



فرائض للعلوم الاقتصادية والإدارية
KHAZAYIN OF ECONOMIC AND
ADMINISTRATIVE SCIENCES
ISSN: 2960-1363 (Print)
ISSN: 3007-9020 (Online)



Comparison between adaptive filtering methods and Box-Jenkins methods for mixed models in time series using simulation

Dr. Arwa Jassim Mohammed Hassan

Ministry of Education / General Directorate of Education, Baghdad, First Rusafa

Arowjassim564@gmail.com

Abstract. This study aims to compare the time series prediction efficiency of Adaptive Filtering (MW) and Box-Jenkins methods when applied to lower-order ARMA mixed models. The study employed statistical simulation using different sample sizes (small, medium, and large), with the analysis performed using the R statistical programming language. The results showed that MW outperformed other methods in most prediction scenarios, particularly with non-stationary time series, due to its ability to adapt to changes in data without being affected by them. In contrast, Box-Jenkins (BJ) methods performed better in some cases before applying control to the predictions, especially with small samples. The results also indicated that controlling the predictions improved the overall prediction accuracy and enhanced the efficiency of MW. The study recommends expanding the application of this method to include seasonal models and multivariate time series.

Keywords: Adaptive Filtering, Forecasting, Stationary, Unit Circle, Mixed model.

DOI: [10.69938/Keas.2603014](https://doi.org/10.69938/Keas.2603014)

المقارنة بين طريقة التنقية التكرارية وطرائق بوكس جينكينز للنماذج المختلطة في السلاسل الزمنية باستعمال المحاكاة

م. د. اروى جاسم محمد حسن

وزارة التربية / المديرية العامة لتربية بغداد الرصافة الأولى

Arowjassim564@gmail.com

تهدف هذه الدراسة إلى مقارنة كفاءة التنبؤ بالسلاسل الزمنية بين طريقة التنقية التكرارية (Adaptive Filtering) وطرائق بوكس-جينكينز (Box-Jenkins) عند تطبيقها على النماذج المختلطة من نوع ARMA ذات الرتب الدنيا. اعتمدت الدراسة أسلوب المحاكاة الإحصائية باستخدام أحجام عينات مختلفة (صغيرة، متوسطة، وكبيرة) مع تنفيذ التحليل باستخدام لغة البرمجة الإحصائية R. أظهرت النتائج تفوق طريقة التنقية التكرارية (MW) في معظم حالات التنبؤ، ولا سيما مع السلاسل الزمنية غير المستقرة لما تمتاز به من قدرة على التكيف مع التغيرات في البيانات دون التأثير بها. في المقابل، حققت طرائق بوكس-جينكينز (BJ) أداءً أفضل في بعض الحالات قبل تطبيق السيطرة على التنبؤات، خصوصاً عند العينات الصغيرة. كما بينت النتائج أن السيطرة على التنبؤات أسهمت في تحسين دقة التنبؤ بشكل عام وعززت من كفاءة طريقة التنقية التكرارية. وتوصي الدراسة بتوسيع تطبيق هذه الطريقة لتشمل النماذج الموسمية والسلاسل الزمنية متعددة المتغيرات.

الكلمات المفتاحية: التنقية التكرارية، التنبؤ، الاستقرار، دائرة الوحدة، النموذج المختلط.

Corresponding Author: E-mail: Arowjassim564@gmail.com

أحد أهم المواضيع في تحليل السلاسل الزمنية هو التنبؤ (Forecasting) لقيم مستقبلية للظاهرة المدروسة. ومن الملاحظ في الكتابات الحديثة للسلاسل الزمنية يكون استخدام مصطلح التنبؤ (عملياً) هو أكثر وأوسع استخداماً من مصطلح (Prediction) والذي يعني التنبؤ (نظرياً). علماً أن الكثير من نتائج التنبؤ قد اشتقت من خلال نظريات التنبؤ الخطي والمقدمة من قبل العديد من العلماء، منهم العالم (Kolmogorov) عام 1941 وكذلك العالم (Wiener) عام 1949 على أثر الحرب العالمية الثانية عندما حاول البريطانيون إيقاف الهجمات الجوية الألمانية من خلال التنبؤ بموقع الطائرات المتوقع بناءً على متغيرات عديدة منها سرعة الطائرة، سرعة القذائف المضادة، مع تأثيرات عشوائية أخرى (Noise)، إذ من هذا التاريخ كانت بدايات موضوع التنبؤ، حيث استطاع كل من (Wiener و Kolmogorov) وبتجاهين مختلفين التوصل إلى التنبؤ المطلوب، فضلاً عن العديد من العلماء غيرهم (Binner et al., 2005).

تستخدم طريقة التنبؤ مجموعة بيانات أو المشاهدات السابقة لبناء النموذج التصادفي، وغالباً ما توصف القيم السابقة بانها سلسلة زمنية (Time Series)، ذات مديات متساوية وفق الزمن والتي من الممكن أن تمثل مبيعات شهرية أو مقدار الاستهلاك اليومي... الخ. إن التنبؤ لسلسلة زمنية تفترض أن السلسلة الزمنية هي تركيبة (Combination) من قيم نمطية وبعض الأخطاء العشوائية، والهدف هو فصل وعزل القيم الفعلية من الأخطاء العشوائية من خلال معرفة وفهم اتجاه النمط. كما يستخدم التنبؤ في صنع القرار في ظل عدم التأكد، من خلال التوقعات للنتائج المطلوبة أو المطلوب إهمالها. إن الاختيار والتزود بعلم المنهج الصحيح بالتنبؤ عادة يعد تخطيطاً مهماً وثمره سيطرة على التنبؤات في كثير من المؤسسات والوكالات. ففي العمليات التنظيمية لمختلف التطبيقات يتم الوثوق والاعتماد كثيراً على الدقة في التنبؤ الناتج من السيطرة على التنبؤات إحصائياً لتلك العمليات التطبيقية (Athiyarath et al., 2020). وهناك طريقتان رئيسيتان للتنبؤ:

- تقدير القيم المستقبلية يعتمد على تحليل العوامل التي يعتقد أن لها تأثير على القيم المستقبلية، وتسمى الطريقة التفسيرية.

- إن التنبؤ يعتمد على التخمين من خلال دراسة السلوك العام لبيانات سابقة مع الزمن، وتسمى الطريقة الاستقرائية.

من الممكن اعتماد أي من الطريقتين المذكورتين للوصول إلى إبداع جيد في مجال التنبؤ، ولكن علينا التذكر أنه حتى في التجارب البسيطة فإن الطريقة الأولى هي كثيراً ما تكون أكثر صعوبة في التطبيق عن الطريقة الثانية. يُعد موضوع التنبؤ وكذلك السيطرة على القيم المتنبأ بها إحصائياً من المواضيع المهمة في عصرنا الحديث، إذ أن السلسلة الزمنية والتي هي عبارة عن سلسلة متعاقبة من المشاهدات يمكن أن تحصل في حقول مختلفة. وتكون معلمات السلسلة الزمنية على نوعين إما مستمرة (Continuous) أو متقطعة (Discrete)، فالنوع الأول، مثلاً: الإشارات الكهربائية (Electric Signal)، التي يمكن أن تسجل بشكل مستمر مع الزمن. أما النوع الثاني، فمثلاً: نسب الفائدة، مقدار المحاصيل الزراعية، أو حجم المبيعات التي تؤخذ وتقاس وفق متغيرات زمنية محددة، فتسمى السلسلة الزمنية متقطعة. علماً أن أي سلسلة زمنية مستمرة متساوية الفترات الزمنية يمكن أن تقدم قيم مقاسه عشرياً بوصفها قيماً ذات فترات متقطعة في الحساب (Wei, 2019).

في سياق تحليل السلاسل الزمنية برزت طريقة التنقية التكميلية كنهج فعال للتنبؤ عندما تكون عملية توليد البيانات الأساسية عرضة لتغيرات هيكلية أو تباينات في الضوضاء (Noise)، إذ تسعى طريقة التنقية التكميلية للوصول إلى أقرب ما يكون من المثالية والكمال في التنقية وصولاً لقيم تنبؤية خالية من الضوضاء أو التشويش. إن طرق التنبؤ التقليدية مثل (ARIMA) أو التمهيد الأسّي (Exponential Smoothing) تفترض ثبات معلمات النموذج بمرور الزمن. مع ذلك في العديد من التطبيقات العملية مثل الأسواق المالية ونمذجة المناخ وغيرها، قد تتغير الخصائص الإحصائية للسلسلة الزمنية بشكل مفاجئ مما يجعل النماذج الثابتة دون المستوى الأمثل، تعالج التنقية التكميلية هذا التحدي بتحديث معلماتها تسلسلياً (sequentially) مع توافر مشاهدات جديدة مما يحافظ على دقة التنبؤ حتى في ظل الظروف غير المستقرة (Clarkson, 2017).

ولطريقة التنقية التكميلية تطبيقات عديدة في التنبؤ بالسلاسل الزمنية بما في ذلك التنبؤ بالأحمال قصيرة المدى (short-term load) في أنظمة الطاقة والتنبؤ بأسعار صرف العملات وتقدير الاتجاهات التكميلية في المؤشرات الاقتصادية. في عام (2002) أجرى الباحث (Hippert) وآخرون دراسة شاملة حول التنبؤ بأحمال الكهرباء قصيرة المدى باستخدام تقنيات متنوعة منها الشبكات العصبية والتنقية التكميلية، ومن أهم النتائج التي توصلوا إليها كانت قدرة هذه الطرق على التكيف مع التغيرات المفاجئة في أنماط الاستهلاك، كتلك الناجمة عن عوامل الطقس أو الأحداث غير المتوقعة، مما يُحسن دقة التنبؤ مقارنة بالطرق التقليدية القائمة على النماذج الخطية الثابتة.

في عام (2009) قدّم الباحث (Gao) وآخرون دراسة تناولت مشكلة إزالة التشويش من السلاسل الزمنية غير الخطية والتي قد تكون فوضوية (Chaotic)، مثل بيانات نظام لورينز وإشارات تخطيط كهربية الدماغ (EEG)، وأظهر الباحثون أن الطرائق الكلاسيكية مثل الانكماش المويجي (Wavelet Shrinkage) تواجه قيوداً في معالجة البيانات غير الخطية أو شديدة الضوضاء. لذلك، اقترحوا خوارزمية ترشيح غير خطية تكيفية يمكنها معالجة هذه المشكلات وإزالة الضوضاء بكفاءة أكبر من الطرق الكلاسيكية. ومن أهم النتائج التي توصلوا إليها أن الخوارزمية التكميلية تُقلل الضوضاء في نظام لورينز بفعالية أكبر من إزالة الضوضاء بالترشيح المويجي باستخدام ثلاث خيارات مختلفة لتحديد العتبات (Thresholds)، كما تُقلل الخوارزمية التكميلية من مُكوّن تخطيط كهربية الدماغ المُلوّث في تخطيط كهربية الدماغ بفعالية أكبر من منهج الموجات.

في عام (2020) اقترح الباحث (Zhong) وآخرون خوارزمية التنقية الديناميكية التكميلية اللبية (DASKRLS)، واستخدمت لمعالجة السلاسل الزمنية غير المستقرة والمضطربة إذ تعتمد هذه الخوارزمية على مبدأ التجزئة التكميلية والإسقاط على المتجه مما يدعم تنبؤاً ديناميكياً في بيئتين ذات ضوضاء عالية وغير خطية. تُظهر تجارب معايرة لورينز وتجارب البيانات الحقيقية أن

خوارزمية (DASKRLS) تحقق أداء تنبؤ أفضل في الأنظمة المعقدة ذات الاضطراب أو التشويش وعدم الاستقرار، كما يقلل استخدام خوارزمية (DASKRLS) من تعقيد الحوسبة الزمنية والمكانية وتحسن القدرة على التنبؤ. في عام (2024) اقترح الباحث (Hu) وآخرون خوارزمية ترشيح تكيفية مبنية على معيار الخطأ المختلط (KHTMC)، بهدف تحديد الأنظمة غير الخطية في بيانات الضوضاء غير الغاوسية. تحسّن هذه الخوارزمية معالجة الإشارات من خلال بناء دالة تكلفة مختلطة (mixed cost) تجمع بين خطأ التربيعي اللوغاريتمي للمتائل ودالة الظل الزائدي، وتدمجها مع طريقة التنقية التكيفية للنواة. ومن أهم النتائج التي توصلوا إليها أن خوارزمية (KHTMC) تُبدي مزايا كبيرة من حيث سرعة التقارب وقلة متوسط مربعات الخطأ في حالة الاستقرار. كما تُظهر موثوقية عالية وأداءً عاليًا في التتبع، خاصةً عند التعامل مع الاضطرابات أو الضوضاء غير الغاوسية المختلطة.

على الرغم من وجود عدد من الدراسات السابقة في الجامعات العراقية والعربية والاجنبية التي قارنت بين طرائق بوكس - جينكينز وطريقة التنقية التكيفية في تحليل السلاسل الزمنية، فإن معظمها ركّز على تطبيقات محدودة أو بيانات واقعية معينة، مع الاكتفاء بالمقارنة المباشرة لمقاييس دقة التنبؤ. يميّز هذا البحث عن تلك الدراسات باعتماده أسلوب المحاكاة الإحصائية لتوليد بيانات اصطناعية وفق نماذج مختلطة من نوع ARMA وبتركيبات مختلفة للمعاملات، مع دراسة أثر أحجام عينات متعددة على كفاءة الطرائق المقارنة. كما ينفرد البحث بتطبيق السيطرة على التنبؤات وتحليل استقرار النتائج عبر تكرارات متعددة للمحاكاة، فضلاً عن توسيع نطاق المقارنة ليشمل عدة نماذج مختلطة، مما يمنحه خصوصية تطبيقية تميّزه عن البحوث السابقة.

2. هدف البحث: يهدف البحث إلى دراسة فعالية طريقة التنقية التكيفية في تحسين دقة تنبؤات السلاسل الزمنية، ويتم ذلك من خلال تطبيقها باستخدام أسلوب المحاكاة، ومقارنة نتائجها بنتائج طرائق بوكس-جينكينز. كما يهدف البحث إلى تحديد أيّ من الطرائق تقدم أداءً أفضل في ظل أحجام عينات مختلفة (صغيرة، متوسطة، وكبيرة)، وذلك باستخدام معيار متوسط مربعات الخطأ (Mse) كمعيار للمقارنة.

3. مفهوم دائرة الوحدة والاستقرارية: تعدّ الاستقرارية مفهومًا أساسيًا في تحليل السلاسل الزمنية، وتمثل الحجر الأساس للعديد من الأساليب الإحصائية المستخدمة لدراسة وتفسير بيانات السلاسل الزمنية. إذ تشير الاستقرارية إلى ثبات الخصائص الإحصائية للسلسلة بمرور الزمن، مثل التوزيع الاحتمالي والمتوسط والتباين. علاوة على ذلك، لا تتأثر الارتباطات الزمنية بموقع المشاهدة على محور الزمن، بل بالفارق الزمني بين المشاهدات. تكمن أهمية مفهوم الاستقرارية في أن معظم النماذج الإحصائية التقليدية مثل نماذج المتوسطات المتحركة (ARMA) ونماذج الانحدار الذاتي تفترض أن السلسلة الزمنية قيد الدراسة تستوفي شرط الاستقرارية لضمان دقة التقدير وصحة النتائج. غالبًا ما يؤدي غياب الاستقرارية أو ما يُعرف بالسلاسل الزمنية غير المستقرة إلى نتائج مضلّة، مما يستلزم إجراء عمليات تحويل أو تمييز لإزالة التغيرات الموسمية أو الاتجاه العام قبل تطبيق النماذج. لذلك، أصبح اختبار الاستقرارية خطوة أولية حاسمة في أي دراسة تنبؤية أو تحليلية للسلاسل الزمنية، لأنه يحدد مدى ملاءمة البيانات للنماذج الخطية التقليدية أو الحاجة إلى نماذج بديلة أكثر مرونة (Box et al., 2016).

كما تلعب دائرة الوحدة دورًا محوريًا في تقييم استقرار وثبات نماذج السلاسل الزمنية مثل الانحدار الذاتي (AR)، والمتوسط المتحرك (MA)، والمتوسطات المتحركة المتكاملة الانحدار الذاتي (ARIMA). ينشأ هذا المفهوم من دراسة جذور متعددات الحدود المميزة المرتبطة بهذه النماذج على وجه التحديد بالنسبة لعملية (AR) يتطلب شرط الاستقرار أن تقع جميع جذور معادلتها المميزة خارج دائرة الوحدة (أي أن يكون لها معامل أكبر من واحد). يضمن هذا الشرط عدم ظهور سلوك مضطرب للسلسلة الزمنية وتبديد الصدمات التي تتعرض لها العملية بمرور الوقت. بالتالي يمكن تعريف دائرة الوحدة بأنها مجموعة جميع الأعداد المركبة التي قيمتها المطلقة (معامل) تساوي واحدًا، أي أن $\{z \in C: |z| = 1\}$. في التحليل في مجال التكرار ترتبط دائرة الوحدة ارتباطًا وثيقًا بتحويل فورييه حيث يُسهّل ربط دالة تحويل نموذج (ARMA) بدائرة الوحدة تقييم الخصائص الطيفية (Brockwell & Davis, 2016).

بيانيًا، يُوفر رسم الجذور في المستوى المعقد أو المركب بالنسبة لدائرة الوحدة أداة تشخيص سهلة الاستخدام، إذ تتوافق الجذور الواقعة تمامًا على دائرة الوحدة مع عمليات جذر الوحدة وهي عمليات غير ثابتة وغالبًا ما تُتمدج من خلال النفاصل. يُعد هذا النهج التشخيصي أساسيًا في تحديد النماذج وتقدير المعاملات والتحقق منها ضمن منهجية (Box-Jenkins). ونظرًا لأهمية دائرة الوحدة التي تعمل كمعيار نظري وعملي لاستقرار النموذج وقابليته على الانعكاس وثباته في تحليل السلاسل الزمنية، حيث تربط الخصائص الجبرية لمتعددات الحدود بالسلوك الديناميكي للعمليات العشوائية (Dickey & Fuller, 1979). سنستعرض هذا المفهوم من خلال نماذج الانحدار الذاتي (Autoregressive) من الرتبين الأولى والثانية لاعتمادهما في الجانب التطبيقي من هذا البحث.

4. التنبؤ بطرائق بوكس-جينكينز (BJ): تكمن الفكرة الأساسية للتنبؤ في إيجاد الصيغة الرياضية التي تولد سلسلة زمنية مثلى تقريباً حسب الصيغة السابقة لها، وهناك طريقتان أساسيتان للتنبؤ حسب طرائق (Box & Jenkins) هما: الإسقاط الذاتي للسلسلة الزمنية (Self-Projecting on Time Series) والتي تستخدم فقط بيانات السلاسل الزمنية الفعالة في مجال التنبؤ لغرض توليد بيانات متنبأ بها. أمّا الطريقة الثانية فهي أسلوب السبب والنتيجة (Cause-and-Effect Approach) المستخدمة اعتماداً على

بيانات السلاسل المعتمد بأنها سبب في سلوك السلسلة الأصلية. أن الطريقة الأولى تُعد من أبرز سمات طريقة التنبؤ لـ (Box & Jenkins)، حيث أن الهدف الأساسي لها هو إيجاد صيغة مناسبة للتنبؤ بحيث تجعل البواقي اقل ما يمكن (Hamilton, 2020).

1-4. التنبؤ بطريقة (BJ) لنموذج ARMA (1,1): لنفرض أن $[\hat{Z}_n(L)]$ تمثل التنبؤ لـ (L) مرحلة مستقبلية لـ (Z_{n+L}) لنموذج الانحدار الذاتي للمتوسطات المتحركة ARMA (1,1) حيث ان:

$$(1 - \phi B)(Z_t - \mu) = (1 - \theta B)\varepsilon_t \quad (1)$$

حيث يمثل Z_t قيمة السلسلة الزمنية عند الزمن t ، وتمثل θ معامل المتوسط المتحرك من الرتبة الأولى MA(1)، وتمثل ϕ معامل الانحدار الذاتي من الرتبة الأولى AR(1)، ويمثل الرمز ε_t حد الخطأ العشوائي (الابتكار) عند الزمن t ، ويفترض أنه يتبع توزيعاً طبيعياً بمتوسط صفري وتباين ثابت σ^2 . ولحساب التنبؤ $[\hat{Z}_n(L)]$ كتوقع شرطي، عند الزمن $(t = n + L)$ ، فيمكن إعادة كتابة النموذج السابق (1) بالصيغة التالية:

$$Z_{n+L} = \mu + \phi(Z_{n+L-1} - \mu) + \varepsilon_{n+L} - \theta \varepsilon_{n+L-1} \quad (2)$$

إذ ان:

$$\hat{Z}_n(L) = \mu + \phi(Z_n - \mu) - \theta \varepsilon_n \quad , \quad L = 1 \quad (3)$$

وكذلك:

$$\hat{Z}_n(L) = \mu + \phi^L(Z_n - \mu) - \phi^{L-1} \theta \varepsilon_n \quad , \quad L \geq 2 \quad (4)$$

ولحساب التباين (Forecast Variance) فيمكن من خلال الصيغة (5) الآتية:

$$var(\hat{Z}_n(L)) = \sigma_\varepsilon^2 \sum_{j=0}^{L-1} \psi_j^2 \quad (5)$$

فعندما $(|\phi| < 1)$ ، فيمكننا حساب الأوزان (Ψ) من خلال نموذج الأوساط المتحركة (MA) وكما في الصيغة (6) الآتية:

$$Z_t = \Psi(B)\varepsilon_t = \varepsilon_t + \Psi_1\varepsilon_{t-1} + \Psi_2\varepsilon_{t-2} + \dots \quad (6)$$

حيث ان $(\Psi_1 = 0)$ ، وأن خطأ التنبؤ (Forecast Error) يكون بالصيغة (7) التالية:

$$e_t(L) = Z_{t+L} - \hat{Z}_t(L) = \sum_{j=0}^{L-1} \Psi_j \varepsilon_{t+L-j} \quad (7)$$

وبما ان توقع خطأ التنبؤ يساوي صفراً، أي ان $\{E[e_t(L)] = 0\}$ ، فإن التنبؤ غير متحيز، وان متوسط مربعات خطأ التنبؤ (FMSE) يكون كالآتي:

$$FMSE(\hat{Z}_t(L)) = var(\hat{Z}_t(L)) = var(e_t(L)) = \sigma_\varepsilon^2 \sum_{j=0}^{L-1} \Psi_j^2 \quad (8)$$

حيث ان $\Psi_j^2 = \phi^{j-1}(\phi - \theta)$ ، $\forall j \geq 1$ ، وعليه فإن تباين التنبؤ (Forecast Variance) للنموذج ARMA(1,1) سيكون بالصيغة (9) التالية:

$$var(\hat{Z}_n(L)) = \sigma_\varepsilon^2 [1 + (L - 1)(1 - \theta)^2] \quad (9)$$

والتي تقترب من $(+\infty)$ عندما $(L \rightarrow \infty)$ ، (Reinsel, 2003).

5. التنبؤ بطريقة التنقية التكيفية (MW): التنقية المعدلة او التنقية التكيفية (Adaptive Filtering) هي فئة من تقنيات معالجة الإشارات، حيث تُحدَّث معاملات الترشيح او التنقية تكرارياً (Iteratively) استجابةً للتغيرات في الخصائص الإحصائية لإشارة الإدخال. بخلاف الطرق ذات المعاملات (المعلمت) الثابتة، يمكن لطريقة التنقية التكيفية التعديل الذاتي او التلقائي بناءً على الخصائص المتطورة للبيانات مما يجعلها هامة جداً وبشكل خاص في البيئات الديناميكية وغير المستقرة. يتمثل المبدأ الأساسي لهذه الطريقة في تقليل متوسط المربعات الخطأ (Mse) من خلال خوارزميات تكرارية مثل خوارزمية متوسط المربعات الصغرى (LMS) وخوارزمية المربعات الصغرى التكرارية (RLS). تُتيح هذه الخوارزميات تكييف المعلمات آنياً دون الحاجة إلى معرفة مسبقة بالنظام الأساسي (Farhang, 2013).

تشمل تطبيقات التنقية التكيفية في التنبؤ بالسلاسل الزمنية، التنبؤ بالأحمال قصيرة المدى في أنظمة الطاقة والتنبؤ بأسعار الصرف وتقدير الاتجاهات التكيفية في المؤشرات الاقتصادية وغيرها. في كل حالة تُعزز قدرة معلمة الترشيح (الفلتر) على الاستجابة السريعة للتغيرات في تركيب الإشارة فاعليته التنبؤية مقارنة بالطرق التقليدية خاصة في البيئات شديدة الضوضاء أو سريعة التغير. علاوةً على ذلك تتميز التنقية التكيفية بكفاءة حسابية عالية مما يجعلها مثالية لسيناريوهات التنبؤ عبر الإنترنت في الوقت الفعلي حيث تكون سرعة اتخاذ القرار أمراً هاماً للغاية (Huang et al., 2020).

إن التنبؤ بطريقة التنقية التكيفية (Forecasting with Adaptive Filtering) تشمل خوارزميات لمراجعة أو لتعديل المعاملات للنماذج الخطية العشوائية وذلك من خلال إضافة حد لتصحيح المعاملات الأصلية والذي هو عبارة عن نسبة بين حاصل ضرب بواقي أحدث تنبؤ وقيم المشاهدات الأولية، ومنذ عام (1977) توسع في الاستخدام ليشمل نماذج سلاسل زمنية مختلفة منها نماذج أخطاء الأوساط المتحركة (Moving Average Errors) لسلاسل مستقرة وغير مستقرة. ويعد التنبؤ بطريقة التنقية التكيفية والمعروفة من قبل (Makridakis and Wheelwright) أكثر دقة وكفاءة تقريباً من أسلوب التنقية المقدمة من قبل (Kalman) المطبقة بشكل فعال في نماذج الانحدار الذاتي (Makridakis & Wheelwright, 1977).

1-5. التنبؤ بطريقة (MW) لنموذج ARMA(1,1): ليكن لدينا النموذج التالي:

$$Z_t = \phi_{1t} Z_{t-1} + \varepsilon_t - \theta_{1t} \varepsilon_{t-1} \quad (10)$$

حيث: $(\phi_{1t}$ و $\theta_{1t})$ هي معاملات غير معلومة (Unknown Parameters) وهي غير ثابتة ولكن ذات تغير طفيف بين فترة زمنية وأخرى. ولغرض الوصول إلى نموذج التنبؤ عن طريق التنقية المعدلة لهذا النموذج فيمكن اتباع الآتي:

أ- للوصول إلى الامتلي به باستعمال طريقة التدرج الأكثر انحدار (Steepest Descent) من أجل الوصول إلى أقل قيمة لمتوسط مربعات الخطأ (Mse) ومن خلال:

$$\varepsilon_t^2 = (Z_t - \phi_{1t} Z_{t-1} + \theta_{1t} \varepsilon_{t-1})^2 \quad (11)$$

المعاملات (ϕ_{1t}) و (θ_{1t}) يمكن أن تقدر من طريقة المربعات الصغرى غير الخطية باستخدام طريقة التدرج الأكثر انحدار (Steepest Descent) للوصول إلى أفضل كفاءة من خلال تفاضل دالة متوسط مربعات الخطأ (Mse). ومن خلال المفاضلة بالنسبة إلى (ϕ_{1t}) ومن ثم (θ_{1t}) ينتج:

$$\frac{\partial \varepsilon_t^2}{\partial \phi_{1t}} = -2 \varepsilon_t Z_{t-1} \quad , \quad \frac{\partial \varepsilon_t^2}{\partial \theta_{1t}} = 2 \varepsilon_t \varepsilon_{t-1}$$

وباستخدام طريقة التكرار نحصل على المعاملات المعدلة التالية (Siqueira et al., 2019):

$$\phi_{1t}^* = \phi_{1t} + 2k \varepsilon_t Z_{t-1} \quad (12)$$

حيث تمثل (ϕ_{1t}^*) تمثل المعلمة المعدلة (المكيفة) الجديدة، ويمثل الرمز (ϕ_{1t}) معلمة الانحدار الذاتي AR(1) قبل التعديل، ويمثل الرمز (K) تمثل ثابت اختياري يقوم بالسيطرة على سرعة التقارب من خلال عدد مرات التكرار المستخدمة.

$$\theta_{1t}^* = \theta_{1t} - 2k \varepsilon_t \varepsilon_{t-1} \quad (13)$$

حيث تمثل (θ_{1t}^*) تمثل المعلمة المعدلة (المكيفة) الجديدة، ويمثل الرمز (θ_{1t}) معلمة المتوسط المتحرك MA(1) قبل التعديل. حيث أن التنقية المستخدمة هنا تدعى التنقية المكيفة المعممة (Generalized Adaptive Filtering).

ب- نبدأ بقيم أولية للمعالم (ϕ_1) و (θ_1) ومن ثم نعدّل تلك القيم باستخدام الطريقة التكرارية حتى نصل إلى الحد الذي لا يوجد تحسين عليه أكثر من خلال متوسط مربعات الخطأ (Mse).

جـ بالتعويض عن قيم (θ_{1t}^*) و (ϕ_{1t}^*) في المعادلة (10) نحصل على صيغة خطأ البواقي المكيفة الجديدة:

$$\varepsilon_t^* = Z_t - \phi_{1t}^* Z_{t-1} + \theta_{1t}^* \varepsilon_{t-1} \quad (14)$$

إذ ان القيمة للتغير المضاف في الأخطاء هي:

$$\nabla \varepsilon_t = \varepsilon_t^* - \varepsilon_t = -2k \varepsilon_t \{Z_{t-1}^2 + \varepsilon_{t-1}^2\} \quad (15)$$

$$\frac{\nabla \varepsilon_t}{\varepsilon_t} = 2k \{Z_{t-1}^2 + \varepsilon_{t-1}^2\} \quad (16)$$

ومن المعادلة (16) يمكن ان نستنتج:

$$0 < k < \frac{1}{Z_{t-1}^2 + \varepsilon_{t-1}^2} \quad (17)$$

وبنفس الأسلوب يمكن الحصول على المعلمات المعدلة لنماذج أخرى منها نموذج ARMA(1,2) إذ ان المعلمات التكيفية:

$$\phi_{1t}^* = \phi_{1t} + 2k \varepsilon_t Z_{t-1} \quad (18)$$

$$\theta_{it}^* = \theta_{it} - 2k \varepsilon_t \varepsilon_{t-i} \quad (19)$$

$$0 < k < \frac{1}{Z_{t-1}^2 + \varepsilon_{t-1}^2 + \varepsilon_{t-2}^2} \quad (20)$$

وبالنسبة الى نموذج ARMA(2,1) فإن المعلمات التكيفية:

$$\phi_{it}^* = \phi_{it} + 2k \varepsilon_t Z_{t-i} \quad (21)$$

$$\theta_{1t}^* = \theta_{1t} - 2k \varepsilon_t \varepsilon_{t-1} \quad (22)$$

$$0 < k < \frac{1}{Z_{t-1}^2 + Z_{t-2}^2 + \varepsilon_{t-1}^2} \quad (23)$$

وبالنسبة الى نموذج ARMA(2,2) فإن المعلمات التكيفية: (Makridakis & Wheelwright, 1977)

$$\phi_{it}^* = \phi_{it} + 2k \varepsilon_t Z_{t-i} \quad (24)$$

$$\theta_{1t}^* = \theta_{1t} - 2k \varepsilon_t \varepsilon_{t-1} \quad (25)$$

$$0 < k < \frac{1}{Z_{t-1}^2 + Z_{t-2}^2 + \varepsilon_{t-1}^2 + \varepsilon_{t-2}^2} \quad (26)$$

6. معايير ضبط دقة التنبؤ: في اغلب حالات التنبؤ فإن الدقة تتجه نحو طريقة التنبؤ المناسبة، وكثيراً ما يطلق على الدقة بكلمة حسن المطابقة (Goodness of Fit) والتي تباعاً تشير إلى كيفية جعل نموذج التنبؤ قادراً على توليد بيانات كقوة. ولنفرض أن (Z_t) تمثل القيمة الفعلية عند الزمن (t) ، و (\hat{Z}_t) تمثل القيمة المتنبأ بها عند الزمن نفسه، إذ ان حد الخطأ يعرف بالصيغة الآتية:

$$e_t = Z_t - \hat{Z}_t \quad (27)$$

عادةً (\hat{Z}_t) تحسب اعتماداً على بيانات $(Z_1, Z_2, \dots, Z_{t-1})$. حيث يمكن اعتبار (e_t) هو خطأ تنبؤ مرحلة واحدة (One-Step Forecast Error). إن المعادلة (27) تُستخدم لاحتساب الخطأ لكل نقطة زمنية، حيث أن معدل تلك المعادلة لفترات زمنية عديدة أي (Mean Error) يفضل أن تكون قيمته صغيرة. ومن عيوبه لا يمكنه إعطاء توضيح كافٍ حول حجم ونوع الأخطاء، ويمكن التعبير عنه بالصيغة (28) التالية (Shumway & Stoffer, 2017):

$$ME = (1/n) \sum_{t=1}^n e_t \quad (28)$$

ومن معايير ضبط الدقة الأخرى معيار متوسط مربعات الخطأ (MSE) والذي يمكن التعبير عنه بالصيغة (29) التالية:

$$MSE = (1/n) \sum_{t=1}^n e_t^2 \quad (29)$$

ويعتبر هذا المعيار أكثر تقدماً وأفضلية من معيار (ME) لكونه أسهل رياضياً، وكثيراً ما يستخدم في العمليات الإحصائية (Skowronski & Harris, 2006). إن المعايير السابقة تكون غير كفاءة للمقارنة بين سلاسل زمنية مختلفة وبين فترات زمنية مختلفة، ومن المعايير الشائعة الأخرى معيار متوسط الخطأ النسبي المطلق (Mean Absolute Percentage Error) والذي يشار إليه بالرمز (MAPE) والذي يمكن التعبير عنه بالصيغة (30) التالية:

$$MAPE = (1/n) \sum_{t=1}^n |PE_t| \quad (30)$$

يستخدم هذا المعيار الخطأ النسبي (Percentage Error) وذلك عندما تكون قيم السلسلة الزمنية صغيرة جداً أو قريبة من الصفر وكذلك عندما تكون القيم كبيرة، يمكن أن يكون هذا المقياس مفيد ويعطي نتائج مفهومة (Monim, 2001).

7. معايير اختيار النموذج المناسب: في تحليل السلاسل الزمنية هناك العديد من النماذج الملائمة والتي يمكن استخدامها لتمثيل البيانات المدروسة، وفي بعض الأحيان يكون الاختيار سهلاً ولكن في أحيان أخرى يكون الاختيار صعباً وذلك من خلال كل من معاملات ارتباط الذاتي (ACF)، ومعاملات الارتباط الذاتي الجزئي (PACF) وغيرهم (Wei, 2019). وهناك العديد من المعايير التي تُستخدم لاختيار رتبة النموذج الملائم معتمدةً على الأخطاء الناتجة من التنبؤ، منها:

أ- معيار اكاكي (AIC): ربما يكون معيار معلومات اكاكي (AIC) من أكثر معايير تعظيم الاحتمال شيوعاً لاختيار النماذج الإحصائية، وفي جوهره يُعبر هذا المعيار عن توازن بين مدى ملائمة النموذج للبيانات وتعقيده الهيكلي، صيغته الأساسية هي كما يلي:

$$AIC = -2 \ln(\hat{L}) + 2k \quad (31)$$

حيث يُشير الرمز (\hat{L}) الى أعظم اماكن الملائم للنموذج ويمثل الرمز (k) عدد المعالم المقدرة، وينشأ هذا المعيار من نهج معلوماتي يُقدّر متوسط تباعد $(Kulback - Leibler)$ بين النموذج الملائم والتوزيع الحقيقي ومن ثم يستبعد او يمنع الزيادات غير الضرورية في عدد المعاملات لتجنب الإفراط في الملاءمة. عملياً، يُستخدم معيار (AIC) لمقارنة مجموعة من النماذج المرشحة على مجموعة البيانات نفسها وبافتراض أن المعلمات تم تقديرها باستخدام طريقة الإمكان الأعظم، فإن النموذج الذي يمتلك اقل قيمة (AIC) من بين هذه النماذج هو الأفضل للتنبؤ خارج العينة. وعندما يكون حجم العينة محدوداً أو تكون نسبة (k/n) غير ضئيلة فإنه يُفضل استخدام النسخة المُصححة من المعيار والخاصة بالعينات الصغيرة، وهي معيار اكاكي المُصحح (AICc) وصيغته الأساسية هي:

$$AICc = AIC + \frac{2k(k+1)}{n-k-1} \quad (32)$$

مما يقلل من تحيز معيار (AIC) ويُحسن أداء الاختيار في السلاسل الزمنية الصغيرة (Cavanaugh & Neath, 2019).
ب- معيار اكاكي (BIC): يعتبر معيار المعلومات البايزي (BIC) أحد أكثر معايير اختيار النماذج استخداماً لتقييم الأدلة البايزية بصورة تقاربيه. وصيغته القياسية هي:

$$BIC = -2 \ln(\hat{L}) + k \ln(n) \quad (33)$$

حيث يمثل الرمز (n) حجم العينة. عملياً، يُستخدم (BIC) لمقارنة النماذج المُقدرة بناءً على نفس البيانات بافتراض تقدير الامكان الاعظم. ويميل هذا النموذج إلى تفضيل النماذج الأبسط مقارنةً بمعيار (AIC) لأن جزاءه يعتمد على $[\ln(n)]$ بدلاً من الثابت (k) . لذلك، يكون معيار (BIC) أكثر موثوقية وحزم مع زيادة حجم العينة (n) بينما يُفضل استعمال معيار (AIC) عندما يكون الأداء التنبؤي خارج العينة معياراً أساسياً. مع ذلك، لا يقدم (BIC) اختبار صلاحية مطلقة ولا يُحقق أداءً جيداً في بعض النماذج غير المنتظمة أو عندما تكون البنية مُعقدة مثل النماذج المختلطة (Gelman et al., 2014).

8. السيطرة على التنبؤات: إن تأثير التشويش (الضوضاء) يمكن أن يُسيطر عليه لتقليل متوسط مربعات الخطأ إذا كان بالإمكان جعل:

$$x_t^+ = -L_1(B) L_2^{-1}(B) N_{t+f+1} \quad (34)$$

حيث يمثل الرمز (x_t^+) الكمية التي يتم إدخالها للتحكم في المخرجات المتوقعة (أي السيطرة المضافة الى التنبؤ)، ويمثل الرمز (B) عامل الازاحة الخلفية، وان $(L_1(B))$ و $(L_2(B))$ يمثلان متعددات الحدود الخطية وهما مرشحات تكيفية للنظام، وعادتا ما ينظر الى (L_1) كجزء من المتوسط المتحرك (MA) و (L_2) كجزء من الانحدار الذاتي (AR) في صياغة نموذج (ARMA). ويمثل الرمز (N_{t+f+1}) عملية الضوضاء او الاضطراب عند الأفق $(t+f+1)$. ويمكن إيجاد اقل متوسط مربعات سيطرة الخطأ (Minimum Mean Square Control Error)، عن طريق استبدال (N_{t+f+1}) بالقيمة المتنبأ بها $(\hat{N}_t(f+1))$ وذلك من خلال استخدام السيطرة على القيمة المتنبأ بها وكما في المعادلة (35) الآتية:

$$x_t^+ = -L_1(B) L_2^{-1}(B) \hat{N}_t(f+1) \quad (35)$$

إذن فإن التعديل يحصل من خلال متغير المعالجة الآتي:

$$\chi_t = -L_1(B) L_2^{-1}(B) [\hat{N}_t(f+1) - \hat{N}_{t-1}(f+1)] \quad (36)$$

اذ أن المقدار $[\hat{N}_t(f+1) - \hat{N}_{t-1}(f+1)]$ في المعادلة (36) يمكن استنتاجه من سلسلة الأخطاء او البواقي وذلك من خلال المعادلة (37) الآتية:

$$N_{t+f+1} = L_4(B) a_{t+f+1} + L_3(B) a_t \quad (37)$$

في هذه الحالة فإن الخطأ في الناتج عند الزمن (t) يمكن أن يُعد خطأً للتنبؤ عند الزمن القادم $(f+1)$ للعملية (N_t) ، أي ان:

$$\varepsilon_t = N_t - \hat{N}_{t-f-1}(f+1) = e_{t-f-1}(f+1) \quad (38)$$

بالتالي فإن السيطرة المضافة الى التنبؤ للسيطرة على التنبؤ وإنتاج اقل متوسط مربعات خطأً للتنبؤات يمكن التعبير عنه في الصيغة (39) الآتية (Akhtar, 2021):

$$x_t^+ = \frac{L_1(B) L_3(B)}{L_2(B) L_4(B)} \varepsilon_t \quad (39)$$

9. وصف برنامج المحاكاة: تعتبر أساليب المحاكاة الإحصائية من أهم الأدوات المنهجية في البحث الكمي المعاصر حيث تربط بفعالية النظرية الإحصائية والتطبيق العملي. وفي مجال تحليل السلاسل الزمنية ازدادت أهميتها بشكل كبير منذ المساهمات الرائدة التي قدمها بوكس-جينكينز (1970) في تطوير منهجية التحليل التنبؤي للسلاسل الزمنية والتي وضعت الأسس النظرية لنماذج الانحدار الذاتي المتكامل المتوسطات المتحركة (ARIMA). تُحاكي المحاكاة الإحصائية وهي عملية رياضية وحسابية متطورة سلوك الأنظمة المعقدة من خلال توليد بيانات تركيبية تعكس خصائص النظام الحقيقي بالاستفادة من مولدات الأرقام العشوائية والخوارزميات المتقدمة. ومع ظهور تقنيات الحوسبة عالية الأداء والذكاء الاصطناعي تتطور أساليب محاكاة السلاسل الزمنية باستمرار، كما تُسهّم خوارزميات التعلم الآلي في تطوير أساليب محاكاة وتجعلها أكثر دقة وكفاءة (Brockwell & Davis, 2016). وتتخلص عملية المحاكاة الخاصة بالدراسة بالخطوات الآتية:

1- باستخدام لغة البرمجة الإحصائية (R) تم توليد بيانات عشوائياً وفق ثلاثة حجوم عينات، عينة صغيرة الحجم ($n=25$) وعينة متوسطة الحجم ($n=50$) وعينة كبيرة الحجم ($n=100$) حيث أن البيانات المولدة وبالأحجام الثلاثة وفق النماذج [ARMA(1,1), ARMA(1,2), ARMA(2,1), ARMA(2,2)]، كما تم اختيار معالم النموذج المنتخب بحيث تحقق شرط السكون (Stationary) وهي:

$$\phi_i = \pm 0.2, \pm 0.5, \pm 0.8 \quad i = 1, 2$$

$$\theta_i = \pm 0.2, \pm 0.5, \pm 0.8 \quad i = 1, 2$$

حيث ولدت قيم (Z_t) المستخدمة للعينات الثلاث وكذلك الأخطاء العشوائية (ε_t) التي ولدت من توزيع طبيعي قياسي، وتم تكرار التجربة (200) مرة على كل عينة من العينات الالفة الذكر، وفي كل عينة تم اعتماد تشكيلة متكاملة من المعلمات السابقة لمعالم النموذج وهما (ϕ_i, θ_i).

2- إجراء عملية التنبؤ بطرائق بوكس-جينكينز على البيانات المولدة في الخطوة الأولى واعتماداً على أحجام العينات الثلاث المذكورة سابقاً، مع إيجاد الحدين الأدنى والأعلى للتنبؤات. ثم احتساب مقاييس جودة التنبؤ وهي (MSE) و (MAPE) على البيانات والتنبؤات السابقة.

3- إجراء التنبؤ بطريقة التنقية التكرارية اعتماداً على البيانات المولدة في الخطوة الأولى، مع توليد بيانات عشوائية أخرى تمثل البواقي بحيث تحقق وسط حسابي مساوي للصفر وتباين مساوي للواحد، علماً أن التنبؤ بهذه الطريقة يعتمد على قيمة (k) المتغيرة في كل مرحلة من مراحل التنبؤ وبناءً على النتائج، ويستمر التنبؤ بشكل مستمر حتى الوصول إلى فرق بين كل قيمتين متتبعين لا يزيد على (0.001) عند ذلك يتوقف التنبؤ بهذه الطريقة.

4- احتساب مقاييس جودة التنبؤ المذكورة للبيانات المتنبأ بها بهذه الطريقة، وتحديد الأقل بين مقاييس جودة التنبؤ التي من الصنف نفسه بين طريقتي التنبؤ المستخدمة. ثم احتساب معايير جودة التنبؤ (MSE و MAPE) وفق كل مجموعة من المجموعتين المتنبأ بهما على حده.

5- إعادة الخطوات السابقة (200) مرة لتكرار العمليات المذكورة انفاً من أجل تناول كل الاحتمالات الممكنة، وقد تم تسجيل نتائج معايير التنبؤ كافة بشكل مستقل لكل طريقة تنبؤية مع السيطرة على التنبؤات.

6- العمل على احتساب الأقل من بين المعايير أي الأقل أو الأفضل لمعيار (MSE) الناتجة من طريقتي التنبؤ، ومن ثم احتساب الأقل لنتائج السيطرة على التنبؤات وأيضاً بأسلوب مشابه، وكذلك الحال فيما يخص معيار (MAPE).

7- إعادة العمليات السابقة جميعاً لباقي الحالات الممكنة لتشكيلة معالم النماذج (ϕ_i, θ_i) لكل نموذج بشكل مستقل عن الآخر.

8- احتساب الأفضل بناءً على النسبة المئوية لعدد الحالات التي تعطي الأقل بين معايير التنبؤ، وفق كل معيار ووفق كل طريقة من طرق التنبؤ مع السيطرة على القيم التنبؤية بالطريقة نفسها.

10. تحليل وتفسير النتائج: توضح النتائج التالية المفاضلة بين طرائق التنبؤ وفق معايير ضبط الدقة والسيطرة على التنبؤ ولجميع النماذج الموصوفة سابقاً وكما يلي:

جدول 1: قيم معايير ضبط دقة التنبؤ لطريقتي التنبؤ المعتمدة للعينة الصغيرة ($n=25$) لنموذج ARMA(1,1)

قيم (MAPE) للسيطرة على التنبؤ		قيم (MAPE) بحسب طرائق التنبؤ		قيم (mse) للسيطرة على التنبؤ		قيم (mse) بحسب طرائق التنبؤ		المعطيات	
طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	θ_1	ϕ_1
2.1933*	4.2951	3.4054	1.24905*	2.4824*	2.9913	0.80447*	0.95021	0.8	0.8
3.4156*	7.7853	1.5858	1.31396*	5.9710*	6.3906	0.92341	0.74454*	0.5	0.8
8.2065*	17.4194	6.9264	1.49945*	9.7924*	11.0926	1.39572	0.67140*	0.2	0.8
5.7990*	6.7347	3.0462	1.02663	50.8840	49.1488*	0.85384	0.63950*	-0.2	0.8
0.9988*	1.6306	43.4247	7.49554*	5.4681*	5.9668	0.95024	0.86296*	-0.5	0.8
3.3997*	4.7712	1.2692	1.04078*	19.4566*	21.8916	0.43800*	0.80384	-0.8	0.8
5.8057*	35.2574	1.4471	1.06059*	6.5727*	9.5055	0.90081	0.57783*	0.8	0.5
2.1998*	5.2864	8.2048	2.76856*	1.5835*	2.1766	1.26802	0.58032*	0.5	0.5
0.9975*	1.6392	16.7116	1.27116*	1.1434*	1.1955	1.15962	0.70556*	0.2	0.5
7.0070*	8.3716	1.7420	1.18612*	14.7979*	16.0650	0.85964*	0.87897	-0.2	0.5
5.8010*	15.6839	3.0216*	3.22883	9.3472*	11.4874	0.70296*	0.85873	-0.5	0.5
0.9983*	2.4009	1.6843	0.87211*	4.2147*	4.6156	1.26907	0.71315*	-0.8	0.5
0.9969*	4.7108	1.6943	1.44750*	0.6063*	1.4104	0.87222	0.82768*	0.8	0.2
2.1886*	18.0670	1.0462	0.78530*	2.7908*	6.7045	0.80951	0.67637*	0.5	0.2
10.5964*	20.8561	6.2377	2.33005*	10.9765*	13.1332	0.95088	0.72888*	0.2	0.2
4.5990*	7.3846	27.6088	6.78124*	6.7154*	8.3139	1.14914	0.81831*	-0.2	0.2
11.7989*	21.9794	3.1103	1.15922*	19.3208	18.8053*	1.01351	0.58206*	-0.5	0.2
4.6043*	7.9289	3.7199	2.31068*	16.6093	15.5683*	0.78129	0.64883*	-0.8	0.2
2.2018*	11.7822	1.7637	1.46469*	2.4963*	3.9406	0.85786	0.69248*	0.8	-0.2
11.8032*	30.5108	4.6312	1.71573*	13.4634*	15.0006	1.14110	0.89075*	0.5	-0.2
7.0008*	17.0088	4.6738	1.53849*	8.3413*	9.4426	1.06242	0.64279*	0.2	-0.2
2.1972*	3.2633	3.6185	1.92920*	1.9238	1.7597*	1.02505	0.57257*	-0.2	-0.2
3.3996*	4.4429	2.5983	1.55146*	5.0234*	6.5583	0.63489*	0.89016	-0.5	-0.2
2.1819*	13.7424	2.8830*	4.18029	3.1049*	3.6673	0.71820	0.59051*	-0.8	-0.2
11.7939*	21.7989	3.1778	1.66489*	30.1082*	41.7225	0.99408*	1.09584	0.8	-0.5
2.2045*	3.2654	3.4051	1.95906*	2.1911*	2.5909	1.19702	0.67715*	0.5	-0.5
0.9991*	1.8733	7.8937	2.03608*	1.4263*	1.5340	1.18689	0.63643*	0.2	-0.5
5.8031*	12.3469	3.3137	1.22053*	6.6096	8.7430*	0.75066*	0.86992	-0.2	-0.5
5.8440*	63.6378	3.3908	1.32929*	6.0837*	7.1167	0.84484*	1.13966	-0.5	-0.5
0.9981*	4.7140	1.5783*	1.86148	1.9251*	2.2987	0.85153*	1.07019	-0.8	-0.5
3.4005*	3.6447	1.2244	1.05760*	21.1651	20.3456*	0.60831*	0.66616	0.8	-0.8
1.0000*	1.2071	3.2523	1.15055*	7.5746*	7.6632	1.58741	0.64586*	0.5	-0.8
3.4023*	3.4739	2.0166	1.38498*	10.1135	8.5315*	0.71177*	0.72646	0.2	-0.8
7.0018*	10.3461	1.7226	1.00349*	16.0566*	22.3829	0.90668	0.82215*	-0.2	-0.8
3.3979*	7.6028	1.7083	1.02860*	2.5456*	3.2022	1.09626	0.68748*	-0.5	-0.8
2.2024*	3.2277	3.5040	1.53242*	2.0387*	2.6716	0.91166	0.84892*	-0.8	-0.8
100%			91.667 %	83.334 %			69.444 %	الأفضل	

المصدر: نتائج التحليل الاحصائي باستخدام برنامج (R).

نلاحظ من الجدول (1) ان أفضلية التنبؤ كانت لطرائق بوكس-جينكينز وبنسبة (69.444%) وفق معيار (MSE) وبلغت النسبة (91.667%) وفق معيار (MAPE). أما بعد استخدام السيطرة على التنبؤات فقد كانت الأفضلية للتنبؤ بطريقة التنقية التكيفية على التنبؤ بطرائق بوكس-جينكينز حيث أن الأفضلية للعينات الصغيرة وفق معيار (MSE) بلغت نسبة (83.334%) أما وفق معيار (MAPE) فقد بلغت نسبة الحالات الأفضل (100%) للعينات صغيرة الحجم (n=25). إذ أظهر تحليل تباين مقاييس الخطأ عبر 200 تكرار محاكاة أن فترات الثقة (95%) لمتوسط فرق الأداء كانت متنسفة مع نسب التفوق المعروضة، مما يعكس استقرار هذه النتائج عبر التكرارات.

جدول 2: قيم معايير ضبط دقة التنبؤ لطريقتي التنبؤ المعتمدة للبيانات المتوسطة (n=50) لنموذج ARMA(1,1)

قيم (MAPE) للسيطرة على التنبؤ		قيم (MAPE) بحسب طرائق التنبؤ		قيم (mse) للسيطرة على التنبؤ		قيم (mse) بحسب طرائق التنبؤ		المعلمات	
طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	θ_1	ϕ_1
0.9997*	1.382	1.8209*	3.1109	0.9979*	1.7640	0.87380*	1.25115	0.8	0.8
4.6258*	17.563	1.5630*	3.0248	4.9889*	5.6258	0.70013*	0.96500	0.5	0.8
4.5918*	8.394	1.1898*	2.2680	12.4011*	12.7228	0.86946*	0.99753	0.2	0.8
3.3980*	4.027	1.4364*	20.8186	18.5338*	20.6256	1.23040	0.92990*	-0.2	0.8
1.0001*	1.194	1.2337*	2.5501	3.9925*	4.2015	0.66351*	0.92111	-0.5	0.8
3.3976*	3.965	37.9259	21.5562*	15.2966	14.8792*	0.75743*	0.87191	-0.8	0.8
3.3993*	4.375	1.1083*	1.2971	2.6694*	3.0156	1.07231	0.75137*	0.8	0.5
8.1912*	18.527	1.8908*	6.8907	7.7961*	12.2489	0.56923*	1.19902	0.5	0.5
2.2006*	3.177	2.5795*	11.2460	3.1616	3.1285*	0.97589*	1.05658	0.2	0.5
2.2002*	2.835	1.0404*	4.2837	5.1732	4.4576*	0.89933	0.84332*	-0.2	0.5
0.9999*	1.058	1.9724*	3.7937	3.1059*	3.2719	0.85941	0.80028*	-0.5	0.5
0.9996*	1.323	6.0845*	10.3234	4.1628*	5.1627	0.61756*	1.02527	-0.8	0.5
3.3942*	10.127	2.0552*	4.2882	4.3842	3.8211*	0.74457*	0.93173	0.8	0.2
1.0145*	5.089	1.0534*	2.1639	0.6306*	0.7592	0.69964*	0.87834	0.5	0.2
2.2011*	3.248	2.9493*	5.8186	1.5731*	1.7060	0.75772*	1.39392	0.2	0.2
0.9999	0.955*	1.3101*	2.7683	1.3481	1.3132*	0.88382*	1.10064	-0.2	0.2
1.0005*	1.656	2.5364*	5.7811	2.3955	2.2954*	0.65498*	0.98339	-0.5	0.2
0.9994*	1.423	9.6353	9.0521*	2.0274*	2.7116	0.95123	0.90686*	-0.8	0.2
2.1980*	5.061	1.1634*	1.7184	7.2804	5.3370*	1.01107	1.00621*	0.8	-0.2
9.6221*	23.555	1.0145*	1.4127	12.7810	9.9444*	0.75876*	0.78787	0.5	-0.2
9.3455*	19.333	2.3782*	5.9941	11.1132*	11.3322	0.96930	0.49922*	0.2	-0.2
0.9991*	1.005	1.5540*	2.2725	0.9583*	1.0521	0.84358*	1.08602	-0.2	-0.2
1.0023*	1.369	1.3271*	7.0292	1.0774*	1.2994	1.02508	1.01190*	-0.5	-0.2
8.2013*	12.078	1.5530*	3.2432	12.6262	11.6565*	0.70124*	1.02706	-0.8	-0.2
0.9996*	1.274	17.9297*	23.7010	1.4909*	1.7520	0.72368*	0.84990	0.8	-0.5
4.6171*	18.343	1.3928*	3.1988	6.6842	6.6807*	1.10552	0.69516*	0.5	-0.5
7.0008*	9.780	1.3024*	2.5518	13.7084*	18.2022	0.75650*	1.03152	0.2	-0.5
1.0013*	1.175	1.6434*	2.4949	0.9607*	1.0495	0.97111	0.85681*	-0.2	-0.5
0.9999*	2.004	2.4824*	7.5133	0.9791*	1.0561	0.86707*	0.96286	-0.5	-0.5
11.8054*	30.560	1.6926*	3.9477	13.7176*	21.0981	0.86206*	0.90903	-0.8	-0.5
2.1988*	2.276	2.0597*	2.6303	4.7019*	4.9780	0.83900	0.78334*	0.8	-0.8
1.0743*	20.075	8.2936*	22.1149	4.4540*	4.6819	0.79125*	0.91737	0.5	-0.8
1.0018*	1.183	9.6262*	24.3688	2.9171*	3.0640	0.63102*	0.85233	0.2	-0.8
1.0130*	1.556	1.3857*	3.4962	1.2514*	1.2936	0.77147*	1.14598	-0.2	-0.8
1.0014*	2.592	1.2004*	2.6237	1.0524*	1.0912	0.91289*	1.23827	-0.5	-0.8
4.5967*	11.961	3.0014*	3.7424	4.8801*	8.7665	0.82973*	1.09564	-0.8	-0.8
97.221%		94.445 %		72.222 %		69.445 %			الأفضل

المصدر: نتائج التحليل الاحصائي باستخدام برنامج (R).

جدول 3: قيم معايير ضبط دقة التنبؤ لطريقتي التنبؤ المعتمدة للعينة الكبيرة (n=100) لنموذج ARMA(1,1)

قيم (MAPE) للسيطرة على التنبؤ		قيم (MAPE) بحسب طرائق التنبؤ		قيم (mse) للسيطرة على التنبؤ		قيم (mse) بحسب طرائق التنبؤ		المعلمات	
طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	طريقة MW	طريقة BJ	θ_1	ϕ_1

20.678*	85.292	1.03642*	2.5331	20.03*	22.44	1.02815*	1.19586	0.8	0.8
98.821*	193.625	0.85853	0.7421*	11.59*	19.33	0.58783	0.32386*	0.5	0.8
0.999*	2.176	1.20840*	2.3636	0.87	0.86*	1.17471*	1.54145	0.2	0.8
20.606*	16.253*	1.35831*	3.2980	15.49*	17.00	0.59890	0.30854*	-0.2	0.8
59.772*	65.849	0.98570*	2.0042	398.82	361.66*	0.80600*	1.11114	-0.5	0.8
40.196*	54.978	3.40076*	12.1413	1101.68*	1777.25	0.69754*	2.50082	-0.8	0.8
20.448*	142.451	1.24038*	2.1448	23.07*	34.04	0.64758*	2.06054	0.8	0.5
1.037*	13.613	0.82171	0.7646*	0.75*	1.05	1.20530	0.92858*	0.5	0.5
101.675*	482.703	0.88292*	0.9206	115.82	113.45*	1.13682	0.75581*	0.2	0.5
59.730*	87.826	1.59945*	2.6881	88.54	75.60*	0.33397*	0.57493	-0.2	0.5
59.727*	74.212	0.76467*	1.5212	183.20	155.07*	0.96778	0.59436*	-0.5	0.5
99.026*	175.793	1.25529*	2.7317	583.93	554.19*	0.25316*	0.82231	-0.8	0.5
40.192*	158.609	2.61089	1.1994*	45.03*	122.55	0.63735*	0.71201	0.8	0.2
60.087*	297.458	0.69477*	2.0108	68.52	63.49*	0.68539*	1.35004	0.5	0.2
99.148*	174.617	0.98173*	4.6177	108.73*	112.08	0.53141*	0.84963	0.2	0.2
20.621*	65.004	1.11263*	1.8506	24.99*	25.08	0.41780*	2.29965	-0.2	0.2
59.813*	102.828	0.84949*	1.4011	67.97*	98.02	0.86537	0.57953*	-0.5	0.2
1.001*	1.335	0.84184*	1.4182	4.95*	5.62	0.87533	0.83573*	-0.8	0.2
0.999*	1.790	0.91415*	1.3177	5.44*	6.76	0.63573	0.61535*	0.8	-0.2
20.600*	22.314	0.85011*	1.6277	16.44*	17.50	0.85066	0.45080*	0.5	-0.2
98.960*	116.988	1.08771	0.9737*	128.11*	137.65	0.87465	0.37066*	0.2	-0.2
98.900*	204.929	1.03173*	1.8019	95.07*	101.26	1.25845*	2.55967	-0.2	-0.2
98.966*	158.459	0.60078*	4.3014	101.67*	123.13	0.94333*	2.46525	-0.5	-0.2
20.555*	63.785	1.28307*	2.8526	23.88*	38.36	0.35179*	1.08911	-0.8	-0.2
1.000*	1.512	0.93437*	1.8814	3.49*	4.99	0.44631*	0.81498	0.8	-0.5
99.046*	261.800	5.23119*	17.6925	168.93*	203.27	0.48449*	0.59282	0.5	-0.5
1.000	0.799*	2.52086*	14.0991	2.68	2.26*	1.10844*	1.39183	0.2	-0.5
20.566*	37.051	0.86052*	1.7104	39.53*	43.13	1.01796*	1.94982	-0.2	-0.5
40.173*	206.560	0.83359	0.7530*	41.25*	93.13	0.84972	0.57209*	-0.5	-0.5
79.352*	459.523	0.66083	0.6235*	82.91*	156.42	0.85831*	0.99711	-0.8	-0.5
40.221*	47.765	0.68014*	0.8071	196.85	195.80*	0.94492	0.72231*	0.8	-0.8
60.030*	305.898	0.82364	0.7587*	235.46*	263.05	0.85635	0.23715*	0.5	-0.8
99.032*	133.065	0.94153*	1.0087	326.87*	350.48	1.45751*	2.10992	0.2	-0.8
20.566*	37.051	0.86052*	1.7104	39.53*	43.13	1.01796*	1.94982	-0.2	-0.8
40.173*	206.560	0.83359	0.7530*	41.25*	93.13	0.84972	0.57209*	-0.5	-0.8
79.352*	159.523	0.66083	0.6235*	82.91*	156.42	0.85831*	0.99711	-0.8	-0.8
94.4 %		75.1 %		75.0 %		61.1 %			الطريقة الافضل

المصدر: نتائج التحليل الاحصائي باستخدام برنامج (R).

نلاحظ من الجدولين (2) و (3) أن التنبؤ بطريقة التنقية المعدلة هو أفضل من التنبؤ بطرائق بوكس-جينكينز للعينات المتوسطة ($n=50$) والكبيرة ($n=100$) حيث بلغت نسبة الحالات (من بين كل الحالات الممكنة لمعالم النموذج المنتخب وفق نموذج $ARMA(1,1)$ التي حققت الأفضلية وفق معيار (MSE) للعينات المتوسطة (69.445%)، أما وفق معيار $(MAPE)$ فقد كانت الأفضلية بمقدار (94.445%)، وبنفس الأسلوب فإن الأفضلية حسب معيار (MSE) للعينات الكبيرة بلغت (61.1%) ووفق معيار $(MAPE)$ فقد بلغت (75.1%). أما بعد استخدام السيطرة على التنبؤات فقد كانت الأفضلية للتنبؤ بطريقة التنقية التكيفية حيث أن بلغت نسبة الأفضلية للعينات المتوسطة وفق معيار (MSE) بلغت (72.222%) وللعينات الكبيرة بلغت النسبة (75.0%)، أما

وفق معيار (MAPE) فقد بلغت نسبة الحالات الأفضل (97.221%) للعينات متوسطة الحجم وبنسبة (94.4%) للعينات ذات الحجم الكبير.

جدول 4: الطريقة الأفضل وفق معايير ضبط الدقة والسيطرة على التنبؤ لنموذج ARMA(1,2)

حجم العينة	نوع معيار المفاضلة	أفضل تنبؤ / BJ	أفضل تنبؤ / MW	أفضل سيطرة على التنبؤ / BJ	أفضل سيطرة على التنبؤ / MW
25	MSE	72.524 %			77.421 %
	MAPE	88.997 %			96.657 %
50	MSE		70.867 %		72.739 %
	MAPE		90.568 %		93.983 %
100	MSE		64.879 %		76.124 %
	MAPE		77.543 %		89.762 %

المصدر: من عمل الباحث بالاعتماد على نتائج التحليل الاحصائي باستخدام برنامج (R).

تلخص نتائج الجدول (4) أداء الطريقتين لنموذج ARMA(1,2) حيث تؤكد نسب التفوق وفترات الثقة المصاحبة لها أن أفضل طريقة التنقية التكرارية، ولا سيما بعد تطبيق السيطرة على التنبؤات، تمثل اتجاهاً مستقراً عبر أحجام العينات المختلفة، في حين يقتصر تفوق طرائق بوكس - جينكينز على بعض الحالات قبل السيطرة فقط.

جدول 5: الطريقة الأفضل وفق معايير ضبط الدقة والسيطرة على التنبؤ لنموذج ARMA(2,1)

حجم العينة	نوع معيار المفاضلة	أفضل تنبؤ / BJ	أفضل تنبؤ / MW	أفضل سيطرة على التنبؤ / BJ	أفضل سيطرة على التنبؤ / MW
25	MSE	64.395 %			86.052 %
	MAPE	87.879 %			98.983 %
50	MSE		73.007 %		70.115 %
	MAPE		92.778 %		88.413 %
100	MSE		76.752 %		78.596 %
	MAPE		84.739 %		89.102 %

المصدر: من عمل الباحث بالاعتماد على نتائج التحليل الاحصائي باستخدام برنامج (R).

يبين الجدول (5) أن نتائج نموذج ARMA(2,1) تتسق مع ما ورد في الجداول السابقة، إذ أظهر تحليل تباين مؤشرات الدقة أن تفوق إحدى الطريقتين في بعض أحجام العينات كان مدعوماً بفترات ثقة مستقرة، مع ملاحظة تحسن واضح في استقرار أداء طريقة التنقية التكرارية بعد إدخال السيطرة على التنبؤات.

جدول 6: الطريقة الأفضل وفق معايير ضبط الدقة والسيطرة على التنبؤ لنموذج ARMA(2,2)

حجم العينة	نوع معيار المفاضلة	أفضل تنبؤ / BJ	أفضل تنبؤ / MW	أفضل سيطرة على التنبؤ / BJ	أفضل سيطرة على التنبؤ / MW
25	MSE	74.784 %			91.457 %
	MAPE	84.974 %			97.995 %
50	MSE		75.751 %		78.918 %
	MAPE		77.848 %		82.673 %
100	MSE		84.022 %		88.601 %
	MAPE		85.903 %		91.004 %

المصدر: من عمل الباحث بالاعتماد على نتائج التحليل الاحصائي باستخدام برنامج (R).

تؤكد نتائج الجدول (6) الخاصة بنموذج ARMA(2,2) أن أفضل طريقة التنقية التكرارية في التنبؤ والسيطرة على التنبؤات ليست حالة استثنائية، بل نمطاً عاماً مدعوماً بانخفاض التشتت وفترات ثقة ضيقة نسبياً لمقاييس الخطأ عبر التكرارات، مما يعزز موثوقية الاستنتاجات النهائية للدراسة.

11. الاستنتاجات

- توجد فروقات معنوية بين طريقتي التنبؤ من حيث التنبؤ والسيطرة على التنبؤات، إذ تكون معلمة النموذج ثابتة في طرائق بوكس-جينكينز (BJ) في الاستخدام لأجراء التنبؤات المطلوبة، في حين في طريقة التنقية التكريرية (MW) فإن معلمة (أو معالم) النموذج سوف أو تُحدَّث وفق كل مشاهدة جديدة متنبأ بها.
- هناك أفضلية لطريقة التنقية التكريرية (MW) على الطرائق بوكس-جينكينز (BJ) إذ تتضمن قدرة الطريقة الأولى على التعامل مع السلاسل الزمنية غير المستقرة. حيث أن الخطوات الجوهرية لهذه الطريقة لا تعتمد ولا تتأثر بالتغيرات البسيطة على البيانات.
- في حالة لعينات صغيرة الحجم هناك أفضلية للتنبؤ بطرائق بوكس-جينكينز على طريقة التنقية التكريرية قبل استخدام السيطرة على التنبؤات، ولكن بعد إجراء السيطرة على التنبؤات فقد عادت الأفضلية لطريقة التنقية المعدلة وبكلا معياري المقارنة (MSE) و (MAPE).

12. التوصيات:

- تعميم طريقة التنقية التكريرية (MW) لتشمل نماذج السلاسل الزمنية الموسمية (Seasonal time series)، ونماذج السلاسل الزمنية متعددة المتغيرات (Multivariate time series).
- استعمال طريقة التنقية التكريرية (MW) في السيطرة على التنبؤات وذلك لقدرتها على التعامل مع البيانات التي تعاني من تشويش وغير المستقرة.

References:

- 1- Akhtar, M. T. (2021). Narrowband feedback active noise control systems with secondary path modeling using gain-controlled additive random noise. *Digital Signal Processing*, 111, 102976.
- 2- Athiyarath, S., Paul, M., & Krishnaswamy, S. (2020). A comparative study and analysis of time series forecasting techniques. *SN Computer Science*, 1(3), 175.
- 3- Binner, J. M., Bissoondeal, R. K., Elger, T., Gazely, A. M., & Mullineux, A. W. (2005). A comparison of linear forecasting models and neural networks: an application to Euro inflation and Euro Divisia. *Applied economics*, 37(6), 665-680.
- 4- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley.
- 5- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting* (3rd ed.). Springer.
- 6- Cavanaugh, J. E., & Neath, A. A. (2019). The Akaike information criterion: Background, derivation, properties, application, interpretation, and refinements. *Wiley Interdisciplinary Reviews: Computational Statistics*, 11(3), e1460.
- 7- Clarkson, P. M. (2017). *Optimal and adaptive signal processing*. Routledge.
- 8- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427-431.
- 9- Farhang-Boroujeny, B. (2013). *Adaptive filters: theory and applications*. John wiley & sons.
- 10- Gao, J., Sultan, H., Hu, J., & Tung, W. W. (2009). Denoising nonlinear time series by adaptive filtering and wavelet shrinkage: a comparison. *IEEE signal processing letters*, 17(3), 237-240.
- 11- Gelman, A., Hwang, J., & Vehtari, A. (2014). Understanding predictive information criteria for Bayesian models. *Statistics and computing*, 24(6), 997-1016.
- 12- Hamilton, J. D. (2020). *Time series analysis*. Princeton university press.
- 13- Hippert, H. S., Pedreira, C. E., & Souza, R. C. (2002). Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on power systems*, 16(1), 44-55.
- 14- Huang, Y., Xu, C., Ji, M., Xiang, W., & He, D. (2020). Medical service demand forecasting using a hybrid model based on ARIMA and self-adaptive filtering method. *BMC Medical Informatics and Decision Making*, 20(1), 237.
- 15- Hu, Y., Bi, C., & Chen, Y. (2024). Kernel Adaptive Filtering Algorithm Based on Hyperbolic Tangent Mixed Error Function. *Symmetry*, 16(12), 1624.
- 16- Makridakis, S., & Wheelwright, S. C. (1977). Forecasting: issues & challenges for marketing management. *Journal of Marketing*, 41(4), 24-38.
- 17- Monim A. M. (2001). The Minimum Mean Square Predictor Error in Spectral Time Series Model. *Iraqi Journal of Statistical Science* (2), 16-23.
- 18- Reinsel, G. C. (2003). *Elements of multivariate time series analysis*. Springer Science & Business Media.
- 19- Shumway, R. H., & Stoffer, D. S. (2017). *Time Series Analysis and Its Applications* (4th ed.). Springer.
- 20- Skowronski, M. D., & Harris, J. G. (2006, May). Minimum mean squared error time series classification using an echo state network prediction model. In *2006 IEEE International Symposium on Circuits and Systems* (pp. 4-pp). IEEE.
- 21- Siqueira, H., Luna, I., Alves, T. A., & de Souza Tadano, Y. (2019). The direct connection between box & Jenkins methodology and adaptive filtering theory. *Mathematics in Engineering, Science & Aerospace (MESA)*, 10(1).
- 22- Wei, W. W. S. (2019). *Time Series Analysis: Univariate and Multivariate Methods* (4th ed.). Pearson.