots, \alpha_p)'$$

$$\beta = (\beta_0, \beta_1, \dots, \beta_q)'$$

$$\theta = (\alpha', \beta)'$$

وأن المشاهدات $(X_{t-p}, \dots, X_0, X_1, \dots, X_n)$ تخضع للتوزيع الهندسي المشروط وتتبع الانموذج بالمعادلة (2).

ولوصف اسلوب الامكان الاعظم سيتم اولاً حساب دالة لوغاريتم الامكان لدالة الكثافة الاحتمالية الشرطية للتوزيع الهندسي $L(\theta)$ وكما يأتي:

$$L(\theta) = \sum_{t=1}^n L_t(\theta) = \sum_{t=1}^n \log P_t + \sum_{t=1}^n X_t \log(1 - P_t)$$

وبدلالة λ_t يكون:

$$L(\theta) = \sum_{t=1}^n [X_t \log \lambda_t - (1 + X_t) \log(1 + \lambda_t)]$$

وبتعظيم الدالة $L(\theta)$ يتم الحصول على تقدير θ وذلك باستخدام الطرائق العددية. ولأجل الحصول على الاخطاء المعيارية التقريبية لتقدير الامكان الاعظم يتم ايجاد المشتقة الاولى للدالة $L(\theta)$ بالنسبة للمعلمة $\theta_i = (i = 0, 1, \dots, p + q)$ بالصيغة الآتية:

$$\frac{\partial L_t}{\partial \theta_i} = \left(\frac{X_t}{\lambda_t} + \frac{1 + X_t}{1 + \lambda_t} \right) \frac{\partial \lambda_t}{\partial \theta_i}$$

والمشتقات الثانية:

$$\frac{\partial^2 L_t}{\partial \theta_i \partial \theta_j} = \left(\frac{X_t}{\lambda_t} + \frac{1 + X_t}{1 + \lambda_t} \right) \frac{\partial^2 \lambda_t}{\partial \theta_i \partial \theta_j} - \left(\frac{X_t}{\lambda_t^2} + \frac{1 + X_t}{(1 + \lambda_t)^2} \right) \frac{\partial \lambda_t}{\partial \theta_i} \cdot \frac{\partial \lambda_t}{\partial \theta_j}$$

عندما $i, j = 0, 1, \dots, p + q$

ومن ثم حساب المشتقات الآتية:

1. للمتغير X_t نسبة الى α_0 :

$$\frac{\partial L_t}{\partial \alpha_0} = \left[\frac{X_t}{\lambda_t} - \frac{1 + X_t}{1 + \lambda_t} \right] \frac{\partial \lambda_t}{\partial \alpha_0}, \quad t = 1, 2, \dots, n$$

$$\frac{\partial \lambda_t}{\partial \alpha_0} = 1 + \sum_{k=1}^q \beta_k \frac{\partial \lambda_{t-k}}{\partial \alpha_0}, \quad t = 1, 2, \dots, n$$

2. للمتغير X_t نسبة الى α_i :

$$\frac{\partial L_t}{\partial \alpha_i} = \left[\frac{X_t}{\lambda_t} - \frac{1 + X_t}{1 + \lambda_t} \right] \frac{\partial \lambda_t}{\partial \alpha_i}, \quad t = 1, 2, \dots, n, \quad i = 1, 2, \dots, p$$

$$\frac{\partial \lambda_t}{\partial \alpha_i} = X_{t-i} + \sum_{k=1}^q \beta_k \frac{\partial \lambda_{t-k}}{\partial \alpha_i}, \quad t = 1, 2, \dots, n, \quad i = 1, 2, \dots, p$$

3. للمتغير X_t نسبة الى β_j :

$$\frac{\partial L_t}{\partial \beta_j} = \left[\frac{X_t}{\lambda_t} + \frac{1+X_t}{1+\lambda_t} \right] \frac{\partial \lambda_t}{\partial \beta_j}, \quad t = 1, 2, \dots, n, \quad i = 1, 2, \dots, q$$

$$\frac{\partial \lambda_t}{\partial \beta_j} = X_{t-j} + \sum_{k=1}^q \beta_k \frac{\partial \lambda_{t-k}}{\partial \beta_j}, \quad t = 1, 2, \dots, n, \quad i = 1, 2, \dots, q$$

ومن ثم استخدام احدي الطرائق التكرارية في حساب المشتقات وتقدير معلمات الانموذج قيد الدراسة، علاوة على ذلك فإن الاخطاء المعيارية التقريبية لـ (MLE) يمكن حسابها من خلال المصفوفة الآتية:

$$\frac{1}{n} (\hat{D}_n \hat{S}_n^{-1} \hat{D}_n')^{-1}$$

إذ أن:

$$\hat{S}_n = n^{-1} \sum_{t=1}^n \frac{\partial L_t}{\partial \theta} \cdot \frac{\partial L_t}{\partial \theta'}$$

$$\hat{D}_n = -n^{-1} \sum_{t=1}^n \frac{\partial^2 L_t}{\partial \theta \partial \theta'} \quad \dots (6)$$

5. الجانب التجريبي:

- خطوات تجربة المحاكاة

1. حساب قيمة (λ_i) حيث ان $i = -p + 1, \dots, -1, 0$

$$2. \text{ حساب قيمة } p_i = \frac{\lambda_i}{1 + \lambda_i}$$

3. توليد قيمة (x_i) عند كل قيمة من قيم p_i التي تم توليدها.

4. حساب قيم (λ_i) وقيم التوزيع الهندسي عندما $i = 1, 2, \dots, n$.

5. تقدير معلمات الانموذج $Geo - GARCH (p, q)$ بأفراض التوزيع الطبيعي والتوزيع الهندسي ايضاً.

6. تكرر التجربة (500) مرة وحساب المعدل ومتوسط مربعات الخطأ لكل معلمة افتراضية.

7. تم تقدير معلمات النماذج المختارة والتي تخضع للتوزيع الهندسي مرّة باستخدام التوزيع نفسه (الهندسي) وفق الصيغ المتبعة في الجانب النظري ومرّة اخرى باستخدام طريقة المربعات الصغرى في تقدير المعلمات في حالة التوزيع الطبيعي.

- نتائج التجربة

عند تصميم تجربة المحاكاة تم اختيار ثلاث نماذج $GARCH (1,0)$ ، $GARCH (2,0)$ و $GARCH (1,1)$ ، وثلاث مجاميع من القيم الافتراضية لمعلمات كل أنموذج وكما يأتي:

جدول (1) يمثل القيم الافتراضية لمعلمات النماذج المختارة

| النماذج | المجموعة الاولى | | | | المجموعة الثانية | | | | المجموعة الثالثة | | | |
|---------|-----------------|------------|------------|-----------|------------------|------------|------------|-----------|------------------|------------|------------|-----------|
| | α_0 | α_1 | α_2 | β_1 | α_0 | α_1 | α_2 | β_1 | α_0 | α_1 | α_2 | β_1 |

| | | | | | | | | | | | | |
|--------------------|----------|------------|-----|------------|----------|------------|-----|------------|----------|------------|-----|------------|
| <i>GARCH</i> (1,0) | 4 | 0.2 | - | - | 3 | 0.5 | - | - | 1 | 0.8 | - | - |
| <i>GARCH</i> (2,0) | 2 | 0.4 | 0.5 | - | 4 | 0.1 | 0.3 | - | 3 | 0.8 | 0.1 | - |
| <i>GARCH</i> (1,1) | 4 | 0.3 | - | 0.5 | 2 | 0.7 | - | 0.2 | 5 | 0.3 | - | 0.3 |

وبالتالي اجراء المقارنة بين مقدرات التوزيعين الطبيعي والهندسي باستخدام معيار متوسط مربعات الخطأ (MSE) وايضاً متوسط مقدر المعلمة. وبعد الحصول على النتائج تم عرضها في الجداول المرقمة (2، 3، 4).

جدول رقم (2) يبين نتائج المحاكاة للانموذج *GARCH* (1,0)

| n | par | Value of par | Normal Dist. | | Geometric Dist. | | Minimum MSE |
|-----|------------|--------------|--------------|--------------|-----------------|--------------|------------------|
| | | | Mean | MSE | Mean | MSE | |
| 50 | α_0 | 4 | 4.185 | 0.601 | 4.365 | 0.558 | Geometric |
| | α_1 | 0.2 | 0.164 | 0.021 | 0.192 | 0.018 | Geometric |
| 100 | α_0 | 4 | 4.099 | 0.255 | 4.434 | 0.497 | Normal |
| | α_1 | 0.2 | 0.177 | 0.012 | 0.190 | 0.011 | Geometric |
| 250 | α_0 | 4 | 4.034 | 0.115 | 4.497 | 0.412 | Normal |
| | α_1 | 0.2 | 0.192 | 0.004 | 0.192 | 0.005 | Geometric |
| 500 | α_0 | 4 | 4.011 | 0.054 | 4.4931 | 0.331 | Normal |
| | α_1 | 0.2 | 0.197 | 0.004 | 2.197 | 0.003 | Geometric |
| 50 | α_0 | 3 | 3.298 | 0.813 | 3.481 | 0.603 | Geometric |
| | α_1 | 0.5 | 0.446 | 0.021 | 0.460 | 0.037 | Normal |
| 100 | α_0 | 3 | 3.155 | 0.279 | 3.510 | 0.532 | Normal |
| | α_1 | 0.5 | 0.468 | 0.008 | 0.473 | 0.019 | Normal |
| 250 | α_0 | 3 | 3.065 | 0.122 | 3.508 | 0.409 | Normal |
| | α_1 | 0.5 | 0.488 | 0.003 | 0.490 | 0.008 | Normal |
| 500 | α_0 | 3 | 3.014 | 0.054 | 3.508 | 0.331 | Normal |
| | α_1 | 0.5 | 0.496 | 0.002 | 0.493 | 0.004 | Geometric |
| 50 | α_0 | 1 | 1.266 | 0.424 | 1.307 | 0.419 | Geometric |
| | α_1 | 0.8 | 0.727 | 0.018 | 0.707 | 0.048 | Normal |
| 100 | α_0 | 1 | 1.109 | 0.126 | 1.563 | 0.111 | Geometric |
| | α_1 | 0.8 | 0.764 | 0.007 | 0.745 | 0.004 | Geometric |
| 250 | α_0 | 1 | 1.063 | 0.047 | 1.500 | 0.296 | Normal |
| | α_1 | 0.8 | 0.783 | 0.002 | 0.786 | 0.001 | Geometric |
| 500 | α_0 | 1 | 1.0253 | 0.021 | 1.483 | 0.255 | Normal |
| | α_1 | 0.8 | 0.792 | 0.006 | 0.792 | 0.005 | Geometric |

جدول رقم (3) يبين نتائج المحاكاة للانموذج $GARCH(2,0)$

| n | par | Value of par | Normal Dist. | | Geometric Dist. | | Minimum MSE |
|-----|------------|--------------|--------------|---------|-----------------|-------|-------------|
| | | | Mean | MSE | Mean | MSE | |
| 50 | α_0 | 2 | 6.606 | 157.531 | 2.653 | 0.731 | Geometric |
| | α_1 | 0.4 | 0.271 | 0.058 | 0.381 | 0.046 | Geometric |
| | α_2 | 0.5 | 0.249 | 0.050 | 0.401 | 0.046 | Geometric |
| 100 | α_0 | 2 | 6.838 | 68.349 | 2.573 | 0.593 | Geometric |
| | α_1 | 0.4 | 0.307 | 0.040 | 0.401 | 0.023 | Geometric |
| | α_2 | 0.5 | 0.289 | 0.034 | 0.433 | 0.023 | Geometric |
| 250 | α_0 | 2 | 7.099 | 132.490 | 2.577 | 0.491 | Geometric |
| | α_1 | 0.4 | 0.319 | 0.029 | 0.394 | 0.009 | Geometric |
| | α_2 | 0.5 | 0.342 | 0.026 | 0.473 | 0.009 | Geometric |
| 500 | α_0 | 2 | 6.057 | 30.236 | 2.537 | 0.406 | Geometric |
| | α_1 | 0.4 | 0.341 | 0.023 | 0.401 | 0.004 | Geometric |
| | α_2 | 0.5 | 0.358 | 0.023 | 0.485 | 0.005 | Geometric |
| 50 | α_0 | 2 | 5.364 | 4.444 | 4.258 | 0.626 | Geometric |
| | α_1 | 0.4 | 0.058 | 0.027 | 0.132 | 0.029 | Normal |
| | α_2 | 0.5 | 0.178 | 0.031 | 0.255 | 0.030 | Geometric |
| 100 | α_0 | 2 | 5.006 | 2.183 | 4.283 | 0.534 | Geometric |
| | α_1 | 0.4 | 0.087 | 0.014 | 0.128 | 0.018 | Normal |
| | α_2 | 0.5 | 0.217 | 0.018 | 0.273 | 0.019 | Normal |
| 250 | α_0 | 2 | 4.754 | 1.155 | 4.386 | 0.388 | Geometric |
| | α_1 | 0.4 | 0.090 | 0.006 | 0.108 | 0.008 | Normal |
| | α_2 | 0.5 | 0.263 | 0.009 | 0.294 | 0.007 | Geometric |
| 500 | α_0 | 2 | 4.640 | 0.779 | 4.440 | 0.358 | Geometric |
| | α_1 | 0.4 | 0.098 | 0.004 | 0.106 | 0.003 | Geometric |
| | α_2 | 0.5 | 0.278 | 0.006 | 0.295 | 0.004 | Geometric |
| 50 | α_0 | 2 | 10.913 | 1374.32 | 3.557 | 0.746 | Geometric |
| | α_1 | 0.4 | 0.487 | 0.0148 | 0.694 | 0.012 | Geometric |
| | α_2 | 0.5 | 0.015 | 0.042 | 0.099 | 0.013 | Geometric |
| 100 | α_0 | 2 | 10.593 | 227.671 | 3.515 | 0.620 | Geometric |
| | α_1 | 0.4 | 0.533 | 0.107 | 0.752 | 0.006 | Geometric |
| | α_2 | 0.5 | 0.036 | 0.032 | 0.091 | 0.007 | Geometric |
| 250 | α_0 | 2 | 10.911 | 333.518 | 3.560 | 0.522 | Geometric |
| | α_1 | 0.4 | 0.558 | 0.087 | 0.776 | 0.003 | Geometric |
| | α_2 | 0.5 | 0.066 | 0.028 | 0.094 | 0.003 | Geometric |
| 500 | α_0 | 2 | 9.724 | 120.754 | 3.547 | 0.446 | Geometric |
| | α_1 | 0.4 | 0.578 | 0.077 | 0.793 | 0.001 | Geometric |

| | | | | | | |
|------------|-----|-------|-------|-------|-------|-----------|
| α_2 | 0.5 | 0.076 | 0.027 | 0.094 | 0.002 | Geometric |
|------------|-----|-------|-------|-------|-------|-----------|

جدول رقم (4) يبين نتائج المحاكاة للانموذج $GARCH(1,1)$

| n | par | Value of par | Normal Dist. | | Geometric Dist. | | Minimum MSE |
|-----|------------|--------------|--------------|---------|-----------------|-------|-------------|
| | | | Mean | MSE | Mean | MSE | |
| 50 | α_0 | 4 | 14.169 | 242.60 | 4.176 | 0.574 | Geometric |
| | α_1 | 0.3 | 0.239 | 0.044 | 0.221 | 0.013 | Geometric |
| | β_1 | 0.5 | -0.005 | 0.385 | 0.598 | 0.029 | Geometric |
| 100 | α_0 | 4 | 9.879 | 107.874 | 4.260 | 0.558 | Geometric |
| | α_1 | 0.3 | 0.257 | 0.024 | 0.234 | 0.037 | Normal |
| | β_1 | 0.5 | 0.222 | 0.227 | 0.582 | 0.023 | Geometric |
| 250 | α_0 | 4 | 5.990 | 19.737 | 4.444 | 0.583 | Geometric |
| | α_1 | 0.3 | 0.273 | 0.011 | 0.250 | 0.042 | Normal |
| | β_1 | 0.5 | 0.434 | 0.050 | 0.505 | 0.032 | Geometric |
| 500 | α_0 | 4 | 5.458 | 8.662 | 4.589 | 0.608 | Geometric |
| | α_1 | 0.3 | 0.283 | 0.007 | 0.266 | 0.045 | Normal |
| | β_1 | 0.5 | 0.453 | 0.029 | 0.437 | 0.039 | Normal |
| 50 | α_0 | 4 | 8.143 | 126.22 | 2.442 | 0.682 | Geometric |
| | α_1 | 0.3 | 0.463 | 0.110 | 0.568 | 0.046 | Geometric |
| | β_1 | 0.5 | -0.015 | 0.187 | 0.331 | 0.066 | Geometric |
| 100 | α_0 | 4 | 7.213 | 263.58 | 2.553 | 0.640 | Geometric |
| | α_1 | 0.3 | 0.503 | 0.085 | 0.607 | 0.027 | Geometric |
| | β_1 | 0.5 | 0.121 | 0.100 | 0.254 | 0.038 | Geometric |
| 250 | α_0 | 4 | 7.037 | 247.04 | 2.591 | 0.656 | Geometric |
| | α_1 | 0.3 | 0.528 | 0.063 | 0.626 | 0.010 | Geometric |
| | β_1 | 0.5 | 0.152 | 0.076 | 0.248 | 0.006 | Geometric |
| 500 | α_0 | 4 | 5.936 | 46.185 | 2.723 | 0.744 | Geometric |
| | α_1 | 0.3 | 0.546 | 0.0522 | 0.633 | 0.006 | Geometric |
| | β_1 | 0.5 | 0.1734 | 0.062 | 0.239 | 0.047 | Geometric |
| 50 | α_0 | 4 | 10.848 | 92.553 | 5.116 | 0.693 | Geometric |
| | α_1 | 0.3 | 0.230 | 0.051 | 0.186 | 0.027 | Geometric |
| | β_1 | 0.5 | -0.087 | 0.377 | 0.384 | 0.036 | Geometric |
| 100 | α_0 | 4 | 8.504 | 44.508 | 5.083 | 0.599 | Geometric |
| | α_1 | 0.3 | 0.262 | 0.026 | 0.248 | 0.010 | Geometric |
| | β_1 | 0.5 | 0.087 | 0.207 | 0.396 | 0.028 | Geometric |
| 250 | α_0 | 4 | 6.936 | 17.035 | 5.115 | 0.490 | Geometric |
| | α_1 | 0.3 | 0.280 | 0.011 | 0.266 | 0.005 | Geometric |
| | β_1 | 0.5 | 0.199 | 0.087 | 0.392 | 0.019 | Geometric |
| 500 | α_0 | 4 | 5.969 | 4.886 | 5.102 | 0.507 | Geometric |

| | | | | | | |
|------------|-----|-------|-------|-------|-------|-----------|
| α_1 | 0.3 | 0.284 | 0.007 | 0.287 | 0.003 | Geometric |
| β_1 | 0.5 | 0.266 | 0.033 | 0.376 | 0.017 | Geometric |

الاستنتاجات

1. من خلال الجدول رقم (2) الذي يوضح تجربة الانموذج $GARCH(1,0)$ يتبين ان ميل المقدرات للتوزيع الطبيعي كانت الاقرب من التوزيع الهندسي وبالاخص عند تقدير المعلمة (α_0) . كما لوحظ ان القيمة التقديرية للمعلمة (α_0) تميل للتوزيع الهندسي فقط عندما يكون حجم العينة صغير (50) ومن ثم يتلاشى الميل عند حجوم العينات الكبيرة. بينما كانت القيمة التقديرية للمعلمة (α_1) تميل الى التوزيع الهندسي عند حجوم العينات الكبيرة على الاغلب.

2. ويلاحظ في تجربة الانموذج $GARCH(2,0)$ والموضح نتائجها في الجدول رقم (3) ما يأتي:
 أ- ان متوسط المقدر للتوزيع الطبيعي (α_0) يبتعد كثيراً عن القيم الافتراضية ويلبها (α_1) ولمعظم حجوم العينة.

ب- ان قيم (MSE) للمقدر الهندسي (α_0) اقل من المقدر الطبيعي مما يعطي انطباع تأثر التقدير الطبيعي للمعلمة نتيجة اتباع المشاهدات للتوزيع الهندسي.
 ج- ان معدل المقدرات $(\alpha_0, \alpha_1, \alpha_2)$ في حالة التوزيع الهندسي كانت مقاربة للقيم الافتراضية، وينطبق التحليل نفسه بالنسبة لمتوسط مربعات الخطأ، عدا المقدر الطبيعي (α_1) فإنه يتفوق على المقدر الهندسي في بعض الحالات وبالاخص العينات الصغيرة، فيما لا تظهر هذه الحالة في العينات الكبيرة.

3. ويتبين من تجربة الانموذج $GARCH(1,1)$ في الجدول رقم (4) ما يأتي:
 أ- ان ميل المقدرات للتوزيع الطبيعي ضعيف جداً في حالة العينات الصغيرة وذلك اعتماداً على قيم (MSE) والمتوسط مقارنة مع القيم الافتراضية وبالاخص المعلمة (β_1) في حالة حجم العينة $(n = 50)$.

ب- ان ميل المقدرات كافة كانت على الاغلب للتوزيع الهندسي عدا مقدر المعلمة الافتراضية (α_1) فانه يتذبذب طبقاً لقيمة تلك المعلمة، كما في حالة القيم الافتراضية للمجموعة الاولى ولحجوم عينة (500، 250، 100).
 ج- اما المقدر الهندسي (β_1) فهناك حالة شاذة واحدة ضمن نفس المجموعة وعندما $(n = 500)$.

التوصيات

1. نوصي بدراسة الانموذج في حالة الرتب العليا تجريبياً.
2. نوصي باستخدام الانموذج المدروس تطبيقياً عند توفر مشاهدات تخضع للتوزيع الهندسي.
3. نوصي بدراسة الانموذج في حالة وجود قيم مفقودة.

المصادر

1. Davis, R. A, Dunsmuir, W.T.M. and Wang, Y. (2000). On autocorrelation in a poisson regression model. Biometrika, 87, pp(491-505).

2. Davis, R.A, Dunsmuir, W.T.M and Streett, S. B. (2003). Observation – driven models for poisson counts. *Biometrika*, 90, pp(777-790).
3. Davis, R. A, and Wn, R. (2009). A negative Binomial model for time series of counts. *Biometrika* 96, pp(735-49).
4. Ferland, R, Latour, A. and Oraichi, D. (2006). Integer – valued GARCH process. *Journal of Time Series Analysis*, 27, (923-942).
5. Fokianos, K. (2011). Count time series. *Time series analysis – methods and application, hand book of statistic, vol.30*, pp(315-347). Amsterdam.
6. Kedem, B. and Fakianos, K. (2002). *Regression method for time series analysis*, holden, new jersey: wiley.
7. Zeger, S. L. (1988). A regression model for time series of counts. *Biometrika*, 75, 621 – 629.
8. Zhu, F., Wang, D., Li, F., and Li, H. (2008). Emperical Likelihood inference for an integer-valued ARCH(p) model in Chinese. *Journal of Jilin university (science edition)*46, 1042 – 1048.
9. Zhu, F., Li, Q. and Wang, D. (2010). A mixture integer – valued ARCH model. *Journal of Statistical Planning and Inference*, 140, pp(2025 – 2036).
10. Zhu, F. (2011). Anegative binomial interger – valued GARCH model, *J. of Time series Analysis*, vol.32, no.1. pp(54-67).
11. Weib, C.H. (2009). Modelling time series of counts with over dispersion. *Statistical methods and application*, 18, pp(507-519).