

**تقدير نموذج ARMA الدوري (PARMA) مع نموذج
الدوري المختلط (M-PGARCH) بالتطبيق على
بيانات سعر صرف الجنية المصري مقابل الدولار الأمريكي**

أ.د. مرفت طلعت المحلاوى

أستاذ الاحصاء التطبيقي

كلية التجارة - جامعة دمياط

أ.م.د. آمال السيد مبارك

أستاذ الاحصاء التطبيقي المساعد

كلية التجارة - جامعة دمياط

أ.م.د. محمد ابراهيم محمد أحمد

أستاذ الاحصاء الرياضي المساعد

كلية التجارة - جامعة دمياط

طارق يحيى يوسف العربي

مدرس مساعد - قسم الاحصاء التطبيقي

كلية التجارة - جامعة دمياط

المستخلص:

يهدف البحث الى بناء نموذج الانحدار الذاتي - المتوسط المتحرك الدوري Periodic Autoregressive Moving Average(PARMA) الامثل لنمذجة التقلبات الموسمية في الوسط والانحراف المعياري وهيكل الارتباط، كما يهدف الى تقليل عدد معالم النموذج المقدر من خلال تقدير المعالم لنموذج PARMA باستخدام تحويلة فوريير المقطعة Discrete Fourier Transform . كذلك تهدف الدراسة الى بناء نموذج GARCH الدوري المختلط Mixture periodic (M-PGARCH) Generalized Autoregressive Conditionally Heteroscedastic لنمذجة التقلبات الدورية من أجل التقاط النمط الدوري في التباين والتغيرات المفاجئة للنظام والتفرطح والانحراف الزائد بالإضافة الى تحسين نموذج PGARCH عن طريق نمذجة k من عمليات التقلب الدوري على التوارى وذلك باستخدام نموذج M-PGARCH. كما يهدف البحث الى تحسين وصف البيانات المالية عن طريق استخدام نموذج M-PGARCH مع نموذج PARMA لالتقاط التقلبات الخطية وغير الخطية وفحص التقلبات الدورية للتباين المشروط وغير المشروط. وقد تم استخدام البيانات التاريخية الشهرية لسعر صرف الجنية المصري مقابل الدولار الامريكي لما لبيانات اسعار الصرف من اهمية كبيرة على الاقتصاد بشكل عام وكذلك لطبيعة تقلباتها الدورية والتي تمثل مشكلة يسمى البحث لحلها. وأشارت النتائج الى أن نموذج M-PGARCH قادر على التقاط التغيرات المفاجئة في التباين بشكل جيد وبشكل أكثر مرونة وأكثر اختزالاً parsimonious. وبالمقارنة بين استخدام نموذج PARMA فقط لوصف البيانات وبين استخدام نموذج M-PGARCH مع نموذج PARMA نلاحظ أن نموذج PARMA كان يتنفسه الوصف الدقيق للتغيرات الدورية في الباقي والتي لم تكن ساكنة، خاصة مع البيانات المالية. ان استخدام نموذج M-PGARCH مع نموذج PARMA يمنه ميزة اضافية وهي القدرة على التقاط تلك التغيرات والتقلبات الدورية في الباقي وهذا ما استطاع نموذج M-PGARCH تطبيقه بشكل جيد وكذلك وصف الخليط الدوري لتلك التقلبات بشكل دقيق مما يسمح لنا بفهم أعمق لطبيعة البيانات المالية المستهدفة.

الكلمات المفتاحية:

الانحدار الذاتي -المتوسط المتحرك الدوري، PARMA، تحويلة فوريير المقطعة، خوارزمية تعظيم التقدير، الانحدار الذاتي الدوري المعمد المشروط بعدم تجانس البيانات، PGARCH، خليط GARCH الدوري، M-PGARCH

**Estimation of the periodic ARMA model (PARMA) with the mixture
periodic GARCH model (M-PGARCH) using data of the Egyptian
pound exchange rate against the US dollar**

Amaal El Sayed
Mubarak
Associate Professor of Applied Statistics
Faculty of Commerce - Damietta University

Mervat Talaat El Mahalawy
Professor of Applied Statistics
Faculty of Commerce - Damietta University

Tarek Yehia Yousef Elorban
Assistant Lecturer Faculty of Commerce - Damietta University

Mohamed Ibrahim
Mohamed Ahmed
Associate Professor of Mathematical Statistics
Faculty of Commerce - Damietta University

Abstract:

The research aims to build the optimal Periodic Autoregressive-Moving Average (PARMA) model to model seasonal variations in the mean, standard deviation, correlation structure, model order determination, and parameter estimation of the PARMA model using the Discrete Fourier Transform to reduce the number of parameters in the estimated model. As well as developing the Mixture Periodic GARCH (M-PGARCH) model to capture the periodic variance, sudden changes in the system, kurtosis, and skew, and improving the PGARCH model by modelling k of periodic fluctuations in parallel using the M-PGARCH model, and improving the description of financial data using the PARMA model with the M-PGARCH model to capture linear and nonlinear fluctuations and examine the periodic fluctuations of conditions, Monthly historical data of the exchange rate of the Egyptian pound against the US dollar has been used because of the great importance of exchange rate data on the economy in general as well as the periodic fluctuations of the data, which represent a problem that the search seeks to solve. The results indicated that the M-PGARCH model can capture the phenomenon of sudden changes in variance very well, more flexibly and more parsimoniously, as there are a lot of estimated parameters whose value goes to zero. Comparing the use of the PARMA model only to describe the data with the use of the PARMA model with the M-PGARCH model, we note that the PARMA model needed an accurate description of the periodic changes in the residuals that were not well stationary, especially with the financial data, and hence the use of the M-PGARCH model with the PARMA model gives it the extra advantage of being able to capture those changes and periodic fluctuations in the residuals, and this is what the M-PGARCH model was able to apply well as well as describe the periodic mixture of those fluctuations accurately, which allows us a deeper understanding of the type of the target financial statements.

Keywords: PARMA, Periodic Autoregressive Moving Average, PGARCH, Periodic Generalized Autoregressive Conditionally Heteroscedastic, Expectation Maximization Algorithm, EM Algorithm, Discrete Fourier Transform, DFT, M-PGARCH, Mixture periodic Generalized Autoregressive Conditionally Heteroscedastic.

١- المقدمة

تعد تحركات أسعار الصرف مقابل الدولار الأمريكي عاملاً مهماً في تشكيل التوقعات في أسواق المال والاقتصاد حيث يتم تعزيز حصة كبيرة من الائتمان والتجارة والديون بالدولار. عادة ما ترتبط التقلبات المفاجئة في أسعار الصرف في الأسواق الناشئة بتدفقات رأس المال الخارجية، وتشديد شروط التمويل، وزيادة عدم الاستقرار المالي. وقد ساهمت السلسلة الزمنية بدور كبير في نمذجة الكثير من الظواهر الاقتصادية والمالية. حيث يوجد في الواقع العملي الكثير من نماذج السلسلة الزمنية التي يمكنها تحليل ذلك النوع من البيانات، مثل نماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية (ARIMA) ونماذج الانحدار الذاتي والمت渥سطات المتحركة التكاملية الموسمية (SARIMA) كما في (Hamilton 1994) ونماذج السلسلة الزمنية الدورية PARMA كما في (Franses and Paap 2004). وتسمح نماذج PARMA لمعامل ARMA بالتغيير وذلك بتغيير الموسم، كما أن نماذج PARMA تصنف بوضوح التقلبات الموسمية في الوسط والانحراف المعياري وكذلك في هيكل الارتباط الذاتي، وبناء على ذلك فإنها تكون مفيدة في توليد نماذج أكثر مصداقية. وظهرت نماذج PARMA في (Gladyshev 1961) and Jones and (1967). كما في كتاب Franses and Paap (2004) نظرة عامة على تلك العائلة من النماذج بشكل جيد، وقد تم تطوير تطبيقات على بيانات تدفقات الأنهار في كتاب Hipel and McLeod (1994). كما تناولت الكثير من التطبيقات العملية نموذج PARMA بالدراسة كما في (Anderson et al. 2007) and Bowers et al. (2012) أو البيانات المالية أو ما شابهها من بيانات حيث تظهر هذه البيانات عادة تغيرات موسمية في المتوسط والانحراف المعياري وهيكل الارتباط الذاتي ، وهذا ما يجعل نماذج PARMA هي الأنسب للتعامل من تلك البيانات. وكما هو معلوم في التحليل القياسي التقليدي أن تباين حد الخطأ العشوائي يفترض أن يكون ثابتاً عبر الزمن وهو ما يعرف بفرضية ثبات التباين (homoscedasticity assumption) ، ولكن في البيانات المالية والاقتصادية غالباً لا يتحقق هذا الشرط حيث تظهر التقلبات وكذلك اختلافات التباين خلال فترات السلسلة المختلفة. وتعتبر فترات التقلب في العرف المالي بفترات المخاطرة أو عدم التأكد، ومعروف في التحليل المالي أن فترات المخاطرة (وهي التقلب الكبير أو التباين الكبير) تتركز في فترات معينة ويعقبها فترات أقل تقلباً (أقل تباين) وهي كذلك تتركز في فترات معينة، وهذه الأنماط تعرف لدى المحللين الماليين بفترات الرواج (calm) وفترات الركود (wild) وعلى ذلك فإن تحقق فرضية ثبات التباين في الغالب تكون

غير متحققة. وبالتالي فإنه من الأفضل في هذه الحالة فحص نمط هذا التقلب في تباين الباقي لمعرفة هل هذا التباين يعتمد على سلوكه التاريخي أو الزمني، أي فحص التباين المشروط (conditional variance) لباقي النموذج تحت الدراسة.

وكان أول من قدم هذه الفكرة Engl (1982) في بحثه حول تقدير تباين التضخم في المملكة المتحدة وقد أدى هذا النوع من النمذجة إلى تحول كبير وظهرت نماذج مختلفة في هذا الإطار منها نموذج (Generalized Autoregressive Conditionally Heteroscedastic GARCH). وقد تم إقتراح العديد من الامتدادات لنمدجه التغيرات في التباين أو التقلب بشكل عام (أو تباين باقي السلسلة بشكل خاص)، من أجل وصف سلسلة البيانات المالية بشكل حقيقي ووصف التغيرات المفاجئة في النظام وكذلك وصف التفريط الزائد وعدم التمايز ودورية التباين العشوائي الشرطي، إلا أن معظم الصيغ المقترنة تعامل مع معالم التقلب الثابتة وبالتالي لا يمكنها تفسير سلوك السلسلة الزمنية التي تعرض تقلب له ارتباط دوري، حيث لا يمكن حسابه باستخدام نماذج الخلط ذات المعالم الثابتة (غير المرنة)، كما أن الكثير من الدراسات أظهرت أن معظم عوائد الأصول وأسعار الصرف تُظهر أنماط موسمية سواء كانت في شكل يومي أو أسبوعي أو شهري أو سنوي أو حتى تأثيرات العطلات الرسمية. وقد أدت هذه الملاحظات إلى تطوير بعض نماذج الخلط التي تتضمن خاصية الدورية، ومنها Bentarzi and Hamdi (2008a,b) حيث تم عرض نموذج "MPARCH" (Mixture Periodic ARCH) والذي يضيف الدورية إلى معالم النموذج حتى يمكن استيعاب الأنماط الديناميكية للتقلبات المشروطة بشكل كامل، وذلك عن طريق خلط عدد k من مكونات PARCH، وهذا يعني أن تكون رتب مكونات الخلط كبيرة جداً ويترتب عليه وقت أكبر لتقدير معالم النموذج. ولذلك فقد قدم Hamdi and Souam (2017) فئة أخرى من نماذج السلسلات الزمنية غير الخطية وهي أكثر مرنة ومقنته أكثر بالمقارنة بنموذج MPARCH إلا وهي نماذج M-PGARCH.

ولقد تعددت الدراسات التي توظف السلسلات الزمنية الدورية لنمدجة مجموعات مختلفة من البيانات في مجالات الاقتصاد والهندسة الكهربائية والبيانات المالية والمناخ والهيبرولوجيا وغيرها ومن الدراسات الهامة في هذا المجال، Lund and Basawa (2000), Lund et al (2001) and Basawa and Lund (2001), Ursue and Turkman (2012), Troutman (1979) و Pagano (1978) حيث قاما بفحص الخصائص الأساسية لعمليات الاتحاد الذاتي الدوري وحد المتغير وأساليب الاستدلال الإحصائي لتقدير المعالم والتقويم ولنم (1994)

وصفاً كاملاً للمراحل الأساسية لبناء نماذج PAR وحيدة المتغير المتمثلة في مرحلة التحديد، التقدير ، الفحص و التشخيص. كما تناول (Akgün 2003) تحديد التغير الدوري عن طريق تحديد رتب نماذج PARMA وحيدة المتغير حيث تم تحديد الرتب المختلفة لنماذج PARMA بعميم الطرق المعروفة في أسلوب بوكس - جينكتز Box-Jenkins، وقد أخذ في الاعتبار تحديد كلًّا من نماذج PARMA ونماذج PAR فقط وقد يستخدم لتحديد النموذج الرسم البياني لدالة الارتباط الذاتي الدوري (PeACF) ودالة الارتباط LSE الذاتي الدوري الجزئي (PePACF). ولتقدير النموذج إستخدمت طريقة المربيعات الصغرى الشرطية والتي طبقت على نماذج PAR حيث أن التقدير يكون معقد جداً وصعب ونتائج تكون غير مرضية عند إضافة عنصر المتوسط المتحرك MA إلى النموذج. كما قدم (Tesfaye 2005) دراسة استعرضت خطوات تحديد نموذج PARMA لتمثيل بيانات التدفق النهري. بينما تناول (Lund et al. 2006) دراسة أساليب "Parsimonious PARMA" تقدير نماذج السلسلة الزمنية الدورية ذات أقل عدد ممكن من المعالم models وذلك بالنسبة لبيانات درجات الحرارة اليومية في بعض الولايات الأمريكية. ونظرًا لما تواجهه نماذج PARMA من صعوبة كبيرة عند تقدير المعالم لبيانات عالية الدقة مثل البيانات الأسبوعية أو اليومية نظرًا للعدد الكبير للمعلم، و للحصول على نماذج مختصرة المعالم "Parsimonious" اقترح Tesfaye et al. (2010) استخدام تحويلة فوريير المقاطع (DFT) discrete Fourier transform لتمثيل معالم نموذج PARMA وأوضحت النتائج ان النموذج المقترن خفض المعاملات من 24 الى 8 مما يوفر نموذج أكثر تخفيف و أكثر دقة. كما أوضح (Francq et al. 2011) بعض من الخصائص التقريبية لمقدرات المربيعات الصغرى المرجحة "Weighted Least Squares" (WLS) لنماذج PARMA مع أخطاء غير متراقبة ولكنها غير مستقلة حيث أوضحت الدراسة أن مقدرات WLS لنماذج PARMA تكون متسلقة بقوة وتقربياً طبيعية. وامتدت الدراسة الى ما ذكره (Basawa and Lund 2001) لتقدير المربيعات الصغرى لنماذج PARMA مع أخطاء مستقلة ويتبين أن مصفوفة التغایر التقريبية لمقدرات WLS التي تم الحصول عليها في ظل أخطاء غير مستقلة تختلف تماماً عن تلك التي تم الحصول عليها في ظل أخطاء مستقلة. كما قدمت الدراسة أمثلة للمحاكاة والتي أوضحت الأهمية العملية للنتائج كما تم التطبيق على بيانات مالية.

ولزيادة القدرة على تحديد رتب نموذج PARMA المناسب بشكل أكثر دقة اقترح (Ursu and Turkman 2012) استخدام الخوارزميات الجينية بالاعتماد على معيار بيز للمعلومات BIC والذي يستخدم لتحديد رتب نموذج الانحدار الذاتي الدوري PAR. وتم مقارنة النموذج المقترن والمحدد باستخدام الخوارزميات الجينية GA مع نموذج PAR المحدد بالطريقة التقليدية والذي اقترحه

وأثبتت الدراسة أن استخدام الخوارزمية الجينية GA يزيد من دقة النموذج. كما تم توضيح إجراءات التبادل لنماذج PARMA عن طريق Anderson et al. (2013) حيث تم باستخدام خوارزمية الابتكار (innovations algorithm) جنباً إلى جنب مع فكرة Ansley (1979) تقديم صيغة تباين الخطأ التقريري بحيث يمكن حساب فترات تبادل جاوس (Gaussian prediction intervals). كما اهتمت دراسة Dudek et al. (2016) بتقدير معالم PARMA وكذلك تمثيل معالم PARMA الدورية باستخدام سلسلة فوريير والتي تهدف إلى تحقيق تخفيض كبير في عدد المعالم المقدرة باستخدام تمثيل فوريير وذلك عن طريق إعطاء العديد من معالم فوريير قيمه صفرية. كما استخدم Sarnaglia et al. (2021) مقدر M-regression لبناء مقدرات طيفية لنماذج السلاسل الزمنية كما تم توسيع هذا النهج عندما تتبع البيانات عمليات PARMA. حيث قدمت الدراسة مقداراً للمعلم بناء على مقدر Whittle الكلاسيكي.

وكانت دراسة Bollerslev and Ghysels (1996) قد اقترحت فئة جديدة من النماذج التي تتميز بعدم التجانس المشروط الدوري، والتي صُممـت لتوصيف التغير الموسمـي المتكرر للعزم الثاني. وترتبط هذه الفئة الجديدة من نماذج P-ARCH، بشكل مباشر بفئة نماذج (ARMA) للوسط. حيث أن العلاقة الضمنـية بين هيـاكل نموذج ARCH الدوري (P-ARCH) وعمليـات GARCH ذات الثبات الموسمـي الضعـيف تؤكـد كـيف قد يـنـتج عن إهمـال الدوريـة في عملية (PARCH) خـسـارة في كـفاءـة التـبـادـلـ. وقـامت الـدرـاسـةـ بـتـحـديـدـ أـهـمـيـةـ وـحـجمـ هـذـهـ خـسـارـةـ لـمـجـمـوعـةـ مـتـوـعـةـ مـنـ دـوـالـ خـسـارـةـ مـنـ كـفـاءـةـ التـبـادـلـ. شـاؤـ (Shao 2006) نـمـاذـجـ خـلـطـ الـانـحدـارـ الذـاتـيـ الدـورـيـ خـلـالـ استـخـدـامـ أـسـالـيـبـ مـحاـكـاةـ مـونـتـيـ كـارـلوـ. كـماـ قـدـمـ (Expectation Maximization) "Expectation Maximization" لـمـلـائـمـةـ نـمـاذـجـ السـلاـسـلـ الزـمـنـيـةـ فـقـدـ عـرـضـتـ الـدرـاسـةـ شـرـوطـ السـكـونـ لمـثـلـ تلكـ السـلاـسـلـ كماـ نـاقـشـتـ تـطـبـيقـ خـواـرـزمـيـةـ (MPARCH) Bentarzi and Hamdi (2008) هو عمل امتداد لنـمـوذـجـ ARCHـ وذلكـ باـسـتـخـدـامـ نـمـوذـجـ Mixture Periodically Correlated ARCH (MPARCH)ـ. كـماـ كانـ الـهـدـفـ الرـئـيـسيـ وـرـاءـ هـذـاـ الـامـتـدـادـ هوـ جـعـلـ النـمـوذـجـ مـتـسـقاـ عـنـ التـفـرـطـحـ العـالـيـ وـالـقـيـمـ وـالـأـحـدـاثـ الـمـتـطـرـفةـ، وـفـيـ نـفـسـ الـوقـتـ قادرـ علىـ التـقـاطـ خـاصـيـةـ الدـورـيـةـ الـتـيـ ظـهـرـ فـيـ هيـكـلـ الـارـتـباطـ الذـاتـيـ، كـماـ قـمـتـ الـدرـاسـةـ مـلـائـمـةـ نـمـاذـجـ MPARCHـ علىـ مـجـمـوعـةـ بـيـانـاتـ حـقـيقـيـةـ وـقـدـ دـعـمـتـ الـدرـاسـةـ التـطـبـيقـيـةـ النـمـوذـجـ المـقـدمـ. بينما اقتـرـحـ Hamdi and Souam (2013) امـتـدـادـ لـنـمـوذـجـ دـمـجـ ARCHـ (MPARCH)ـ ليـصـبـحـ لـنـمـوذـجـ دـمـجـ GARCHـ (MPGARCH)ـ، كـماـ عـرـضـ هـذـاـ الـبـحـثـ بـعـضـ الـخـصـائـصـ الـاحـتمـالـيـةـ لـهـذـهـ فـئـةـ

من النماذج. و لقد اقترحت الدراسة طريقة تقدير تعتمد على خوارزمية تعظيم التوقع.(EM) . وقد أوضحت نتائج التحليل التجاري أن نموذج الخلط المقترن يعطي أفضل أداء بين النماذج المنافسة. وقد قدم (Hamdi and Souam(2017) فئة أخرى من نماذج السلسل الزمنية غير الخطية وهي أكثر مرونة ومقدنه أكثر بالمقارنة بنموذج MPARCH التي قدمت عام 2013 ألا وهي نماذج M-PGARCH . مما يسمح بتصنيف التغير الدوري وقد أوضحت الدراسة أن هذه النماذج تتسم بمرونة و كفاءة أكثر مقارنة مع نماذج MPARCH ذات الرتب الاعلى. وأشارت النتائج التجريبية إلى أن نموذج M-PGARCH يمكن أن يسجل بشكل جيد ظاهرة التغيرات الحادة في التقلبات.

ما سبق نجد أن استخدام نماذج السلسل الزمنية المقترنة يمكن أن يساعد في رفع كفاءة التقدير و جعل النموذج أكثر دقة و أقل في عدد المعالم مما يمكننا من مواجهة صعوبات مرحلة تحديد الرتبة و تقدير المعالم نظراً للعدد الكبير لمعامل نموذج PARMA . وقد تم تنظيم الأقسام التالية من البحث على النحو التالي،

القسم الثاني يتناول تحديد الرتب وتقدير نموذج PARMA أما القسم الثالث فستعرض فيه تمثيل معالم PARMA باستخدام تحويلة فورية المقطعة DFT بينما يتناول القسم الرابع تقدير نموذج GARCH الدوري المختلط لباقي نموذج PARMA المقدر وأخيراً يعرض القسم الخامس التطبيق.

2- تحديد الرتب وتقدير نموذج PARMA

يمكن تعريف نماذج PARMA من وجهتي نظر مختلفتين:

من وجهة النظر الأولى تُعتبر نماذج PARMA هي امتدادات دورية لنماذج ARMA غير الموسمية، بمعنى آخر يكون نموذج PARMA من نموذج ARMA منفصل لكل موسم. وجهة النظر الثانية لتعريف نماذج PARMA هو اعتبارها نوع خاص من نماذج ARMA متعددة المتغيرات. حيث أوصى (Franses and Paap (2004) بأن التمثيل متعدد المتغيرات يكون مفيد للغاية لتحليل خصائص الاستقرار للنموذج و انه يمكن كتابة نماذج PARMA في صيغة نماذج ARMA متعددة.

2-1- التمثيل وحيد المتغير لنموذج PARMA

Univariate Representation of PARMA model

يتكون نموذج PARMA من نماذج ARMA متصلة لكل موسم، بافتراض أن السلسلة الزمنية وحيدة المتغير هي y_t والتي شاهد خلال N من السنوات، حيث أن $t = 1, 2, \dots, NS$ ، ϵ_t المتغير هو ϵ_t والتي تتألف من الانحدار الذاتي -المتوسطات المتحركة الدورية ذو الرتبة P, q, S ، ويمكن كتابة نموذج الانحدار الذاتي -المتوسطات المتحركة الدورية ذو الرتبة P, q, S كما يلى :

$$y_t = \mu_v + \phi_1(v)y_{t-1} + \dots + \phi_{p(v)}(v)y_{t-p(v)} + \epsilon_t + \theta_1(v)\epsilon_{t-1} + \dots + \theta_{q(v)}(v)\epsilon_{t-q(v)} \quad (1),$$

أو يمكن عرض النموذج بالصورة التالية :

$$\phi_k(v)[L] y_t = \mu_v + \theta_k(v)[L]\epsilon_t \quad (2)$$

حيث أن

$$\phi_k(v)[L] = 1 - \phi_1(v)[L] - \dots - \phi_{p(v)}(v)[L^{p(v)}],$$

$$\theta_h(v)[L] = 1 + \theta_1(v)[L] + \dots + \theta_{q(v)}(v)[L^{q(v)}]$$

وتعزى μ_v بانها معلمة ثقابوت وتتغير موسمياً. كما تمثل $[\phi_1(v), \dots, \phi_{p(v)}(v)]$ و $[\theta_1(v), \dots, \theta_{q(v)}(v)]$ معالم الانحدار الذاتي والمتوسطات المتحركة ذات الرتبة k و h على الترتيب، حيث أن $h = 1, 2, \dots, q(v)$ ، $k = 1, 2, \dots, p(v)$ ، والتي يمكن أن تختلف خلال الموسم v ، حيث أن $v = 1, 2, \dots, S$. كما أن السلسلة y_t تعتبر عملية عشوائية بحثة دورية periodic white noise (PWN) $\sim PWN(0, \sigma_v^2)$. ويمكن لرتب الانحدار الذاتي $p(v)$ والمتوسط المتحرك $q(v)$ في النموذج (1) أن تختلف باختلاف الموسم v ومع ذلك فإنه من الناحية النظرية والرياضية يمكن التعويض عن رتب الانحدار الذاتي $p(v)$ والمتوسط المتحرك $q(v)$ بعدد ثابت خلال الموسم v ولن يكون هناك أي خلل في النموذج بشكل عام وذلك من خلال اعتبار أن :

$$p = \max_{v=1, \dots, S} p(v)$$

$$q = \max_{v=1, \dots, S} q(v)$$

وبالتالي فإنه قد نجد في بعض المواسم أن معالم AR و MA يمكن أن تأخذ قيمة صفرية، Lund and (1990) حيث $\phi_K(v) = 0$ ، $p(v) < k \leq p$ حيث $\theta_K(v) = 0$

.(Basawa, 2000

ويمكن القول بأن السلسلة الزمنية $\{Y_t\}$ ذات ارتباط دوري إذا كان وسطها الحسابي μ_t دالة تغافيرها الذاتي $\gamma(t_1, t_2)$ لهم قيم منتهية خلال الفترة u والتي تكون عدد صحيح موجب، ويمكن القول أن $\gamma(t_1, t_2)$ معالم دورية خلال الفترة الدورية u إذا كان:

$$\mu_t = \mu_{t+u}, \forall t, t+u \in \mathbb{Z}$$

ومن الآن فصاعد سنتفترض أن $\mu_t = 0$ لأى سلسلة دورية، دون أن فقد خاصية التعميم. وبافتراض أن $\{Y_t, t \in \mathbb{N}\}$ هي سلسلة زمنية ذات ارتباط دوري فإنه يمكن التعبير عن الدليل الزمني t في الشكل التالي $n = nS + v$ ، حيث أن n تمثل السنة وتأخذ القيم $0, 1, \dots, n-1$ و v تمثل عدد الموسماً وتأخذ القيم التالية $S = 1, \dots, v$ ، بمعنى آخر يمكن القول أنه لأى سلسلة زمنية Y_t يتم استبدال معلمة مؤشر الزمن $t = nS + v$ ، حيث أن كتابة الدليل الزمني بالشكل التالي $nS + v$ يعطي فهماً عملياً أكثر كما يلقى الضوء على دورية السلسلة، حيث يعطى تفصيلاً أوضح للموسماً والفترات الدورية، وبافتراض أن $\{Y_{nS+v}\}$ هي سلسلة زمنية دورية تكتب كما يلى:

$$Y_{nS+v} = \sum_{k=1}^{p(v)} \phi_k(v) Y_{nS+v-k} + \varepsilon_{nS+v} + \sum_{k=1}^{q(v)} \theta_k(v) \varepsilon_{nS+v-k} \quad (3)$$

كما يمكن كتابة المعادلة (3) بالشكل التالي:

$$Y_{nS+v} = \phi_1(v) Y_{nS+v-1} + \dots + \phi_{p(v)}(v) Y_{nS+v-p(v)} + \varepsilon_{nS+v} + \theta_1(v) \varepsilon_{nS+v-1} + \dots + \theta_{p(v)}(v) \varepsilon_{nS+v-p(v)}$$

ويكون النموذج الناتج في المعادلة السابقة مفيد في نمذجة بيانات السلسلة الزمنية المختلفة المستمدة من علم الاقتصاد والمناخ والهيدرولوجيا والهندسة الكهربائية وغيرها. حيث أن $S = 1, \dots, v$ ، أما المتغير العشوائي Y_{nS+v} يمثل قيم المتغير خلال الموسم v في السنة n ($n \in \mathbb{Z}$). كما تمثل $(\phi_k(v))$ و $(\theta_k(v))$ معلم نموذج AR ونموذج MA على التوالي خلال الموسم v . بينما يعتبر حد الخطأ في النموذج (3) عملية عشوائية بحثة دورية periodic white noise حيث أن تباين الخطأ يكون أكبر من الصفر

$$\text{var}(\varepsilon_{nS+v}) = \sigma_\varepsilon^2(v) > 0, E(\varepsilon_{nS+v}) = 0$$

يمكن القول أن نموذج PARMA للسلسلة الزمنية Y_{nS+v} المعرفة في المعادلة (3) نموذج سيبي أو دالة سيبي لـ ε_{nS+v} إذا كان هناك موسم $v = 1, 2, \dots, S$ ، المتسلسلات $\{\psi_i(v)\}_{i=1}^\infty$ كما يلى:

$$Y_{nS+v} = \sum_{i=0}^{\infty} \psi_i(v) \varepsilon_{nS+v-i} \quad (4)$$

حيث $(\psi_i(v))$ تشير على أنها الأوزان الموسمية والتي تحقق الشرط:

$$\max_{1 \leq v \leq S} \sum_{i=1}^{\infty} |\psi_i(v)| < \infty, \quad \forall v \text{ لكل موسم}$$

كما يمكن القول أن نموذج PARMA للسلسلة الزمنية Y_{ns+v} المعرفة في المعادلة (4) قابلة للانعكاس

لكل موسم v اذا كانت السلسلة $\pi_i(v)$ invertible

$$\pi_i(v) = \pi_0(v) + \pi_1(v)[B] + \pi_2(v)[B^2] + \dots$$

حيث يكون

$$\max_{1 \leq v \leq S} \sum_{i=1}^{\infty} |\pi_i(v)| < \infty , \quad \text{لكل موسم } v \quad \pi_0(v) = 1$$

و يكون

$$\varepsilon_{ns+v} = \sum_{i=0}^{\infty} \pi_i(v) Y_{ns+v-i}$$

2- التمثيل متعدد المتغيرات لنموذج PARMA

Vector Representation of PARMA Model

يافتراض أن Y_t هي عملية ARMA ذات S - فترة دورية فإنه يمكن كتابة المعادلة (1) في شكل متوجه ذو S - متغير (S-variate) ، حيث تمثل S عدد المواسم في السنة.

$$\Phi_0 Y_n - \sum_{k=1}^P \Phi_k Y_{n-k} = \Theta_0 \epsilon_n + \sum_{i=1}^Q \Theta_i \epsilon_{n-i}$$

$$\Phi_0 Y_n - \Phi_1 Y_{n-1} - \dots - \Phi_P Y_{n-P} = \Theta_0 \epsilon_n - \Theta_1 \epsilon_{n-1} - \dots - \Theta_P \epsilon_{n-Q}$$

أو

$$\Phi(L) Y_n = \Theta(L) \epsilon_n \quad (5)$$

حيث

$$\Phi(L) = \Phi_0 - \Phi_1 L - \dots - \Phi_P L^P$$

$$\Theta(L) = \Theta_0 - \Theta_1 L - \dots - \Theta_Q L^Q$$

كما أن

$$\epsilon_n = (\varepsilon_{ns+1}, \varepsilon_{ns+2}, \dots, \varepsilon_{ns+S})^T \quad \text{و} \quad Y_n = (Y_{ns+1}, Y_{ns+2}, \dots, Y_{ns+S})^T$$

عشواقي $(S \times 1)$. حيث أن، $n = 0, 1, \dots, N-1$ ، $p = [\frac{(p-1)}{S} + 1]$ ، $Q = [\frac{(q-1)}{S} + 1]$

$.q = \max_{v=1, \dots, S} q(v)$ ، كما أن، $p = \max_{v=1, \dots, S} p(v)$

حيث أن Φ_0 هي مصفوفة $(S \times S)$ متماثلة سفلية ذات قطر عناصره (الوحدة) الواحد الصحيح كما يلى:

$$\Phi_0 = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 & 0 \\ -\phi_1(2) & 1 & 0 & \dots & 0 & 0 \\ \vdots & & \ddots & & & \vdots \\ -\phi_{s-2}(s-1) & -\phi_{s-3}(s-1) & -\phi_1(s-1) & 1 & 0 \\ -\phi_{s-1}(s) & -\phi_{s-2}(s) & -\phi_2(s) & -\phi_1(s) & 1 \end{bmatrix} \quad (6)$$

كما يلى: $(S \times S)$ هي مصفوفة Φ_k $k = 1, 2, \dots, P$

$$\Phi_k = \begin{bmatrix} \phi_{ks}(1) & \phi_{ks-1}(1) & \dots & \phi_{kS-(s-2)}(1) & \phi_{kS-(s-1)}(1) \\ \phi_{ks+1}(2) & \phi_{ks}(2) & \dots & \phi_{kS-(s-3)}(2) & \phi_{kS-(s-2)}(2) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \phi_{kS+(s-2)}(S-1) & \phi_{kS+(s-3)}(S-1) & \dots & \phi_{ks}(s-1) & \phi_{kS-[s-(s-1)]}(S-1) \\ \phi_{kS+(s-1)}(S) & \phi_{kS+(s-2)}(S) & \dots & \phi_{kS+s-(s-1)}(S) & \phi_{ks}(S) \end{bmatrix} \quad (7)$$

حيث T (.) تمثل مقلوب المتجة.

كما أن Θ_0 هي مصفوفة $(S \times S)$ مثلثية سفلية ذات قطر عناصره (الوحدة) الواحد الصحيح كما يلى:

$$\Theta_0 = \begin{bmatrix} 1 & 0 & \dots & 0 & 0 & 0 \\ -\theta_1(2) & 1 & \dots & 0 & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ -\theta_{s-2}(S-1) & -\theta_{s-3}(S-1) & \dots & -\theta_1(S-1) & 1 & 0 \\ -\theta_{s-1}(S) & -\theta_{s-2}(S) & \dots & -\theta_2(S) & -\theta_1(S) & 1 \end{bmatrix} \quad (8)$$

هي مصفوفة $(S \times S)$ كما يلى: $i = 1, 2, \dots, Q$, Θ_i

$$\Theta_i = \begin{bmatrix} \theta_{is}(1) & \theta_{is}(1) & \dots & \theta_{is-(s-2)}(1) & \theta_{is-(s-1)}(1) \\ \theta_{is+1}(2) & \theta_{is}(2) & \dots & \theta_{is-(s-3)}(2) & \theta_{is-(s-2)}(2) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \theta_{is+(s-2)}(S-1) & \theta_{is+(s-3)}(S-1) & \dots & \theta_{is}(S-1) & \theta_{is-[s-(s-1)]}(S-1) \\ \theta_{is+(s-1)}(S) & \theta_{is+(s-2)}(S) & \dots & \theta_{is+s-(s-1)}(S) & \theta_{is}(S) \end{bmatrix} \quad (9)$$

2-3-تقدير معالم نموذج PARMA

تعتبر مرحلة تقدير المعالم هي المرحلة الثانية من مراحل بناء النموذج والتي يمكن أن تستخدم نتائجها في تحسين تحديد النموذج والتحقق من اختيار النموذج. وبالنظر إلى طرق التقدير التي يمكن أن تستخدم في تحليل السلسلة الزمنية فإن أكثر هذه الطرق شيوعا هي طريقة العزوم (method of moments)، طريقة تقدير المربيعات الصغرى (least squares estimation) وطريقة تقدير الإمكان الأكبر (maximum likelihood estimation). وقد قارن (1994) Smadi نظرياً بين هذه الطرق الثلاث، طريقة العزوم، طريقة LS الشرطية وطريقة ML الشرطية، عن طريق دراسة محاكاة لثلاث نماذج

PAR مختلفة. وأظهرت المقارنة أن كل الأساليب تنتج تقديرات قريبة من القيم الفعلية للمعلم فوجد أن كلاً من تقديرات LS الشرطية و ML الشرطية للمعلم هي نفسها وأيضاً مطابقة لتقديرات العزوم باستثناء بعض المواسم الأولية التي كان بها بعض المشاهدات المفقودة. كما استنتج (Smadi 1994) في نهاية الدراسة أن تقديرات LS الشرطية تكون متوقعة على تقديرات العزوم من حيث التحيز ومراعي متوازن الخطأ وذلك عند التعامل مع نموذج PAR. ولكن بالإضافة جزء المتوسط المتحرك MA إلى النموذج الدوري أي عند تقدير معلم نموذج PARMA فإن طريقة العزوم باستخدام Yule-Walker equations تكون غير ملائمة. حيث يكون استخدام تقدير الامكان الأكبر MLE "Maximum Likelihood Estimation" في هذه الحالة أكثر ملائمة. وفيما يلى نستعرض خوارزمية تقدير الامكان الأكبر القربي

استخدم Hillmer and Tiao (1979) تقنية ناجحة من أجل تحديد الاحتمال القربي لعملية

ARMA المتعددة. حيث يتم في البداية يتم إجراء عملية تحويل y إلى w على النحو التالي:

$$w_{p+j} = y_{p+j} - \sum_{k=1}^p \phi_k(p+j) y_{p+j-k} \quad (10)$$

وذلك عند $j = 1, 2, \dots, NS - p$ وذلك فان w_p يكفى احتمال y_p التحول من y_p إلى w_p هو "unit Jacobian" ولذلك فان احتمال w_p يكفى احتمال y_p الذي يعطى عن طريق $y_p, y_1, y_2, \dots, y_q$, كما أن w_p تتبع عملية PMA(q) والتي تبدأ عند الزمن $1 + p$ وتنتهي عند NS . وبالتالي وبالاعتماد على الاحتمال الدقيق عند $p=0$ فإنه يمكن ايجاد ضعف لوغاريتم دالة الامكان السالبة "negative log-likelihood" وذلك للسلسلة w_p بالمعادلة التالية،

$$-2 \ln[L(\phi, \theta, \sigma | w_p)] = NS \ln(2\pi) + \ln|D_{p+1-q, NS}| + \ln|A_{\theta, p}| \quad (11) \\ + \hat{\epsilon}'_* D_{p+1-q, p}^{-1} \hat{\epsilon}_* + \hat{\epsilon}'_p D_{p+1, NS}^{-1} \hat{\epsilon}_p$$

حيث إن،

$$D_{i,j} = \text{diag}\{\sigma^2(i), \sigma^2(i+1), \dots, \sigma^2(j)\},$$

$$A_{\theta, m} = D_{m+1-q, m}^{-1} + F'_{\theta, m} D_{m+1, NS}^{-1} F_{\theta, m},$$

$$F_{\theta, m} = -L_{\theta, m}^{-1} M_{\theta, m},$$

$$\hat{\epsilon}_* = E(\epsilon_* | y_m), \quad \hat{\epsilon}_p = E(\epsilon_p | y_m).$$

و عند

$$\hat{\epsilon}_* = [\hat{\epsilon}_{p+1-q}, \hat{\epsilon}_{p+2-q}, \dots, \hat{\epsilon}_p]' = A_{\theta, p}^{-1} F'_{\theta, p} D_{p+1, NS}^{-1} L_{\theta, p}^{-1} w_p \quad (12)$$

ويكون،

$$\hat{\epsilon}_{p+j} = w_{p+j} + \sum_{k=1}^q \theta_k(p+j) \hat{\epsilon}_{p+j-k}, \quad (13)$$

عند $j = 1, 2, \dots, NS - p$

ونحصل على تدبير المعلم ϕ, θ, σ عن طريق تدنب المعادلة (11) ذلك لأنه عندما تكون $p > 0$ فإن الاحتمال يعتمد على السلسلة $y_{NS}, y_{NS-1}, \dots, y_{p+1}, y_p$ وذلك بالاعتماد على السلسلة y_p, \dots, y_2, y_1 . و يكون من السهل عند $0 = p$ إثبات أن تدنب المعادلة (11) يتواافق مع تدبير المربعات الصغرى وهو يعادل تقريباً تدبير يول ولكر yule-walker ولكن الموسمى (Pagano, 1978). وعند افتراض أن $q > 0$ فإن التدنب المباشرة للمعادلة (11) عن طريق التفاضل تكون غير ممكنه ومن ثم يمكن استخدام نمط التحسين غير الخطى لتدنب المعادلة (11). وقد أوضح Vecchia(1985a,b) ان تلك الخوارزمية تتطلب وقتاً أقل بكثير للحساب ومتلك كذلك خصائص تقارب أفضل من التدنب المباشر للمعادلة (11) بالإضافة إلى الحصول على تدبرات جيدة. ولحساب تدبرات التباين للبواقي يمكن تعريف $K_1 S < p + 1 - q$ على أن كل منها يمثل أكبر عدد صحيح يحقق الشرط $K_2 S < p + 1 + S$.

وتتلخص خطوات خوارزمية تدبر الامكان الأكبر التقريبية فيما يلى:

- 1- استخدام تدبرات أولية $\hat{\phi}_0, \hat{\theta}_0$ للمعلم ϕ, θ .
- 2- افتراض أن $0 = j$ عند $p + 1 \leq j \leq p + 1 - q$ و حساب قيمة j عند NS باستخدام المعادلة (13)
- 3- حساب تدبرات التباين للبواقي،
- 4- استخدام نمط التحسين لاجداد قيم المعلم $\hat{\phi}, \hat{\theta}$ التي تعمل على تدنب قيمة $\hat{\sigma}$ في المعادلة (12) بالنسبة للمعلم ϕ, θ وذلك عند $\hat{\sigma} = [\hat{\sigma}^2(1), \dots, \hat{\sigma}^2(S)]'$.
- 5- حساب تدبرات التدبرات للسوق j حيث أن $0 \leq j \leq p + 1 - q \leq NS$ باستخدام المعادلة (12) و المعادلة (13) عند $\hat{\sigma} = \hat{\phi}, \phi = \hat{\theta}$ و $\theta = \hat{\theta}$.

- إعادة الخطوة من 3 الى 5 حتى يحدث التقارب النهائي.

3- تمثيل معالم PARMA باستخدام تحويلة فورييه المقطعة DFT

للحصول على نموذج PARMA فان ذلك يتطلب تقدير عدد كبير من المعالم مما يجعل التقدير صعباً حسابياً. ويكون من الأفضل استغلال الهيكل الدوري للنموذج من أجل تقليل عدد المعالم. حيث يعتبر تقدير يول ووالكر "Yule-Walker" طريقة حسابية بسيطة ولكن عند تواجد المتوازنات المتحركة الدورية "PMA" في النموذج فإن طريقة يول ووالكر تكون غير كافية. ويمكن تقليل أبعاد مساحة البحث بشكل كبير عن طريق تحويل المعالم ϕ, θ وعرضها في شكل معالم فوريير a, b والتي تظهر عند تمثيل معالم PARMA في شكل تحويلة فوريير المقطعة كما يلى: Brelsford(1967) و التي قدمها ، "Discrete Fourier Transform (DFT)" .

$$\begin{aligned}\phi_j(t) &= a_{j,1} + \sum_{n=1}^{\left[\frac{T}{2}\right]} a_{j,2n} \cos\left(\frac{2\pi nt}{T}\right) + \sum_{n=1}^{\left[\frac{T}{2}\right]} a_{j,2n+1} \sin\left(\frac{2\pi nt}{T}\right), \\ \theta_k(t) &= b_{k,1} + \sum_{n=1}^{\left[\frac{T}{2}\right]} b_{k,2n} \cos\left(\frac{2\pi nt}{T}\right) + \sum_{n=1}^{\left[\frac{T}{2}\right]} b_{k,2n+1} \sin\left(\frac{2\pi nt}{T}\right),\end{aligned}\quad (14)$$

كما انه يمكن حيث يمكن ايجاد قيم معالم فوريير b , a باستخدام تقديرات ϕ, θ كما يلى،

$$a_r = \begin{cases} v^{-1} \sum_{m=0}^{v-1} \cos\left(\frac{2\pi rm}{v}\right) \phi_m & (r = 0 \text{ or } \frac{v}{2}) \\ 2v^{-1} \sum_{m=0}^{v-1} \cos\left(\frac{2\pi rm}{v}\right) \phi_m & (v \text{ even}) \quad (r = 1, 2, \dots, \frac{v-1}{2}) \\ 2v^{-1} \sum_{m=0}^{v-1} \sin\left(\frac{2\pi rm}{v}\right) \phi_m & (v \text{ odd}) \quad (r = 1, 2, \dots, \frac{v-1}{2}) \end{cases} \quad (15)$$

$$b_r = \begin{cases} v^{-1} \sum_{m=0}^{v-1} \cos\left(\frac{2\pi rm}{v}\right) \theta_m & (r = 0 \text{ or } \frac{v}{2}) \\ 2v^{-1} \sum_{m=0}^{v-1} \cos\left(\frac{2\pi rm}{v}\right) \theta_m & (v \text{ even}) \quad (r = 1, 2, \dots, \frac{v-1}{2}) \\ 2v^{-1} \sum_{m=0}^{v-1} \sin\left(\frac{2\pi rm}{v}\right) \theta_m & (v \text{ odd}) \quad (r = 1, 2, \dots, \frac{v-1}{2}) \end{cases} \quad (16)$$

وذلك عند $p = 1, 2, \dots, q$ و $j = 1, 2, \dots, T - 1$ و $k = 0, 1, \dots, T - 1$. حيث يمكن تقليل فضاء بحث المعالم من خلال خلق فضاءات فرعية من a, b عن طريق تقييد بعض أو معظم الترددات (\sin, \cos) لتكون ذات سعة صفرية. ونظرًا لأن تحويلة فوريير المتقطعة DFT للمعلم ϕ, θ إلى B, A تكون خطية وقابلة للانعكاس فإن الفضاء الجزئي الخطى للمعلم a, b يتحول مرة أخرى إلى فضاء جزئي خطى للمعلم ϕ, θ . وتميز هذه الطريقة بتقليل وقت الحساب بالإضافة إلى انتاج حلول وحيدة.

.“Unique Solution

في المرحلة الأخيرة يتم فحص وتشخيص النموذج المقدر من خلال التأكيد من أن النموذج الذي تم بناءه يصف بشكل كافى السلسلة الزمنية قيد الدراسة وذلك بناء على اختبارات احصائية والتي يشار إليها بفحوص التشخيص Diagnostic Checks (Hipel and Mcleod, 1994). ولحد أهن طرق فحص وتشخيص النموذج هي تحليل الباقي للنموذج الملام و ذلك لضمان الاستقلالية وأنها تتبع التوزيع الطبيعي "normality". ومن أفضل المعايير التي يمكن الاستعانة بها هنا هو AIC و BIC والتي يمكن من خلالها اختيار أقل عدد معالم "parsimony" للنموذج الملام "fitted model". ويتم حساب AIC و BIC باستخدام المعادلات التالية:

$$AIC^{(k)} = -2 \ln L(\hat{\phi}, \hat{\theta}) + 2k,$$

$$BIC^{(k)} = -2 \ln L(\hat{\phi}, \hat{\theta}) + 2k \log N.$$

حيث أن، k : يمثل إجمالي عدد المعالم لمجموعة المعالم ϕ, θ او في حالة تمثل فوريير للمعلم

$A, B, \text{ و } N$: تمثل عدد العينات الخطية المستقلة

4- تقدير نموذج GARCH الدوري المختلط لباقي نموذج PARMA المقدر

يمكن القول إن $\{y_t; t \in \mathbb{Z}\}$ هي عملية ذات سكون دوري تمام strictly periodically stationary (s.p.s.) للفترة الدورية S ، إذا كانت توزيعاتها ذات الأبعاد المحدودة ثابتة لا تتغير في ظل الإزاحات الزمنية الدورية S وهذا يعني أن المتوجه $(y_{t_1}, y_{t_2}, \dots, y_{t_K})$ و $(y_{t_1+\tau S}, y_{t_2+\tau S}, \dots, y_{t_K+\tau S})$ يكون لهما نفس التوزيع الاحتمالي المشترك لكل $1 \leq k \leq K$ و $\tau \geq 1$ و $t_1, \dots, t_K \in \mathbb{Z}$.

كما يمكن القول إن $\{y_t; t \in \mathbb{Z}\}$ هي عملية ذات سكون دوري ضعيف(weakly (w.p.s.)) للفترة الدورية S إذا كان وسطها $E(y_t) = \mu$ و دالة التغير الذاتي لها periodically stationary

$$\mu_t = \mu_{t+s} \quad \gamma_h^{(t)} := cov(y_t, y_{t+h})$$

والتغير $\gamma_h^{(t+ts)} = \gamma_h^{(t+ts)}$, وذلك

ويافتراض أن x_t هي بواقي نموذج PARMA المقدر و أن Z_t هي سلسلة لها توزيع متماثل مستقل (i.i.d)، بينما $Z_t = (Z_t^{(1)}, \dots, Z_t^{(K)})$ هي متوجهات أبعادها K ، وعناصر $Z_t^{(K)}$ تساوى 1 إذا كانت المشاهدة x_t مشتقة من العنصر k^{th} دالة الكثافة الشرطية و 0 فيما عدا ذلك. بينما تمثل $\beta_{t,j}^{(K)}$ معالم النموذج والتي تكون دورية عند الزمن t وبفترات دورية S . حيث أن المعالم، $i = 1, \dots, q_k$ ، $j = 1, \dots, p_k$ ، $k = 1, \dots, K$ ، بينما $\alpha_{t,i}^{(k)} \geq 0$ و $\beta_{t,j}^{(k)} \geq 0$ عند أي $i = 1, \dots, q_k$ ، $j = 1, \dots, p_k$ ، $k = 1, \dots, K$. كما أن مجموع نسب الخليط يجب أن تساوى الواحد الصحيح أي أن $\sum_{k=1}^K \lambda_k = 1$ ، في حين $0 < \lambda_k$ لكل قيم k . وبالتالي فإن نموذج GARCH الدوري المختلط للفترة الدورية S ، يمكن

تعريفه من خلال المعادلة التالية: (Hamdi and Souam, 2017)

$$\begin{cases} x_t = \left(\sum_{k=1}^K h_t^{(k)} \mathbf{1}_{(Z_t^{(k)}=1)} \right)^{1/2} \xi_t, & t \in \mathbb{Z} \\ h_t^{(k)} = \alpha_{t,0}^{(k)} + \sum_{i=1}^{q_k} \alpha_{t,i}^{(k)} x_{t-i}^2 + \left[\sum_{j=1}^{p_k} \beta_{t,j}^{(k)} \left(\sum_{l=1}^K \lambda_l h_{t-j}^{(l)} \right) \right], & k = 1, \dots, K \end{cases} \quad (17)$$

حيث أن $\{\xi_t ; t \in \mathbb{Z}\}$ هـ سلسلة من المتغيرات العشوائية لها توزيع (i.i.d) بوسط حسابي صفيـ و تباين قيمته واحد، و كذلك ξ_t تكون مستقلة عن x_t لكل $t > t$. ويمكن اعتبار q_k و p_k ثوابـتـ في أي انه يمكن القول أن $(p, q) = (\max p_k, \max q_k)$ اي أن المعالم $\alpha_{t,i}^{(k)} = 0$ اذا كانت $i > q_k$ و كذلك $\beta_{t,j}^{(k)} = 0$ اذا كانت $j > p_k$ ، كما تكون معالم النموذج دورية عند الزمن t خلال الموسم S ، حيث $\alpha_{t,i}^{(k)} = \alpha_{t+ts,i}^{(k)}$ و $\beta_{t,j}^{(k)} = \beta_{t+ts,j}^{(k)}$ ، حيث ان الزمن t يشير الى الفترة الدورية، $t = nS + v$ ، حيث تشير v الى الموسم $v = 1, 2, \dots, S$ ، خلال المدة الزمنية n و التي قد تكون سنوات اذا كانت المواسم شهور، كما يمكن كتابة معادلة (17) في الشكل التالي

$$\begin{cases} x_t = \left(\sum_{k=1}^K h_{ns+v}^{(k)} \mathbf{1}_{(Z_{ns+v}^{(k)}=1)} \right)^{1/2} \xi_{ns+v}, \\ h_{ns+v}^{(k)} = \alpha_{v,0}^{(k)} + \sum_{i=1}^{q_k} \alpha_{v,i}^{(k)} x_{ns+v-i}^2 + \sum_{j=1}^{p_k} \sum_{l=1}^K \lambda_l \beta_{v,j}^{(k)} h_{ns+v-j}^{(l)}, & k = 1, \dots, K \end{cases}$$

وتعتبر طريقة الإمكان الأكبر "Maximum Likelihood" (ML) هي أحد أهم طرق التقدير. فهي طريقة لتقدير كثافة مجموعة من البيانات عن طريق البحث عبر توزيعاتها الاحتمالية وكذلك معالمها. حيث تعد طريقة عامة وفعالة تقوم على أساسها العديد من خوارزميات التعلم الآلي، حيث يمكن الحصول على تقدير معلم النموذج من خلال تعظيم دالة الاحتمال الشرطي لمتغير الدراسة. وتكون طريقة الإمكان الأكبر معقده حسابياً وذلك عند وجود متغير من المتغيرات المتقابلة أو أن سلسلة بيانات الدراسة غير كاملة ويعرف بالمتغير الكامن "Latent variable". وقد اقترح (Dempster et al 1977) خوارزمية تعظيم التقدير EM "Expectation Maximization" التي تعد طريقة لتقدير الإمكان الأكبر في ظل وجود بيانات مفقودة أو ما يعرف بالمتغير الكامن. (Hamid and Souam, 2018)

ويمكن تعريف خوارزمية EM على أنها طريقة تكرارية "iteration approach" تدور بين مرحلتين: في المرحلة الأولى يتم تقدير المتغير الكامن (البيانات غير المشاهدة) بمعلومية البيانات المشاهدة وتسمى هذه المرحلة بمرحلة التقدير E-Step. حيث نحصل منها على البيانات المشاهدة وتقدير للبيانات الكامنة أي بيانات كاملة.

في المرحلة الثانية يتم تعظيم معلم النموذج في ظل البيانات الكاملة وكذلك تحسين تلك المعلمات "optimum" وتسمى تلك المرحلة بمرحلة التعظيم M-Step. ويتكرر تلك المراحل نصل في النهاية إلى القارب الأمثل لتقدير معلم النموذج.

ويافتراض أن $\underline{x} = (x_1, x_2, \dots, x_{NS}, Z_1, Z_2, \dots, Z_{NS})$ تمثل سلسلة من البيانات غير الكاملة (جزء مشاهد وجزء مفقود على الترتيب)، حيث $Z = (Z_1, Z_2, \dots, Z_{NS})$ تمثل الجزء المفقود، حيث إن $Z_t = (Z_t^{(1)}, Z_t^{(2)}, \dots, Z_t^{(K)})$ هو متوجه أبعاده $K \times 1$ وعنصره $Z_t^{(k)}$ تكون قيمتها بواحد صحيح اذا كانت المشاهدة x_t ناتجه عن دالة التوزيع الشرطي ذات الرتبة k^{th} . ويافتراض أن $\theta'_{s,k} = (\lambda'_s, \theta'_{1,1}, \dots, \theta'_{S,1}, \theta'_{1,2}, \dots, \theta'_{S,2}, \dots, \theta'_{1,K}, \dots, \theta'_{S,K})'$ كما ان المعلمة $r = \max(p, q)$ و $\underline{\lambda}' = (\lambda_1, \dots, \lambda_{K-1}, (\alpha'_{s,0}, \alpha'_{s,1}, \dots, \alpha'_{s,q}, \beta'_{s,1}, \dots, \beta'_{s,p})')$ وبناء على البيانات المشاهدة $(x_1, x_2, \dots, x_{NS}) = x$ فان دالة الإمكان المشروطة تكون:

$$\mathcal{L}(\underline{\theta}, \underline{x}) = C + \sum_{t=r+1}^{NS} \sum_{k=1}^K Z_t^{(k)} \left[\ln(\lambda_k) - \frac{1}{2} \ln(h_t^{(k)}) - \frac{x_t^2}{2 h_t^{(k)}} \right] \quad (18)$$

حيث أن، $s = 1, \dots, S$ ، كما أنه يافتراض أن، $C = \frac{r+1-NS}{2} \ln(2)$ عند $t = s + \tau S$ عند $t = s$ ، $0, 1, \dots, N-1$ ، $r+1 = s_0 + \tau_0 S$ for $1 \leq s_0 \leq S$

$$\tau_0 = \begin{cases} \left\lceil \frac{r+1}{S} \right\rceil, & \text{if } s_0 \neq S, \\ \left\lceil \frac{r+1}{S} \right\rceil - 1, & \text{if } s_0 = S, \end{cases}$$

وبالتالي يمكن إعادة كتابة المعادلة (18) كما يلى:

$$\begin{aligned} \mathcal{L}(\underline{\theta}; \underline{x}) = C + \sum_{s=s_0}^S \sum_{k=1}^K Z_{s+\tau_0 S}^{(k)} \left[\ln(\lambda_k) - \frac{1}{2} \ln(h_{s+\tau_0 S}^{(k)}) - \frac{x_{s+\tau_0 S}^2}{2 h_{s+\tau_0 S}^{(k)}} \right] \\ + \sum_{s=1}^S \sum_{\tau=\tau_0+1}^{N-1} \sum_{k=1}^K Z_{s+\tau S}^{(k)} \left[\ln(\lambda_k) - \frac{1}{2} \ln(h_{s+\tau S}^{(k)}) - \frac{x_{s+\tau S}^2}{2 h_{s+\tau S}^{(k)}} \right] \end{aligned} \quad (19)$$

وفقا لطريقة EM يتم تغير المعالم عن طريق تعظيم لوغاريتم دالة الإمكان في معادلة (18)، و في كل خطوة تكرارية "iteration" يكون هنالك مرحلتين أساسيتين مرحلة التقدير E-Step ومرحلة التعظيم M-Step. وبافتراض أن البداية تكون عند الخطوة التكرارية "i + 1" فإنه يجب أن يتوافر تغير المعالم $\lambda_k^{(i)}$ و $\theta_{s,k}^{(i)}$ اي تغير للمعلم عند التكرار السابق "i" او ما يعرف بالقيمة المبدئي لذك المعالم "initial value" ، ويتم في مرحلة التقدير Expectation حساب قيمة الدلة - Q والتي تتطلب تحديث

التوزيع الشرطي لـ $Z_t^{(k)}$ الذي يمثل المتغير الكامن،

$$p(Z_t^{(k)} | x_t, \underline{\theta}^{(i)}) = \frac{p(x_t | \underline{\theta}^{(i)}, Z_t^{(k)}) \cdot p(Z_t^{(k)})}{\sum_{k=1}^K p(x_t | \underline{\theta}^{(i)}, Z_t^{(k)}) \cdot p(Z_t^{(k)})}$$

ثم بعد ذلك حساب قيمة الدلة - Q، حيث أن

$$Q(\underline{\theta}; \underline{\theta}^{(i)}) = \mathbb{E} (\mathcal{L}(\underline{\theta}; \underline{x}) | x_t, \underline{\theta} = \underline{\theta}^{(i)})$$

بعد تحديد المعالم في مرحلة التعظيم M-step والحصول على $\underline{\theta}^{(i+1)} = argmax Q(\underline{\theta}; \underline{\theta}^{(i)})$ يبدأ التكرار التالي "next iteration" بالاعتماد على المعلمة الجديدة $\underline{\theta}^{(i+1)}$ التي تم تحديدها. وتستمر خوارزمية EM في العمل بهذه الطريقة الا ان تصل للتقريب اللازم لانهاء الخوارزمية التكرارية.

وهنالك عدة معايير لاختيار الرتب (p_k, q_k) المناسبة لمكونات نموذج M-PGARCH وكذلك Mixture ARCH مكونات الخليط K. حيث قام كلا من Wong and Li (2001) و Bentarzi and Hamdi (2008a) بتقديم معيار المعلومات البايزى (BIC) Bayesian Information Criterion على الترتيب حيث تم استخدام تعظيم دالة كثافة الاحتمال Mixture PARCH و Mixture ARCH الشرطية للنموذج، كما تم ملائمة هذا المعيار مع نموذج M-PGARCH بواسطة Hamid and Souam (2018) ، ويتم حساب معيار BIC كما يلى:

$$BIC = -2(NS - r)\mathcal{L}^* + \log(NS - r) \left(K - 1 + S \left(\sum_{k=1}^K (p_k, q_k) + K \right) \right)$$

حيث إن

$$\mathcal{L}^* = \frac{\sum_{t=r+1}^{NS} \log(f(x_t | \mathcal{F}_{t-1}))}{NS - r}$$

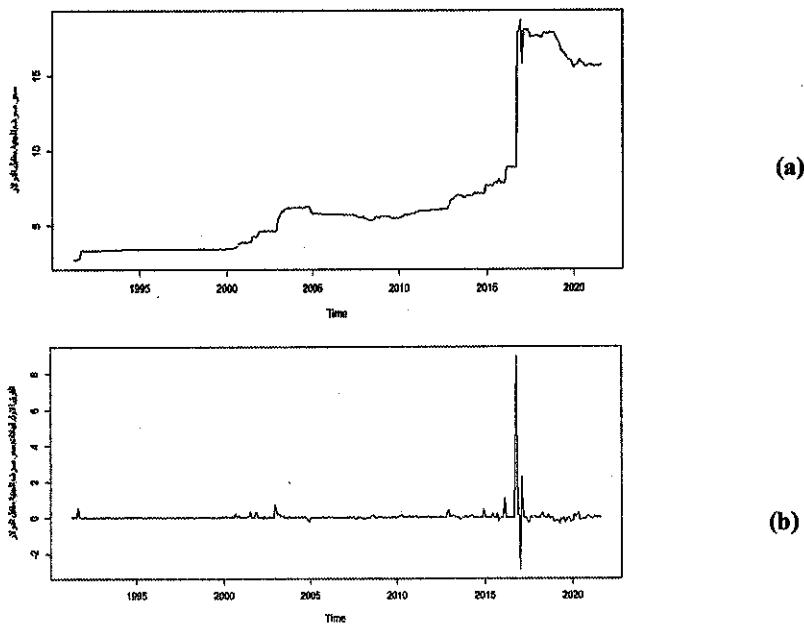
و $f(x_t | \mathcal{F}_{t-1})$ هي دالة الاحتمال الشرطي لـ x_t بمعلومية المعلومات السابقة للزمن t

5- التطبيق

الهدف الأساسي من هذه الدراسة هو بناء نموذج PARMA الأفضل بالتطبيق على البيانات التاريخية لسعر صرف الجنية المصري مقابل الدولار الأمريكي فقد اختارت هذه الدراسة بيانات سعر صرف الجنية المصري مقابل الدولار الأمريكي وذلك لما لها من أهمية كبيرة على الاقتصاد ويعتبر نموذج ARMA الدوري "PARMA" هو نموذج السلسلة الزمنية المناسب لذاك البيانات نظراً ان التغيرات في سعر صرف الجنية مقابل الدولار تعد تغيرات دورية بشكل كبير نتيجة للعوامل الاقتصادية والسياسية التي توفر على سعر الصرف وتتغير بشكل دوري تقريباً.

1- تحديد نموذج PARMA

في البداية يجب التأكد من سكون السلسلة من عدمه من حيث التباين والوسط الحسابي ولمعرفة ذلك يتم فحص الرسم البياني للسلسلة الزمنية لسعر صرف الجنية المصري مقابل الدولار الأمريكي، حيث أن البيانات التي استُخدمت في هذا البحث تتكون من سلسلة زمنية شهرية بواقع 364 مشاهدة شهرية ($t=364$) والتي تمثل البيانات التاريخية لسعر صرف الجنية مقابل الدولار للفترة من أبريل 1991 وحتى أغسطس 2021.

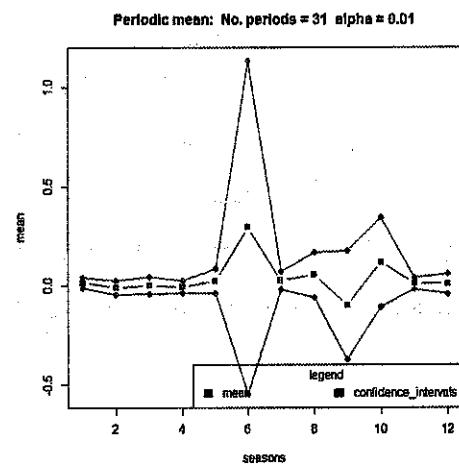


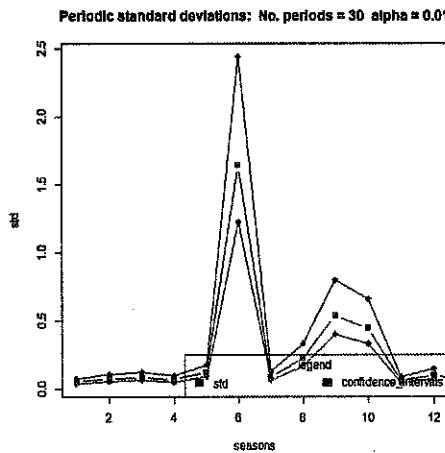
شكل (1) : حيث أن الشكل (a) يمثل الرسم البياني للسلسلة الزمنية لبيانات سعر الصرف بينما

سلسلة الفروق الأولى لبيانات سعر صرف الجنية المصري مقابل الدولار

ويتضح من شكل (1, a) وجود إتجاه عام نحو الارتفاع وكذلك عدم ثبات التباين لذا لازلة الاتجاه العام
وزيادة استقرار السلسلة يتم حساب الفروق العادبة الأولى للسلسلة الزمنية لجعل الوسط الحسابي مستقر

كما هو موضح في شكل (1, b)





شكل (2): الوسط الحسابي الدوري والانحراف المعياري الدوري لسلسلة الفروق الأولى

و بالنظر للشكل (2) نجد أن السلسلة الزمنية لسعر الصرف قد استقرت تقريباً ولكن يبقى هناك انحراف ناتج عن تعويم الجنيه الذي قامت به الحكومة المصرية كأحد اجراءات الاصلاح الاقتصادي و الذي حرك سعر صرف الجنيه بشكل مفاجئ من 8.8799 في أكتوبر 2016 إلى 17.865 في نوفمبر 2016 و تبعه بعد ذلك زيادة في سعر صرف الدولار أمام الجنيه إلى أن استقر عند قيمة تتراوح بين 15 إلى 16 جنية مصرى. و نجد أنه من حيث الوسط الحسابي و التباين وذلك للمواسم المختلفة نجد استقرار في الوسط الحسابي الدوري و استقرار تقريبي في التباين حيث أن الوسط الحسابي والانحراف المعياري الدوري يقعون داخل حدود الثقة بدرجة ثقة 99%. كما أن شكل السلسلة الزمنية استقر بشكل كبير، وبالتالي تكون الخطوة التالية هي تحديد نموذج PARIMA لبيانات السلسلة.

ولتحديد نموذج PARIMA لبيانات سلسلة الفروق الأولى الشهرية لسعر صرف الدولار أمام الجنيه يعرض جدول (1) نماذج PARIMA الشهرية الأفضل التي تم اختيارها بالاعتماد على قيم كل من "AIC" و "BIC" و "Negative log likelihood" من بين 17 نموذج تم تقاديره باستخدام الرتب p و q ، التي تتراوح قيمتها بين 0 إلى 4 بالتبادل وذلك عند تثبيت كافة شروط التقدير لكل النماذج.

جدول(1) : قيم كل من AIC و BIC و Negative log likelihood المقدرة لكل نموذج

Model PARIMAS(P,I,Q)	Negative log likelihood	AIC value	BIC value
PARIMA ₁₂ (1,1,3)	-5.981207	20.01879	70.64603
PARIMA ₁₂ (3,1,3)	-11.96809	26.03191	99.92059

وبمقارنة قيم معايير المعلومات وقيمة سالب اللوغاریتم الاحتمالي للنماذج الأفضل المختارة، نجد أن النموذج الأفضل هو النموذج الذي يتفوق على باقى النماذج في عدد أكثر من المعايير، حيث أن نموذج PARIMA₁₂(1,1,3) يتفوق على باقى النماذج من حيث AIC و BIC.

5-1-1- تقدير معالم نموذج PARMA

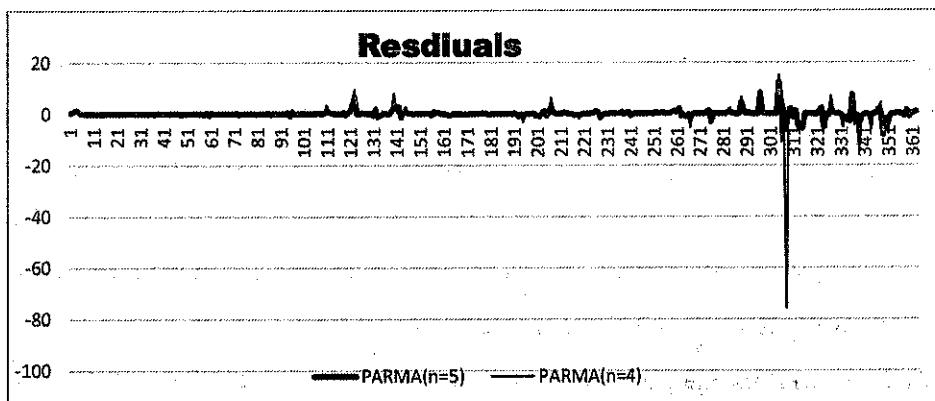
في مرحلة التحديد وقع الاختيار على نموذج الأفضل بعد مفاضلته مع كل النماذج المحتملة، ثم تأتي الخطوة التالية وهي تقدير معالم النموذج. ولتقدير المعالم للنموذج المختار يتم استخدام خوارزمية تقدير الامكان الاقرب التقريبية حيث تكون اولى خطوات تلك الخوارزمية هي ايجاد تقدیرات اولية للمعلم θ_0 ، ϕ_0 ، حيث أن $\hat{\theta}_0 = \theta_0$ و $\hat{\phi}_0 = \phi_0$ هي تقدیرات θ ، ϕ والتي يتم الحصول عن طريق تحويل المعالم $\hat{\theta}_0 = \hat{\theta}$ و $\hat{\phi}_0 = \hat{\phi}$ وعرضها في شكل سلسلة فوريير باستخدام تحويلة فوريير المتقطعة DFT وبالتالي يكون التعامل مع معالم فوريير الاولية \hat{b}_0 و $\hat{a}_0 = \hat{a}_0$. ثم بعد ذلك وبالاعتماد على معالم فوريير الاولية، يتم استخدام طرق التحسين غير الخطية للحصول على الحد الأدنى لقيمة سالب اللوغاریتم دالة الامكان، "minimum of negative logarithm of likelihood function". وذلك باستخدام خوارزمية تقدير الامكان الاقرب التقريبية ولكن بالاعتماد على معاملات فوريير الاولية، حيث يتم استخدام طريقة التحسين التكرارية (BFGS) Broyden, Fletcher, Goldfarb, Shanno (BFGS). ثم يتم اعادة خطوات تكرارية لحل مشاكل التحسين غير الخطية غير المقيدة (Kelley, 1999). ثم يتم اعادة خطوات الخوارزمية حتى الوصول الى الحل الأفضل الذي يحقق تعظيم دالة الامكان. ولكن يبقى تحديد عدد التوفيقات "Harmonics" التي تجعل النموذج المقترن أقل في عدد المعالم وفي نفس الوقت الأفضل. وعند تحديد عدد التوفيقات n المناسب فإنه يتم عادة استبعاد التوفيقات الاولى من $\frac{S}{n}$ ، حيث $\frac{S}{2} = n$ و وبالتالي $S=12$ فإنه عادة ما يتم استبعاد التوفيقات عند $n=0,1,2$ لأنها تكون قليلة جدا للتغيير عن المعالم ϕ و θ . كما يفضل ان تكون عدد التوفيقات $\frac{S}{2} \leq n$ ، اي يفضل دراسة جودة النماذج ذات التوفيقات $n=3,4,5,6$. وبما أن النموذج المختار كان PARIMA₁₂(1,1,3) فيمكن تقدير معالمه باستخدام تمثيل $n=3,4,5,6$ "Fourier coefficients" a, b اذ ذلك عند عدد توفيقات

و من ثم اختيار التقدير الذى يحقق أقل عدد و أفضل جودة. ويعرض جدول (2) قيم معايير اختيار النموذج عند عدد توفيقات $n=3, 4, 5, 6$ Harmonics

جدول (2) : قيم $AIC^{(n)}$ و $BIC^{(n)}$ لنموذج PARIMA_{12(1,1,3)}

Number of Harmonics (n)	$AIC^{(n)}$	$BIC^{(n)}$	Akaike's Final Prediction Error for estimated model $FPE^{(n)}$
3	20.01879	70.64603	2771.296
4	-41.58301	36.30504	2178488
5	-82.27875	15.08132	2.414864
6	-93.65123	23.18085	171.7118

بناءً على نتائج جدول (2) يمكن القول أن النموذج عند عدد توفيقات 5 $n=4$ هو الأفضل بالنظر إلى جميع المعايير. و يعتبر نموذج PARIMA_{12(1,1,3)} عند $n=5$ هو الأفضل، وذلك لأن له القيم الأقل لجميع المعايير باستثناء معيار AIC. وبالمقارنة بين بواقي النموذجين عند $n=4, n=5$ يظهر في شكل (3) أن سلسلة البواقي عند $n=5$ هي الأكثر سكوناً ولا يوجد بها قيم متطرفة كالتي تظهر عندما تكون $n=4$ ، ولذلك سيكون من الأفضل تمثيل معالم النموذج ϕ و θ باستخدام معالم فوريير a و b عند عدد توفيقات 5 $n=5$. و تظهر تقديرات ϕ و θ لنموذج PARIMA_{12(1,1,3)} في الجدول (3)، بينما يعرض جدول (4) تقديرات معالم a و b المختلفة باستخدام تحويلة فوريير.



شكل (3): الرسم البياني لسلسلة البواقي لنموذج PARIMA_{12(1,1,3)} عند عدد توفيقات 5 $n=4, 5$ لتمثيل فوريير لمعامل النموذج.

جدول (3): معالم نموذج $\hat{\phi}_i(v), \hat{\theta}_i(v)$ المقدرة PARIMA_{12(1,1,3)}

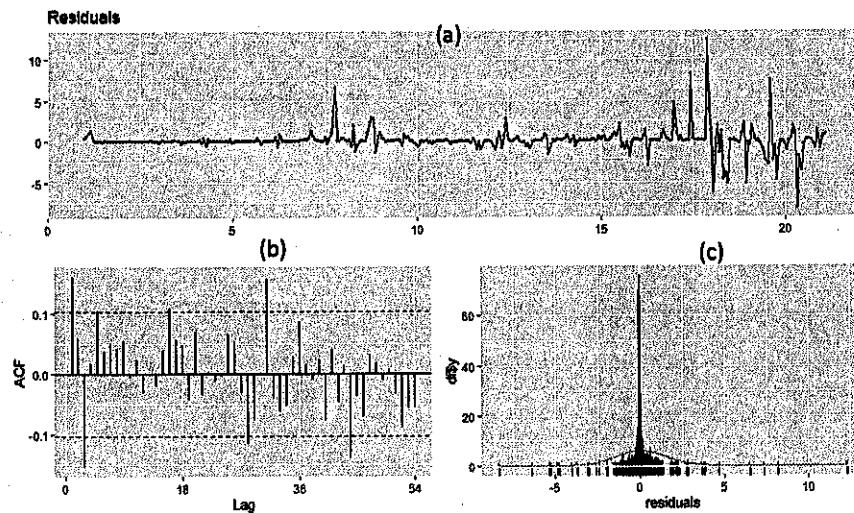
Period(v)	$\hat{\phi}_i(v)$	$\hat{\sigma}(v)$	$\hat{\theta}_i(v)$		
			1	2	3
1	1.23974	0.05776	-0.06707	-0.01765	-0.00298
2	0.65768	0.0428	-0.08215	-0.0224	-0.00615
3	-0.41066	-0.09154	-0.10766	-0.05295	-0.01424
4	-1.1644	0.05588	-0.0948	-0.10276	-0.07231
5	-1.16026	0.39233	0.006785	-0.12114	-0.19125
6	-0.57265	0.72877	0.18175	-0.06417	0.31846
7	-0.34684	0.8438	0.341168	0.054537	-0.37264
8	-0.51146	0.67421	0.388619	0.165826	0.31279
9	-0.84909	0.36432	0.299504	0.200886	-0.17571
10	-0.75465	0.12844	0.139655	0.14867	-0.04533
11	-0.01211	0.06214	0.005704	0.060515	0.016937
12	0.90625	0.08432	-0.05461	-0.00097	0.015154

جدول (4): معالم فوريير المختزلة المقدرة a, b لنموذج PARIMA_{12(1,1,3)}

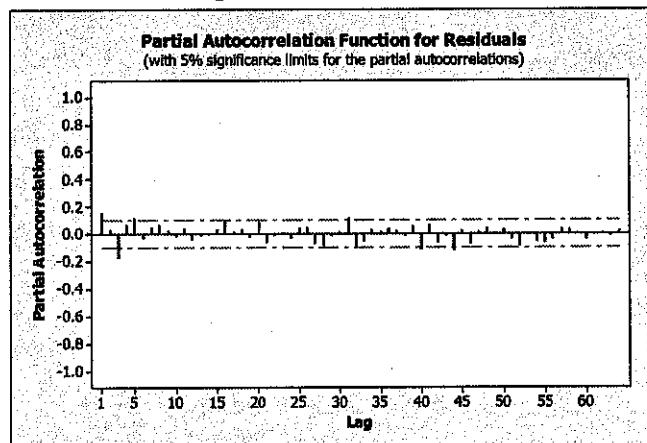
Harmonics	$a_i(v)$	$b_0(v)$	$b_i(v)$		
			1	2	3
1	-0.25654	0.27147	0.079738	0.020701	-0.12331
2	0.79329	-0.39302	-0.20412	-0.03609	0.184827
3	-0.20488	-0.03628	-0.11723	-0.12571	-0.01349
4	0.70299	0.17931	0.057309	-0.00226	-0.0645
5	-0.02522	-0.05245	0.051776	0.060206	-0.00451

5-2-1-5- فحص ملاءمة نموذج PARIMA_{12(1,1,3)} الشهري

كما قد توصلنا في مرحلة التقدير الى أنه يكون من الأفضل تمثيل معالم النموذج PARIMA_{12(1,1,3)}، ϕ و θ ، باستخدام معالم فوريير a و b المختزلة باستخدام عدد n=5 من التوفيقات. وبالتالي س يتم فحص بواقي ذلك النموذج. حيث يتم فحص دالة الارتباط الذاتي والارتباط الذاتي الجزئي للبواقي للتأكد من أن البواقي عبارة عن تغيرات عشوائية و أن الارتباطات الذاتية للبواقي مستقلة و تتوزع توزيع طبيعي وكذلك المدرج التكراري للبواقي للتأكد من أنها تتبع التوزيع الطبيعي.



شكل (4): تحليل سلسلة الباقي لنموذج $\text{PARIMA}_{12}(1,1,3)$ حيث الشكل (a) يمثل سلسلة الباقي، الشكل (b) يمثل دالة ACF لسلسلة الباقي، الشكل (c) يمثل المدرج و المنحنى التكراري لسلسلة الباقي.



شكل (5): دالة الارتباط الذاتي الجزئي لسلسلة الباقي لنموذج $\text{PARIMA}_{12}(1,1,3)$ و نلاحظ من شكل (4) و (5) أن سلسلة الباقي مستقرة تقريباً و لكن ليس بشكل جيد حيث ان هناك تقلبات عالية و منخفضه في نهاية السلسلة ناتجة عن تحريك سعر صرف الجنية امام الدولار، كما نلاحظ من الرسم البياني للمدرج و المنحنى التكراري للباقي شكل (4,c) أنها تتبع التوزيع الطبيعي تقريباً الا انها يوجد بها انحراف و تفريط، و بفحص دالة ACF للباقي شكل (4,b) و دالة PACF للباقي شكل (5) نجد أن الارتباط الذاتي للباقي و الارتباط الذاتي الجزئي لاغلب الفجوات الزمنية lags يقع

داخل حدود الثقة مما يدل على أن الباقي عبارة عن تغيرات عشوائية وأن الارتباطات الذاتية للباقي تكون مستقلة وتتبع التوزيع الطبيعي بشكل تقريبي.

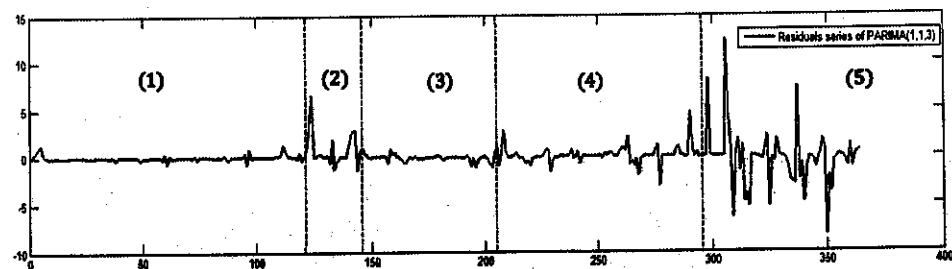
٥-٢-١-٢- تقيير نموذج GARCH الدوري المختلط لباقي نموذج PAIMA_{12(1,1,3)} المقدرة.

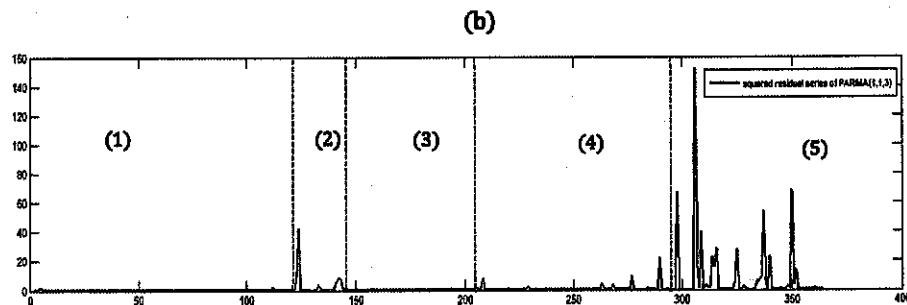
بالنظر الى سلسلة الباقي لنموذج PAIMA_{12(1,1,3)} المقدر نجد أنها مازالت غير ساكنة حيث نلاحظ وجود تقلبات دورية وكذلك عند فحص دالة ACF و PACF للباقي نلاحظ خروج بعض القيم عن حدود الثقة عند بعض فترات الازاحة (lags). ولدراسة تلك التقلبات وزيادة دقة النموذج المقترن سيتم في هذا الجزء دراسة الباقي باستخدام نموذج M-PGARCH وتغيير معامله لدراسة بباقي نموذج PARMA وتقديرها، وبالتالي يكون الناتج في النهاية هو تقيير لنموذج PARMA مع نموذج M-PGARCH.

٥-٢-١-٣- تحديد نموذج M-PGARCH باستخدام سلسلة الباقي لنموذج PARIMA_{12(1,1,3)} الشهري

لتحديد قيمة الخليط K المناسب لسلسلة الباقي وبحض الرسم البياني لهذه السلسلة يتضح من الشكل (6) وجود ظاهرة التقلب العنقودية "the volatility clustering phenomenon" وينتشر في الشكل واضح من خلال الرسم البياني لسلسلة الباقي وكذلك لمربع سلسلة الباقي ان هناك بعض الانقطاعات، حيث يكون هناك تقلبات مخفضة "low volatility" في الجزء (1) و (3) في الشكل (6)، بينما تكون هناك تقلبات متوسطة في الجزء (2) و (4) وفي نهاية السلسلة في الجزء (5) نلاحظ وجود تقلبات مرتفعة حيث تم في نوفمبر 2016 تحرير سعر صرف الجنيه مقابل الدولار الاميركي مما ادى الى تقلبات مرتفعة في سعر صرف الجنيه مقابل الدولار بلغ ذروته في تلك الفترة.

(a)





شكل (6): يمثل (a) سلسلة الباقي لنموذج $\text{PARIMA}_{12}(1,1,3)$ الشهري بينما يمثل (b): مربع سلسلة الباقي لنموذج $\text{PAIMA}_{12}(1,1,3)$

وبحساب المقاييس الوصفية لسلسلة الباقي لنموذج $\text{PARIMA}_{12}(1,1,3)$ و كذلك لكل سلسلة شهرية على حدي وبالنظر الى نتائج الانواء نجد أن سلسلة الباقي الكاملة لها القاء موجب (ناحية اليمين) ولكن عند قياس الانواء لكل سلسلة شهرية نجد ان هناك انواء سالب لشهر يونيو يوليو وبنابريل بينما يكون موجب لباقي شهور السنة. كما تظهر النتائج أن مقاييس التفرطح لكامل السلسلة وكذلك للشهور جميعها أكبر بكثير من 3 فيما عدا شهر ديسمبر و مارس و أبريل يكون التفرطح أقل من 3 وهذا يعكس حقيقة أن ذيول توزيعات الباقي أكثر سمكاً من التوزيع الطبيعي وهذا أمر عادة ما يتم ملاحظته في السلسل الرزمنية المالية لأسعار الصرف خاصة للعملات الناشئة في الدول النامية.

وقد تم اقتراح العديد من النماذج الدورية التي تسمح بوصف التقلبات الموسمية في السلسلة وذلك عند $S=12$ ورتب p, q تتراوح قيمهما بين 1 الى 3. كما أنه من الشكل (6) يمكن القول أن قيمة K والذي يمثل عدد مكونات الخليط تكون $K=2$ او $K=3$ بحد أقصى. وتمثل احدى المشكلات الرئيسية في تحليل نماذج الخليط في تحديد عدد المكونات K وكذلك رتب النموذج الأفضل، وبالتالي فبالإضافة إلى الاعتماد على تحليل الرسم البياني للسلسلة المستهدفة فإن استخدام معيار المعلومات AIC و BIC للمقارنة بين النماذج المقترحة يكون أكثر موثوقية. ويعرض جدول (5) النماذج الأفضل التي قد تم اختيارها.

جدول (5): يعرض النماذج المقترحة بالتطبيق على سلسلة الباقي لنموذج $\text{PARIMA}_{12}(3,1,1)$

الشهري

Model	AIC	BIC
$M - PGARCH_S(K; p_1, p_2, \dots, p_K; q_1, q_2, \dots, q_K)$		
M-PGARCH ₁₂ (2;1,1;1,1)	554.99	838.88
M-PGARCH ₁₂ (3;1,1,1;1,1,1)	666.365	1094.141

و من النتائج السابقة فى جدول (5) نجد أن أفضل نموذجين يمكن دراستهم و المفاضلة بينهم هما نموذج $M-PARCH_{12}(2;1,1;1,1)$ و نموذج $M-PGARCH_{12}(3;1,1;1,1)$ و بالتالي يمكن ملاحظة أن الأفضلية عندما $K=2$ وهذا يعني ان النموذج قد اظهر نوعين مختلفين من التقلبات لسلسلة البواقي ويظهر ذلك بشكل واضح في الرسم البياني لمربع البواقي في الشكل (6-b). وفي الخطوة التالية سيتم تقييم معلمات نموذج $M-PGARCH_{12}(3;1,1,1;1,1,1)$ و نموذج $M-PGARCH_{12}(2;1,1;1,1)$ و المفاضلة بينهم للتوصيل للنموذج الأفضل الذي يصف بواقي نموذج PARIMA الشهري.

5-2-2 - تقييم معلمات نموذج $M-PGARCH$ لبواقي نموذج (1,1,3) PARIMA₁₂ الشهري
 يتم في هذه المرحلة تقييم معلمات النموذج المقترن بالاعتماد على خوارزمية Expectation Maximization لتقدير الامكان الافضل، وقد تم اختيار افضل النماذج المقترنة في مرحلة التحديد وذلك لتقييم معلماتهم و فحص ايمهم الافضل، وفيما يلى نعرض تقييم المعلمات لكل نموذج من النماذج المقترنة. تعرض الجداول التالية تقييم المعلمات وكذلك نتائج شرط السكون الدوري. حيث يعرض الجدول (6) تقييمات المعلمات لنموذج $M-PGARCH_{12}(2;1,1;1,1)$ حيث نجد أن النموذج قد يتحقق شرط توافق مختلفين من التقلبات لسلسلة البواقي، تقلب منخفض يحدث بنسبة $\lambda_2 = 56.632\%$ وتقلب أعلى يحدث بنسبة $\lambda_1 = 43.368\%$. كما نجد أن المعلم المقدرة لكل مكون k تتحقق شرط السكون الدوري، حيث أن قيمة $-0.7 = \prod_{v=1}^S (\alpha_{v,1}^{(1)} + \alpha_{v,1}^{(2)}) = 1.1333e$ وهو أقل من الواحد الصحيح وكذلك عند $k=2$ حيث أن $-10 = \prod_{v=1}^S (\alpha_{v,1}^{(2)} + \alpha_{v,1}^{(3)}) = 1.4909e$ وهو أيضاً أقل من الواحدة، بينما نجد أن معلمات النموذج المقدر كل تكون لها سكون دوري ضعيف و يظهر ذلك بالنظر لقيمة φ حيث أن شرط سكون سلسلة $M-PGARCH$ يكون كالتالي:

$$\varphi = \prod_{v=0}^{S-1} \left(\sum_{k=1}^K \lambda_k (\alpha_{v,1}^{(k)} + \beta_{v,1}^{(k)}) \right) < 1$$

حيث تشير إلى أن قيمة φ ستتحسن *Becomes* أقل من 1 بينما نجد أن $\varphi < 1.6148e - 08$ للنموذج ككل أقل من الوحدة، هذا بالإضافة إلى أن مستوى الاستقرار الدوري عند $k=1, k=2$ مقارب. كما نلاحظ من تحليل النموذج المقدر لكل موسم على حدى أن النموذج المقابل للمواسم $5, 6, 7, 8$ اي الخاص بشهر مايو يونيو وأغسطس يكون غير

ساكن دوريأً وينتسب ذلك من قيمة $(\alpha_{v,1}^{(k)} + \alpha_{v,1}^{(k)}) \sum_{v=1}^S \lambda_k$ لكل الموسماً و التي نجدها أقل من الواحد فيما عدا عند $8, 6, 5 = 7$ فانها تكون أكبر من الواحد. وبالنسبة للموسماً الثلاث التي تكون فيها السلسلة غير ساكنة دوريأً $8, 6, 5 = 7$ نلاحظ أن هناك وزن أكبر للمعلمة $\alpha_{v,1}^{(k)}$ و للمعلمة $\beta_{v,1}^{(k)}$ من تلك المعلمات في الموسماً الساكنة دوريأً، ويعود ذلك بشكل كبير إلى تحرير سعر صرف الجنيه أمام الدولار في عام 2016م و الذي أدى إلى انحرافات كبيرة في سعر الصرف ظهرت بشكل واضح خلال بعض الفترات الدورية الشهرية وحتى بعدأخذ الفروق للسلسلة.

جدول (6): تغير معالم نموذج M-PGARCH₁₂(2,1,1;1,1) لبيانى نموذج PARIMA₁₂(1,1,3) الشعوى

λ_k	K=1			K=2			$\sum_{v=1}^S \lambda_k (\alpha_{v,1}^{(k)} + \alpha_{v,1}^{(k)})$
	0.433681			0.566319			
period	$\alpha_{v,0}^{(k)}$	$\alpha_{v,1}^{(k)}$	$\beta_{v,1}^{(k)}$	$\alpha_{v,0}^{(k)}$	$\alpha_{v,1}^{(k)}$	$\beta_{v,1}^{(k)}$	
$v = 6$	1.212576	26.43128	0.595072	0.000807	2.135956	0.600461	13.27049
$v = 7$	4.672325	1.57E-13	0.054984	0.005229	8.37E-14	0.055547	0.055303
$v = 8$	3.241246	1.178532	0.24592	0.01313	0.54341	0.254835	1.069819
$v = 9$	0.006758	0.189041	6.43E-15	1.101492	0.287101	6.50E-15	0.244575
$v = 10$	0.04643	2.56E-13	0.057225	4.955133	2.94E-13	0.057812	0.057557
$v = 11$	0.029821	5.19E-14	0.056619	4.86898	5.70E-14	0.05754	0.057141
$v = 12$	0.02105	8.43E-15	0.05707	0.600214	5.35E-15	0.058562	0.057915
$v = 1$	3.050213	1.65E-12	0.058296	0.022518	3.91E-13	0.055538	0.056734
$v = 2$	0.073935	1.88E-13	0.052625	0.004228	1.04E-13	0.057108	0.055164
$v = 3$	0.004037	1.52E-13	0.049689	44.93644	2.31E-13	0.063635	0.057587
$v = 4$	0.094838	1.846749	1.06E-14	8.05E-05	0.236856	1.05E-14	0.935036
$v = 5$	0.45115	5.440596	2.03E-16	0.000171	0.459561	2.04E-16	2.61974
$\prod_{v=1}^S (\alpha_{v,1}^{(k)} + \alpha_{v,1}^{(k)})$	1.1333e-07			1.4909e-10			
φ	1.6148e-08						
Log Likelihood	-127.1197						
	Number of observations outside the limits			14			

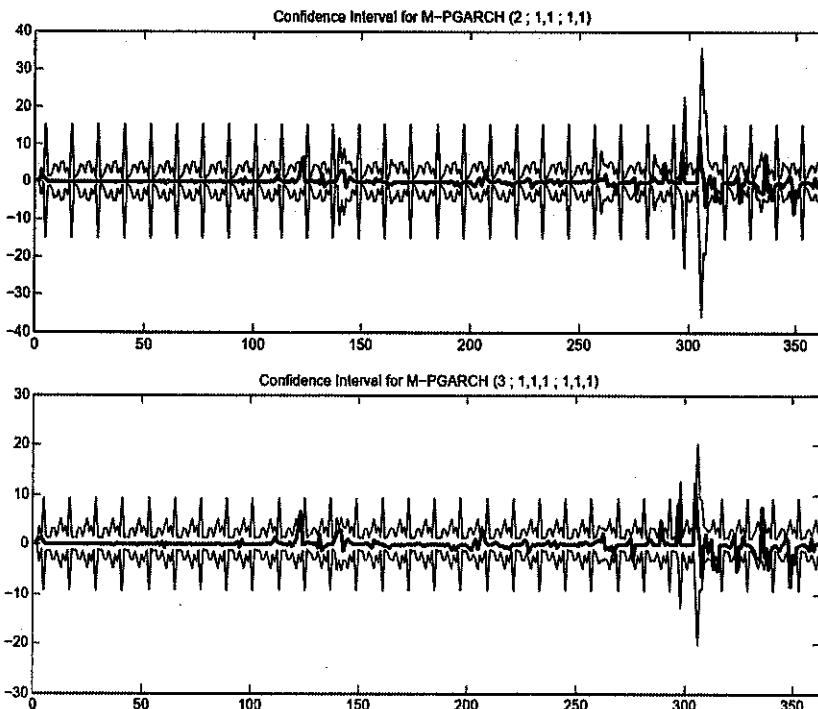
جدول (7): تثبيت معالم نموذج M-PGARCH₁₂(3;1,1,1;1,1,1) لبيانی نموذج PARIMA₁₂(1,1,3) پسیو

	$k = 1$			$k = 2$			$k = 3$			$\sum_{v=1}^S \lambda_k (a_{v,1}^{(k)} + a_{v,1}^{(k)})$						
λ_k	0.405594			0.055253			0.539153									
period	$a_{v,0}^{(k)}$	$a_{v,1}^{(k)}$	$\beta_{v,1}^{(k)}$	$a_{v,0}^{(k)}$	$a_{v,1}^{(k)}$	$\beta_{v,1}^{(k)}$	$a_{v,0}^{(k)}$	$a_{v,1}^{(k)}$	$\beta_{v,1}^{(k)}$							
$v = 6$	0.143634	3.552861	0.597098	0.163721	4.303427	0.597502	0.001274	1.452814	0.529124	3.022557						
$v = 7$	0.485156	6.35E-14	0.054375	15.74464	4.59E-14	0.054729	0.006216	3.27E-14	0.054401	0.054409						
$v = 8$	1.206041	0.167353	0.248155	4.333443	0.196766	0.248378	0.028979	0.322232	0.246925	0.499985						
$v = 9$	0.007354	0.064321	6.38E-15	0.06749	0.073917	6.40E-15	0.5125	0.186858	6.42E-15	0.130917						
$v = 10$	0.716331	6.23E-14	0.056955	13.84749	4.61E-14	0.056806	0.110691	7.74E-14	0.056547	0.056727						
$v = 11$	0.086236	2.28E-14	0.056451	0.429997	2.28E-14	0.056464	4.75168	1.94E-14	0.056508	0.056483						
$v = 12$	0.023288	1.81E-15	0.056357	0.084627	1.49E-15	0.056508	0.763703	1.60E-15	0.056559	0.056474						
$v = 1$	3.118997	1.94E-13	0.057441	1.288759	1.87E-13	0.051855	0.059737	1.34E-13	0.057241	0.057025						
$v = 2$	0.136313	5.72E-14	0.056762	1.747001	7.92E-14	0.057005	0.015388	2.16E-14	0.056011	0.056371						
$v = 3$	0.012054	6.61E-14	0.061	0.335009	8.15E-14	0.062053	17.68471	4.97E-14	0.061986	0.06159						
$v = 4$	0.370198	0.474384	1.03E-14	0.359869	0.416532	1.04E-14	0.000193	0.154217	1.04E-14	0.298568						
$v = 5$	0.315342	0.966549	1.98E-16	1.493956	1.011936	1.99E-16	0.000313	0.32001	1.99E-16	0.620473						
$\prod_{v=1}^S (a_{v,1}^{(k)} + \beta_{v,1}^{(k)})$	9.9653e-11			1.2368e-10			2.0325e-11									
ϕ	7.1440e-11															
Log Likelihood	-34.338															
	Number of observations outside the limits									16						

و بالنظر الى نتائج جدول (7) نجد أن نموذج (7) نجد أن نموذج M-PGARCH₁₂(3;1,1,1 ; 1,1,1) المقدر مكون من ثلاثة نماذج PGARCH(1,1) عند $k=1, 2, 3$. حيث نجد أن المكون k ذو أعلى معلمة خلط "mixing parameter" يكون عند $k=3$ بعلمه خلط $\lambda_3 = 0.53915$ ويكون له تقلبات متخصصة طويلة المدى. بينما المكونين الآخرين عند $k=1$ و $k=2$ يكون لهم معامل خلط $\lambda_2 = 0.40559$ و $\lambda_1 = 0.05525$ حيث أن قيمة $\prod_{v=1}^S (\alpha_{v,1}^{(k)} + \beta_{v,1}^{(k)})$ عند $k=1, 2, 3$ و التي تعد شرط السكون لكل مكون k , تكون $\prod_{v=1}^S (\alpha_{v,1}^{(k)} + \beta_{v,1}^{(k)})$ على الترتيب، وبفحص قيم $2.0325e-11, 9.9653e-11, 1.2368e-10$ نجد أن التقلبات للثلاثة مكونات مترابطة. ونلاحظ أن معالم النموذج المقدر M-PGARCH₁₂(3;1,1,1 ; 1,1,1) لها سكون دوري ضعيف ويظهر ذلك بالنظر لقيمة φ والتي تكون $= \varphi < 1$ حيث نجد أن $\prod_{v=0}^{S-1} (\sum_{k=1}^K \lambda_k (\alpha_{v,1}^{(k)} + \beta_{v,1}^{(k)})) < 1$ لهذا النموذج. وعند تحليل النموذج المقدر لكل موسم من المواسم نجد أن فقط النموذج المقابل للموسم $6 = \eta$ اي الخاص بشهر يونيو يكون غير ساكن دوري حيث أن قيمة $\sum_{v=1}^S \lambda_k (\alpha_{v,1}^{(k)} + \beta_{v,1}^{(k)})$ لكل الموسم أقل من الواحد فيما عدا عند $6 = \eta$ تكون أكبر من الواحد على عكس نموذج M-PGARCH₁₂(2;1,1;1,1) الذي يوجد به عدم سكون عند ثلاثة مواسم دورية.

وبالنظر لما تقدم من تحليل للنموذجين نجد أن قيمة Log-Likelihood لنموذج M-PGARCH₁₂(3;1,1,1 ; 1,1,1) وهي -34.338 أكبر من قيمة Log-Likelihood لنموذج M-PGARCH₁₂(2;1,1;1,1) والتي تساوى -127.1197، كما نجد أن النموذجين ككل ساكتين دوريان وعند كل مكون k نجد أن هناك سكون دوري الا أنه عند فحص السكون الدوري لكل موسم من المواسم لكل نموذج يتضح أن نموذج M-PGARCH₁₂(3;1,1,1 ; 1,1,1) هو الأفضل حيث يكون فقط النموذج عند الموسم $6 = \eta$ غير ساكن بينما يكون ساكن في باقي المواسم الدورية الشهرية على عكس نموذج M-PGARCH₁₂(2;1,1;1,1) الذي يتواجد به عدم سكون دوري عند ثلاثة مواسم دورية هم $5, 6, 8$. ويعرض شكل (7) فترة الثقة للباقي $\hat{h}_t = \sqrt{\hat{h}_t} \pm \sqrt{\hat{h}_t}$ حيث أن $\hat{\sigma}$ هي الوسط الحسابي لسلسلة الباقي كما أن \hat{h}_t تغير عن التقلبات (التباينيات) المقدرة "estimated volatility" حيث أن $\hat{h}_t = \sqrt{\mathbb{E}(y_t^2 | \mathcal{F}_{t-1}, \underline{\theta} = \hat{\underline{\theta}})}$. وبفحص شكل (7) نجد أن عدد المشاهدات التي تقع خارج حدود الثقة لكلا النموذجين مقارب جدا حيث يكون هناك 14 مشاهدة خارج

حدود الثقة لنموذج (1) بينما يكون هناك 16 مشاهدة خارج حدود الثقة لنموذج $M\text{-PGARCH}_{12}(3;1,1,1;1,1,1)$. وبالتالي وبناء على ما تقدم من تحليل يمكن القول ان نموذج (1) هو الأفضل والأكثر تعبيراً عن البيانات.



شكل(7): يعرض فترة الثقة لبيانات سلسلة الباقي بالاعتماد على نماذج M_PGARCH المقترنة.

النتائج Conclusions

تناول البحث أحد أهم نماذج السلسل الزمنية الخطية الشائع استخدامها مع البيانات الموسمية ذات الطابع الدوري وهي نماذج PARMA. حيث تم دراسة خصائص النموذج وتقدير معالمه واختيار النموذج الأفضل من بين البدائل المتاحة بالتطبيق على بيانات سعر صرف الجنية المصري أمام الدولار الأمريكي حيث يعد سعر الصرف أحد اهم الادوات المالية المؤثرة على الاقتصاد المصري. ولحل مشكلة عدد المعالم الكبير التي تظهر في مرحلة التقدير تم استخدام تمثيل فوريير لمعالم نموذج PARMA عن طريق تحويلة فوريير المقطعة DFT والتي من خلالها استطعنا خفض عدد المعالم المقدرة من 60 معلومة

الى 25 معلمة فقط، ونتيجة لان سلسلة الباقي لمودج $\text{PARMA}_{12}(1,1,3)$ المقدر لم تكن ساكنة بل كان بها تقلبات وتباعدات يجب دراستها اقتربت الدراسة استخدام فئة من النماذج غير الخطية للسلسل الزمنية الدورية وهي نماذج GARCH الدورية المختلط "M-PGARCH". حيث تسمح نماذج M-PGARCH بالتقاط النمط الدوري والتغير المفاجئ والبيانات المتغيرة للباقي بالإضافة الى شكل التوزيعات الشرطية والتي تظهر بشكل دائم مع السلسل الزمنية المالية والاقتصادية. حيث تم دراسة الخصائص الاحتمالية لهذه الفئة من النماذج وكذلك طريقة التقدير. وأشارت النتائج الى أن نموذج M-PGARCH₁₂(3;1,1,1;1,1,1) قادر على التقاط ظاهرة التغيرات المفاجئة في التقلبات بشكل جيد للغاية وبشكل أكثر مرونة وأكثر اختزلاً "parsimonious" حيث ان هناك الكثير من المعالم المقدرة تؤول قيمتها الى الصفر. وبالمقارنة بين استخدام نموذج PARMA فقط لوصف البيانات وبين استخدام نموذج PARMA مع نموذج M-PGARCH نلاحظ أن نموذج PARMA كان ينقصه الوصف الدقيق للتغيرات الدورية في الباقي والتي لم تكن ساكنة هذا بالإضافة الى الالتواء والتفرطع الذي ظهر عند حساب المقاييس الوصفية لها. ان استخدام نموذج M-PGARCH₁₂(3;1,1,1;1,1,1) مع نموذج PARMA₁₂(1,1,3) قد ساعد في وصف الخليط الدوري لتلك التقلبات بشكل دقيق واظهار مواضع عدم السكون في السلسلة التي أدت الى تلك التقلبات وذلك من خلال قدرته على اظهار السكون الدوري لكل عنصر من عناصر الخليط الدوري بالإضافة الى دراسة السكون لكل موسم من المواسم على التوازي مما يمكننا من تفسير تلك التقلبات في الباقي بشكل واضح ودقيق. ويوصي الباحث بتطوير نسخة دورية متعددة المتغيرات من هذا النموذج من أجل الاخذ في الاعتبار المتغيرات الأخرى والتي يكون لها تأثير كبير على الاقتصاد.

المراجع

- Abdallah, M. (2013) Generation of PAR Time Series Models Using Periodic Levinson-Durbin Algorithm. (MSc). The Islamic University of Gaza.
- Abo-Hammour, Z. Al-Smadi, O. Al-Smadi, A. M. Zaqout, M. and Saraireh, M. (2012) ARMA Model Order and Parameter Estimation using Genetic Algorithms. Mathematical and Computer Modeling of Dynamical Systems. 18(2), 201–221.
- Akgün, B. (2003) Identification of Periodic Autoregressive Moving Average Models. (MSc). Middle East Technical University.
- Anderson, P. L. and Meerschaert, M. M. (1998) Modelling river flows with heavy tails. Water Resources Research. 34(9), 2271–80.
- Anderson, P. L., Tesfaye, Y. G., & Meerschaert, M. M. (2007). Fourier-PARMA Models and Their Application to River Flows. Journal of Hydrologic Engineering, 12(5), 462–472. [https://doi.org/10.1061/\(asce\)1084-0699\(2007\)12:5\(462\)](https://doi.org/10.1061/(asce)1084-0699(2007)12:5(462))
- Anderson, P. Meerschaert, M. and Zhang, K. (2013) Forecasting with prediction intervals for periodic autoregressive moving average models. Journal of Time Series Analysis. 34, 187-193.
- Ansley, C.F. (1979), An algorithm for the exact likelihood of a mixed autoregressive-moving average process. Biometrika 66(1), 59–65.
- Basawa, I. and Lund, R. (2001) Large sample properties of parameter estimates for periodic ARMA models. Journal of Time Series Analysis 22, 651–63.
- Bentarzi M, Hamdi F (2008a) Mixture periodic autoregressive conditional heteroskedastic models. Comput Stat Data Anal 53:1–16
- Bentarzi M, Hamdi F (2008b) Mixture periodic autoregression with periodic ARCH errors. Adv Appl Stat 8:219–246
- Bentarzi, M., & Hamdi, F. (2008). Mixture periodic autoregressive conditional heteroskedastic models. Computational Statistics and Data Analysis, 53(1), 1–16. <https://doi.org/10.1016/j.csda.2008.06.019>
- Bowers, M. C. Tung, W. W. and Gao, J. B. (2012) On the distributions of seasonal river flows: lognormal or power law?. Water Resources Research.48, W05536
- Dudek, A. E., Hurd, H., & Wójtowicz, W. (2016). Periodic autoregressive moving average methods based on Fourier representation of periodic

- coefficients. Wiley Interdisciplinary Reviews: Computational Statistics, 8(3), 130–149. <https://doi.org/10.1002/wics.1380>
- Fan, P. ying, Wu, S. xin, Zhao, Z. long, & Chen, M. (2017). M-estimation for periodic GARCH model with high-frequency data. Acta Mathematicae Applicatae Sinica, 33(3), 717–730. <https://doi.org/10.1007/s10255-017-0694-x>
 - Ferwana, A. (2011). Periodically Correlated Time Series Models: Representation and Identification. September.(PhD). The Islamic University of Gaza.
 - Francq, C. Roy, R. and Saidi, A. (2011) Asymptotic Properties of Weighted Least Squares Estimation in Weak PARMA Models. Journal of Time Series Analysis.
 - Franses, P. and Paap, R. (2004) Periodic Time Series Models. New York: Oxford University Press.
 - Gladyshev, E. G. (1961) Periodically correlated random sequences. Soviet Mathematics 2, 385–88.
 - Hamdi, F., & Souam, S. (2013). Mixture periodic GARCH models: Applications to exchange rate modeling. 2013 5th International Conference on Modeling, Simulation and Applied Optimization, ICMSAO 2013, November 2015. <https://doi.org/10.1109/ICMSAO.2013.6552570>
 - Hamdi, F., & Souam, S. (2017). Mixture periodic GARCH models: theory and applications. Empirical Economics, 55(4), 1925–1956. <https://doi.org/10.1007/s00181-017-1348-9>
 - Hamilton, J. (1994) Time Series Analysis. Princeton University Press, NJ.
 - Hillmer, S and Tiao, G (1979) Likelihood function of stationary multiple autoregressive-moving average models, Journal of the American Statistical Association 74 (3) 652–660.
 - Hipel, K. and McLeod, A. (1994) Time Series Modelling of Water Resources and Environmental Systems. London; Amsterdam: Elsevier.
 - Jones, R. H. and Breisford, W. M. (1967) Times series with periodic structure. Biometrika 54, 403–8.
 - Jose' ,A , Sarnaglia,Q , Reisen, V , Bondon,P and Leduc,C. (2021) M-regression spectral estimator for periodic ARMA models. An empirical investigation. Stochastic Environmental Research and Risk Assessment 35:653–664

- Lund, R. and Basawa, I. (2000) Recursive prediction and likelihood evaluation for periodic ARMA models. *Journal of Time Series Analysis* 21, 75–93.
- Lund, R. Shao, Q. and Basawa, I. V. (2006) Parsimonious periodic time series modeling. *Australian & New Zealand Journal of Statistics* 48, 33–47.
- McLeod, A. (1994) Diagnostic checking periodic autoregression models with applications. *Journal of Time Series Analysis* 15, 221–33.
- Sarnaglia, A., Reisen, V. and Bondon, P.(2021) M-regression spectral estimator for periodic ARMA models. An empirical investigation. *Stochastic Environmental Research and Risk Assessment*.
- Shao, Q. (2006). Mixture periodic autoregressive time series models. *Statistics and Probability Letters*, 76(6), 609–618.
<https://doi.org/10.1016/j.spl.2005.09.015>
- Tesfay, G. (2005) Seasonal Time Series Models and Their Application to the Modeling of River Flows. (PhD). Reno: University of Nevada.
- Tesfaye, Y. Anderson, P. and Meerschaert, M. (2010) Asymptotic results for Fourier- PARMA time series. *Journal of Time Series Analysis*. 32, 157-174.
- Troutman, B. (1979) Some results in periodic auto regression. *Biometrika* 66, 219–28.
- Ursu, E. and Turkman, K. (2012) Periodic Autoregressive Model Identification using Genetic Algorithms. *J. Time Ser. Anal.* 33, 398–405.
- Vecchia, A.V., 1985a. Periodic autoregressive-moving average (PARMA) modeling with applications to water resources. *Water Resour. Bull.* 21, 721–730.
- Vecchia, A.V., 1985b. Maximum likelihood estimation for periodic autoregressive moving average models. *Technometrics* 27, 375–384.