

نمذجة وتحليل البقع الشمسية الشهرية باستخدام نماذج المكونات غير المشاهدة

الباحث: محمود مقداد إلياس م.د. مزاحم محمد الهاشمي م.م. أحمد نزيه عبدالله الخطيب
كلية علوم الحاسوب والرياضيات كلية علوم الحاسوب والرياضيات كلية علوم الحاسوب والرياضيات
جامعة الموصل جامعة الموصل جامعة الموصل
Mahmoud@yahoo.com muzahim63@gmail.com ahmednazih17@gmail.com

المستخلص:

يعد التكهّن بعدد البقع الشمسية التي يحتمل حدوثها خلال أي دورة معينة أمراً مهماً للعلماء المعنيين بفهم العواقب الأرضية للنشاط الشمسي، ولهذا فقد ابتكر العديد من الطرق وتم الجمع بينها وتنقيحها في محاولة للتنبؤ بنشاط البقع الشمسية. في هذا البحث، تم تسليط الضوء على نماذج المكونات غير المُشاهدة (Unobserved Components Models)، وتم استخدامها في نمذجة وتحليل البيانات الشهرية للبقع الشمسية وللفترة من كانون الثاني ١٩٠٠ إلى كانون الأول ٢٠١٨ (١٤٢٨ شهراً)، وهي بيانات غير مستقرة ولها دورية واضحة. أظهر التحليل قدرة انموذج المكونات غير المُشاهدة الفائقة في تمثيل بيانات البقع الشمسية وذلك من خلال اجتيازه للاختبارات التشخيصية فضلاً عن قدرته التكهنية العالية. تبين من خلال التحليل ان مكونات المستوى والموسمية هي نماذج عشوائية، وان مكون الانحدار الذاتي والدورية والميل هي نماذج حتمية. تم التكهّن بعدد البقع الشمسية ولمدة (١٠٠) شهر وابتداء من كانون الثاني ٢٠١٩ ولغاية نيسان ٢٠٢٦. على ضوء التكهّن، من المتوقع ان يكون الحد الأقصى لعدد البقع الشمسية في الدورة الشمسية (٢٥) ١٤٦ بقعة شمسية، ومن المتوقع حدوثها في اذار ٢٠٢٣، مع دورة شمسية طولها 125.38331 شهراً أو ما يعادل ١٠,٤٥ سنة. تم استخدام البرنامج الاحصائي SAS 9.4 في التحليل.

الكلمات المفتاحية: السلاسل الزمنية، التكهّن، نماذج المكونات غير المُشاهدة، ارقام البقع الشمسية الشهرية، الدورة الشمسية.

Modeling and Analysis the Monthly Sunspots Using Unobserved Components Models

Researcher: Mahmoud Mekdad Elias
College of Computer Science and Mathematics
University of Mosul

Lecturer Dr. Muzahim M. AL-Hashimi
College of Computer Science and Mathematics
University of Mosul

Assist. Lecturer Ahmed N. A. AL-Khateeb
College of Computer Science and Mathematics
University of Mosul

Abstract:

Predicting the number of sunspots which is likely to occur during any given cycle is important for scientists who understanding the terrestrial consequences of solar activity. Many methods have been devised and combined and refined in an attempt to predict the activity of sunspots. In this paper, Unobserved Components Models (UCM)

were highlighted and used for modeling and analyzing the monthly sunspot data for the period from January 1900 to December 2018 (1428 months), which is unstable and has a clear cycle. The analysis showed the superiority of unobserved components model to fit the sunspot data by passing the diagnostic tests as well as its high predicting. The analysis revealed that the level and seasonal components are stochastic models, and the auto regression, cycles and slope are deterministic models. The number of sunspots was predicted for a period of 100 months from January 2019 to April 2026. The sunspot number maximum in cycle 25 is predicted to occur in April 2023 with a sunspot number 146 and a solar cycle length of 125.38331 months or 10.45 years. SAS 9.4 was used in the analysis.

Keywords: Time Series, Forecast, Unobserved Components Models, Monthly Sunspots Numbers, Solar Cycle.

المقدمة

تمثل انجازات كل من (Holt, 1957; Holt, 2004) و (Winters, 1960) المتمثلة بطرائق المتوسط المتحرك الأسّي الموزون Exponentially Weighted Moving Average: EWMA أمثلة ناجحة ومبكرة لأسلوب المكونات غير المُشاهدة Unobserved Components Models: UCM. كما يمكن النظر إلى نماذج الـ (UCM) على أنها التطور الطبيعي لطرائق (EWMA) في النمذجة العشوائية. إذ من المعروف أن طرائق (EWMA) تعتمد قواعد التنبؤ بدون انموذج، في حين أن التحليل المتسلسل الزمني الحديث يحدد أولاً ويقدر انموذج عشوائي يقترب من آلية توليد البيانات ثم يستخدم صيغة التنبؤ الأمثل لهذا الانموذج.

بعد نشر كتاب (Box and Jenkins, 1976) الشهير في سبعينيات القرن الماضي، اعتبر العديد من الباحثين بأن نماذج الانحدار الذاتي ذو الأوساط المتحركة المندمج Auto Regressive Integrated Moving Average: ARIMA هي أفضل الأدوات المتاحة للتنبؤ بالسلسلة الزمنية. لكن وبمرور الوقت ومع اجراء التطبيقات والمقارنات سرعان ما أثبتت أن تقنيات (EWMA) في كثير من الأحيان تتفوق على نماذج (ARIMA)، (Pelagatti, 2015: 51).

تستند نماذج المكونات غير المُشاهدة على اختيار أفضل الميزات لكل من الطريقتين (EWMA) و (ARIMA). فهي تشترك في نفس الإطار العشوائي لنماذج (ARIMA)، (يمكن اعتبار UCM كمجموع من نماذج ARIMA)، وفي نفس الوقت تعتمد على مكونات (EWMA). لذا فإن نماذج المكونات غير المُشاهدة تميل إلى الأداء الجيد في التنبؤ.


لقد لوحظت المظاهر الداكنة والمغناطيسية والمعروفة باسم البقع الشمسية، وتسمى أحياناً بدورات الطاقة الشمسية (Solar Cycle) التي تظهر بانتظام على سطح الشمس، وسجلتها الحضارات المختلفة منذ آلاف السنين. ويرجع أول دليل معروف لملاحظات البقع الشمسية إلى الصين في القرن ٢٨ قبل الميلاد. وفي أوروبا، ونظراً لأن مفاهيم أرسطو في علم الكون المتمثلة بأن الكون مثالي وغير متغير، فقد سيطرت هذه المفاهيم على مدى قرون، مما أدى إلى عرقلة وإلى حد كبير الدراسات الشمسية وحفظ السجلات. ويرجع تاريخ أول السجلات المفهومة والأكثر اكتمالاً إلى أوائل القرن السابع عشر الميلادي في أوروبا، إذ استخدم علماء الفلك (غاليليو غاليلي: Galileo Galilei) و (توماس هاريوت: Thomas Harriot) و (جوهانس وديفيد فابريسيوس:

(Christoph Scheiner و (كريستوف شاينر: Johannes and David Fabricius) التلسكوبات لتسجيل المشاهدات على البقع الشمسية وذلك في العامين ١٦١٠ و ١٦١١ على التوالي. واستمرت مشاهدة البقع الشمسية مع أنظمة لحفظ البيانات المختلفة حتى عام ١٨٤٩ عندما بدأ مرصد زيورخ في سويسرا بالتسجيل اليومي للنشاط الشمسي. وفي عام ١٨٧٤، بدأ المرصد الملكي غرينتش في إنكلترا بمشاهدة النشاط الشمسي والبقع الشمسية (Carlowicz and Lopez, 2002: 45-49). منذ ذلك الوقت، بدأ عصر جديد من مشاهدات البقع الشمسية ومهد الطريق لتسجيل مستمر تقريباً للنشاط الموضعي على مدار ٤٠٠ سنة الماضية. كما أدت إلى تطور معايير مراقبة البقع الشمسية وحفظ السجلات والى فهم أكبر لهذه الظاهرة.

تظهر البقع الشمسية عادة كمساحة صغيرة نسبياً ومظلمة وتشبه المسامات على سطح أو قرص الشمس (فوتوسفير photosphere). ويبلغ متوسط حجم البقع الشمسية، عند ظهورها للمرة الأولى، حوالي ١٦٠٠ كيلومتر (١٠٠٠ ميل) ويستمر الظهور هذا عادة لبضع ساعات. وقد تستمر بعض البقع الشمسية في النمو وسرعان ما تصبح أكبر بمرات عديدة من الأرض ويمكن أن تستمر لأكثر من شهر. في بعض الأحيان، تستمر البقع الشمسية في النمو وتصبح الأكبر، عندما تتشكل في أزواج وتحيط بها العديد من البقع الصغيرة الأخرى (Tarbuck et al., 1997: 681).

لقد أثارت الدورات الغامضة في أعداد البقع الشمسية اهتمام العديد من الباحثين، بما في ذلك الجيولوجيون والفلكيون وعلماء المناخ والاقتصاديون والمؤرخون وعلماء تغير المناخ والإحصائيون. إذ ان للبقع الشمسية تأثيرات كبيرة على مختلف الظواهر الأرضية. مثال على ذلك، التنبؤ الطويل المدى بالطقس. وعليه يجب أخذ أرقام البقع الشمسية بعين الاعتبار في الاتصالات السلكية واللاسلكية والرحلات الفضائية بين الكواكب.

تمثل نمذجة بيانات البقع الشمسية تحدياً كبيراً للإحصائيين. فقد حاول العديد من الإحصائيين إيجاد علاقة دالية بين أعداد البقع الشمسية (Li et al., 1990: 1). وقد أشار ايزمنمان (Izenman, 1985: 27) الى ان أعداد البقع الشمسية تحتوي على خصوصيات كونها غير خطية وغير ثابتة فضلاً عن انها غير طبيعية (Abnormal). وعليه، فإنها تستخدم في المقام الأول كمقياس للمقارنة وللحكم على طرائق التنبؤ والنمذجة الإحصائية الجديدة.



الشكل (١): البقع الشمسية

The SOHO Archive, <https://sohowww.nascom.nasa.gov/>

إن التغيرات التي تطرأ على عدد البقع الشمسية لها فترات ثابتة مقدارها حوالي ١١ سنة، وتبلغ فترة دورة النشاط المغناطيسي ضعف دورة النشاط الشمسي، أي حوالي ٢٢ سنة في المتوسط. علاوة على ذلك، فإن النشاط الشمسي الذي يمثله مؤشر التوهج، يكشف أيضاً عن التواتر الأكثر وضوحاً في ١١ عاماً. ويعتقد أن طاقة التوهجات الشمسية مشتقة من الحقول المغناطيسية في الهالة الشمسية (Yan et al, 2012: 387).

إن متغير النشاط المغناطيسي الشمسي المعروف باسم دورة الطاقة الشمسية (١١ عاماً أو ما يساويها ١٣٢ شهراً) لديه أطول سلسلة زمنية من المشاهدات، إذ تمتد من عام ١٧٤٩ ولغاية الآن. وتؤثر هذه الدورات بشكل كبير على الظروف المحيطة بالغلاف الجوي والبيئة الفضائية للأرض.

تركز البحوث المعاصرة على القوى التي تقود الدورة الشمسية والتأثيرات المحتملة لهذه الحوادث على الأرض. لقد أصبح التنبؤ بعدد البقع الشمسية التي يحتمل حدوثها خلال أي دورة معينة أمراً مهماً للعلماء المعنيين بفهم العواقب الأرضية للنشاط الشمسي، وقد تم ابتكار العديد من الطرق والجمع بينها وتنقيحها في محاولة للتنبؤ بنشاط البقع الشمسية. فعلى سبيل المثال لا الحصر، استخدم (Shaikh et al., 2008) طريقة Fast Fourier Transform Technique: FFT تحليل مجموعة البيانات الشهرية للبقع الشمسية للسنوات بين ١٨١٨ و ٢٠٠٢. وفي عام ٢٠١٢ اقترح (Chattopadhyay & Chattopadhyay, 2012) نماذج (ARIMA) والشبكة العصبية ذات الانحدار الذاتي Auto Regressive Neural Network: AR-NN في تحليل السلسلة الزمنية الشهرية للبقع الشمسية بين عامي ١٩٩٢ و ٢٠٠٨.

وفي بحث آخر، عرض (Gkana & Zachilas, 2015) استخدام متوسط المعلومات المتبادلة Average Mutual Information: AMI وأساليب أقرب الجيران الكاذبة False Nearest Neighbors: FNN في تقدير المعلمات المناسبة للسلسلة الزمنية الشهرية للبقع الشمسية بين عامي ١٧٤٩ و ٢٠١٣.

وفي عام ٢٠١٩، اقترح (Pala and Atici, 2019) استخدام طريقة الذاكرة القصيرة والطويلة المدى Long-Short-Term Memory: LSTM وانموذج الشبكة العصبية ذات الانحدار الذاتي في تحليل البيانات الشهرية للبقع الشمسية بين ١٧٤٩ و ٢٠١٨. وفي عام ٢٠١٨، تبنى (Safiullin et al., 2018) طريقة جديدة للتنبؤ الشهري بسلسلة زمنية لعدد البقع الشمسية للفترة من ١٩٩٧-٢٠١٨، وهذه الطريقة هي شبكة الانحدار الذاتي غير الخطية ذات المدخل الخارجي Nonlinear Auto Regressive network with exogenous input: NARX.

هدف البحث:

نظراً لأهمية الدورة الشمسية والتأثيرات المحتملة لها على الأرض والمتمثلة بتغيرات المناخ فضلاً عن تأثيرها على الاتصالات وإشارات الراديو والـ (GPS) وتكنولوجيات أخرى، فقد أصبح التكهن بعدد البقع الشمسية التي يحتمل حدوثها خلال أي دورة معينة أمراً مهماً للعلماء المعنيين بفهم العواقب الأرضية للنشاط الشمسي. يهدف البحث إلى نمذجة وتحليل سلوك البقع الشمسية باستخدام نماذج المكونات غير المشاهدة.

نماذج المكونات غير المُشاهدة (Unobserved Components Models):

تعد طريقة بوكس-جنكينز، وإلى حد ما، طرائق التمهيد الأسّي (Exponential Smoothing) نماذج مناسبة فقط للسلسلة الزمنية المستقرة، وهي تجريبية بطبيعتها. إذ ليس من الممكن دائماً الحصول على سلسلة زمنية مستقرة عن طريق اخذ الفروقات أو استخدام وسائل أخرى. وعليه، يمكن أن يقتصر هذا الأسلوب على عدد قليل من البيانات. فضلاً عن ذلك، فإن دالة الارتباط الذاتي والارتباط الذاتي الجزئي التي تحدد النماذج ليست مفيدة دائماً، خاصة في العينات الصغيرة، مما قد يؤدي إلى نماذج وتوقعات غير ملائمة (Brintha et al., 2014: 523).

يعد انموذج المكونات غير المُشاهدة (UCM) وتعرف أيضاً باسم نماذج السلاسل الزمنية الهيكلية (Structural time series models) كأسلوب بديل لنماذج (ARIMA) وتوفر منهجاً مرناً لتمهيد وتحليل السلسلة الزمنية، وذلك من أجل التغلب على المشاكل التي تعترض نماذج (ARIMA). وبموجب هذه الطريقة، يتم تحليل السلسلة الزمنية إلى مكونات كامنة مثل الاتجاه والدورية والتأثير الموسمي وتأثيرات الانحدار الخطية وغير الخطية. ومن المفترض أن تعبر المكونات في الانموذج عن السمات البارزة للسلسلة الزمنية والتي يمكن أن تكون مفيدة في شرح سلوكها والتنبؤ بها. تكمن ميزة الـ (UCM) في أنها تتبع النماذج العشوائية المناسبة وتوفر مجموعة مناسبة من الأنماط لانتقاء السلوك المميز للسلسلة الزمنية (عبد الله، ٢٠١٨: ١٢٣).

إن السمة الرئيسية لنماذج المكونات غير المُشاهدة هي في تحليل السلسلة الزمنية إلى مكونات الاتجاه الموسمية والدورية فضلاً عن المكونات غير النظامية، إذ يتم صياغة كل مكون على أنه عملية عشوائية (Stochastic) تتغير مع مرور الزمن. إن تحليل السلسلة الزمنية غير المُشاهدة إلى عمليات عشوائية غير مُشاهدة يؤدي إلى فهم أفضل للخصائص الديناميكية للسلسلة فضلاً عن الطريقة التي تتغير بها هذه الخصائص مع مرور الزمن. ويمثل مكون الاتجاه عادة التطورات على المدى الطويل للسلسلة الزمنية، ويتم تحديده باعتباره دالة للزمن. أما المكون الموسمي فهو يتجسد في الأنماط المتكررة والمتغيرة باستمرار خلال السنوات، بينما يمثل مكون الدورية في السلسلة الزمنية السمات الديناميكية المرتبطة بدورة معينة.

يمكن اعتبار انموذج المكونات غير المُشاهدة كأنموذج انحدار متعدد المتغيرات مع معاملات متغيرة بمرور الزمن. إذ يستند انموذج المكونات غير المُشاهدة إلى المبادئ الآتية:

١. عرض السلسلة الزمنية على أنها قابلة للتحلل إلى مكونات الاتجاه والموسمية والدورية، وإن تجاهل الباحث للخصائص البارزة للسلسلة الزمنية، من المرجح أن يؤدي إلى تنبؤ غير دقيق.
٢. عدم اعطاء اوزان متساوية للملاحظات القريبة والبعيدة. إذ في العديد من السلاسل الزمنية تكون الملاحظات المتجاورة أكثر ارتباطاً ببعضها البعض من الملاحظات البعيدة. ونتيجة لذلك، فإن نماذج السلاسل الزمنية التي تعطي اوزاناً للملاحظات الحديثة أكثر من الملاحظات في الماضي البعيد، تميل إلى التنبؤ بشكل أفضل من النماذج التي تعالج بيانات السلاسل الزمنية على نفس القدر من الأهمية (Fomby, 2008: 2).

يمكن كتابة انموذج المكونات غير المُشاهدة بالصيغة الآتية:

$$y_t = \mu_t + \gamma_t + \psi_t + r_t + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^m \beta_j x_{jt} + \varepsilon_t \dots (1)$$

اذ ان (y_t) ، تمثل متغير الاستجابة، وهي السلسلة الزمنية المطلوب نمذجتها والتنبؤ بها. (μ_t) ، هي مكونات الاتجاه، و (γ_t) هي المكونات الموسمية، و (Ψ_t) ، هي المكونات الدورية، و (r_t) مكونات الانحدار الذاتي (Auto regressive component)، و β_j ، هي معلمات الانحدار، و (x_{jt}) ، هي المتغيرات التوضيحية، و (ε_t) ، المكونات غير المنتظمة (Irregular component). ان إدراج حدود الانحدار الذاتي $(\sum_{i=1}^p \phi_i y_{t-i})$ يمثل زخم للسلسلة الزمنية من حيث صلتها بالملاحظات السابقة، اما حدود الانحدار التوضيحية $(\sum_{j=1}^m \beta_j x_{jt})$ فتمثل العوامل السببية التي تؤثر على السلسلة الزمنية (Fomby, 2008: 2). ومن الجدير بالذكر، انه من النادر ان أن تحتوي الـ (UCM) على جميع المكونات اعلاه. في التحليل التقليدي للسلسلة الزمنية، فانه غالباً ما يُفترض أن السلسلة الزمنية y_t يمكن أن تتحلل إلى أربع مكونات، وهي الاتجاه، والموسمية، والدورية، والمكونات غير المنتظمة، وكما هو واضح في الصيغة الاتية:

$$y_t = T_t + S_t + C_t + \varepsilon_t \dots (2)$$

اذ ان (T_t) تمثل الاتجاه في (y_t) عند الزمن (t) ، (S_t) تمثل التأثير الموسمي عند الزمن (t) ، (C_t) تمثل تأثير الدورية عند الزمن (t) وان (ε_t) تمثل التأثير غير المنتظم عند الزمن (t) ، وهو يمثل الخطأ الكلي (المكون غير المنتظم) والذي يُفترض أنه ازعاج أبيض يتبع التوزيع الطبيعي بتباين مقداره (σ_ε^2) . يستخدم انموذج الـ (UCM) هذا التحلل، ولكنه فضلا عن ذلك، يسمح بتأثيرات الانحدار الذاتي غير المُشاهد فضلا عن تأثيرات الانحدار التوضيحية (Explanatory regression)، مما يجعله أنموذجاً قوياً للغاية. يتم تقدير معلمات نماذج المكونات غير المُشاهدة بطريقة الامكان الاعظم. يتم نمذجة مكونات الاتجاه والموسمية بوساطة عمليات عشوائية ديناميكية خطية (Linear Dynamic Stochastic Processes) تعتمد على الضجيج (Disturbances). اذ يتم صياغة المكونات بطريقة مرنة ويسمح لها بالتغير مع الزمن على خلاف العمليات الحتمية (Deterministic). مكونات الـ (UCM):

يتكون الـ (UCM) من مكونات الاتجاه والدورية والموسمية والمكونات غير المنتظمة (Harvey and Stock, 1993: 56).

أ. **تقدير تأثير الاتجاه (Estimating trend effect):** يعرف الاتجاه على انه النزعة الطبيعية للسلسلة الزمنية بالزيادة باطراد (ذات الاتجاه المتزايد) أو متناقصة (ذات الاتجاه المتناقص) او ان تبقى ثابتة على مدى فترة من الزمن في ظل غياب تأثير أي متغير آخر. يمكن توصيف مكون الاتجاه بطرق مختلفة. اذ يمكن نمذجة مكون الاتجاه كعملية مشي عشوائي (Random Walk Process)، الذي يشير إلى أن الاتجاه يبقى ثابتاً خلال فترة زمنية معينة. وان صيغة التقدير هي الاتي:

$$T_t = T_{t-1} + \delta_t ; \delta_t \sim i.i.d N(0, \sigma_\delta^2) \dots (3)$$

اذ ان $(i.i.d N(0, \sigma_\delta^2))$ تعني ان السلسلة الزمنية تتوزع توزيعاً طبيعياً وبصورة مستقلة بوسط حسابي مقداره الصفر وتباين مقداره (σ_δ^2) . وان سلسلة الضجيج (δ_t) مستقلة

تسلسليا (Serially independent) ومستقلة عن جميع سلاسل الضجيج الأخرى المتعلقة بـ (y_t) في المعادلة (١). كما يمكن توصيف مكون الاتجاه على أنه اتجاه خطي له ميل إلى الأعلى أو إلى الأدنى. وبموجب هذه الطريقة، ينمذج الاتجاه (T_t) ، على أنه مكون عشوائي تصادفي بمستوى وميل يتغيران مع الزمن، وله الصيغة الآتية (Harvey, 1990: 37):

$$T_t = T_{t-1} + \beta_{t-1} + \delta_t ; \delta_t \sim i.i.d N(0, \sigma_\delta^2) \dots (4)$$

$$\beta_t = \beta_{t-1} + \tau_t ; \tau_t \sim i.i.d N(0, \sigma_\tau^2) \dots (5)$$

اذ ان (β_t) تمثل الميل للاتجاه الخطي للزمن. ويفترض ان الضوضاء (δ_t) و (τ_t) مستقلة بشكل متبادل.

ب. تقدير التأثير الدوري: يقال بان بيانات السلسلة الزمنية تتضمن تغيرات دورية، عندما تتغير السلسلة صعودا وهبوطا بفترة زمنية غير ثابتة، وعادة ما تكون مدة هذه التقلبات سنين على الأقل. وعليه، إذا كانت التقلبات غير محددة المدة فهي دورية، أما إذا لم تتغير الفترة وارتبطت ببعض جوانب التقويم الزمني، فسيكون النمط موسميًا. بشكل عام، فإن متوسط طول الدورات أطول من طول النمط الموسمي، ويميل حجم الدورات إلى أن يكون أكثر تغيراً من حجم الأنماط الموسمية. يمكن صياغة الدورة (C_t) على أنها عملية عشوائية تستند إلى عملية مثلثية متغيرة مع الزمن (Time-varying trigonometric process) وفقاً للتكرار (λ) ، اذ ان $(0 \leq \lambda \leq \pi)$ ، والذي يقاس عادة بالراديان (الزاوية نصف القطرية أو التقدير الدائري). ان فترة الدورية $(2\pi/\lambda)$ ، هي الفترة الزمنية التي تتطلب لإكمال سلسلة من القيم، ويمكن التعبير عن الدورة كمزيج من موجات الجيب والجيب تمام، اعتماداً على المعلمتين (α) و (β) ، (Harvey and Stock, 1993: 56):

$$C_t = \alpha \cos \lambda t + \beta \sin \lambda t \dots (6)$$

$$C_t^* = -\alpha \sin \lambda t + \beta \cos \lambda t \dots (7)$$

اذ ان $(\alpha^2 + \beta^2)^{\frac{1}{2}}$ يسمى السعة و $\tan^{-1}(\frac{\beta}{\alpha})$ هي الطور، كما هو الحال مع الاتجاه الخطي. يمكن بناء الدورة بشكل متكرر، مما يؤدي إلى انموذج العشوائية.

$$\begin{bmatrix} C_t \\ C_t^* \end{bmatrix} = \begin{bmatrix} \cos \lambda & \sin \lambda \\ -\sin \lambda & \cos \lambda \end{bmatrix} \begin{bmatrix} C_{t-1} \\ C_{t-1}^* \end{bmatrix} \dots (8)$$

وان مكونات الدورية (C_t) يمكن نمذجتها وفقاً للصيغة الآتية:

$$\begin{bmatrix} C_t \\ C_t^* \end{bmatrix} = \rho \begin{bmatrix} \cos \lambda & \sin \lambda \\ -\sin \lambda & \cos \lambda \end{bmatrix} \begin{bmatrix} C_{t-1} \\ C_{t-1}^* \end{bmatrix} + \begin{bmatrix} v_{t-1} \\ v_{t-1}^* \end{bmatrix} \dots (9)$$

اذ ان (ρ) هو عامل التخميد (Damping factor) او عامل الخصم (Discount factor)، وان $(0 \leq \rho \leq 1)$ والذي يتم تضمينه لفرض عملية مستقرة لمكون الدورة العشوائية. وان كلا من (v_t) و (v_t^*) هما سلسلتان للضجيج الدوري (Cyclical disturbance series)، مستقلتان تسلسليا ومستقلتان بشكل متبادل، فضلاً عن انهما مستقلتان عن كل سلاسل الضجيج الأخرى، وانهما يتبعان التوزيع الطبيعي بوسط مقداره الصفر وتباين مقداره (σ_v^2) . وينتج عن ذلك دورة تصادفية خامدة (Damped stochastic) لها طور وسعة متغيرة بمرور الوقت، وفترة زمنية ثابتة تساوي $(2\pi/\lambda)$. عليه، فان معلمات المكونات غير المُشاهدة هي تباينات التشويش المختلفة و

(δ_t) و (τ_t) و (σ_v^2) ، وعامل التخمين (ρ) والتكرار (λ) . ويعد الانموذج مستقرا إذا كانت (ρ) اقل من الواحد بشكل كبير وإذا كانت (λ) مساوية للصفر أو (π) ، فإنها تختزل الى عملية انحدار ذاتي من الرتبة الاولى.

ج. تقدير التأثير الموسمي: يقال بان السلسلة الزمنية تتضمن نمط موسمي عند وجود نمط ثابت من الاختلاف يتأثر بالعوامل الموسمية (على سبيل المثال، ربع السنة، أو يوم من أيام الأسبوع، وما إلى ذلك). وعليه، فان الموسمية هي دائما لفترة ثابتة ومعروفة. وعادة ما تظهر السلسلة الزمنية المبنية على فترات فصلية أو شهرية سلوكاً موسمياً. ومن المرجح أن تتغير الأنماط الموسمية على مدى فترة زمنية طويلة. وعليه، فان مثل هذه التغيرات، يمكن التعامل معها بموجب نماذج المكونات غير المُشاهدة، وذلك عن طريق عنصر موسمي عشوائي. يمكن إضافة مكوّن موسمي إلى انموذج يتألف من اتجاه ومكون غير منتظم، وبحسب الصيغة الاتية:

$$y_t = \mu_t + \gamma_t + \varepsilon_t \dots (10)$$

يمكن نمذجة الانموذج الموسمي الثابت بالصيغة الاتي:

$$\gamma_t = \sum_{j=1}^s \gamma_j z_{jt} \dots (11)$$

اذ ان (s) هي عدد المواسم، وان المتغير (z_{jt}) هو متغير وهمي، يأخذ القيمة ١ في الموسم (j) و (٠) ماعدا ذلك. وان (γ_j) (اذ ان $j = 1, \dots, s$) مقيدة بان يكون مجموعها مساويا للصفر. عليه، فان تأثيرات الموسمية يتم استبعادها من المشاهدات السنوية.
معايير دقة التوفيق:

١. **معيار معلومات اكاكي (Akaike Information Criterion: AIC)**، وهو مقياس تقديري لجودة كل انموذج من النماذج الاقتصادية او الاحصائية المتاحة لمجموعة معينة من البيانات. وعليه، فهو يستخدم لاختيار انموذج مثالي وشامل من بين مجموعة من النماذج (Bozdogan, 1987: 346).

وصيغة اكاكي، هي الاتي (Burnham & Anderson, 2004: 63):

$$AIC = n \log \left(\frac{SSE}{n} \right) + 2k \dots (12)$$

اذ ان (n) تمثل عدد المشاهدات، (k) عدد معلمات الانموذج المقدرة، وان $(SSE = \sum (y_i - \hat{y}_i)^2)$ ويمثل مجموع مربعات الخطأ. وبموجب هذا المعيار يتم اختيار الانموذج الذي له اقل قيمة لمعيار اكاكي.

٢. **معيار معلومات بيز (Bayesian information criterion: BIC)**، وهو ايضا مقياس تقديري للجودة ويستخدم لاختيار انموذج مثالي وشامل من بين مجموعة من النماذج، كما هو الحال بالنسبة لمعيار اكاكي.

وصيغة المعيار، هي الاتي (Priestley, 1981: 376):


$$BIC = n \log \left(\frac{SSE}{n} \right) + k \log(n) \dots (13)$$

وبموجب هذا المعيار يتم اختيار الانموذج الذي له اقل قيمة لمعيار معلومات بيز.


التطبيق العملي:

تعد السلسلة الزمنية للبقع الشمسية من أطول السلاسل الزمنية التي تم جمعها وحفظ بياناتها الى الان. وهي سلسلة تبدأ من سنة 1749، ومتاحة ولقترات زمنية مختلفة (يومية وشهرية وسنوية) على موقع مركز البيانات العالمي لحفظ ونشر عدد البقع الشمسية الدولي المسمى (Sunspot Index and Long-term Solar Observations). وقد ارتأى الباحثون تحليل السلسلة الشهرية للبقع الشمسية ابتداء من كانون الثاني ١٩٠٠ ولغاية كانون الاول ٢٠١٨، اي بواقع ١٤٢٨ مشاهدة شهرية. وتعد هذه الفترة كافية لدراسة سمات وخصائص الظاهرة الكونية هذه، فضلا عن التكهن بعدد البقع الشمسية ولفترة ١٠٠ شهر.

يبين الشكل (١) متوسط عدد البقع الشمسية الشهرية، اذ يلاحظ من سلسلة البقع الشمسية انها مستقرة في الوسط ولها تباين غير ثابت يتغير باستمرار مع مرور الزمن، بمعنى اخر، وجود نمط لذبذبات صغيرة ونمط لذبذبات كبيرة. كما يلاحظ وجود الطبيعة الدورية للسلسلة، ويبدو انه سلوك دوري منتظم، فضلا عن عدم وجود اتجاه خطي واضح في السلسلة.



الشكل (١): السلسلة الزمنية لبيانات البقع الشمسية الشهرية من ١٩٠٠/١/١ ولغاية ٢٠١٨/١٢/٣١. تم إجراء التحليل الطيفي لسلسلة البقع الشمسية (الشكل ٢)، ويلاحظ من هذا التحليل ان لسلسلة البقع الشمسية دورة قوية لمدة ١٣٠ شهرا، والمتمثل بالخط المرجعي الذي يبين موضع الذروة الرئيسية في الكثافة الطيفية.



الشكل (٢): تقدير الكثافة الطيفية

تمت الإشارة في الجانب النظري، بأن نقطة الضعف الرئيسة في نماذج (ARIMA) هو أن السلسلة الزمنية يجب أن تكون مستقرة. وفي الواقع، فإن هذا الافتراض يصعب تحقيقه في بعض الأحيان.

عليه، فإن نماذج المكونات غير المشاهدة (UCM) تعد بديلاً لنماذج (ARIMA) في التغلب على هذه المشكلة، ذلك لأنها لا تستند إلى افتراض الاستقرارية (Brintha et al., 2014: 423; عبدالله، ٢٠١٨: ١٢٢)، فضلاً عن ذلك، فإنها تقسم سلسلة متغير الاستجابة إلى مكونات، مثل الاتجاهات والدورية والموسمية وتأثير الانحدار والانحدار الذاتي. بما أن نموذج المكونات غير المشاهدة يتضمن أي من مكونات الدورية والموسمية والاتجاه وتأثير الانحدار والانحدار الذاتي والمكونات غير النظامية أو جمع لجزء من هذه المكونات أو جميعها. عليه، ولغرض بناء نموذج بيانات البقع الشمسية، فإن إحدى طرائق بناء الـ (UCM) الجيدة لسلسلة زمنية معينة تتمثل في بناء نموذج هيكلي أساسي للسلسلة الزمنية (Basic Structural model: BSM) ثم إضافة مكونات أخرى إلى النموذج الأساسي بحسب الضرورة (Harvey, 1990: 47). ويتم اختبار مكونات النموذج من خلال تحليلين اثنين. الأول، يتم فيه اختبار فرضية العدم القائلة بأن المكونات محل الاهتمام غير عشوائية، مقابل الفرضية البديلة القائلة بأن المكونات محل الاهتمام عشوائية. أي اختبار الفرضية الاتية:

H_0 : Corresponding component is non-stochastic

H_1 : Corresponding component is stochastic

علماً بأنه لا يمكن تحديد النموذج فيما إذا كان عشوائياً أم لا من خلال تقديرات معلمات المرحلة الأولى، إنما يتم تحديده من خلال تحليل المرحلة الثانية.

اذ يتم فيه اختبار فرضية العدم القائلة بأن المكون محل الاهتمام هو مكون غير معنوي، مقابل الفرضية البديلة القائلة بأن المكون محل الاهتمام هو مكون معنوي. أي اختبار الفرضية الاتية: (Brintha et al., 2014: 527; Fomby, 2008: 20).

H_0 : Given component is not significant

H_1 : Given component is significant

بناءً على ما سبق، فإن متغير الاستجابة المراد صياغته يمثل البقع الشمسية (y). وبما أن للسلسلة الزمنية دورية واضحة، عليه، سيتم بناء النموذج الأساسي الأول (BSM1) من الدورية فضلاً عن المكون غير المنتظم (وهو مكون رئيس في النموذج الـ UCM ويمثل الخطأ العشوائي). يبين الجدول (١)، تباينات الخطأ للمكون غير المنتظم والدورية، والتي تسمى بالمعلمات الحرة (Free parameters) للنموذج فضلاً عن قيم (t) و (P) المقترنة بها لاختبار فرضية العدم القائلة بأن مكونات النموذج غير عشوائية مقابل الفرضية البديلة القائلة بأن مكونات النموذج عشوائية. تشير النتائج إلى أن تباين الخطأ للمكون غير المنتظم معنوي ($p < 0.0001$)، كما يلاحظ بأن تباين الخطأ لمكون الدورية معنوي ايضاً ($p = 0.0067$)، وهذا يعني بأن هذين المكونين عشوائيين وفق المرحلة الأولى من التحليل. ومع ذلك، وكما تم ذكره، فإنه لا يمكن تحديد النموذج فيما إذا كان عشوائياً أم لا من خلال تقديرات معلمات المرحلة الأولى (الجدول ١)، وإنما يتم تحديده من تحليل المرحلة الثانية. فضلاً عن ذلك، فإن تحليل المرحلة الثانية للمكون يساعد في

تحديد ما إذا كان يمكن استبعاد المكون غير المعنوي من الانموذج، إلا إذا كان ذلك يؤدي الى تراجع في دقة توفيق الانموذج (Fomby, 2008: 27). يلاحظ من الجدول (٢)، ان المكونات غير النظامية والدورية غير معنويين في الحالة النهائية. وهذا يعني بان مكون الدورية هو مكون حتمي، او ما يسمى بالمكون الثابت (fixed). اما المكون غير النظامي فهو مكون اساسي في الانموذج ويمثل الخطأ العشوائي.

الجدول (١): التقديرات النهائية للمعلمات الحرة للانموذج (BSM1)

Final Estimates of the Free Parameters					
Component	Parameter	Estimate	Approx Std Error	t Value	Approx Pr> t
Irregular	Error Variance	276.11766	21.23528	13.00	<.0001
Cycle	Damping Factor	0.99102	0.0034156	290.14	<.0001
Cycle	Period	173250	16251875	0.01	0.9915
Cycle	Error Variance	205.83307	75.89713	2.71	0.0067

الجدول (٢): تحليل معنوية مكونات الانموذج (BSM1)

Significance Analysis of Components (Based on the Final State)			
Component	DF	Chi-Square	Pr>ChiSq
Irregular	1	0.01	0.9349
Cycle	2	0.11	0.9471

الجدول (٣) يشير الى نتائج الانموذج الاساسي الثاني (BSM2)، اذ تم اضافة مكون الانحدار الذاتي الى الانموذج السابق مع الابقاء على مكون الدورية في الانموذج، اذ ان استبعاده من الانموذج ادى الى تراجع في دقة توفيق الانموذج. يلاحظ من الجدول، معنوية تباينات الخطأ لكل من الدورية والانحدار الذاتي، وعند النظر الى الجدول (٤)، الذي يمثل تحليل معنوية مكونات الانموذج، يلاحظ ان المكونات غير معنوية، أي انها مكونات حتمية غير عشوائية. وعند مقارنة دقة التوفيق للانموذج (BSM1) مع (BSM2) (انظر الجدول ٩)، يلاحظ بان تحسنا قد تحقق في الانموذج (BSM2) عما كان عليه في الانموذج (BSM1).

الجدول (٣): التقديرات النهائية للمعلمات الحرة للانموذج (BSM2)

Final Estimates of the Free Parameters					
Component	Parameter	Estimate	Approx Std Error	t Value	Approx Pr> t
Irregular	Error Variance	0.00001570	0.03504	0.00	0.9996
Auto Reg	Damping Factor	0.25909	0.04673	5.54	<0.0001
Auto Reg	Error Variance	360.62004	30.67384	11.76	<0.0001
Cycle	Damping Factor	0.99328	0.0028939	343.23	<0.0001
Cycle	Period	192370	18657908	0.01	0.9918
Cycle	Error Variance	149.82524	62.65810	2.39	0.0168

الجدول (٤): تحليل معنوية مكونات الانموذج للانموذج (BSM2)

Significance Analysis of Components (Based on the Final State)			
Component	DF	Chi-Square	Pr>ChiSq
Irregular	1	0.00	1.0000
Auto Reg	1	0.01	0.9227
Cycle	2	0.10	0.9528

الجدول (٥) يشير الى نتائج الانموذج الاساسي الثالث (BSM3)، اذ تم اضافة مكونات الاتجاه، وهما الميل والمستوى الى الانموذج السابق مع الابقاء على مكونات الدورية والانحدار الذاتي في الانموذج. اذ ان استبعادهما من الانموذج ادى الى تراجع في دقة توفيق الانموذج. تبين من خلال التحليل ان مكون المستوى غير معنوي، وعند تقديره باعتباره مكونا حتميا، تم الحصول على نتائج أفضل. يبين الجدول (٥)، معنوية الانحدار الذاتي ومكون الدورية وعدم معنوية الميل، وعند النظر الى الجدول (٦)، يلاحظ ان المستوى مكون معنوي، بينما البقية غير معنوية. وعند مقارنة دقة التوفيق للأنموذج (BSM3) مع (BSM2)، (انظر الجدول ٩)، يلاحظ بان هناك تحسنا ملحوظا في الانموذج (BSM3) عما كان عليه في الانموذج (BSM2).

الجدول (٥): التقديرات النهائية للمعلمات الحرة للأنموذج (BSM3)

Final Estimates of the Free Parameters					
Component	Parameter	Estimate	Approx Std Error	t Value	Approx Pr> t
Irregular	Error Variance	0.00178	0.43846	0.00	0.9968
Slope	Error Variance	0.00008698	0.0001208	0.72	0.4713
Auto Reg	Damping Factor	0.37739	0.03378	11.17	<.0001
Auto Reg	Error Variance	475.12516	29.01980	16.37	<.0001
Cycle	Damping Factor	0.99665	0.0014882	669.68	<.0001
Cycle	Period	125.38221	3.93752	31.84	<.0001
Cycle	Error Variance	23.19838	9.27445	2.50	0.0124

الجدول (٦): تحليل معنوية مكونات الانموذج للأنموذج (BSM3)

Significance Analysis of Components (Based on the Final State)			
Component	DF	Chi-Square	Pr>ChiSq
Irregular	1	0.00	0.9999
Level	1	9.09	0.0026
Slope	1	3.14	0.0764
Auto Reg	1	0.01	0.9393
Cycle	2	4.91	0.0859

في الانموذج الاساسي الرابع (BSM4)، تم اضافة مكون الموسمية الى الانموذج السابق مع الابقاء على جميع المكونات. من خلال التحليل، تم التوصل الى ان طول الفترة الموسمية المناسبة والتي تؤدي الى تحسين دقة التوفيق هي ٢. ومن الجدول (٧)، يلاحظ معنوية الانحدار الذاتي والدورية، وعدم معنوية الميل والموسمية. وعند النظر الى الجدول (٨)، يلاحظ معنوية المستوى والموسمية، أي انها مكونات عشوائية. وان كلا من الميل والدورية غير معنوية، أي انها مكونات غير عشوائية. وعند مقارنة دقة التوفيق للأنموذج (BSM4) مع (BSM3)، (انظر الجدول ٩)، يلاحظ بان تحسنا طفيفا قد تحقق في الانموذج (BSM4) مقارنة بالأنموذج (BSM3).

الجدول (٧): التقديرات النهائية للمعلمات الحرة للأنموذج (BSM4)

Final Estimates of the Free Parameters					
Component	Parameter	Estimate	Approx Std Error	t Value	Approx Pr> t
Irregular	Error Variance	0.00466	0.61690	0.01	0.9940
Slope	Error Variance	0.00008752	0.0001218	0.72	0.4724
Season	Error Variance	5.3818E-13	.	.	.
Auto Reg	Damping Factor	0.38192	0.003372	11.33	<.0001
Auto Reg	Error Variance	472.89108	28.99795	16.31	<.0001
Cycle	Damping Factor	0.99667	0.0014867	670.39	<.0001
Cycle	Period	125.38331	3.92389	31.95	<.0001
Cycle	Error Variance	23.02382	9.24029	2.49	0.0127

الجدول (٨) تحليل معنوية مكونات الانموذج للأنموذج (BSM4)

Significance Analysis of Components (Based on the Final State)			
Component	DF	Chi-Square	Pr>ChiSq
Irregular	1	0.00	1.0000
Level	1	9.11	0.0025
Slope	1	3.13	0.0770
Auto Reg	1	0.00	0.9966
Cycle	2	4.86	0.0881
Season	1	9.20	0.0024

تم التوقف عن اضافة مكونات اخرى الى الانموذج الاخير وذلك لأنها لم تؤدي الى تحسن في الانموذج. عليه يعد الانموذج (BSM4) هو انموذج البقع الشمسية المقدر. ومن الجدول (٧)، يلاحظ بان الانموذج المقدر يتضمن دورة شهرية مدتها ١٢٥,٣٨٣٣ شهرا، وكان التقدير لعامل التخمين ٠,٩٩٦٦٧، مما يشير إلى أن النمط الدوري لا يتناقص بسرعة.


الاشكال (٣) الى (٨) تمثل الرسوم المتعلقة بمكونات الانموذج المقدر والمدرجة في الجدول (٧). الشكلين (٣) و (٤) يمثلان رسم مكوني المستوى والميل لفترة الدراسة وبحدود الثقة 95%، على الترتيب. والشكلين (٥) و (٦) يمثلان رسم مكوني الاتجاه والموسمية لفترة الدراسة وبحدود الثقة 95%، على الترتيب. والشكلين (٧) و (٨) يمثلان رسم مكوني الانحدار الذاتي والدورية لفترة الدراسة وبحدود الثقة 95%، على الترتيب.

يوضح الجدول (٩)، مقارنة بين النماذج الأساسية الأربعة (BSM1-BSM4) وفق معايير

دقة التوفيق، كل من AIC، BIC، MSE، RMSE و Adjusted R-Squared. اذ يتضح من الجدول ان الانموذج BSM4 هو الأكثر دقة وملائمة في توفيق بيانات البقع الشمسية الشهرية من النماذج الأخرى، ذلك لان للأنموذج اقل قيم لـ AIC، BIC، MSE و RMSE، كما ان له اعلى قيم لـ Adjusted R-Squared و R-Square.

الجدول (٩): معايير دقة التوفيق للنماذج المقدره

Goodness of fit	BSM1	BSM2	BSM3	BSM4
AIC	13141	13118	13004	12994
BIC	13162	13150	13046	13036
MSE ⁽¹⁾	635.7117	623.9259	580.5230	578.9070
RMSE ⁽²⁾	25.2133	24.9785	24.0940	24.0604
R-Square ⁽³⁾	0.87333	0.87568	0.88434	0.88466
Adjusted R-Squared ⁽⁴⁾	0.87306	0.87524	0.8837	0.8840



الشكل (٣): يمثل رسم مكون المستوى لفترة الدراسة وبحدود الثقة 95%

(١) MSE، هو متوسط مربعات الخطأ (Mean Squared Error)، وصيغته كالاتي:

$$MSE = \frac{SSE}{n}$$

اذ ان $SSE = \sum (y_i - \hat{y}_i)^2$.

(٢) RMSE، هو الجذر التربيعي لمتوسط مربعات الخطأ (Root Mean Squared Error)، وصيغته كالاتي:

$$RMSE = \sqrt{MSE}$$

اذ ان MSE، هو متوسط مربعات الخطأ.

(٣) R-Square، هو معامل التحديد (coefficient of determination)، وصيغته كالاتي:


$$R^2 = 1 - \frac{SSE}{SST}$$

اذ ان:


$$SSE = \sum (y_i - \hat{y}_i)^2 \text{ وان } SST = \sum (y_i - \bar{y})^2$$

(٤) Adjusted R-squared، هو معامل التحديد المعدل، وصيغته كالاتي:


$$R^2_{adj} = 1 - \left(\frac{n-1}{n-k} \right) (1 - R^2)$$




الشكل (٤): يمثل رسم مكون الميل لفترة الدراسة وبحدود الثقة 95%




الشكل (٥): يمثل رسم مكون الاتجاه لفترة الدراسة وبحدود الثقة 95%



الشكل (٦): يمثل رسم مكون الموسمية لفترة الدراسة وبحدود الثقة 95%




الشكل (٧): يمثل رسم مكون الانحدار الذاتي لفترة الدراسة وبحدود الثقة 95%




الشكل (٨): يمثل رسم مكون الدورية لفترة الدراسة وبحدود الثقة 95%

بموجب الانموذج الاخير، يوضح الشكل (٩) مدى تطابق القيم التقديرية وفق طريقة الـ (UCM) للفترة من كانون الثاني ١٩٠٠ ولغاية كانون الاول ٢٠١٨ مع القيم الحقيقية. اذ يلاحظ ان القيم التقديرية تتبع القيم الحقيقية بشكل قريب جداً مما يدل على ان الانموذج وفق البيانات بشكل جيد. لغرض التحقق من صحة الانموذج ومدى كفاءته، وبالتحديد من طبيعية البواقي، تم رسم المدرج التكراري والربيعات الطبيعية للبواقي (Normal quantile plot). وللتحقق من التشويش الابيض، تم رسم الارتباطات الذاتية والذاتية الجزئية لفروق مختلفة، وكما موضح ذلك في الشكل (١٠). اذ يلاحظ من المدرج التكراري للبواقي انه متماثل، ويلاحظ من رسم الربيعات الطبيعية للبواقي، ان البواقي في معظمها محيطة بالخط المرجعي، ماعدا بعض القيم في طرف الخط العلوي والتي ابتعدت قليلاً عن القسم الاعظم من البيانات، وهي تشير الى وجود قيم متطرفة، الا انها لا تشير الى ابتعاد توزيع البواقي عن التوزيع الطبيعي. كما ان رسم كلا من الـ (ACF) والـ (PACF) لا تشير الى وجود مخالفات واضحة لافتراض التشويش الابيض، اذ ان جميع الارتباطات بين الارتدادات الزمنية غير الصفريية تبدو على انها غير معنوية وأنها واقعة ضمن حدود الثقة.




الشكل (٩): القيم المُشاهدة والتقديرية وفق طريقة الـ (UCM) لسلسلة لبقع الشمسية للفترة من كانون الثاني ١٩٠٠ ولغاية كانون الاول ٢٠١٨.



الشكل (١٠): رسوم اختبارات تشخيص البواقي لأنموذج السلسلة الزمنية
يبين الشكل (١١)، رسم البواقي مع الزمن، للتحقق ما إذا كان هناك أي نمط في البواقي. اذ يلاحظ من الشكل عدم وجود نمط في البواقي. ويبين الشكل (١٢)، رسم البواقي التراكمية مع الزمن وذلك لغرض التحقق فيما إذا كان هناك عدم تماسك في الأنموذج المقدر ضمن فترة الدراسة. من الشكل يلاحظ ان البواقي التراكمية ضمن حدود الثقة طوال فترة الدراسة، مما يعني ان الأنموذج متماسك طيلة فترة الدراسة.




الشكل (١١): رسم البواقي مقابل الزمن




الشكل (١٢): يمثل البواقي التراكمية مقابل الزمن

يتبين مما تقدم ان نموذج المكونات غير المشاهدة (BSM4) هو الانموذج الملائم للبيانات وانه قد وفق البيانات بشكل جيد، كما انه قد اجتاز اختبار تحليل البواقي والتشويش الابيض والتي تمثل الفحوص التشخيصية للانموذج.

لغرض معرفة فيما إذا كان انموذج المكونات غير المشاهدة ملائماً للتكهن، فقد تم التكهن بـ ٢٨ مشاهدة، ومن اب ٢٠١٦ ولغاية كانون الثاني ٢٠١٨، والشكلين (١٣) و (١٤) يبينان قيم التكهن ومقارنتها مع القيم الاصلية. اذ يلاحظ بان قيم التكهن تتبع معظم القيم الاصلية. وعليه، يعد انموذج المكونات غير المشاهدة أنموذجاً ملائماً للتكهن بالبقع الشمسية.




الشكل (١٣): المقارنة بين قيم التكهن والقيم الاصلية وفقاً لطريقة الـ (UCM) لسلسلة لبقع الشمسية للفترة من اب ٢٠١٦ ولغاية كانون الاول ٢٠١٨



الشكل (١٤): صورة اشمل للشكل (١٣) وذلك لغرض المقارنة بين قيم التكهن والقيم الاصلية تم التكهن بعدد البقع الشمسية الشهرية لمدة مئة شهر، وابتداء من كانون الثاني ٢٠١٩ ولغاية نيسان ٢٠٢٦. وتعد فترة التكهن هذه فترة طويلة وتمثل اختبار حقيقي لقدرة الانموذج في

تمثيل السلسلة قيد الدراسة وفي التكهّن بها، كما انها تعكس في نفس الوقت قدرة الانموذج على تقليد سلوك السلسلة الزمنية لفترة طويلة. من الشكل (١٥)، يلاحظ ان قيم التكهّن على شكل موجة جيبيه مشابهة للموجة التي قبلها، مما يدل على دقة الانموذج المستخدم في التوفيق وفي التكهّن.



الشكل (١٥): التكهّن بعدد البقع الشمسية لمدة ١٠٠ شهر وللفترة من كانون الثاني ٢٠١٩ ولغاية نيسان ٢٠٢٦

مقارنة نتائج البحث مع بعض الدراسات الحديثة:

لغرض مقارنة التكهّن بالحد الأقصى لعدد البقع الشمسية وزمن بلوغها، والتي تم التوصل في هذا البحث مع بعض البحوث الحديثة، والتي تناولت تحليل البقع الشمسية والتكهّن بالحد الأقصى لعددها فضلاً عن فترة حدوثها. نشير هنا الى ان ذروة عدد البقع الشمسية التي تم التكهّن بها في هذا البحث هو ١٤٦ بقعة شمسية، ومن المتوقع حدوثها في اذار ٢٠٢٣، مع دورة شمسية طولها 125.38331 شهراً أو ما يعادل ١٠,٤٥ سنة (انظر الجدول ٧ والشكل ١٥).

في دراسة اجراها (Quassim and Hamdy et al., 2007) لغرض تقدير الحد الأقصى لعدد البقع الشمسية باستخدام اسلوب الشبكات العصبية المضببة (Neural fuzzy approach). توصل الباحثون الى ان العدد الأقصى للدورة الشمسية السابقة (الدورة ٢٤) هو ١١٠ وستكون في العام ٢٠١١، وان عدد البقع الشمسية سيصل الذروة في الدورة الشمسية الحالية (الدورة ٢٥) الى ١١٦ في عام ٢٠٢١. الا ان تقديراتهم للدورة الشمسية السابقة كانت غير موفقة، ذلك لان العدد الأقصى كان في شباط من عام ٢٠١٤. وبالتالي، يمكن القول ان التقديرات للدورة (٢٥) قد لا تكون موثوقة (Pala and Atici, 2019: 50). توقع (Pishkalo, 2008) ان يصل عدد البقع الشمسية الى ١١٢,٣ في نيسان-ايار من عام ٢٠٢٣.

وفي دراسة اخرى لنفس الباحث (Pishkalo, 2014)، توقع ان يصل عدد البقع الشمسية في الدورة الشمسية (٢٥) ما بين ١٠٥-١١٠ بقعة شمسية.

وفي دراسة اجراها (Rigozo et al., 2011)، وبناءً على استقراء المكونات الطيفية (Extrapolation of spectral components)، فقد تكهنوا بان الحد الأقصى لعدد البقع الشمسية سيحدث في نيسان ٢٠٢٣ وبعده ١٣٢,١ بقعة شمسية، مع دورة شمسية طولها ١١٨ شهراً أو ما يعادل ٩,٨ سنة. وفي نفس الدراسة، توقع أن يبلغ الحد الأقصى لعدد البقع الشمسية (للدورة الشمسية ٢٤) ١١٣,٣ بقعة شمسية، وان يكون ذلك في تشرين الثاني ٢٠١٣. علماً ان الحد الأقصى كان في شباط من عام ٢٠١٤ وبعده مقداره (١٤٦,١). لذا تعد تقديراتهم التي توصلوا للدورة الشمسية (٢٤) جيدة، نظراً لقربها من القيم الحقيقية (Pala and Atici, 2019: 50).

استنتج (Li et al., 2015) وباستخدام بعض العلاقات الإحصائية الكلاسيكية لخصائص البقع الشمسية، أن عدد البقع الشمسية سيصل إلى ١٠٩,١ في تشرين الأول ٢٠٢٣. استخدم (Okoh et al., 2018) طريقة شبكة الانحدار العصبية الهجينة (Hybrid Regression-Neural Network)، وهي طريقة تجمع بين تحليل الانحدار والشبكة العصبية وذلك لتقدير عدد البقع الشمسية. وقد تكهنوا بأن الحد الأقصى لعدد البقع الشمسية سيكون في كانون الثاني ٢٠٢٥ وبعده قدره 122.1 بقعة شمسية. ولغرض إيجاد الحد الأقصى لعدد البقع الشمسية، فقد استخدم (Sabarinath and Anilkumar, 2018) نموذج هجين (hybrid model) وذلك بتوظيف تقنية الانحدار متعدد المتغيرات (Multivariate regression technique) ودالة المزيج الثنائي لتوزيع لابلاس (binary Mixture of Laplace distribution function)، وقد توصلوا إلى أن العدد سيكون ما بين ٧٥ و ٩٥ بقعة شمسية.

اقترح (Sarp et al., 2018) أسلوب لاخطي (Nonlinear approach) في تقدير الحد الأقصى لعدد البقع الشمسية، وتوقعوا أن يحدث ذلك في شباط من عام ٢٠٢٣، بعدد مقداره ١٥٧ بقعة شمسية. واستخدم (Pala and Atici, 2019) طريقة الذاكرة القصيرة والطويلة المدى (Long-Short-Term Memory: LSTM) وانموذج الشبكة العصبية ذات الانحدار الذاتي لإيجاد الحد الأقصى لعدد البقع الشمسية، وقد استنتجوا أن عدد البقع الشمسية سيكون ١٦٧,٣ بقعة شمسية في تموز ٢٠٢٢.

يلاحظ مما سبق، أن النتائج التي تم التوصل في هذا البحث تتسق مع النتائج التي توصل إليها كل من (Sarp et al., 2018) و (Pala and Atici, 2019) و (Rigozo et al., 2011) و (Pishkalo, 2008).

الاستنتاجات والتوصيات

أولاً. الاستنتاجات:

١. أثبت التحليل قدرة انموذج المكونات غير المُشاهدة في تمثيل بيانات البقع الشمسية الشهرية والفترة من كانون الأول ١٩٠٠ ولغاية كانون الثاني ٢٠١٨ وذلك لاجتيازه الاختبارات التشخيصية.
٢. أثبت التحليل قدرة انموذج المكونات غير المُشاهدة على التكهّن ولفترة طويلة (١٠٠ شهر)، وذلك من خلال تقارب القيم التوفيقية مع القيم الأصلية، فضلاً عن تقليد الانموذج لنمط السلوك التاريخي للسلسلة الزمنية وقدرته على إعادة إنتاجها.
٣. تبين من خلال التحليل أن مكونات المستوى والموسمية هي نماذج عشوائية، وأن مكون الانحدار الذاتي والدورية والميل هي نماذج حتمية.
٤. أن ذروة عدد البقع الشمسية التي تم التكهّن بها في هذا البحث هي ١٤٦ بقعة شمسية، ومن المتوقع حدوثها في آذار ٢٠٢٣، مع دورة شمسية طولها 125.38331 شهراً أو ما يعادل ١٠,٤٥ سنة.

ثانياً. التوصيات:

١. نوصي ليس فقط بالتكهّن بعدد البقع الشمسية، وإنما بتحديد مكانها أيضاً.
٢. نوصي بدراسة معدل درجة حرارة الأرض وعلاقتها مع عدد البقع الشمسية من خلال منظومة معادلات انية.
٣. نوصي بمقارنة طريقة المكونات غير المُشاهدة مع الطرق المقترحة في الدراسات السابقة، وخصوصاً تلك التي ثبت أنها موثوقة في الوصول إلى تكهنات جيدة للدورة الشمسية (٢٤).

المصادر:

أولاً. المصادر العربية:

١. عبدالله، محمود حمدون، (٢٠١٨)، تقدير الطلب على الطاقة الكهربائية لمقطاع السكني في محافظة نينوى للسنوات ٢٠١٦-٢٠٠٤ باستخدام المكونات غير المشاهدة، المجلة العراقية للعلوم الإحصائية، ١٥، ١٢١-١٣٦.

ثانياً. المصادر الأجنبية:

أ. الكتب:

1. Box, G. and G. Jenkins, (1976), Time Series Analysis: Forecasting and Control. San Francisco: Holden-Day.
2. Carlowicz, M. J. and R. E. Lopez, (2002), Storms from the sun: the emerging science of space weather, Joseph Henry Press.
3. Harvey, A. C., (1990), Forecasting, structural time series models and the Kalman filter, Cambridge university press.
4. Holt, C. C., (1957), Forecasting trend and seasonality by exponentially weighted moving averages. Office of Naval Research INR 52, Carnegie Institute of Technology.
5. Pelagatti, M. M., (2015), Time series modelling with unobserved components, Chapman and Hall/CRC.
6. Priestley, M. B., (1981), Spectral analysis and time series (Vol. 1): Academic press London.
7. Tarbuck, E. J., F. K. Lutgens and D. Tasa, (1997), Earth science, Prentice Hall Upper Saddle River, NJ.

ب. البحوث والاطاريح:

1. Brintha, N., S. Samita, N. Abeynayake, I. Idirisinghe and A. Kumarathunga, (2014), "Use of unobserved components model for forecasting non-stationary time series: a case of annual national coconut production in Sri Lanka." Tropical Agricultural Research 25(4): 423-431.
2. Bozdogan, H., (1987), Model selection and Akaike's information criterion (AIC): The general theory and its analytical extensions. Psychometrika, 52(3), 345-370.
3. Burnham, K. P., & Anderson, D. R., (2004), Multimodel inference: understanding AIC and BIC in model selection. Sociological methods & research, 33(2), 261-304.
4. Chattopadhyay, G., & Chattopadhyay, S., (2012), Monthly sunspot number time series analysis and its modeling through autoregressive artificial neural network. The European Physical Journal Plus, 127(4), 43.
5. Fomby, T., (2008), "The unobservable components model." SAS HELP file under the keyword "Proc UCM.
6. Gkana, A., & Zachilas, L., (2015), Sunspot numbers: data analysis, predictions and economic impacts. Journal of Engineering Science & Technology Review, 8(1): 79-85.
7. Harvey, A. and J. H. Stock, (1993), "Estimation, smoothing, interpolation and distribution for structural time series models in continuous time." Models, Methods and Applications of Econometrics: 55-70.

8. Holt Charles, C., (2004), "Forecasting seasonals and trends by exponentially weighted moving averages", International Journal of Forecasting 20(1): 5-10.
9. Izenman, A. J., (1985), JR wolf and the Zürich sunspot relative numbers. The Mathematical Intelligencer, 7(1), 27-33.
10. Li, K. J. Feng, W. & Li, F. Y., (2015), Predicting the maximum amplitude of solar cycle 25 and its timing. Journal of Atmospheric and Solar-Terrestrial Physics, 135, 72-76.
11. Li, M., Mehrotra, K., Mohan, C. K., & Ranka, S., (1990), Forecasting sunspot numbers using neural networks.
12. Okoh, D. I., Seemala, G. K., Rabiou, A. B., Uwamahoro, J., Habarulema, J. B., & Aggarwal, M., (2018), A Hybrid Regression-Neural Network (HR-NN) Method for Forecasting the Solar Activity. Space Weather, 16(9), 1424-1436.
13. Pala, Z., & Atici, R., (2019), Forecasting Sunspot Time Series Using Deep Learning Methods. Solar Physics, 294(5), 50.
14. Pishkalo, M. I., (2008), Preliminary prediction of solar cycles 24 and 25 based on the correlation between cycle parameters. Kinematics and Physics of Celestial Bodies, 24(5), 242.
15. Pishkalo, M. I., (2014), Prediction of solar cycle 24 using sunspot number near the cycle minimum. Solar Physics, 289(5), 1815-1829.
16. Quassim, Maha S., Abdel-Fattah Attia, and Hamdy K. Elminir. "Forecasting the peak amplitude of the 24th and 25th sunspot cycles and accompanying geomagnetic activity", Solar Physics 243.2 (2007): 253-258.
17. Rigozo, N. R., Echer, M. S., Evangelista, H., Nordemann, D. J. R., & Echer, E., (2011), Prediction of sunspot number amplitude and solar cycle length for cycles 24 and 25. Journal of Atmospheric and Solar-Terrestrial Physics, 73(11-12), 1294-1299.
18. Sabarinath, A., and A. K. Anilkumar. "Sunspot cycle prediction using multivariate regression and binary mixture of Laplace distribution model." Journal of Earth System Science 127.6 (2018): 84
19. Safiullin, N., Porshnev, S., & Kleeorin, N., (2018, May), Monthly sunspot numbers forecast with artificial neural network combined with dynamo model: comparison with modern methods. In 2018 Ural Symposium on Biomedical Engineering, Radioelectronics and Information Technology (USBREIT) (pp. 199-202). IEEE.
20. Shaikh, Y. H., Khan, A., Iqbal, M., Behere, S., & Bagare, S., (2008), Sunspots data analysis using time series. Fractals, 16(03), 259-265.
21. Sarp, V., Kilcik, A., Yurchyshyn, V., Rozelot, J. P., & Ozguc, A., (2018), Prediction of solar cycle 25: a non-linear approach. Monthly Notices of the Royal Astronomical Society, 481(3), 2981-2985.
22. Winters, P. R., (1960), Forecasting sales by exponentially weighted moving averages. Management science, 6(3), 324-342.
23. Yan, X., Deng, L., Qu, Z., Xu, C., & Kong, D., (2012), Phase relationship between sunspot number, flare index and solar radio flux. Journal of Astrophysics and Astronomy, 33(4), 387-397.