

نموذج تنبؤ مقترح باستخدام السلاسل الزمنية ذات المعلومات المتغيرة مع الزمن "دراسة تطبيقية"

الباحثة: أسماء السعيد إسماعيل الشربيني

مدرس مساعد بقسم الإحصاء التطبيقي والتأمين كلية التجارة – جامعة المنصورة

الأستاذ الدكتور: فاطمة علي عبد العاطي

أستاذ الإحصاء التطبيقي كلية التجارة – جامعة المنصورة

الأستاذ الدكتور: إبراهيم محمد مهدى (رحمه الله)

أستاذ الرياضيات والإحصاء الاكتواري كلية التجارة – جامعة المنصورة

الدكتور: محمد إبراهيم الصعيدي

مدرس الإحصاء التطبيقي كلية التجارة – جامعة المنصورة

ملخص:

تهدف هذه الدراسة إلى التنبؤ بأسعار الصرف في ظل مشكلتي الذاكرة الطويلة والمعلومات المتغيرة مع الزمن. ولتحقيق هذا الهدف، تم تطبيق أربعة نماذج إحصائية على بيانات أسعار الصرف اليومية للدولار الأمريكي مقابل الجنيه المصري خلال الفترة من عام ٢٠٢٠م حتى ٢٠٢٤م، وهي:

١. نموذج ARIMA الذي يعتمد على الفرق الأول لتسكين السلسلة الزمنية.
 ٢. نموذج ARFIMA الذي يفترض ثبات معلمة الذاكرة الطويلة.
 ٣. نموذج GAS الذي يعالج مشكلة التباين غير الثابت.
 ٤. النموذج المقترح في هذه الدراسة Rolling ARFIMA الذي يسمح بتغير معلمة الذاكرة الطويلة مع الزمن باستخدام نوافذ زمنية متحركة.
- وأظهر نموذج Rolling ARFIMA أفضل أداء تنبؤي عند الأفق الطويل (٩٠ مشاهدة)، بفضل قدرته على تمثيل التغير الديناميكي في معلمة الذاكرة الطويلة. أما نموذج GAS فتميز بدقة عالية في الأفق القصير (٦٠ مشاهدة)، لكنه فقد كفاءته مع زيادة فترة التنبؤ. في المقابل، قدم نموذج ARIMA أداءً مقبولاً على المدى القصير، لكنه لم يكن مناسباً للبيانات ذات التباين المتغير. بينما سجل نموذج ARFIMA أقل أداء بين النماذج، نتيجة ثبات معلمة الذاكرة الطويلة، الذي لا يتماشى مع طبيعة البيانات المتقلبة. وتشير النتائج إلى تفوق النماذج ذات المعلومات المتغيرة على النماذج التقليدية.

الكلمات المفتاحية:

أسعار الصرف؛ الذاكرة الطويلة؛ المعلومات المتغيرة مع الزمن؛ Rolling ARFIMA

Abstract:

This study aims to forecast exchange rates in light of two key challenges: long memory and time-varying parameters. To achieve this objective, four statistical models were applied to the daily exchange rate data of the US dollar against the Egyptian pound during the period from 2020 to 2024:

1. ARIMA model, which relies on first-order differencing to stationarizes the time series.
2. ARFIMA model, which assumes a constant long memory parameter.
3. GAS model, which addresses the issue of time-varying volatility.
4. The proposed model in this study, Rolling ARFIMA, which allows the long memory parameter to vary over time using rolling windows.

The Rolling ARFIMA model demonstrated the best forecasting performance in the long-term horizon (90 observations), due to its ability to capture dynamic changes in the long-memory parameter. In contrast, the GAS model showed high accuracy in the short term (60 observations), but its performance declined significantly with longer forecast horizons. The ARIMA model performed reasonably well in the short term but was unsuitable for data with changing volatility. The ARFIMA model recorded the weakest performance, as its assumption of a constant long-memory parameter did not align with the volatile nature of the data. The results highlight the superiority of models with time-varying parameters over traditional fixed-parameter models.

Keywords:

Exchange Rates- Long Memory – Time-Varying Parameters- Rolling ARFIMA

١ - مقدمة

يتمثل مجال التطبيق في هذه الدراسة في التنبؤ بأسعار الصرف والتي تُعد من أبرز المتغيرات الاقتصادية التي خضعت للدراسة منذ تحوُّل الدول الصناعية الكبرى إلى نظام

تعويم سعر الصرف في السبعينات. فقد اكتسبت خصائصها الزمنية أهمية كبيرة في فهم النماذج الاقتصادية وتحسين دقة التنبؤ بها.

غير أن السلاسل المالية والاقتصادية غالباً ما تتعرض لصدمات طويلة المدى، مما يجعل نماذج السلاسل الزمنية التقليدية - مثل نماذج الانحدار الذاتي - غير كافية في تمثيل تلك الخصائص. ولهذا، يوصى باستخدام نماذج الذاكرة الطويلة مثل نماذج التكامل الكسري (ARFIMA)، التي تتيح تمثيلاً أفضل للتقلبات المستمرة.

وعلى الرغم من أن نماذج الذاكرة الطويلة الثابتة قد حظيت باهتمام واسع في الدراسات السابقة، فإن افتراض ثبات المعلمات مع مرور الزمن قد لا يكون مناسباً في حالة البيانات المالية أو الاقتصادية التي تمتد لفترات زمنية طويلة أو تشهد تغيرات في السياسات أو سلوك الأسواق. إذ يؤدي ذلك إلى عدم استقرار في خصائص السلسلة الزمنية، مما يضعف من كفاءة التنبؤ. مما يستدعي استخدام نماذج ديناميكية تسمح بتغير المعلمات مع الزمن لتحسين دقة التنبؤ.

لذا، فإن الحاجة أصبحت ملحة لنمذجة معلمة الذاكرة الطويلة بشكل زمني (d_t)، وقد طُورت عدة نماذج لتحقيق ذلك، من أبرزها النموذج الذاتي المعمم المعتمد على النتيجة (Generalized Autoregressive Score - GAS).

وبالإضافة إلى النماذج الحديثة مثل GAS، تُعد نماذج Rolling ARFIMA من الأساليب الواعدة التي تسمح بتغير معلمة الذاكرة الطويلة عبر الزمن دون الحاجة إلى افتراض شكل محدد لهذا التغير. ويقوم هذا النموذج على تقدير المعلمات داخل نوافذ زمنية متحركة، مما يجعله أكثر مرونة في التعامل مع تقلبات الأسواق والصدمات المفاجئة.

ونظراً لندرة الدراسات التي تناولت استخدام نموذج Rolling ARFIMA في تحليل أسعار الصرف، تسعى هذه الدراسة إلى سد هذه الفجوة من خلال تقديم تطبيق جديد لهذا النموذج، بما يتيح تتبع تغيرات معلمة الذاكرة الطويلة (d_t) بمرور الزمن بطريقة مرنة وواقعية. ، وتطبيقه على بيانات أسعار الصرف اليومية للدولار الأمريكي مقابل الجنيه المصري خلال الفترة (٢٠٢٠م-٢٠٢٤م).

٢- مشكلة البحث

تُظهر بيانات السلسلة الزمنية لأسعار الصرف اليومية للدولار الأمريكي مقابل الجنيه المصري خلال الفترة (٢٠٢٠-٢٠٢٤م) خصائص مركبة، تتمثل في وجود أثر للذاكرة الطويلة بالإضافة إلى عدم الخطية التي تؤدي إلى تغير المعلمات بمرور الزمن ومن ثم، تتمثل مشكلة الدراسة في كيفية نمذجة معلمة الذاكرة الطويلة المتغيرة مع الزمن d_t بما يسمح بتمثيل ديناميكية أسعار الصرف بدقة أكبر، بهدف الوصول إلى أفضل أداء تنبؤي في ظل التقلبات المستمرة التي تتسم بها تلك السلاسل المالية.

٣- هدف البحث

تهدف هذه الدراسة إلى تحليل السلسلة الزمنية لأسعار الصرف اليومية للدولار الأمريكي مقابل الجنيه المصري خلال الفترة (٢٠٢٠-٢٠٢٤م)، وذلك من خلال:

- (١) تحديد طبيعة السلسلة من حيث كونها قصيرة الذاكرة أو طويلة الذاكرة.
- (٢) بناء نموذج ARFIMA لتقدير السلسلة بافتراض ثبات المعلمات عبر الزمن.
- (٣) تطبيق النموذج المقترح (Rolling ARFIMA) الذي يسمح بتغير معلمة الذاكرة الطويلة مع مرور الزمن.
- (٤) مقارنة أداء النموذجين في التنبؤ بأسعار الصرف، بهدف التحقق من مدى كفاءة كل نموذج في تمثيل سلوك السلسلة.
- (٥) تقييم دقة التنبؤ باستخدام معايير دقة التنبؤ.

٤- أهمية البحث:

أولا الأهمية العلمية:

تتبع الأهمية العلمية للدراسة من تقديمها معالجة إحصائية متقدمة لبيانات السلاسل الزمنية التي تنقسم بالذاكرة الطويلة والمعلومات المتغيرة عبر الزمن. وذلك من خلال تطبيق النموذج المقترح (Rolling ARFIMA) ، الذي يُعد من الأساليب الحديثة في التعامل مع التقلبات الديناميكية للأسواق المالية. وتمثل هذه الدراسة مساهمة في إثراء الأدبيات العلمية من خلال تقديم نموذج أكثر مرونة وكفاءة في التنبؤ في ظل بيئات تتصف بعدم الاستقرار.

ثانيا: الأهمية العملية:

تتمثل الأهمية العملية للدراسة في بناء نموذج إحصائي يُستخدم للتنبؤ بأسعار الصرف في جمهورية مصر العربية خلال الفترة (٢٠٢٠-٢٠٢٤م)، بما يُمكن من مواجهة التقلبات الحادة في سعر الصرف.

وقد تم تقسيم الدراسة في هذا البحث على النحو التالي، تم تخصيص الفصل الثاني لعرض السلاسل الزمنية ذات الذاكرة الطويلة، أما الفصل الثالث فقد تم تخصيصه للتعرف على المعلومات المتغيرة مع الزمن، أما الفصل الرابع عرض النموذج المقترح للدراسة، وتم عرض الدراسة التطبيقية الخاصة بالبحث في الفصل الخامس وأخيرا الفصل السادس الذي يتضمن النتائج والتوصيات الخاصة بالدراسة.

٥- السلاسل الزمنية ذات الذاكرة الطويلة:

الذاكرة الطويلة هي ظاهرة يمكن ملاحظتها في بيانات السلاسل الزمنية وتضح عندما يكون الفرق الزمني بين مشاهدتين أكثر تباعدا ويؤثر بشكل كبير على المجال المالي.

٥-١ التحقق من خاصية الذاكرة الطويلة:

١- الرسم البياني لدالة الارتباط الذاتي (Autocorrelation Function Plot):

يمكن تحديد ظاهرة الذاكرة الطويلة عندما تتناقص دالة ACF ببطء عن التناقص الاسي وفقا للصيغة التالية:

$$\rho(h) = \frac{\Gamma(1-d)\Gamma(h+d)}{\Gamma(d)\Gamma(1+h-d)} \quad (5-1)$$

حيث: $-0.5 < d < 0.5$ ، $h \rightarrow \infty$.

٢- الرسم البياني R/S :

خطوات الحصول على هذا الرسم البياني:

يتم حساب ($R/S = Q$) لجميع القيم الممكنة عبر الزمن t والفجوة $Lag(k)$ حيث R تعبر عن المدى، S تعبر عن الانحراف المعياري.

- نرسم $Log(K), Log(Q)$.
- الخط المستقيم $y = a \pm b \log(k)$
- تقدير المعاملات a, b باستخدام طريقة المربعات الصغرى.

٣- الرسم البياني لدالة الكثافة الطيفية (Spectral Density Function):

أبسط استخدام من خلال رسم دالة الكثافة الطيفية حيث نلاحظ تركز أغلب البيانات حول نقطة الصفر. ويجب صياغة دالة الكثافة الطيفية قبل انشاء الرسم البياني، وتكون الصيغة على النحو التالي كما قدمها (J.Beran 1994):
عملية التغيرات الساكنة X_t تكون عملية ذات ذاكرة طويلة اذا كانت دالة الكثافة الطيفية f عند $\lambda \rightarrow 0^+$ هي:

$$f(\lambda) \sim G_f(\lambda) \cdot |\lambda|^{-2d}, \quad d \in \left(0, \frac{1}{2}\right) \quad (5-2)$$

حيث:

$$G_f(\lambda) = \frac{\sigma_\epsilon^2 |\psi(1)|^2}{2\pi |\phi(1)|^2} \quad (5-3)$$

$\psi(1)$ هي المتوسط المتحرك، $\phi(1)$ هي الانحدار الذاتي متعددة الحدود، وعامل الفجوة للخلف $= 1$ ، وتتغير الدالة السابقة تدريجيا الي الصفر عند التكرار صفر، أي ان معظم البيانات تتركز حول الصفر.

٤- تحليل R/S (Rescaled Range) :

قدم الباحث (Hurst 1951) هذه الطريقة لأول مرة في ميدان الري، حيث يتم في هذا التحليل تقسيم المدي على الانحراف المعياري، ووجد (Mandelbrot 1972) ان تحليل R/S قد أظهر خصائص أفضل من ACF وتحليلات دالة التباين الزمني، وقام (A.W.LO 1991) بتعديل تحليل R/S وحدد انه أداة قوية للتوزيعات غير الطبيعية، والاعتماد قصير المدى، والتغيرات الشرطي تحت فرضية العدم، وفيما يلي صيغة تحليل R/S :

$$\frac{R(n)}{S(n)} = \frac{\max_{1 \leq k \leq n} \sum_{i=1}^k (X_i - \bar{X}_n) - \min_{1 \leq k \leq n} \sum_{i=1}^k (X_i - \bar{X}_n)}{\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right)^{\frac{1}{2}}} \quad (5-4)$$

حيث n تمثل حجم العينة، $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ ، k هي عدد المجاميع الجزئية بين مفردات السلسلة X_t ومتوسطها الحسابي $\bar{X}_t$ ، وأثبت Hurst رياضيا أن قيمة الإحصائية R_n/S_n موجبة دائما ويمكن تقريبها بالعلاقة الآتية:

$$R_n/S_n = Q_n = n^H \quad (5 - 5)$$

حيث H عبارة عن ثابت يسمى بمعامل Hurst وقيمته محصورة بين $0 < H < 1$ ويمكن حسابه من المعادلة (5-5) كما يلي:

$$H \cong \frac{\log Q_n}{\log n} \quad (5 - 6)$$

وتمكن فيما بعد الباحثين (Mandelbort and van Ness 1968) من تحديد العلاقة بين معامل Hurst ومعامل درجة التكامل الكسري لنماذج ARFIMA أي المعامل d كما يلي:

$$d = H - \frac{1}{2} \quad (5 - 7)$$

ومن خلال هذه العلاقة يمكن تحديد قيمة d ومعرفة فيما اذا كانت السلسلة ذات ذاكرة طويلة.

٥- إحصائية LO:

لقد أثبت الباحث (Andrews Lo 1991) بأن تحليل R/S يمكن أن يكون متحيزا ويعطي نتائج مضللة حول وجود ذاكرة طويلة، وهذا في الحالة التي يكون هناك ارتباط ذاتي في المدى القصير بالنسبة للسلسلة الزمنية قيد الدراسة، لذلك اقترح الباحث Lo إحصائية أخرى ل R/S معدلة كما يلي:

$$\tilde{Q}_n = \frac{\max_{1 \leq k \leq n} \sum_{i=1}^k (X_i - \bar{X}_n) - \min_{1 \leq k \leq n} \sum_{i=1}^k (X_i - \bar{X}_n)}{\left[\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 + \frac{2}{n} \sum_{i=1}^q \omega(q) \left(\sum_{j=i+1}^n (X_i - \bar{X}_n)(X_{j-i} - \bar{X}_n) \right) \right]^{1/2}} \quad (5-8)$$

$$\omega_i(q) = 1 - \frac{i}{q+1} \quad (5 - 9)$$

تختلف الإحصائية $\tilde{Q}_n$ عن الإحصائية Q_n لأنها لا تأخذ بعين الاعتبار التباينات لقيم المفردات فقط، وإنما تأخذ أيضا التباينات المشتركة المرجحة كدالة تابعة لمعامل التأخر q ، حيث اقترح الباحث Lo القاعدة الآتية لاختيار المعامل q :

$$q = \left[\left(\frac{3n}{2} \right)^{1/3} \left(\frac{2\hat{p}}{1-\hat{p}} \right)^{2/3} \right] \quad (5-10)$$

حيث:

$\hat{p}$ هو عبارة عن المعلمة المقدرة لنموذج الانحدار الذاتي AR(1).

ليتم فيما بعد تحديد قيمة الإحصائية V_{cal} الحسابية كما يلي:

$$V_{cal} = \frac{\tilde{Q}_n}{\sqrt{n}} \quad (5-11)$$

وعليه فمن أجل اختبار وجود ذاكرة طويلة فإنه يجب اختبار الفرضيتين الاتيتين:
 H_0 يوجد ذاكرة قصيرة في السلسلة الزمنية وهذا يعنى ان $H=0.5$ ويتم قبولها عند مستوى معنوية 5% ، اذا كانت $v \in [0.809; 1.862]$.

H_1 يوجد ذاكرة طويلة في السلسلة الزمنية إذا تم رفض الفرض العدمي H_0 .

٢-٥ طرق تقدير معلمة الذاكرة الطويلة:

يوجد العديد من الطرق لتقدير معلمة الذاكرة الطويلة (d) منها:

١. معامل هيرست (Hurst Exponent):

قام (Hurst 1951) باقتراح هذه الطريقة لتقدير معلمة الذاكرة الطويلة وتحسب من الصيغة التالية:

$$Q_{(n)} = \frac{R_{(n)}^*}{S_{(n)}^*} = \frac{\max_{1 \leq k \leq n} \sum_{i=1}^k (X_i - \bar{X}_n) - \min_{1 \leq k \leq n} \sum_{i=1}^k (X_i - \bar{X}_n)}{\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \right)^{\frac{1}{2}}} \quad (5-12)$$

٢. المقدّر (GPH's):

بالاعتماد على معادلة الانحدار Y_i اقترح كل من (Geweke and Porter-1983) تقدير المعلمة $\hat{d}_n$ من خلال طريقة المربعات الصغرى وفقا للمعادلة التالية:

$$\hat{d}_n = - \left(\sum_{i=1}^n (X_i - \bar{X})^2 \right)^{-1} \left(\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right) \quad (5-13)$$

حيث:

$$Y_i = \alpha + \beta X_i + \varepsilon_i, \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i \quad (5-14)$$

أوضح كلا من Agiakloglou, Newbold and Wohar (1992) أن مقدر GPH له تحيز كبير في العينة المحددة، وهو غير فعال عندما تكون ε_t عملية مستمرة في AR أو MA.

٣. دالة الفروق الكسرية (Fracdiff):

هي دالة أخرى في برنامج R تستخدم لتقدير قيمة d في دالة الفروق الكسرية (Fracdiff). تستخدم هذه الدالة طريقة تقدير الانحدار لتقدير الفرق الكسري d من نموذج ARFIMA.

ويتم تعريفه باستخدام سلسلة ذات الحدين على النحو التالي:

$$\begin{aligned} \nabla^d &= (1 - B)^d = \sum_{k=0}^{\infty} \binom{d}{k} (-B)^k \\ &= 1 - dB - \frac{1}{2}d(1-d)B^2 - \frac{1}{6}d(1-d)(2-d)B^3 \\ &\quad - \dots \end{aligned} \quad (5-15)$$

٣-٥ نموذج الذاكرة الطويلة (ARFIMA):

يقال ان السلسلة الزمنية (x_t) تتبع نموذج ARFIMA (p,d,q) اذا كان:

$$\phi_p(L)\nabla^d x_t = \theta_q(L)\varepsilon_t \quad (5-16)$$

$$\phi_p(L) = (1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p) \quad (5-17)$$

$$\theta_q(L) = (1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q) \quad (5-18)$$

$$\nabla^d = (1 - L)^d \quad (5-19)$$

حيث

ϕ_p هي كثيرة الحدود لنماذج الانحدار الذاتي من الرتبة p ويرمز لها بالرمز AR(p)، θ_q هي كثيرة الحدود لنماذج المتوسطات المتحركة من الرتبة q ويرمز لها بالرمز MA(q)،

d (عدد حقيقي) $d \in [-0.5, 0.5]$ ، L عوامل الازاحة الخلفية $L^k X_t = X_{t-k}$ ، ε_t الخطأ العشوائي بمتوسط صفر وتباين ثابت (σ_ε^2) وتمثل عملية الضجة البيضاء.

وفيما يتعلق بقيمة (d) نلاحظ مل يلي:

- (١) إذا كان $(d > -0.5)$ كل جذور كثيرة الحدود $\theta_q(L)$ تقع خارج دائرة الوحدة فإن X_t قابلة للانعكاس Invertible وغير محدودة.
- (٢) إذا كان $(d < -0.5)$ كل جذور كثيرة الحدود $\phi_p(L)$ تقع خارج دائرة الوحدة فإن X_t مستقرة.
- (٣) إذا كان $(-0.5 < d < 0)$ فإن X_t قابلة للانعكاس بذاكرة قصيرة وغير دائمة.
- (٤) إذا كان $(0 < d < 0.5)$ فإن X_t مستقرة بذاكرة طويلة ومستقرة وفي هذه الحالة تتناقص دالة الارتباط الذاتي (التي تعتبر موجبة) بوتيرة بطيئة نحو الصفر على شكل قطع زائد عندما تزيد عدد الفجوات k.
- (٥) إذا كان $(d = 0)$ فإن X_t لديها ذاكرة قصيرة وبالتالي تعتبر نماذج ARIMA ذات ذاكرة قصيرة لان $d = 0$.

يوجد العديد من الطرق التي تستخدم في تقدير نموذج ARFIMA، حيث قسمت هذه الطرق الي قسمين هما:

- أ- طرق التقدير بمرحلة واحدة.
- ب- طرق التقدير بمرحلتين.

غير ان اغلب الدراسات تتجه نحو استخدام طرق التقدير بمرحلتين نظرا لسهولة تطبيقها. حيث في طرق التقدير بمرحلتين يتم تقدير المعلمة d في المرحلة الأولى، وفي المرحلة الثانية يتم تقدير معلمات ARMA معلمة الانحدار الذاتي p ومعلمة المتوسطات المتحركة q للسلسلة المحولة التي تتميز بالتكامل الكسري ويتم تقديرهم بالاعتماد على الطرق التقليدية للسلاسل الزمنية، ومن امثلة طرق التقدير بمرحلتين طريقة GPH حيث يتم تقدير المعلمة d في المرحلة الأولى باستخدام طريقة المربعات الصغرى ويتم في المرحلة الثانية تقدير معلمات ARMA كما في منهجية Box-Jenkins.

٦- المعلمات المتغيرة مع الزمن:

المعلمات المتغيرة مع الزمن تُشير إلى تلك المعلمات التي لا تفترض الثبات خلال الفترة الزمنية محل الدراسة، بل يُفترض أنها تتغير استجابةً لتقلبات البيئة المحيطة أو التحولات الهيكلية في السلسلة الزمنية. وتُستخدم هذه المعلمات في النماذج الديناميكية لتوفير مرونة أكبر في تمثيل العلاقات الاقتصادية أو المالية.

٦-١ اختبارات التحقق من المعلمات المتغيرة مع الزمن:

١- اختبار (Ramsey Test):

اقترح Ramsey طريقة تسمى Reset Test (اختبار خطأ توصيف الانحدار)، لنفترض ان لدينا نموذج الانحدار الخطي التالي:

$$Y_i = \lambda_1 + \lambda_2 X_i + u_i \quad (6 - 1)$$

ونحصل على $(\hat{Y}_i, \hat{u}_i)$ عند تقدير النموذج فاذا لوحظ من خلال الرسم البياني للمقدر $\hat{Y}_i$ وجود أنماط فهناك شك ان النموذج غير مناسب ولا يزال من الممكن نمذجته باستخدام $\hat{Y}_i$. وفيما يلي خطوات اختبار Ramsey:

١- تقدير المتغير التابع Y_i

٢- اذا كان المقدر $\hat{Y}_i$ لديه نمط فانه يمكن إضافة $\hat{Y}_i$ بأشكال أخرى مثل $\hat{Y}_i^2, \hat{Y}_i^3$ لزيادة قيمة R^2 ليصبح نموذج الانحدار كالتالي:

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 \hat{Y}_i^2 + \beta_4 \hat{Y}_i^3 + u_i \quad (6 - 2)$$

٣- حساب قيمة R^2 من نموذج الانحدار الأول والثاني ثم استخدام اختبار F كما يلي:

$$F_{hit} = \frac{(R_{model2}^2 - R_{model1}^2)/k}{(1 - R_{model2}^2)/(n - p_2)} \quad (6 - 3)$$

حيث k هو عدد المتغيرات المستقلة الإضافية، n هي عدد المشاهدات، p_2 هي عدد المتغيرات المستقلة في النموذج الثاني.

٤- اذا كانت $F_{hit} > F(\alpha, k, n - p_2)$ نرفض الفرض العدمي حيث:

الفرض العدمي: النموذج الأول خطي،

الفرض البديل: النموذج الأول غير خطي.

٢- اختبار (White test):

هذا الاختبار مبني على نماذج الشبكات العصبية Neural network ومن أشهرها شبكة التغذية الامامية ذات الطبقة الخفية الواحدة، وفيما يلي معادلة نموذج الشبكة العصبية المكون من طبقة خفية واحدة وعدد q نيرون:

$$f(x, \theta) = \tilde{x}\gamma_o + \sum_{j=1}^q \beta_j \varphi(\tilde{x}\gamma_j) = o \quad (6 - 4)$$

حيث

O: مخرجات الشبكة.

$\tilde{x}\gamma_0$: المكون الخطي.

$\sum_{j=1}^q \beta_j \varphi(\tilde{x}\gamma_j)$: المكون غير الخطي.

β_j : وزن الشبكة العصبية من الطبقة الخفية الي طبقة المخرجات.

γ_j : وزن الشبكة العصبية من طبقة المدخلات الي الطبقة الخفية.

φ : هي دالة التحفيز (sigmoid function).

يكون النموذج خطي عندما تكون قيمة $(q = 0)$ حيث يوجد طبقتين فقط (طبقة المدخلات وطبقة المخرجات)، والفرض العدمي لاختبار White test هو:

$$H_0: \beta_1 = \dots = \beta_q = 0$$

ويتحقق الفرض العدمي للخطية عندما تساوي الاوزان صفر.

٦-٢ السلاسل الزمنية ذات المعلمات المتغيرة مع الزمن:

قام (Cox 1981) بتصنيف نماذج السلاسل الزمنية ذات المعلمات المتغيرة مع الزمن (Time-varying parameters) إلى نوعين من النماذج:

(١) النماذج المعتمدة على الملاحظة Observation-driven models.

(٢) النماذج المعتمدة على المعلمة Parameter-driven models.

أولاً: في النماذج المعتمدة على الملاحظة تكون المعلمات الحالية عبارة عن دوال محددة وبالرغم من ان المعلمات تتطور بشكل عشوائي مع الزمن لكنه يمكن التنبؤ بها بخطوة واحدة للأمام بشكل مثالي بالاعتماد على المعلومات السابقة، وإجراءات التقدير البسيطة لهذه النماذج حيث ان الإمكان الأعظم متاح في شكله المعروف من خلال تحليل أخطاء التنبؤ

ثانياً: في النماذج المعتمدة على المعلمة تتغير المعلمات مع الزمن كعمليات ديناميكية لها تجديدات خاصة. لكن في ظل المشاهدات الماضية والحالية المعطاة فإن التنبؤ بالمعلمات يكون غير مثالي ويعتبر تقدير معظم هذه النماذج أكثر تعقيداً لأنها تعتمد في حساب دالة الإمكان الأعظم على التكامل المتعدد بسبب وجود عدد كبير من المتغيرات في هذه النماذج. فنجد ان دوال الإمكان الأعظم الخاصة بها غير متوفرة في شكلها المعروف، ويتم تطبيق طرق المحاكاة لحساب الدالة اللوغاريتمية للإمكان الأعظم.

٦-٣ نمذجة المعلمات المتغيرة مع الزمن:

لالتقاط السلوك الديناميكي لعمليات السلاسل الزمنية وحيدة المتغير ومتعددة المتغيرات يمكننا السماح للمعلمات ان تكون متغيرة مع الزمن من خلال جعلها دوال فجوة للمتغيرات

التابعة وكذلك المتغيرات المشتركة (Exogenous variables) وذلك يتطلب وجود أساليب لنمذجة هذه المعلومات لإدخال الاعتماد على الزمن وقد أثبت (Koopman et al 2012) في دراسته لمقارنة النماذج المعتمدة على المعلمة مقابل النماذج المعتمدة على الملاحظة افضلية نموذج GAS في التنبؤ عن النماذج الأخرى المستخدمة لنمذجة المعلومات المتغيرة مع الزمن.

١-٣-٦ نماذج (GAS) (Generalized autoregressive score) (model):

تسمى أيضا (DCS) (Dynamic conditional score) او (Score driven model) او (Dynamic score model). هي نماذج حديثة تم تقديمها في أعمال: (Harvey, Creal, Lucas, Koopman, 2013) يعتبر نموذج (GAS) فرع من النماذج المعتمدة على الملاحظة، ويشمل GARCH (يعتمد على العزوم الاولى والثانية فقط)، بينما يعتمد (GAS) أيضا على أن (s_t) دالة الهدف هي دالة كثافة الاحتمال الشرطية، وهي أدوات جديدة وفعالة للتنبؤ وتؤدي غالبا لمكاسب مهمة للتنبؤ مقارنة بفئات أخرى من النماذج المعتمدة على الملاحظة.

يتم صياغة نموذج GAS كونه عاملا دافعا للمعلومات المتغيرة مع الزمن كما يلي:

بفرض ان لدينا f_t متجه المعلومات المتغيرة مع الزمن، θ متجه المعلومات الثابتة، X_t دالة كثافة المشاهدات $X_t \sim P(X_t | \theta)$ وكانت X_t لها دالة كثافة تجميعية بمعلومية $F(\theta)$ حيث $\theta = (\alpha_1, \dots, \alpha_n)$ هي متجه معلومات $F(\theta)$. فإن نموذج GAS للمعلمة المتغيرة مع الزمن يكون علي النحو التالي:

$$\theta_t = \alpha_0 + a s_{t-1} + \beta \theta_{t-1} \quad (6-5)$$

حيث:

θ_t تمثل متجه المعلمة $F(\theta)$ ،

α_0, a, β تمثل متجهات المعلومات المراد تقديرها،

s_{t-1} هي (Scaled Score Function) الآلية المحركة.

ويتم حساب Scaled Score كالتالي:

$$s_t = \frac{\partial \ln(X_t | \theta_t, \alpha_0, a, \beta)}{\partial \theta} \quad (6-6)$$

حيث s_t هي المقياس (Scalar)، $(X_t | \theta_t, \alpha_0, a, \beta)$ دالة الكثافة الشرطية.

لذلك يتم تعريف نموذج GAS(p,q) باستخدام الاعتماد علي الآلية المحركة X_t و s_t .

٧- النموذج المقترح للدراسة:

عند تحليل بيانات السلاسل الزمنية المالية نستخدم النموذج الاحصائي ويكون الافتراض الرئيسي هو ثبات معلمات النموذج مع مرور الزمن، لكن في ظل البيئة الاقتصادية المتغيرة قد لا يكون من المعقول افتراض ثبات المعلمات.

يتم استخدام التحليل المتجدد لتقييم ثبات نموذج السلسلة الزمنية مع مرور الزمن، وذلك عن طريق تقديرات المعلمات عبر نافذة متجددة فاذا كانت المعلمات ثابتة بالفعل لن تكون تقديرات النوافذ المتجددة مختلفة عنها، وإذا تغيرت تقديرات المعلمات في مرحلة ما فان تقديرات النوافذ المتجددة سوف ترصد حالة عدم الثبات هذه.

النموذج المقترح للدراسة هو Rolling ARFIMA نموذج يستخدم لتحليل السلاسل الزمنية التي تظهر خاصية الذاكرة الطويلة عن طريق تطبيق نموذج ARFIMA بشكل متكرر علي نوافذ متحركة (Rolling Windows) من البيانات وذلك بهدف تحليل ديناميكية السلسلة الزمنية بمرور الزمن واستيعاب التغيرات في الهيكل الزمني، حيث يتم تقدير النموذج باستخدام جزء فقط من البيانات (نافذة) يتم تحريكها عبر السلسلة الزمنية ومع كل خطوة يتم اسقاط البيانات الاقدم وازضافة احدث نقطة للسلسلة، مما يسمح بفحص التغيرات الهيكلية والتكيف مع الديناميكيات الزمنية.

١-٧ الخطوات الاساسية لتطبيق النموذج:

- ١- تحديد النافذة المتحركة عن طريق اختيار طول النافذة الزمنية (مثلا ٣٠ نقطة للبيانات اليومية او ١٢ اذا كانت البيانات شهرية) واستخدام هذه النافذة لتقسيم البيانات الي نوافذ ذات طول ثابت.
- ٢- بناء نموذج ARFIMA حيث يتم تقدير معلمات نموذج ARFIMA لكل نافذة من البيانات.
- ٣- التحليل المتكرر حيث تحرك النافذة بمرور الوقت (اضافة قيم جديدة وحذف القيم القديمة) ويتم اعادة تقدير المعلمات في كل خطوة.
- ٤- تقييم النتائج عن طريق استخدام النموذج المتعلم من النافذة المتحركة للتنبؤ بالقيم التالية وحساب معيار الخطأ مثل RMSE لتقييم الاداء داخل كل نافذة.
- ٥- تحريك النافذة الي الامام باضافة قيمة جديدة وحذف الاقدم وتكرار الخطوات السابقة.

٢-٧ تقدير معلمة الذاكرة الطويلة المتغيرة مع الزمن باستخدام نموذج

:Rolling ARFIMA

خطوات التقدير:

- ١- اعداد البيانات وتنسيقها علي شكل سلسلة زمنية ومعالجة القيم المفقودة او الشاذة.
- ٢- تحديد خصائص نموذج $ARFIMA(p,d,q)$

٣- تحديد النافذة المتحركة عن طريق تحديد حجم النافذة الزمنية ثم تحليل البيانات داخل كل نافذة بشكل منفصل لتقدير d.

٤- تقدير d لكل نافذة.


٥- رسم القيم المقدرة.

٨- الدراسة التطبيقية

اهتمت الدراسة التطبيقية ببناء النموذج الملائم للتنبؤ بأسعار صرف الدولار الأمريكي مقابل الجنية المصري، باستخدام البيانات اليومية من اول يناير ٢٠٢٠م حتى سبتمبر ٢٠٢٤م.

٨-١ التعرف على البيانات Data Identification :

إن الخطوة الاولى في تحليل أي سلسلة زمنية هي التوقع البياني لمشاهدات السلسلة مع الزمن. وهي خطوة أساسية وهامة في التحليل لأنها تظهر الملامح الوصفية للبيانات، وفيما يلي الرسم البياني لسلسلة أسعار الصرف اليومية للدولار الأمريكي مقابل الجنية المصري وذلك عن الفترة الزمنية (٢٠٢٠م - ٢٠٢٤م)^١.



شكل (٨-١) التوقع البياني لسلسلة البيانات

ونلاحظ من الرسم البياني تطور أسعار الصرف اليومية للدولار الأمريكي مقابل الجنيه المصري خلال الفترة من عام ٢٠٢٠ إلى عام ٢٠٢٤. ويُلاحظ من الشكل أن السلسلة الزمنية تتسم بعدة خصائص مهمة:

١- طبيعة البيانات عالية التردد (High Frequency data):

^١ تم الحصول على هذه البيانات من موقع البنك المركزي المصري ورسم السلسلة باستخدام برنامج SPSS.

السلسلة مبنية على بيانات يومية، مما يوفر مستوى عالٍ من التفاصيل حول سلوك أسعار الصرف، ويعكس ديناميكية واضحة وتغيرات متتابة على فترات زمنية قصيرة.

٢- وجود فترات استقرار تليها طفرات مفاجئة خلال الفترة من ٢٠٢٠ حتى نهاية ٢٠٢١، تنسم السلسلة بثبات نسبي، ثم تبدأ طفرات متتالية في الأسعار بدايةً من عام ٢٠٢٢، وهو ما يُشير إلى **تغيرات هيكلية** في السلسلة مرتبطة بأحداث اقتصادية أو قرارات سياسية مؤثرة.

٣- عدم استقرار التباين (Heteroskedasticity) يُلاحظ بعد عام ٢٠٢٣ أن السلسلة تظهر تذبذبًا مرتفعًا (Volatility)، وهو ما يُشير إلى وجود تقلبات حادة في السوق، مما يدعم الحاجة إلى استخدام نماذج تسمح بتغير المعلومات مع الزمن.

٤- مؤشرات علي وجود ذاكرة طويلة (Long Memory) السلسلة لا تعود إلى المتوسط بسرعة بعد الصدمات، مما يعكس إمكانية وجود خاصية الذاكرة الطويلة، وهي سمة شائعة في السلاسل المالية. فيما يلي مخرجات برنامج R الخاصة بتحليل الإحصاء الوصفي للبيانات.

جدول (٨-١) الإحصاء الوصفي للبيانات^٢

Descriptive Statistics		
Exchange Rate		
N	Valid	1705
	Missing	0
Minimum		15.5964
Maximum		49.5743
Mean		23.57
Median		18.44
Std. Deviation		10.24
Skewness		1.24
Kurtosis		3.51
Jarque-Bera		231.22
P-Value		0.000000

^٢ مخرجات برنامج R.

القيمة الاحتمالية (P-Value) لاختبار (Jarque-Bera) قيمته تساوى صفر وهو اقل من مستوى المعنوية (0.05)، وبالتالي يتم رفض الفرض العدم (ان البيانات تتبع التوزيع الطبيعي)، وهذا يعنى ان بيانات السلسلة الزمنية لأسعار الصرف لا تتبع التوزيع الطبيعي وهذا ما نتصف به معظم السلاسل الزمنية المالية.


٢-٨ اختبارات استقراره البيانات:

جدول (٢-٨) نتائج اختبار جذر الوحدة

Unit Root Test	Test Statistic	p-value	Alternative hypothesis
(ADF)	-1.7111	0.7006	stationary
PP	-6.2428	0.7615	Stationary

ويتضح من الجدول ان قيمة (P-VALUE = 0.7006) لاختبار ADF أكبر من مستوى المعنوية (0.05) وهذا يعني قبول الفرض العدمي بوجود جذر وحدة والذي يعنى عدم استقراره البيانات، وهذا ما اكده ايضا نتيجة اختبار PP حيث (P-VALUE = 0.7006) اكبر من مستوى المعنوية (0.05).


٣-٨ التنبؤ باستخدام نموذج ARIMA



شكل (٢-٨) مقارنة بين أسعار الصرف الفعلية والمتنبأ بها باستخدام نموذج ARIMA(0,1,0) لآخر ٦٠ مشاهدة

يتضح من الرسم أن النموذج فشل في التقاط التقلبات الحقيقية التي شهدتها السلسلة الزمنية، حيث كانت التنبؤات شبه ثابتة وغير متوافقة مع التغيرات الفعلية في البيانات

٨-٤ التحقق من خاصية الذاكرة الطويلة: أولاً: استخدام الرسوم البيانية:



شكل (٨-٢) دالتي الارتباط الذاتي والجزئي للبيانات

نلاحظ من خلال الرسم البياني لسلسلة أسعار الصرف ودالتي الارتباط الذاتي والجزئي ان سلسلة بيانات أسعار الصرف تتميز بالميزات النوعية لعمليات الذاكرة الطويلة.
ثانياً: استخدام الاختبارات الإحصائية:

• اختبار معامل (Hurst) للتحقق من وجود ذاكرة طويلة:

قيمة H باستخدام التقديران (R/S and Theoretical Hurst exponent) يساوي $(0.5381431, 0.8772277)$ علي التوالي، وهذه القيم أكبر من 0.5 وتقترب من 1 مما يؤكد وجود خاصية الذاكرة الطويلة لسلسلة أسعار الصرف، وان السلسلة غير ساكنة لذلك سيتم تسكين السلسلة باستخدام الفروق الكسرية.

ويتم تقدير معلمة الذاكرة الطويلة d كخطوة اولي لبناء نموذج ARFIMA .

٨-٥ تقدير معلمة الذاكرة الطويلة (d):


فيما يلي نستعرض تقدير المعلمة d بطرق مباشرة وطرق غير مباشرة تعتمد على معامل Hurst.

جدول (٨-٣) طرق تقدير معلمة الذاكرة الطويلة (d)

الطريقة	قيمة H	تقدير d	ADF Test P-value
(GPH)	-	1.038411	0.01
(dSperio)	-	1.07048	0.01

0.01	0.49986		(Fracdiff)
0.01	0.3772277	0.8772277	R/S
0.99	-0.5	0	(EHE)
0.6216	0.03581431	0.5381431	(THE)

وبالاعتماد على نتائج الطرق السابقة تكون قيمة الفرق الكسري باستخدام طريقة Fracdiff تساوي (0.49986)، وباستخدام طريقة R/S تساوي (٠,٣٧٧٢٢٧٧).
٨-٦ استخدام نموذج ARFIMA في التنبؤ:



شكل (٨-٣) مقارنة القيم الفعلية مع قيم تنبؤات نموذج ARFIMA

يتضح من مقارنة القيم الفعلية مع القيم التنبؤية ان هناك فجوة واضحة بين القيم الفعلية والمتوقعة، حيث أن النموذج يتوقع اتجاهًا هبوطيًا، في حين أن البيانات الفعلية تُظهر اتجاهًا تصاعديًا ثم استقرارًا نسبيًا، وهذا يشير إلى أن النموذج لا يُحسن تمثيل الاتجاه المستقبلي للسلسلة الزمنية وذلك بسبب ان تقدير المعلمات ثابت عبر مرور الزمن.

٨-٧ اختبارات التحقق من المعلمات المتغيرة مع الزمن

فيما يلي بعض اختبارات عدم الخطية كأحد مصادر تغير المعلمة:


جدول (٨-٤) نتائج بعض اختبارات عدم الخطية لسلسلة أسعار الصرف

١-Tsay's Test for nonlinearity: Null hypothesis: The time series follows some AR process Alternative hypothesis: The time series follows some TAR process F-stat = 4.026197 p-value = 0.04503779	Reject null
---	--------------------

٢-McLeod-Li test: Null hypothesis: The time series follows some ARIMA process Maximum p-value = 0	Reject null
٣-Keenan's one-degree test for nonlinearity: Null hypothesis: The time series follows some AR process F-stat = 3.981231 p-value = 0.04625077	Reject null
٤-RESET test: Null hypothesis: There is linearity in the model RESET = 492.36, df1 = 2, df2 = 1656, p-value < 2.2e-16	Reject null
5-Teraesvirta Neural Network Test Null hypothesis: Linearity in "mean" X-squared = 6.6079, df = 2, p-value = 0.03674	Reject null

يتضح من الجدول السابق رفض الفرض العدمي لاختبارات عدم خطية اسعار الصرف، واوضحت نتائج اختبار RESET لاختفاء التوصيف ايضا رفض الفرض العدمي وذلك يجعل المعلمات متغيرة مع الزمن.


٨-٨ التنبؤ باستخدام نموذج GAS:٣



شكل (٨-٤) مقارنة القيم التنبؤية لنموذج GAS-Student t (1,1) مع القيم الفعلية لافق تنبؤ ٦٠ مشاهدة

٣ باستخدام برنامج Time series Lab


نلاحظ ان هناك تقارب واضح بين القيم المتوقعة والفعلية وان النموذج يتتبع سعر الصرف بشكل جيد جدا مما يشير الي اداء جيد للنموذج في التنبؤ، ولا توجد تقلبات ضخمة غير متوقعة مما يدل علي ملائمة النموذج لتغيرات التباين. لكن عند تجربة نموذج GAS لتوليد التنبؤات لعدد ٩٠ مشاهدة مستقبلية (افق تنبؤ اطول)، لوحظ تراجع في دقة النتائج بالمقارنة مع تنبؤات عدد ٦٠ مشاهدة كما هو موضح في الشكل التالي. ويُعزى هذا التراجع إلى الطبيعة الديناميكية للنموذج التي تستجيب بدرجة أعلى للتقلبات القصيرة الأجل، مما يجعله اكثر ملائمة للتنبؤات قصيرة ومتوسطة المدى.



شكل (٨-٥) مقارنة القيم التنبؤية لنموذج GAS-Student t (1,1) مع القيم الفعلية لافق تنبؤ ٩٠ مشاهدة

يتضح من الرسم أن هناك انحرافاً كبيراً بين القيم الحقيقية والقيم المتنبأ بها، مما يدل على ضعف دقة النموذج في هذا الأفق الزمني.


٨-٩ التنبؤ باستخدام النموذج المقترح Rolling ARFIMA:



شكل (٨-٦) قيم المعلمة d المتغيرة مع الزمن

يوضح هذا الشكل كيف تغيرت معلمة d الخاصة بالذاكرة الطويلة في نموذج Rolling ARFIMA مع الزمن، والتغيرات البسيطة تعني أن خصائص السلسلة الزمنية لم تكن ثابتة، ولهذا استخدمنا النموذج المتحرك (Rolling). وقيمة d قريبة من ٠,٥، وهذا يدل على أن البيانات فيها ذاكرة طويلة بشكل ثابت تقريباً.

● مرحلة التنبؤ باستخدام نموذج Rolling ARFIMA:




شكل (٧-٨) مقارنة القيم الفعلية مع تنبؤات نموذج Rolling ARFIMA

يعرض الشكل مقارنة بين القيم الفعلية لسعر الصرف وتنبؤات نموذج Rolling ARFIMA ويمكن ملاحظة أن النموذج يتبع الاتجاه العام للحركة، مع وجود بعض الفروقات في بعض الفترات، خاصة عند التقلبات الحادة. هذا يشير إلى أن النموذج قادر على تمثيل السلوك الديناميكي للسلسلة الزمنية، ويستفيد من تحديث المعلومات بشكل مستمر داخل النوافذ المتحركة، مما يعزز دقة التنبؤ في ظل وجود الذاكرة الطويلة.

٨-١٠ المقارنة بين النماذج:


أولاً: المقارنة بين نموذجي ARIMA, GAS



شكل (٨-٨) مقارنة القيم الفعلية مع تنبؤات نموذجي ARIMA, GAS

يتضح من الرسم أن نموذج GAS تمكن من تمثيل السلوك الفعلي للسلسلة بشكل أدق، حيث اقتربت تنبؤاته بشكل كبير من القيم الفعلية في معظم الفترات، مقارنةً بنموذج ARIMA الذي أظهر انحرافًا واضحًا خاصة عند وجود تقلبات في البيانات. تعكس هذه النتيجة قدرة نموذج GAS على التعامل مع التباين غير الثابت في السلاسل الزمنية، مما يجعله أكثر كفاءة في بيئات تتسم بالتقلبات الحادة، كحالة أسعار الصرف

ثانياً: المقارنة بين ARFIMA, Rolling ARFIMA



شكل (٨-٨) مقارنة القيم الفعلية مع تنبؤات نموذجي ARFIMA, Rolling ARFIMA

جدول (٨-٥) مقارنة معايير دقة التنبؤ

حالة المعلمة	التباين ثابت	التباين متغير		معلمة الذاكرة الطويلة ثابتة	معلمة الذاكرة الطويلة متغيرة
النماذج	ARIMA	GAS	GAS	ARFIMA	Rolling ARFIMA
أفق التنبؤ	التنبؤ بعدد ٦٠ مشاهدة		التنبؤ بعدد ٩٠ مشاهدة		
MAE	0.848	0.1019	14.50	26.20038	0.3522
RMSE	0.993	0.1444	14.52	26.2	0.395
MAPE	1.74	0.2110	3.104	53.798	0.7224

٩- النتائج والتوصيات

فيما يلي أهم النتائج التي تم التوصل إليها في هذه الدراسة، وتُختتم هذه النتائج بمجموعة من التوصيات العملية والنظرية التي يمكن أن تسهم في تطوير نماذج التنبؤ بسعر الصرف في الدراسات المستقبلية.

أهم النتائج:

(١) نموذج ARIMA

أظهر نموذج ARIMA أداء مقبول في التنبؤ بأسعار الصرف على المدى القصير، إلا أن دقته كانت أقل مقارنة بالنماذج الأخرى، ويرجع ذلك إلى اعتماده على افتراض ثبات التباين وعدم قدرته على تمثيل التقلبات الحادة أو الذاكرة الطويلة في السلسلة. وبذلك يُعد مناسباً فقط في الحالات التي تتسم بالاستقرار، بينما تقل كفاءته في النمذجة الدقيقة للبيانات المالية ذات الطبيعة المتقلبة.

(٢) نموذج ARFIMA

- أظهر أداءً مقبولاً في التنبؤ، خاصة عند استقرار خصائص السلسلة الزمنية.
- يتميز ببساطة في التقدير والتحليل، لكنه أقل مرونة في التعامل مع التغيرات الهيكلية أو التقلبات المفاجئة.
- معايير الدقة (مثل RMSE و MAE) كانت أعلى نسبياً مقارنة بالنماذج الأخرى، مما يدل على أن التنبؤات أقل دقة.

(٣) نموذج GAS

- قدم النموذج نتائج دقيقة في أفق التنبؤ القصير (٦٠ مشاهدة) مع أخطاء منخفضة جداً.
- مع زيادة فترة التنبؤ (٩٠ مشاهدة)، انخفضت الدقة بشكل كبير، وارتفعت مؤشرات الخطأ بشكل ملحوظ، مما يشير إلى ضعف الأداء على الأمد الطويل.
- نموذج GAS مناسب للتنبؤات القصيرة الأجل، ويتميز بقدرته على التعامل مع التغيرات المفاجئة والتقلبات، لكنه يحتاج إلى ضبط أدق أو دمج مع تقنيات أخرى لتحسين أدائه في التنبؤات طويلة الأجل.

(٤) نموذج Rolling ARFIMA

- أتاح مرونة أكبر من خلال إعادة تقدير النموذج على نوافذ متحركة، مما جعله أكثر استجابة لتغيرات السوق.
- أظهر تحسناً واضحاً في دقة التنبؤ مقارنة بـ ARFIMA التقليدي.
- كان قادراً على التقاط الذاكرة الطويلة المتغيرة عبر الزمن، مما ساهم في تحسين الأداء في الفترات ذات التغير الهيكلي.

اهم التوصيات:

في ضوء النتائج السابقة يمكن تقديم عدد من التوصيات البحثية والمقترحات المستقبلية التي من شأنها تطوير هذا المجال وتعزيز دقة النماذج التنبؤية:

(١) تطوير نماذج هجينة (Hybrid Models):

- تشير نتائج الدراسة إلى أن الجمع بين نموذج Generalized Autoregressive Score (GAS) ونموذج Rolling ARFIMA يعزز من دقة التنبؤ بأسعار الصرف، لاسيما في ظل البيانات التي تتسم بالتقلبات غير الثابتة وخصائص الذاكرة الطويلة المتغيرة مع الزمن.

حيث نموذج GAS يتميز بقدرته على التكيف مع التغيرات المفاجئة في التباين، مما يجعله مناسباً للتعامل مع التقلبات الحادة وغير المتوقعة في السوق. في المقابل، يتيح نموذج Rolling ARFIMA تقدير معلمة الذاكرة الطويلة بطريقة ديناميكية، ما يساهم في متابعة التحولات التدريجية في هيكل السلسلة الزمنية. وبناءً على ذلك، فإن اعتماد النموذجين معاً يوفر إطاراً متكاملًا لتحليل وتنبؤ سلوك أسعار الصرف، ويُعد خياراً مناسباً في البيئات الاقتصادية التي تتسم بعدم الاستقرار والتقلب المستمر.

١٠-المراجع

أولاً:المراجع العربية:

(١) البرعى، سارة سعد حسن، مبارك، امال السيد عبد الغني. (٢٠٢٣)، "التنبؤ باستخدام نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية الكسرية $ARFIMA(p,d,q)$: دراسة تطبيقية"، المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط.

(٢) ساهد عبد القادر، مكيدش محمد. (٢٠١٤)، "استخدام نماذج الذاكرة الطويلة $ARFIMA$ للتنبؤ بأسعار البترول" كلية العلوم الاقتصادية والتجارية، جامعة أم البواقي.

ثانياً: المراجع الاجنبية:

- 1) Al-Gounmeein, Remal Shaher, and Mohd Tahir Ismail. "Comparing the performances of artificial neural networks models based on autoregressive fractionally integrated moving average models." *IAENG International Journal of Computer Science* (2021).
- 2) Blasques, Francisco, and Creal, Drew." Generalized Autoregressive Score Models for Time-varying Parameters: new models and applications". (2014).
- 3) Blasques, Francisco, Christian Francq, and Sébastien Laurent. "A new class of robust observation-driven models." (2020).
- 4) Boutahar, Mohamed, Gilles Dufrénot, and Anne Péguin-Feissolle. "A simple fractionally integrated model with a time-varying long memory parameter dt ." *Computational Economics* (2008).
- 5) Creal, Drew, Siem Jan Koopman, and André Lucas. "Generalized autoregressive score models with applications." *Journal of Applied Econometrics* (2013).

- 6)** Esposti, Federico, Manuela Ferrario, and Maria Gabriella Signorini. "A blind method for the estimation of the Hurst exponent in time series: theory and application." *Chaos: An Interdisciplinary Journal of Nonlinear Science* (2008).
- 7)** Gerolimetto, Margherita, and Luisa Bisaglia. "Testing for (non) linearity in economic time series: a Monte Carlo comparison. (2014).
- 8)** Kamika, Mbuaya Grace. *An application of the generalised autoregressive score model to market risk modelling*. University of Johannesburg (South Africa), 2019.
- 9)** Karia, Abdul Aziz, Imbarine Bujang, and Ismail Ahmad. "Fractionally integrated ARMA for crude palm oil prices prediction: case of potentially overdifference." *Journal of Applied Statistics* (2013).
- 10)** Koopman, Siem Jan, Andre Lucas, and Marcel Scharth. "Predicting time-varying parameters with parameter-driven and observation-driven models." *Review of Economics and Statistics* (2016).
- 11)** Maqsood, Arfa, and S. M. Burney. "LONG MEMORY FORECASTING: AN APPLICATION TO KSE SHARE INDEX." *Pakistan Journal of Statistics* (2014).
- 12)** Sheng, Hu, Y. Q. Chen, and Tianshuang Qiu. "On the robustness of Hurst estimators." *IET Signal Processing* (2011).
- 13)** Samimi, Alireza Erfani Ahmad Jafari. "Long memory forecasting of stock price index using a fractionally differenced ARMA model." *Journal of Applied sciences research* (2009).