التنبؤ بإنتاج النفط الخام في العراق باستعمال الأنموذج الموجي الرمادي بخطوط محاذاة متساوية

أ.د. احمد شاكر محمد طاهر
الجامعة المستنصرية/ كلية الادارة والاقتصاد

م. علي محمد علي خضير الفرداوي
جامعة ميسان/ كلية الادارة والاقتصاد

تاريخ استلام البحث: 2022/10/15

تاريخ قبول البحوث: 2022/11/23

نشر البحث في العدد الثامن عشر: مارس / اذار 2023

رمز التصنيف ديوي / النسخة الالكترونية (Online): 2522-64X/519.287

رمز التصنيف ديوي / النسخة الورقية (Print): 2519-948X/519.287

التنبؤ بإنتاج النفط الخام في العراق باستعمال الأنموذج الموجي الرمادي بخطوط محاذاة متساوية

أ.د. احمد شاكر محمد طاهر
الجامعة المستنصرية/ كلية الادارة والاقتصاد

م. علي محمد علي خضيرم الفرداوي
جامعة ميسان/ كلية الادارة والاقتصاد

المستخلص

تتعامل نظرية النظام الرمادي مع المعلومات غير المؤكدة للظواهر إذ يمكن بموجبها استعمال بعض البيانات لإنشاء نماذج دون مراعاة توزيع تلك البيانات. لذا تم استعمال هذه النظرية على نطاق واسع في مجال معالجة الصور والتنبؤ في مجال السلاسل الزمنية وتحسين النظام والتحكم والقرار وما إلى ذلك. يعد التنبؤ بالنظام الرمادي أحد أهم المكونات في نظرية النظام الرمادي الذي يعمل على ايجاد قواعد تطوير النظام من خلال إجراءات معينة لمعالجة البيانات من أجل التنبؤ بمستقبل النظام علميًا وكميًا. عندما تكون بيانات السلسلة الزمنية ذات تقلبات كبيرة ونطاق تأرجحها أكبر، يكون من الصعب بناء نموذج مناسب لوصف سلوك تلك السلسلة الزمنية، في هذه الحالة يمكننا التفكير في التنبؤ بموجة تطوير البيانات السلوكية في المستقبل بناءً على موجة البيانات الأصلية، ويسمى هذا النوع من التنبؤ بالتنبؤ بالموجات. يعد التنبؤ بالموجات أحد المحتويات المهمة لنظام التنبؤ الرمادي، وعملية النمذجة الخاصة به واضحة وبسيطة، لذا فإن التنبؤ بالموجات يكتسب قيمة عالية للتطبيق في العديد من المجالات. في هذا البحث تم استعمال نماذج التنبؤ الموجية الرمادية للتنبؤ بإنتاج النفط الخام في العراق بالاعتماد على بيانات السلسلة الزمنية لمعدل الإنتاج الشهري والتي تعاني مشاهداتها من التقلبات الكبيرة، وقتم التوصل إلى فعالية هذه الطريقة في التنبؤ بالسلسلة الزمنية.

الكلمات المفتاحية: الأنموذج الموجي الرمادي، خطوط محاذاة متساوية، إنتاج النفط الخام.

Prediction of Crude Oil Production in Iraq by Using the Gray Wave Model with Equal Interval Contour Lines

ABSTRUCT

Gray system theory deals with the uncertain information of phenomena, according to which some data can be used to create models without taking into account the distribution of that data. So, this theory has been widely used in the field of image processing, time-series prediction, system optimization, control and resolution, etc. Gray system prediction is one of the most important components of gray system theory that works to find rules for system development through certain data processing procedures in order to predict the future of the system scientifically and quantitatively. When the time series data have large fluctuations and their oscillation range is larger, it is difficult to build a suitable model to describe the behavior of that time series. In this case we can think of predicting the wave of development of behavioral data in the future based on the original data wave. Wave prediction is one of the important contents of the gray prediction system, and its modeling process is clear and simple, so wave prediction is gaining high application value in many fields. In this research, gray wave prediction models were used to predict crude oil production in Iraq based on the time series data of the monthly production rate,

the observations of which suffer from large fluctuations, and the effectiveness of this method in predicting the time series was reached.
Keywords: Grey Wave Forecasting, Equal Interval Contour Lines, Crude Oil Production.

1. المقدمة

في نظرية الأنظمة تستعمل الألوان للتعبير عن توفر المعلومات من عدمه للنظام المدروس، إذ يعتمد اللون الأبيض للتعبير عن توفر المعلومات الكاملة للنظام لذا يسمى بالنظام الأبيض بينما يعتمد اللون الأسود للتعبير عن عدم توفر المعلومات بشكل كامل ويطلق عليه النظام الأسود، في حين يسمى النظام بالنظام الرمادي إذا كانت المعلومات الخاصة به يشوبها عدم التأكد أو الدقة وبالنسبة لهذا النظام نجد أن بعض المعلومات تكون معروفة والقسم الآخر يكون غير معروف.

يمكن تعريف نظرية النظام الرمادي بأنها بحث في غير المؤكد بسبب استخدامها لبيانات ومعلومات قليلة، هذه النظرية تستخدم مع بيانات قليلة وغير مؤكدة والتي تحتوي على عينات صغيرة من البيانات والمعلومات الجزئية والضعيفة باعتبارها مدخلات البحث الأساسية.

اقترح النظام الرمادي من قبل العالم الصيني Deng Ju-Long في عام 1982 [8]. والذي يتم اعتماده كطريقة للتنبؤ بالسلاسل الزمنية غير الخطية، وقد تم تطوير هذا النظام من قبل الباحثين واعتماده في مختلف المجالات الاقتصادية والصناعية والظواهر الطبيعية.

النماذج الرمادية تكون مفيدة للتنبؤ بسلوك السلسلة الزمنية الرتيبة بمعنى التي تمتاز بأنها تصاعدية أو تنازلية إذ تعطي تنبؤات ذات دقة عالية ولكنها تكون غير كفؤة في حالة السلاسل الزمنية ذات التقلبات الدورية والعرضية، مما دفع بالباحثين إلى التفكير بالتنبؤ بموجة سلوك البيانات في المستقبل بناءً على موجة البيانات الأصلية ويسمى هذا النوع من التنبؤ بالتنبؤ بالموجة، والذي يعد أحد أهم التنبؤات الرمادية والأنموذج المعتمد يسمى بالأنموذج الموجي الرمادي وهو محل اهتمام هذا البحث.

تم تقسيم هذا البحث إلى خمسة أقسام رئيسة الأول يتضمن المقدمة، والثاني يتضمن أنموذج التنبؤ الرمادي وتوضيح آلية عمله وخطوات بنائه، والثالث يتضمن الأنموذج الموجي الرمادي وتوضيح مسوغات وجوده وخطوات بنائه، والقسم الرابع يتضمن الجانب التطبيقي للبحث حيث يتم التطبيق على سلسلتين من البيانات، وأخيراً القسم الخامس للاستنتاجات.

2. أنموذج التنبؤ الرمادي Grey Forecasting Model

يعد أنموذج التنبؤ الرمادي من النماذج الكمية المستعملة في التنبؤ والتي تعتمد على دالة التوليد الرمادية حيث تستعمل عملية التوليد التراكمية لتكوين معادلات تفاضلية لها خصائص تتطلب بيانات أقل لذا يظهر هذا الأنموذج كأداة فعالة للحصول على معلومات قيمة من مجموعات البيانات الصغيرة [9].

ويشار إلى هذا الأنموذج بـ GM(p,q)، إذ إن الرمز p يشير إلى رتبة المعادلة التفاضلية والرمز q يشير إلى عدد المتغيرات الداخلة في الأنموذج [4].

كحالة خاصة من أنموذج التنبؤ الرمادي GM(p,q)، الأنموذج GM(1,1) والذي يمتاز ببساطته ودقته فضلاً عن أنه الأكثر استعمالاً بالرغم من وجود عدة أنواع أخرى ولكن معظم الباحثين يركزون على استعمال هذا الأنموذج لكفاءته الحسابية، وهذا الأنموذج يوصف بأنه أنموذج رمادي خطي من الدرجة الأولى إذ يتكون من معادلة تفاضلية من الدرجة الأولى مع متغير واحد فقط [18].

يمكن تلخيص فكرة GM(1,1) في تحويل سلسلة البيانات الأصلية ذات الطبيعة العشوائية إلى سلسلة بيانات منتظمة لتحقيق ترتيب يلبي متطلبات أنموذج التنبؤ، حيث تخضع البيانات الأولية التي تعاني من العشوائية إلى عملية تجميع تراكمي تسمى بعملية التوليد التراكمي Accumulative Generation Operator (AGO)، ثم يتم حل المعادلة التفاضلية للأنموذج بالاعتماد على سلسلة البيانات الناتجة من عملية التراكم وذلك للحصول على القيمة المتوقعة، ثم يتم تطبيق معكوس عملية التراكم للحصول على القيمة التنبؤية [14]. وبذلك يمكننا أن نقول إن التنبؤ في النماذج الرمادية يشمل عمليات رئيسة

ثلاث هي: عملية التوليد التراكمي، الأنموذجة الرمادية، معكوس عملية التوليد التراكمي [5]، وسيتم توضيح هذه الخطوات كما يأتي:

a. تهيئة بيانات السلسلة الزمنية الأصلية على افتراض أنها تمثل كالآتي [1]:

$$x^{(0)} = \left(\mathrm{x}^{(0)}(1) , \mathrm{x}^{(0)}(2) , \dots , \mathrm{x}^{(0)}(\mathrm{n}) \right) \quad , n \geq 4 \qquad \dots (1)$$

ومن استعمال عملية التوليد التراكمي لإنشاء تسلسل جديد لسلسلة البيانات الأصلية وكما يأتي:

AGO: $x^{(0)} \rightarrow x^{(1)}$

$$x^{(1)} = \left[\, x^{(1)}(1), x^{(1)}(2), \dots , x^{(1)}(n) \right]$$

حيث إن $x^{(1)}$ تمثل السلسلة الجديدة بعد الإضافات التراكمية والتي يتم الحصول عليها كما يأتي:

$$x^{(1)}(m) = \sum_{k=1}^{m} x^{(0)}(k) \quad , m = 1,2, \dots , n \qquad \dots (2)$$

b. يضعف ويقل تأثير العشوائية وعدم الانتظام في سلسلة البيانات الأصلية بعد أن تجرى عملية التوليد التراكمي، وتصبح البيانات الناتجة ذات قاعدة نمو متزايدة، ويتم تحسين تسلسل البيانات الأصلية تدريجياً إلى أن تتضح قيمة التطوير والتغيير في المستقبل ليتم بعد ذلك إنشاء نمذجة النظام وإنشاء معادلة تفاضلية وهذه المعادلة تعد الأساس الذي يستند عليه التنبؤ [6]. بعد أن تنشأ المعادلة التفاضلية يتم حلها باستعمال طريقة المربعات الصغرى الاعتيادية (OLS) Ordinary Least Squares للحصول على معلمة α التي تعكس اتجاه التغيير في السلسلة $x^{(1)}$ وعمود البيانات الأصلية $x^{(0)}$ ومعلمة β التي تعكس العلاقات المتغيرة بين البيانات ومن ثم الحصول على القيمة المتوقعة للنظام والتنبؤ بسلوك النظام في المستقبل [10] والمعادلة الآتية تمثل المعادلة التفاضلية من الدرجة الأولى التي من خلالها يمكننا نمذجة $x^{(1)}$ [16]:

$$x^{(0)}(m) + \alpha z^{(1)}(m) = \beta \quad , m = 2,3, \dots , n \qquad \dots (3)$$

حيث إن:

α: يمثل معامل التطوير (Developed Coefficient).

β: يمثل متغير السيطرة الرمادي (Grey Controlled Variable).

$z^{(1)}(m)$: تمثل قيم التسلسل الجديد للوسط المتولد من $x^{(1)}$ وتحسب كما يأتي:

$$z^{(1)}(m) = 0.5 \left(x^{(1)}(m) + x^{(1)}(m-1) \right) \quad , m = 2,3, \dots \qquad \dots (4)$$

ويمكن إعادة صياغة المعادلة (3) كما يأتي:

$$x^{(0)}(m) = -\alpha z^{(1)}(m) + \beta \quad , m = 2,3, \dots , n \qquad \dots (5)$$

ويمكننا صياغة المعادلة (5) على شكل مصفوفات وكما يأتي:

$$\begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} = \begin{bmatrix} -z^{(0)}(2) & 1 \\ -z^{(0)}(3) & 1 \\ \vdots & \vdots \\ -z^{(0)}(n) & 1 \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} \qquad \dots (6)$$

ويتم تقدير معلمات الأنموذج الرمادي في المعادلة (6) باستعمال طريقة المربعات الصغرى، وكما يأتي:

$$\hat{p} = \begin{bmatrix} \hat{\alpha} \\ \hat{\beta} \end{bmatrix} = (Z'Z)^{-1}Z'\underline{y}$$

Where:

$$Z = \begin{bmatrix} -z^{(0)}(2) & 1 \\ -z^{(0)}(3) & 1 \\ \vdots & \vdots \\ -z^{(0)}(n) & 1 \end{bmatrix}, \underline{y} = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix}$$

بعد الحصول على قيم $\hat{\alpha}$ و$\hat{\beta}$ يتم حساب قيم الاستجابة الزمنية ($\hat{x}^{(1)}(m)$) وكما يأتي:

$$\hat{x}^{(1)}(m) = \left(x^{(0)}(1) - \frac{\hat{\beta}}{\hat{\alpha}}\right)e^{-\hat{\alpha}(m-1)} + \frac{\hat{\beta}}{\hat{\alpha}} \quad ; m = 1,2,\dots,n,n+1,\dots \qquad \dots (7)$$

c. بعد أن يتم الحصول على جميع قيم $\hat{x}^{(1)}$، يتم إجراء معكوس عملية التوليد التراكمي (Inverse Accumulated Generating Operation) عن طريق المعادلة الآتية [7]:

$$\hat{x}^{(0)}(m+1) = \hat{x}^{(1)}(m+1) - \hat{x}^{(1)}(m) \qquad \dots (8)$$

3. أنموذج التنبؤ الموجي الرمادي Grey Wave Forecasting Model

النماذج الرمادية لمتغير واحد أو أكثر تكون مفيدة للتنبؤ بسلوك السلسلة الزمنية الرتيبة إذ تعطي تنبؤات ذات دقة عالية ولكنها تكون غير كفؤة في حالة السلاسل الزمنية ذات التقلبات الدورية والعرضية، مما دفع بالباحثين إلى التفكير بالتنبؤ بموجة سلوك البيانات في المستقبل بناءً على موجة البيانات الأصلية ويسمى هذا النوع من التنبؤ بالتنبؤ بالموجة، والذي يعد أحد أهم التنبؤات الرمادية والأنموذج المعتمد يسمى بالأنموذج الموجي الرمادي [12] وتتلخص فكرة أنموج التنبؤ الموجي الرمادي في ثلاث خطوات رئيسة: اختيار خطوط المحاذاة (Contour Lines)، تحديد المتتابعات الزمنية، وتطبيق الأنموذج الرمادي GM(1,1) على المتتابعات الزمنية [13] وسيتم توضيح هذه الخطوات كما يأتي:

a. اختيار خطوط المحاذاة (Choosing Contour Lines): تستعمل في الأنموذج الموجي الرمادي في الأصل خطوط محاذاة متساوية مبنية على معدل أعلى وأدنى قيمة في البيانات [3]. الآن، لنرمز للسلسة الأصلية X=X(1), X(2), …, X(n)، بعد ذلك نرتب هذه السلسلة تصاعدياً للحصول على سلسلة جديدة $X^a = \left(X^a(1), X^a(2), \dots, X^a(n)\right)$. ولتكن $\xi_0 = X^a(1)$ و$\xi_s = X^a(n)$ ولتكن $\xi_1, \xi_2, \dots, \xi_{s-1}$ هي s-quantile للبيانات، حيث إن:

$$\xi_i = \xi_0 + w_i \qquad \dots (9)$$

باعتبار أن $w_i = n(i/(s+1))$. وإن ξ_i تمثل الخطوط المحاذية متساوية الفاصل (Equal-Interval Contour Lines) للسلسلة الأصلية

b. تحديد المتتابعات الزمنية (Identifying Contour Time Sequences): يتم تحديد المتتابعات الزمنية بناءً على الخطوط متساوية الفاصل التي تم الحصول عليها من المعادلة (9). لتكن السلسلة الأصلية هي X=X(1), X(2), …, X(n)، وخط المحاذاة ξ_i يتقاطع مع السلسة الزمنية الأصلية، ولتكن $X_{\xi_i} = (P_1, P_2, \dots, P_{m_i})$ مجموعة من نقاط التقاطع (Intersection Points)، P_j تقع على الخط المكسور ذي الرتبة t_j واحداثيات P_j (Coordinates) تكون $(q(j), \xi_j)$، حيث إن [15]:

$$q(j) = t_j + \frac{\xi_j - x(t_j)}{x(t_j + 1) - x(t_j)} \ , \ j = 1,2,\dots,m \qquad \dots(10)$$

بالتالي $Q_i^{(0)} = (q_i(1), q_i(2), \dots, q_i(m_i)), i = 0,1,2,\dots,s$ تمثل المتتابعات الزمنية للخط المحاذي ξ_i.

c. ترشيح المتتابعات الزمنية والتنبؤ بواسطة (Filtrating Contour Time Sequences and Forecasting with GM(1,1)): بالنسبة للتنبؤ الموجي الرمادي فأنه في الأصل يتم استعمال المتتابعات الزمنية التي تحتوي على 4 عناصر أو أكثر [15] ولكن عندما تتقلب السلسلة الزمنية فأن هذا لا يعد ملائماً للتنبؤ بل يكون من الضروري ترشيح هذه المتتابعات عند استعمالها مع GM(1,1) [2]. تعتمد فكرة الترشيح على الارتباط الذاتي (Autocorrelation) للسلسلة الزمنية، حيث إن الارتباط الذاتي يقيس التشابه بين المشاهدات كدالة بدلالة الزمن، بناءً عليه يمكننا اختيار المتتابعات الزمنية التي تكون نهاياتها قريبة من تسلسل أول قيمة مستقبلية، ثم يمكننا استعمال أنموذج GM(1,1) بناءً على المتتابعات التي يتم اختيارها وكما يأتي [17]:

لتكن t_1^f تمثل تسلسل أول قيمة مستقبلية و$Q_i^{(0)} = (q_i(1), q_i(2), \dots, q_i(m_i))$ تمثل المتتابعات الزمنية المختارة للخط المحاذي ξ_i.

تكوين الأنموذج الرمادي GM(1,1) بناءً على $Q_i^{(0)} = (q_i(1), q_i(2), \dots, q_i(m_i))$ للحصول على القيم التنبؤية $q_i(m_i + 1), q_i(m_i + 2), \dots, q_i(k_i)$.

الترتيب التصاعدي لجميع القيم في المتتابعات الزمنية $Q_0^{(0)}, Q_1^{(0)}, \dots, Q_s^{(0)}$ وحذف القيم الباطلة (invalid value)، أي أن:

q(1)<q(2)<…<q(ns)

حيث إن q(k) هي نقطة تقع على الخط المحاذي وإن الموجة المولدة من العينة تكون كالآتي:

$$X = \left\{ \xi_{q(k)} + \frac{t - q(k)}{q(k+1) - q(k)} \left[\xi_{q(k+1)} - \xi_{q(k)} \right] \right\}, \qquad k = 1,2,\dots,ns \quad \dots(11)$$

4. التطبيق Application

تم التطبيق على بيانات حقيقية تمثل المعدل الشهري لإنتاج النفط الخام بملايين البراميل في العراق، للفترة من شهر كانون الثاني 2016 إلى كانون الأول عام 2021، أي 72 مشاهدة، والشكل الآتي يوضح رسم هذه السلسلة:

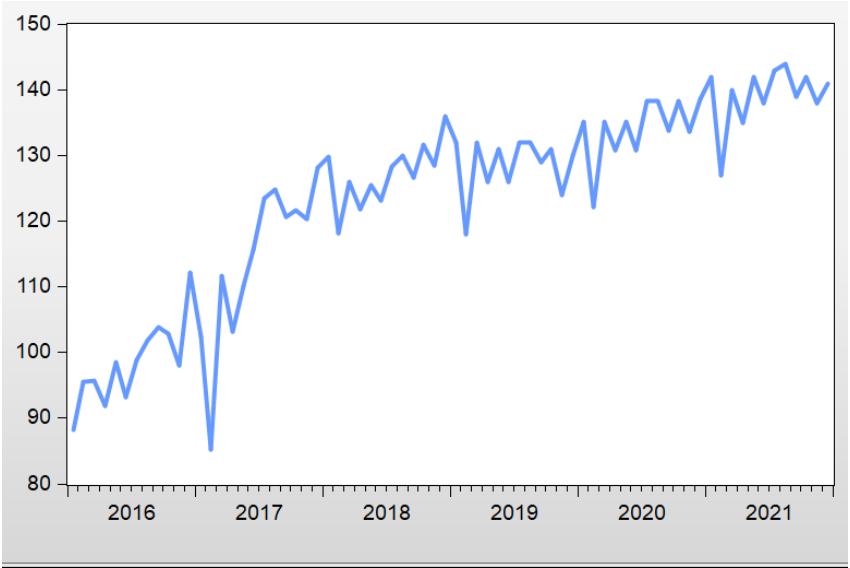

شكل (1): البيانات الشهرية لإنتاج النفط الخام في العراق من كانون الثاني 2016 إلى كانون الأول 2021

نلاحظ من الشكل 1 أن السلسلة هي متذبذبة، ويؤيد هذا الكلام الإحصاءات الوصفية المتعلقة بها، حيث إن الفرق بين أعلى قيمة وأكبر قيمة يعد كبيراً نسبياً، كما أن نتائج اختبار Jarque-Bera تدل على أن هذه البيانات لا تتبع التوزيع الطبيعي والجدول الآتي يعرض هذه المقاييس:

جدول (1): الإحصاءات الوصفية للبيانات الشهرية لإنتاج النفط الخام في العراق

Mean	Max	Min	Std. Dev.	Bera -Jarque Test
123.5736	144	85.3	15.23413	9.494792 (0.008674)

والجدول 2 يوضح معاملات الارتباط الذاتي من التخلف الزمني (Lag) الأول إلى التخلف الزمني العاشر، حيث تشير إلى أن هذه السلسة ذات ارتباط ذاتي عالي (Highly Auto-Correlative) لذا فيمكننا اختيار المتتابعات الزمنية منها.

جدول (2): تحليل الارتباط الذاتي لبيانات إنتاج النفط الخام

Lag	1	2	3	4	5
ACF	0.834	0.820	0.783	0.710	0.675
prob.	0.000	0.000	0.000	0.000	0.000
Lag	6	7	8	9	10
ACF	0.587	0.583	0.523	0.495	0.465
prob.	0.000	0.000	0.000	0.000	0.000

ولأغراض التنبؤ فقد تم تقسيم هذه السلسلة المتكونة من 72 مشاهدة إلى جزأين الجزء الأول للفترة من كانون الثاني عام 2016 إلى كانون الأول عام 2020 بمعنى أنها 60 مشاهدة، والجزء الثاني عبارة عن 12 مشاهدة للفترة بين شهر كانون الثاني وكانون الأول من عام 2021. حيث تم استخدام الجزء الأول

لاختيار الخطوط المحاذية وتحديد المتتابعات الزمنية، والجزء الثاني استعمل لتقييم التنبؤ، والتنبؤ في هذا البحث هو تنبؤ بـ 14 خطوة.

الآن يتم البدء بالخطوة الأول من خطوات التنبؤ الموجي الرمادي والمتمثلة باختيار الخطوط المحاذية، حيث تم استخدام s=9 بمعنى هناك عشرة خطوط محاذية كما موضحة في الشكل 2

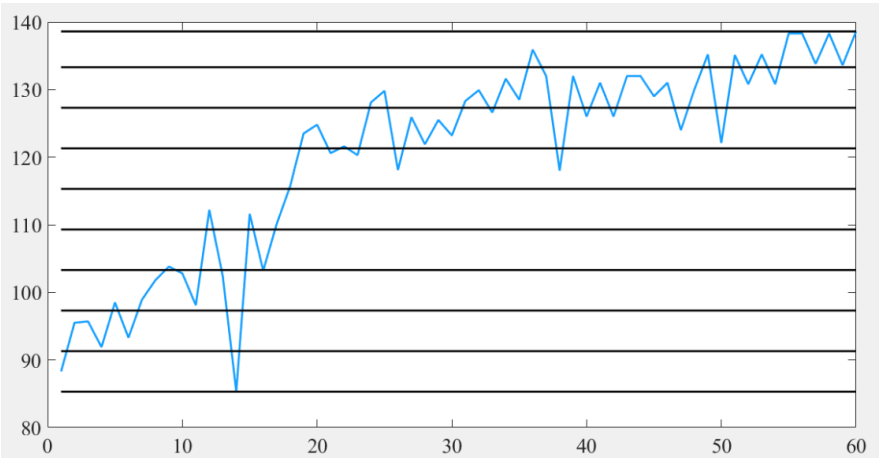

شكل (2): خطوط المحاذاة العشرة لبيانات إنتاج النفط الخام

الجدول 4 أيضاً يعرض عدد الخطوط المكسورة التي تقاطع لكل خط محاذاة، وكما يأتي:

جدول (4): خطوط المحاذاة ونقاط تقاطعها مع السلسلة الزمنية

i	0	1	2	3	4	5	6	7	8	9
ξ_i	85.3	91.3	97.3	103.3	109.3	115.3	121.3	127.3	133.3	138.6
m_i	1	3	5	6	5	1	9	15	9	1
t_i	14	1	4	8	11	17	18	23	35	60
		13	5	9	12		20	25	36	
		14	6	11	14		21	30	48	
			13	12	15		22	32	49	
			14	14	16		23	33	50	
				16			25	37	51	
							26	38	52	
							37	39	53	
							38	40	54	
								41		
								42		
								46		
								47		
								49		
								50		

الجدول 5 يمثل المتتابعات الزمنية التي تمثل الخطوة الثانية، وكما يأتي:

جدول (5): المتتابعات الزمنية لخطوط المحاذاة

i	0	1	2	3	4	5	6	7	8	9
$Q_i^{(0)}$	14	1.42	4.82	8.75	11.79	17.93	18.72	23.9	35.65	60
		13.65	5.23	9.5	12.3		20.83	25.21	36.67	
		14.23	6.71	11.37	14.91		21.70	30.8	48.63	
			13.3	12.91	15.27		22.23	32.79	49.15	
			14.46	14.68	16.88		23.13	33.14	50.86	
				16.01			25.73	37.34	51.42	
							26.41	38.66	52.57	
							37.76	39.78	53.43	
							38.24	40.26	54.33	
								41.74		
								42.22		
								46.53		
								47.55		
								49.6		
								50.4		

الآن نبدأ بالخطوة الثالثة، والتي تمثل ترشيح المتتابعات الزمنية وبناء أنموذج GM(1,1)، ومن المعلوم أن أول قيمة مستقبلية هي ذات الترتيب 61، كما علمنا أيضاً أن السلسلة فيها ارتباط ذاتي قوي كما هو موضح في الجدول 3، وقد تم اختيار $Q_6^{(0)}, Q_7^{(0)}\ and\ Q_8^{(0)}$ لنمذجة GM(1,1)؛ وذلك لأنها الأقرب إلى القيم المستقبلية، وعملية التوليد التراكمي يتم إيجادها طبقاً للمعادلة (2) لجميع هذه المتتابعات، وبذلك نحصل على الجدول 6 الآتي:

جدول (6): عملية التوليد التراكمي

i	6	7	8
AGO	18.72	23.9	35.65
	39.55	49.11	72.32
	61.25	79.91	120.95
	83.48	112.7	170.1
	106.61	145.84	220.96
	132.34	183.18	272.38
	158.75	221.84	324.95
	196.51	261.62	378.38
	234.75	301.88	432.71
		343.62	
		385.84	
		432.37	
		479.92	
		529.52	
		579.92	

فيما بعد سيتم الحصول على قيم $z^{(1)}(m)$ طبقاً للمعادلة (4)، وكما في الجدول الآتي:

جدول (7): الوسط المتولد للمتتابعات القريبة

i	6	7	8
$z_i^{(1)}$	29.14	36.51	53.99
	50.40	64.51	96.64
	72.37	96.31	145.53
	95.05	129.27	195.53
	119.48	164.51	246.67
	145.55	202.51	298.67
	177.63	241.73	351.67
	215.63	281.75	405.55
		322.75	
		364.73	
		409.11	
		456.15	
		504.72	
		554.72	

باستعمال طريقة المربعات الصغرى يتم الحصول على التقديرات الآتية:

$$\hat{p}_6 = \begin{bmatrix}\hat{\alpha}_6 \\ \hat{\beta}_6\end{bmatrix} = \begin{bmatrix}-0.1021 \\ 15.4501\end{bmatrix}$$

$$\hat{p}_7 = \begin{bmatrix}\hat{\alpha}_7 \\ \hat{\beta}_7\end{bmatrix} = \begin{bmatrix}-0.0432 \\ 27.8887\end{bmatrix}$$

$$\hat{p}_8 = \begin{bmatrix}\hat{\alpha}_8 \\ \hat{\beta}_8\end{bmatrix} = \begin{bmatrix}-0.0366 \\ 41.4248\end{bmatrix}$$

وبعد الحصول على قيم كل من $\hat{\alpha}$ و$\hat{\beta}$ قيم وقت الاستجابة يمكن حسابها كما يأتي:

$$q_6^{(1)}(m) = \left(x^{(0)}(1) - \frac{\hat{\beta}_6}{\hat{\alpha}_6}\right)e^{-\hat{\alpha}_6(m-1)} + \frac{\hat{\beta}_6}{\hat{\alpha}_6} = 170.04e^{0.1021(m-1)} - 151.32$$

$$q_7^{(1)}(m) = \left(x^{(0)}(1) - \frac{\hat{\beta}_7}{\hat{\alpha}_7}\right)e^{-\hat{\alpha}_7(m-1)} + \frac{\hat{\beta}_7}{\hat{\alpha}_7} = 669.47e^{0.0432(m-1)} - 645.57$$

$$q_8^{(1)}(m) = \left(x^{(0)}(1) - \frac{\hat{\beta}_8}{\hat{\alpha}_8}\right)e^{-\hat{\alpha}_8(m-1)} + \frac{\hat{\beta}_8}{\hat{\alpha}_8}$$
$$= 1167.48e^{0.0417(m-1)} - 1131.83$$

عندئذ:

$$q_i(m) = q_i^{(1)}(m) - q_i^{(1)}(m-1)$$

بعد الحصول على القيم المقدرة، يمكننا التنبؤ بالسلسلة الزمنية، وتم حساب قيمة معيار جذر متوسط مربعات الخطأ (RMSE) وكانت قيمتها تساوي 3.567، وبالنسبة للسلسلة الأصلية ومقارنتها بالسلسلة المقدرة، والشكل الآتي يوضح مدى التقارب بينهما:

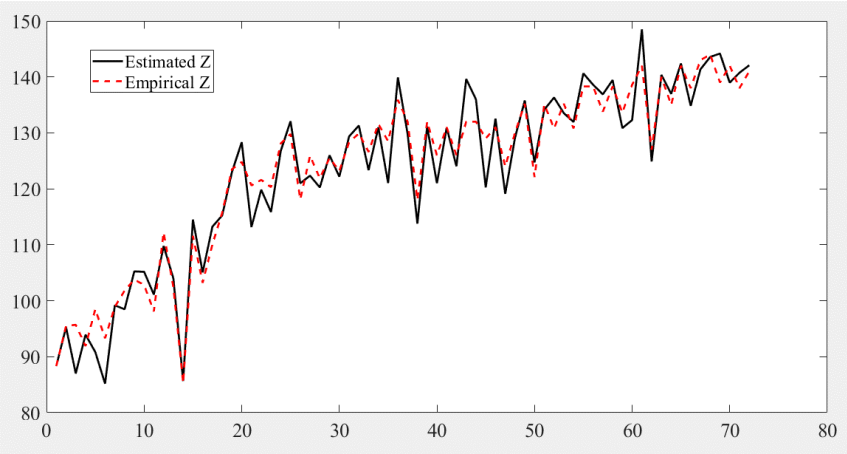

شكل (3): القيم التقديرية والتجريبية للسلسلة

5. الاستنتاجات Conclusion

في هذا البحث تمت دراسة المعدل الشهري لإنتاج النفط الخام في العراق، وأظهرت النتائج أن هذه السلسلة تعاني من أنها ليست سلسلة رتيبة بل ان هناك تقلبات، كما أظهرت النتائج أن هذه البيانات لا تتبع التوزيع الطبيعي وأن الارتباط الذاتي قوي. وقد تم استعمال المتتابعات الزمنية (6 ، 7 ، 8) للتنبؤ بالسلسلة لأنها الأقرب إلى القيمة المستقبلية الأولى. أظهر الرسم البياني مدى قرب السلسلة التجريبية الأصلية مما تم تقديره بطريقة الموجة الرمادية.

References

1. Chang, C. J., Der-Chiang, L. I., Chien-Chih, C. H. E. N., & Wen-Chih, C. H. E. N. (2019). EXTRAPOLATION-BASED GREY MODEL FOR SMALL-DATASET FORECASTING. Economic Computation & Economic Cybernetics Studies & Research, 53(1).
2. Chen, Y., Liu, B., & Wang, T. (2020). Analysing and forecasting China containerized freight index with a hybrid decomposition–ensemble method based on EMD, grey wave and ARMA. Grey Systems: Theory and Application.
3. Chen, Y., Zou, Y., & Wang, S. (2015). Grey wave forecasting with qualified unequal-interval contour lines and its application in metal prices prediction. In 2015 IEEE International Conference on Grey Systems and Intelligent Services (GSIS) (pp. 261-265). IEEE.
4. Duman, G. M., Kongar, E., & Gupta, S. M. (2019). Estimation of electronic waste using optimized multivariate grey models. Waste Management, 95, 241-249.
5. Geng, N., Zhang, Y., Sun, Y., Jiang, Y., & Chen, D. (2015). Forecasting China's annual biofuel production using an improved grey model. Energies, 8(10), 12080-12099.
6. Guo, Y. L., Zhao, M. H., & Deng, Z. W. (2014). Tunnel surrounding rock deformation forecast analysis based on GM and FEM. Electronic Journal of Geotechnical Engineering, 19, 1379-1394.
7. Hu, Y. C. (2020). Energy demand forecasting using a novel remnant GM (1, 1) model. Soft Computing, 24(18), 13903-13912.

8. Julong, D. (1982). Grey control system. *Journal of Huazhong University of Science and Technology*, *3*(9), 18.
9. Kahraman, C., & Yavuz, M. (2010). Production engineering and management under fuzziness (Vol. 252). Springer.
10. Lin, L., & Lind, H. (2010). AN APPLICATION OF GREY SYSTEM THEORY INTO REAL ESTATE INVESTMENT DECISION-MAKING (Doctoral dissertation, MS thesis, Department of Real Estate and Construction Management, KTH, Stockholm, Sweden).
11. Liu, S., Dang. Y, Fang, Z. (2010). Grey System Theory and Its Application. 5th edition Beijing China: Science Press.
12. Liu, S., & Forrest, J. Y. L. (2010). Grey systems: theory and applications. Springer Science & Business Media.
13. Liu, S. & Lin, Y. (2010). Grey Systems: Theory and Applications. Springer.
14. Liu, S., Yang, Y., Xie, N., & Forrest, J. (2016). New progress of grey system theory in the new millennium. Grey Systems: Theory and Application.
15. Wan, Q., Wei, Y., & Yang, X. (2010). Research on grey wave forecasting model. In Advances in Grey Systems Research (pp. 349-359). Springer, Berlin, Heidelberg.
16. Wu, W. Z., & Zhang, T. (2020). An improved gray interval forecast method and its application. Communications in Statistics-Theory and Methods, 49(5), 1120-1131.
17. Yin, K., Lu, D., & Li, X. (2017). A novel grey wave method for predicting total Chinese trade volume. Sustainability, 9(12), 2367.
18. Zhang, L., Wang, L., Zheng, Y., Wang, K., Zhang, X., & Zheng, Y. (2017). Time prediction models for echinococcosis based on gray system theory and epidemic dynamics. International journal of environmental research and public health, 14(3), 262.