

استعمال الأنموذج الهجين STARIMA-GARCH لنمذجة امكانية انتشار مرض الحصبة في محافظة ديالى

انعام هيثم يعقوب*  ، فراس احمد محمد  ID

قسم الاحصاء، كلية الإدارة والاقتصاد، جامعة بغداد، بغداد، العراق.

*Corresponding author: anaamalsafi7@gmail.com

الكلمات المفتاحية	الملخص
<p>النمذجة الزمكانية، أنموذج STARIMA، أنموذج GARCH، خوارزمية سرب القطط، مرض الحصبة، الأنموذج الهجين، التنبؤ بالأوبئة.</p>	<p>يهدف هذا البحث إلى نمذجة وتحليل السلوك الزمني والمكاني لانتشار مرض الحصبة في محافظة ديالى باستخدام أنموذج هجين يجمع بين أنموذج السلاسل الزمنية المكانية المتكاملة ذات المتوسطات المتحركة STARIMA وأنموذج التباين الشرطي GARCH، مع اعتماد خوارزمية سرب القطط (Cat Swarm Optimization – CSO) في تقدير معالم الأنموذج. تم استخدام بيانات أسبوعية لإصابات الحصبة في ثمانية قطاعات صحية في محافظة ديالى خلال مدة 130 أسبوعاً للفترة من 1 كانون الثاني 2023 إلى 1 تموز 2025. أظهرت النتائج الأولية باستعمال اختبار Mann–Kendall وجود اتجاه عام غير مستقر في جميع السلاسل الزمنية، مما استلزم أخذ الفرق الأول لتحقيق الاستقرارية. كما أثبت اختبار موران وجود ترابط مكاني معنوي بين القطاعات، مما يؤكد أن انتشار المرض يتبع نمطاً مكانياً مترابطاً. بعد ذلك، تم تقدير مجموعة من نماذج STARIMA باستخدام خوارزمية سرب القطط، واختيار الأنموذج الأمثل اعتماداً على معايير المفاضلة الإحصائية AIC وBIC وHQ، حيث تبين أن الأنموذج الذي يأخذ الإزاحة المكانية الأولى (Lag = 1) هو الأكثر ملاءمة للبيانات. تم حساب البواقي الناتجة عن الأنموذج المختار وإخضاعها لأنموذج GARCH(1,1) لتمثيل التغير الديناميكي في التباين، وقد أظهرت النتائج وجود تباين غير ثابت يعكس موجات التفشي الوبائي. وأسهم دمج STARIMA مع GARCH في تحسين توصيف كل من المتوسط الشرطي والتباين الشرطي لسلسلة الإصابات، مما وفر أنموذجاً أكثر دقة وموثوقية للتنبؤ قصير ومتوسط الأجل. يخلص البحث إلى أن الأنموذج الهجين STARIMA–GARCH يمثل إطاراً إحصائياً فعالاً لتحليل وانتشار الأمراض الوبائية ذات الطبيعة الزمانية المكانية، ويمكن الاعتماد عليه في دعم متخذي القرار الصحي في وضع استراتيجيات وقائية مبنية على أسس علمية دقيقة.</p>
<p>Keywords Spatio-temporal modelling, STARIMA, GARCH, Cat Swarm Optimization, Measles, The hybrid model, Epidemic forecasting</p>	<p>Abstract This study aims to model and analyze the spatio-temporal dynamics of measles incidence in Diyala Governorate using a hybrid framework that combines the Space–Time Autoregressive Integrated Moving Average (STARIMA) model with the Generalized Autoregressive Conditional Heteroskedasticity (GARCH) model, where the parameters of STARIMA are estimated using the Cat Swarm Optimization (CSO) algorithm. Weekly measles case data from eight health sectors in Diyala were used over a period of 130 weeks from January 1, 2023, to July 1, 2025. Preliminary analysis using the Mann–Kendall test revealed the presence of significant temporal trends in all series, indicating non-stationarity, which was corrected by applying first-order differencing. The Moran’s I test confirmed the existence of significant spatial autocorrelation among the sectors, implying that measles transmission follows a spatially dependent pattern. Several STARIMA models with different orders were estimated using CSO and evaluated based on the Akaike Information Criterion (AIC), Bayesian Information Criterion (BIC), and Hannan–Quinn Criterion (HQ). The results showed that the STARIMA model with first-order spatial lag (Lag = 1) provided the best fit. The residuals of the selected STARIMA model were further modeled using a GARCH(1,1) specification, which revealed significant conditional heteroskedasticity, reflecting the volatility associated with epidemic outbreaks. The integration of STARIMA and GARCH enabled a more accurate representation of both the conditional mean and the conditional variance of the measles incidence series, leading to improved short- and medium-term forecasting performance. The</p>

findings demonstrate that the proposed STARIMA–GARCH hybrid model provides a robust and efficient statistical framework for analyzing and forecasting spatio-temporal epidemic data, offering valuable support for public health planning and disease control strategies.

1- المقدمة

تعدّ الأمراض الوبائية ذات الطبيعة المعدية، مثل مرض الحصبة، من أبرز التحديات الصحية التي تواجه المجتمعات، نظرًا لقدرتها العالية على الانتشار وتأثيرها بعوامل متعددة ومتداخلة تشمل الزمن والمكان معًا. ولا يقتصر انتشار هذه الأمراض على البعد الزمني فقط، بل يرتبط أيضًا بالتوزيع الجغرافي للسكان وأنماط الاتصال بين المناطق المتجاورة، الأمر الذي يجعل فهم ديناميكيتها وتحليلها الإحصائي باستخدام النماذج الزمنية التقليدية أمرًا غير كافٍ لتمثيل خصائصها بصورة دقيقة على الرغم من النجاح الواسع الذي حققته نماذج السلاسل الزمنية الكلاسيكية من نوع ARIMA في تحليل البيانات الزمنية، إلا أنها تفترض استقلالية المشاهدات مكانيًا، وهو افتراض لا يتلاءم مع طبيعة الأمراض المعدية التي تنتقل بين المناطق نتيجة التفاعل الجغرافي والحركة السكانية. ومن هنا برزت الحاجة إلى نماذج أكثر تطورًا قادرة على دمج البعدين الزمني والمكاني ضمن إطار إحصائي واحد، وهو ما أدى إلى ظهور نماذج السلاسل الزمنية المكانية بوصفها امتدادًا طبيعيًا لنماذج ARIMA التقليدية.

ويُعدّ نموذج (Space–Time Autoregressive Integrated Moving Average) STARIMA من أهم هذه النماذج، إذ يدمج بين الاعتماد الزمني والمكاني من خلال استخدام مصفوفة الأوزان المكانية لتمثيل درجة الترابط بين المواقع الجغرافية المختلفة. وقد أثبت هذا النموذج كفاءة عالية في نمذجة الظواهر التي تنسم بانتشار زمني متزامن، مثل الأمراض الوبائية، والتلوث البيئي، والظواهر المناخية، لما يوفره من قدرة على توصيف العلاقات المتبادلة بين الزمن والمكان بصورة أكثر واقعية. إلا أن تقدير معاملات نماذج STARIMA يواجه تحديات حسابية كبيرة نتيجة تعدد المعلمات وتداخل التأثيرات الزمانية والمكانية، مما يجعل بعض طرق التقدير التقليدية أقل كفاءة أو غير مستقرة. وفي هذا السياق، برزت خوارزميات التحسين الذكية المستوحاة من الطبيعة، ومن بينها خوارزمية سرب القطط (Cat Swarm Optimization – CSO)، التي تتميز بقدرتها على البحث عن الحلول المثلى في فضاءات معقدة وغير خطية دون الحاجة إلى افتراضات صارمة حول شكل دالة الهدف [8].

ومن ناحية أخرى، غالبًا ما تنسم بيانات الأمراض الوبائية بتقلبات حادة في عدد الإصابات عبر الزمن نتيجة حدوث موجات تفشٍ مفاجئة، مما يؤدي إلى عدم تجانس التباين في سلسلة الأخطاء الناتجة عن النماذج التنبؤية. ويؤثر هذا السلوك على كفاءة النماذج الإحصائية ودقة تنبؤاتها، الأمر الذي يستدعي استخدام نماذج قادرة على توصيف التغير الديناميكي في التباين، مثل نماذج ARCH و GARCH.

وبناءً على ما تقدم، يسعى هذا البحث إلى نمذجة وتحليل السلوك الزمني والمكاني لانتشار مرض الحصبة في محافظة ديالى من خلال بناء نموذج هجين يجمع بين نموذجي STARIMA وخوارزمية سرب القطط في تقدير المعلمات، ونموذج GARCH في توصيف التباين الشرطي لسلسلة الأخطاء، بما يوفر إطارًا إحصائيًا متكاملًا قادرًا على تمثيل ديناميكية انتشار المرض بدقة أعلى.

2-1 مشكلة البحث

تُعدّ نمذجة انتشار الأمراض الوبائية ذات الطبيعة الزمانية المكانية من القضايا الإحصائية المعقدة، لكونها تنسم بوجود ترابط زمني ومكاني متزامن، إضافةً إلى التغير الديناميكي في تباين الإصابات عبر الزمن نتيجة موجات التفشي. وتعاني النماذج الزمنية التقليدية من قصور في تمثيل هذه الخصائص، إذ تهمل البعد المكاني ولا تأخذ عدم تجانس التباين بنظر الاعتبار، مما يؤدي إلى انخفاض دقة التنبؤ. ومن هنا تبرز الحاجة إلى تطوير نموذج إحصائي قادر على توصيف كل من الاعتماد الزمني والمكاني والتغير في التباين، وبصورة خاصة في حالة انتشار مرض الحصبة في محافظة ديالى.

3-1 هدف البحث

يهدف هذا البحث إلى نمذجة وتحليل السلوك الزمني والمكاني لانتشار مرض الحصبة في محافظة ديالى من خلال بناء نموذج هجين يجمع بين نموذجي STARIMA و GARCH، مع اعتماد خوارزمية سرب القطط (CSO) في تقدير معاملات النموذج، وذلك بغرض تحسين توصيف المتوسط والتباين الشرطي لسلسلة الإصابات ورفع كفاءة التنبؤ قصير ومتوسط الأجل، بما يسهم في دعم متخذي القرار الصحي في وضع استراتيجيات وقائية فعالة.

2- السلاسل الزمنية المكانية

تُعرّف السلاسل الزمنية المكانية بأنها النماذج التي تُستخدم لدراسة العلاقات الخطية بين المتغيرات عبر بعدين أساسيين هما الزمن والمكان، حيث تسمح هذه النماذج بتحليل كيفية تطور الظواهر في مواقع جغرافية متعددة عبر الزمن. ويكمن الهدف الرئيس لهذه النماذج في فهم الأنماط الديناميكية للبيانات، والتنبؤ بالقيم المستقبلية، ودعم اتخاذ القرار في المجالات التي تنسم بتداخل التأثيرات الزمنية والمكانية، مثل الصحة العامة، والجغرافية، والعلوم البيئية، والاقتصاد [5][11].

وفي مجال الصحة العامة، تُعدّ السلاسل الزمنية المكانية أداة فعالة لتحليل انتشار الأمراض المعدية، إذ تُمكن الباحث من تتبع انتقال المرض بين المناطق المتجاورة، والكشف عن مناطق الخطر المرتفع، وفهم آليات التفشي الوبائي بطريقة أكثر واقعية مقارنة بالنماذج الزمنية الأحادية البعد.

1-2 نموذج STARIMA

تم تطوير نموذج STARIMA في سبعينيات القرن الماضي على يد الباحثين (Cliff &Ord) [4]، ثم تم توسيعه وتطويره لاحقاً بواسطة (Pfeifer&Deutsch) [8] ليصبح أحد أهم النماذج القياسية في تحليل السلاسل الزمنية المكانية. ويُعد هذا النموذج امتداداً مباشراً لنماذج ARIMA التقليدية، حيث يسمح بإدخال البعد المكاني عبر مصفوفة الأوزان المكانية ضمن البنية الرياضية للنموذج. الصيغة العامة لنموذج STARIMA تُعطى كما يأتي [10]:

$$\phi_{p,\lambda}(B)\nabla^d Z_t = \theta_{q,m}(B)a_t \quad \dots (1)$$

$$\phi_{p,\lambda}(B) = 1 - \sum_{k=1}^p \sum_{l=0}^{\lambda k} \phi_{kl} w_l B^k \quad \dots (2)$$

$$\nabla^d = (1 - B)^d \quad \dots (3)$$

$$\theta_{q,m}(B) = \sum_{k=1}^q \sum_{l=0}^{mk} \theta_{kl} w_l B^k \quad \dots (4)$$

حيث ان :

- Z_t : قيمة السلسلة الزمنية
- ϕ_{kl} : معلمة الانحدار الذاتي عند الزمن k والموقع L
- P : رتبة نموذج الانحدار الذاتي
- λt : رتبة نموذج الانحدار الذاتي المكاني
- W_L : مصفوفة الأوزان
- θ_{kl} : معلمة الاوساط المتحركة عند الزمن k والموقع L
- mk : رتبة نموذج الاوساط المتحركة المكاني
- ∇^d : معلمة الفروق

a_t : متغيرات عشوائية غير مترابطة لها وسط حسابي يساوي صفر وتباين ثابت يطلق عليها اسم الضجّة او الضوضاء البيضاء (White Noise)
 $E[a_i(t)] = 0$

$$E[a_i(t)a_j(t+s)] = \begin{cases} \sigma_a^2 & i = j, s = 0 \\ 0 & otherwise \end{cases} \quad \dots (5)$$

2-2 مصفوفة الوزن المكاني (Spatial Weight Matrix)

تعد مصفوفة الوزن المكاني عنصراً أساسياً في نموذج STARIMA لتمثيل العلاقات المكانية بين مواقع مختلفة. اذ تحدد هذه المصفوفة كيفية تأثير القيم او الاحداث في موقع معين على المواقع الاخرى المجاورة، مما يتيح للنموذج التعامل مع التداخل المكاني والزمني بشكل دقيق. وتعتمد طريقة بناء هذه المصفوفة واستعمالها على طبيعة البيانات والظاهرة المدروسة. اما طريقة كتابتها فهي مصفوفة مربعة وعلى افتراض انه هناك N من المواقع في منطقة الدراسة فان اجمالي الارتباطات المكانية n * n , وان عناصر المصفوفة W_{ij} تعبر عن وزن العلاقة بين الموقع i والموقع j , ويمكن تمثيلها كالآتي [2]:

$$W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1j} \\ w_{21} & w_{22} & \dots & w_{2j} \\ \vdots & \vdots & \ddots & \vdots \\ w_{i1} & w_{i2} & \dots & w_{ij} \end{bmatrix}$$

اذ تُستعمل مصفوفة الأوزان المكانية لتمثيل العلاقات المكانية بين المواقع بدرجات متفاوتة من التأثير، مع إمكانية عكس التغيرات الزمنية أو الاختلافات المكانية في طبيعة هذه العلاقات. ويتم تحقيق ذلك من خلال دمج هذين المفهومين في هياكل نماذج المكان والزمان الحالية، وتتميز هذه المصفوفات بأنها تمكن منسئ الأنموذج من التحكم في عدد المعلمات التي يجب تقديرها. [13]

1-2-2 الشروط العامة لمصفوفة الوزن المكاني [9]

- $W_{ij} \neq 0$ اي ان مصفوفة الاوزان المربعة لها مسار متصل
- $w^{(0)}$ هي مصفوفة الوحدة وتعني ان هناك ارتباطات لجميع المواقع مع بعضها
- يشترط ان يكون مجموع عناصر كل صف مساوياً للواحد الصحيح , ويعني ذلك ان التأثير الكلي للمناطق المجاورة على كل منطقة يكون متوازياً .

3- اختبار Mann-Kendall [7]

ويعتبر اختبار Mann-Kendall اختبار لا معلمي. *non-parametric* يستخدم للكشف عن الاتجاه العام للسلاسل الزمنية دون الحاجة للافتراض بأن البيانات تتبع توزيعاً معيناً. منهجية الاختبار

لنفرض ان لدينا سلسلة زمنية Y_1, Y_2, \dots, Y_n ومن ثم نحسب إحصاء الاختبار S كالآتي

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{Sign}(Y_j - Y_i) \quad \dots (6)$$

اذ ان:

Y : تمثل السلسلة الزمنية

n : طول السلسلة الزمنية

وإذا كان حجم العينة ($n \geq 18$) فإن الاحصاء S تتوزع طبيعياً بمتوسط يساوي صفر، وان التباين يعرف كالآتي:

$$\text{Var}(S) = \frac{n(n-1)(2n+5) - \sum_{i=1}^n t_i i(i-1)(2i+5)}{18} \quad \dots (7)$$

اذ ان:

t_i : تمثل عدد البيانات في المجموعة المرتبطة

m : يمثل عدد مجموعات الرتب المتعادلة

ثم نحسب قيمة Z الاحصائية لاختبار الفرضية والتي تساوي

$$Z = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}} & \text{if } S > 0 \\ 0 & \text{if } S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(s)}} & \text{if } S < 0 \end{cases} \quad \dots (8)$$

فإذا كانت القيمة المطلقة لإحصائه الاختبار المحسوبة Z اكبر من $Z_{\alpha/2}$ فأنا نرفض فرضية العدم (عدم وجود اتجاه) أي ان هناك اتجاهًا في السلسلة وبالتالي هي غير مستقرة، اما اذا كانت القيمة المطلقة لإحصاء الاختبار المحسوبة Z اصغر من $Z_{\alpha/2}$ فأنا نقبل فرضية العدم والتي تدل على عدم وجود مشكله الاتجاه في السلسلة.

4- اختبار موران للكشف عن الترابط المكاني [15]

يعد مقياس موران (Moran's I) أحد أكثر المقاييس شيوعاً في تحليل البيانات المكانية، ويستخدم للكشف عن وجود ترابط مكاني بين القيم الموزعة عبر مناطق جغرافية مختلفة. وتنبع أهمية هذا المقياس من قدرته على تحديد ما إذا كان نمط توزيع الظاهرة المدروسة عشوائياً او يميل الى التجمع او التشتت، مما يساعد الباحث على فهم طبيعة العلاقات المكانية بين عناصر البيانات. وبحسب مقياس موران وفق الصيغة الآتية:

$$I = \frac{N \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{(\sum_{i=1}^n \sum_{j=1}^n w_{ij}) \sum_{i=1}^n (x_i - \bar{x})^2} \quad \dots (9)$$

حيث ان:

N : عدد الوحدات المكانية (المواقع)

X_i : قيمة المتغير في الموقع i

X_j : قيمة المتغير في الموقع j

\bar{x} : المتوسط الحسابي لقيم المتغير

W_{ij} : مصفوفة الوزن المكانية

5- التقدير باستخدام خوارزمية سرب القطط [1][3]

ويمكن تلخيص خطوات سرب القطط كالآتي:

- (1) في هذه الخطوة يتم إنشاء N من سرب القطط i حيث ان $i=1,2,\dots,n$
- (2) نقوم بتوزيع سرب القطط بشكل عشوائي في مساحة الحل M الأبعاد، والتي تكون في نطاق السرعة القصوى، ثم نختار بشكل عشوائي عدداً من القطط لتعيينها في نمط التتبع ووضع الأخرى في وضع البحث لتكوين خوارزمية MR
- (3) نقوم بتقييم قيمة اللياقة البدنية لكل قطة من خلال تطبيق أوضاع القطط في وظيفة اللياقة البدنية، والتي تمثل معيار هدفنا ومن ثم نحتفظ بأفضل قطة في الذاكرة.

4) في هذه الخطوة يتم تحريك سرب القطط وفقا لأعلامها ، إذا كانت القط في وضع البحث ، فيتم تطبيق القطعة على عملية نمط البحث ، غير ذلك فيتم تطبيقها على عملية نمط التتبع.

5) ثم يتم إعادة اختيار عدد من سرب القطط ونقم بتعيينها في وضع التتبع وفعال MR ، ثم ايتم ضبط القطط الأخرى في وضع البحث.

ويتم تكرار الخطوات من الخطوة 3 الى الخطوة 5 وعند الوصول للحل ، نقم بإنهاء البرنامج بعد التأكد من شرط الإنهاء

6- المعايير المعلوماتية لتحديد الرتبة:

1-6 معيار أكاي للمعلومات [12] Akaike Information Criterion (AIC)

يعد هذا العيار أحد أقدم وأشهر المعايير ، طور بواسطة *Hirotsugu Akaike* في 1974 ، ويستخدم بكثرة في النماذج الزمانية والمكانية. ويمكن كتابة صيغته كالآتي:

$$AIC(P) = n \ln \hat{\sigma}_a^2 + 2P \quad \dots (10)$$

اذ ان:

$AIC(P)$: تمثل معلومات معيار أكاي

P : تمثل إجمالي عدد المعلمات المقترنة مكانيا وزمانيا

n : تمثل عدد المشاهدات

$\hat{\sigma}_a^2$: يمثل تقدير خطأ تباين الأنموذج

2-6 معيار بيز للمعلومات [12] Bayesian Information Criterion (BIC)

الذي اقترحه لأول مره هو الباحث الاحصائي *Gideon Schwarz* في 1978 اذ اعتمد الباحث على الاحتمالية البيزية، ويمكن كتابة صيغته كالآتي:

$$BIC(p) = n \ln \hat{\sigma}_a^2 + p \ln(n) \quad \dots (11)$$

اذ ان:

$BIC(p)$: يمثل معلومات معيار بيز

3-6 معيار حنان – كوين [12] Hannan – Quinn Criterion (HQ)

وهو معيار ثالث قدمه الباحثان *E. J. Hannan* و *B. G. Quinn* سنة 1979 في بحثهم الكلاسيكي عن تحديد رتبة الانحدار الذاتي (AR)، ويمكن كتابة صيغته كالآتي:

$$HQ(P) = n \ln \hat{\sigma}_a^2 + 2p C \ln(\ln n)/n \quad c > 2 \quad \dots (12)$$

اذ ان:

$HQ(P)$: يمثل معيار حنان – كوين

C : هو ثابت ويسمى ثابت عقوبة. الباحثان اثبتا ان شرط اللازم للاتساق هو ان $C = 1$

7- نماذج GARCH

تُعد نماذج التباين الشرطي غير المتجانس ($GARCH$) من النماذج المهمة في تحليل السلاسل الزمنية التي تعاني من عدم ثبات التباين عبر الزمن، وهي مشكلة شائعة في البيانات الحقيقية، لا سيما البيانات الاقتصادية والوبائية. وقد طُوّرت هذه النماذج كامتداد لنماذج $ARCH$ التي قدمها *Engle*، وذلك لمعالجة القيود التي تعاني منها نماذج $ARCH$ عند استخدام رتب عالية. [14]

1-7 تشخيص عدم تجانس التباين [14]

قبل تطبيق نماذج $GARCH$ ، لا بد من التحقق من وجود مشكلة عدم تجانس التباين في بواقي الأنموذج الزمني، إذ تُعد هذه الخطوة أساسية لتبرير استخدام هذا النوع من النماذج. وتوجد عدة اختبارات إحصائية تُستخدم لهذا الغرض، من أهمها:

• اختبار $ARCH-LM$ (Engle's ARCH Test):

يُعد من أكثر الاختبارات شيوعاً، ويهدف إلى الكشف عن وجود ارتباط ذاتي في مربعات البواقي، إذ يشير رفض فرضية العدم إلى وجود عدم تجانس في التباين.

• اختبار $Ljung-Box$ لمربعات البواقي:

يُستخدم لاختبار استقلالية مربعات البواقي، ويدل وجود ارتباط معنوي فيها على عدم ثبات التباين عبر الزمن.

وفي حال أظهرت هذه الاختبارات دلالة إحصائية، فإن ذلك يشير إلى ملاءمة استخدام نماذج $GARCH$ لمعالجة هذه المشكلة

2-7 الصيغة العامة لأنموذج $GARCH(p, q)$ [6]

و تُعرف المعادلات على النحو التالي:

$$y_t = \phi x_t + \mu_t, \quad \mu_t \sim N(0, \sigma_t^2) \quad \dots (13)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \mu_{t-i}^2 + \sum_{i=1}^q \beta_i \sigma_{t-i}^2 \quad \dots (14)$$

حيث أن :

- y_t : السلسلة الزمنية عند الزمن t
- ϕ : معامل الانحدار
- x_t : قيم المشاهدات للسلسلة الزمنية y_t
- μ_t : حد الخطأ العشوائي عند الزمن t ، والذي يتبع توزيعاً طبيعياً
- σ_t^2 : التباين الشرطي لحد الخطأ عند الزمن t
- ω : ثابت موجي يمثل الحد الأساسي للتباين الشرطي
- α_i : معاملات تأثير مربعات الأخطاء السابقة
- β_i : معاملات تأثير التباين الشرطي السابق على التباين الحالي
- μ_{t-i}^2 : مربع حد الخطأ عند الإزاحة الزمنية i
- σ_{t-i}^2 : التباين الشرطي عند الإزاحة الزمنية السابقة
- p : عدد مربعات الأخطاء السابقة
- q : عدد التباينات الشرطية السابقة

3-7 أنموذج $GARCH(1,1)$ [6]

يُعد أنموذج $GARCH(1,1)$ من أكثر النماذج شيوعاً في التطبيقات العملية، ويكتب بالشكل:

$$\sigma_t^2 = \omega + \alpha \mu_{t-1}^2 + \beta \sigma_{t-1}^2 \quad \dots (12)$$

ويشترط أن $\alpha + \beta < 1$ لضمان استقرارية التباين .

8- مصدر البيانات

تم الحصول على بيانات مرض الحصبة من وزارة الصحة العراقية – دائرة صحة ديالى – قسم الأمراض الانتقالية، وتمثل هذه البيانات السجلات الرسمية المعتمدة لعدد الإصابات في محافظة ديالى خلال مدة الدراسة.

8-1 وصف البيانات

تمثل البيانات سلسلة زمنية مكانية أسبوعية لمرض الحصبة، تم جمعها خلال مدة 130 أسبوعاً، ابتداءً من 1 كانون الثاني 2023 ولغاية 1 تموز 2025، وشملت ثماني مناطق (قطاعات) صحية في محافظة ديالى:

قطاع الخالص، قطاع المقدادية، قطاع بعقوبة الأول، قطاع بعقوبة الثاني، قطاع بلدروز، قطاع جلولاء، قطاع خانقين، قطاع المنصورية.

وقد تم اختيار هذه القطاعات اعتماداً على التقارب الجغرافي فيما بينها، نظرًا لأهمية البعد المكاني في تفسير أنماط انتشار مرض الحصبة بين المناطق المتجاورة

ولغرض إعطاء تصور أولي عن خصائص البيانات، تم حساب مجموعة من المؤشرات الإحصائية الوصفية لكل قطاع، كما هو موضح في الجدول (1).

الجدول (1): المؤشرات الإحصائية للبيانات الزمانية المكانية لمرض الحصبة في قطاعات محافظة ديالى

ت	المنطقة او القطاع	الوسط الحسابي	الوسيط	الانحراف المعياري	الالتواء	التقلطح
1	قطاع الخالص	9.3386	1	15.029	1.6875	4.4144
2	قطاع المقدادية	5.189	1	10.387	2.4443	7.8073
3	قطاع بعقوبة الاول	11.622	5	16.22	1.6424	4.6879
4	قطاع بعقوبة الثاني	11.283	2	19.173	2.176	6.8749
5	قطاع بلدروز	3.8976	1	5.8674	1.7708	5.2328
6	قطاع جلولاء	2.9921	1	5.1908	2.281	7.4005
7	قطاع خانقين	1.189	0	1.9179	1.9047	6.0554
8	قطاع المنصورية	0.7874	0	1.4289	2.4588	9.2772

تُظهر نتائج الجدول (1) وجود تباين واضح في المتوسطات الحسابية بين القطاعات المختلفة، حيث سجل كل من قطاع بعقوبة الأول وقطاع بعقوبة الثاني أعلى متوسط لعدد الإصابات مقارنة ببقية المناطق، مما يشير إلى كونهما من أكثر المناطق تعرضاً لتفشي المرض خلال مدة الدراسة. كما نلاحظ أن الوسط الحسابي أكبر من الوسيط في معظم القطاعات، مما يدل على أن توزيع الإصابات يميل إلى الانحراف الموجب، وهو ما تؤكد قيم معامل الالتواء الموجبة في جميع المناطق.

أما الانحراف المعياري، فقد كشف عن تفاوت كبير في درجة التذبذب الزمني للإصابات بين القطاعات، إذ كانت التقلبات أعلى في بعقوبة والخالص مقارنة بمناطق مثل خانقين والمنصورية. كذلك فإن قيم التفرطح المرتفعة في أغلب القطاعات تعكس وجود قمم حادة وذيول ثقيلة في التوزيع، وهي سمة شائعة في بيانات الأمراض الوبائية نتيجة حدوث موجات تفشٍ مفاجئة.

2-8 اختبار Mann-Kendall للكشف عن الاتجاه العام

بعد توصيف البيانات إحصائياً، يصبح من الضروري فحص وجود اتجاه عام (Trend) في السلاسل الزمنية المكانية لإصابات مرض الحصبة، لأن وجود اتجاه يعني أن السلسلة غير مستقرة زمنياً، وهو ما يتطلب إجراء عمليات تحويل قبل تطبيق نموذج STARIMA. ولهذا الغرض، تم اعتماد اختبار Mann-Kendall بوصفه أحد أكثر الاختبارات اللا معلمية شيوعاً للكشف عن الاتجاه في السلاسل الزمنية

تم صياغة فرضيتي الاختبار كما يأتي:

H_0 : لا يوجد اتجاه عام في السلسلة

H_1 : يوجد اتجاه عام في السلسلة

وقد تم حساب إحصائية الاختبار وقيمة الاحتمال لكل قطاع من قطاعات محافظة ديالى، وكانت النتائج كما موضحة في الجدول (2).

الجدول (2): نتائج اختبار Mann-Kendall قبل أخذ الفرق

ت	المنطقة او القطاع	Z	p-value	Trend Significance
1	قطاع الخالص	-3.3295	0.00086995	Significant
2	قطاع المقدادية	-2.8355	0.0045749	Significant
3	قطاع بعقوبة الاول	-7.1263	1.0314e-12	Significant
4	قطاع بعقوبة الثاني	-4.2867	1.8136e-05	Significant
5	قطاع بلدروز	-6.0702	1.2778e-09	Significant
6	قطاع جلولاء	-4.2536	2.1036e-05	Significant
7	قطاع خانقين	-5.1333	2.8466e-07	Significant
8	قطاع المنصورية	-4.8722	1.1037e-06	Significant

تشير نتائج الجدول (2) إلى أن جميع القيم كانت أصغر من مستوى الدلالة ، كما أن القيم المطلقة لإحصائية z كانت أكبر من القيمة الجدولية ، مما يعني رفض فرضية العدم وقبول الفرضية البديلة ، أي أن جميع السلاسل الزمنية المكانية تحتوي على اتجاه عام معنوي، وبالتالي فهي غير مستقرة زمنيًا.

3-8 تحقيق الاستقرار باستخدام الفرق الأول

لإزالة الاتجاه العام وتحقيق الاستقرار، تم أخذ الفرق الأول للسلاسل الزمنية المكانية

وبعد ذلك، أُعيد تطبيق اختبار Mann-Kendall على السلاسل بعد الفرق للتحقق من زوال الاتجاه، كما هو موضح في الجدول (3).

الجدول (3): نتائج اختبار Mann-Kendall بعد أخذ الفرق الأول

ت	المنطقة او القطاع	Z	p-value	Trend
1	قطاع الخالص	-0.31055	0.75614	Not Significant
2	قطاع المقدادية	-0.043739	0.96511	Not Significant
3	قطاع بعقوبة الاول	-0.006598	0.99474	Not Significant
4	قطاع بعقوبة الثاني	-0.034973	0.97210	Not Significant
5	قطاع بلدروز	0.19884	0.84239	Not Significant
6	قطاع جلولاء	-0.057784	0.95392	Not Significant
7	قطاع خانقين	-0.75381	0.45096	Not Significant
8	قطاع المنصورية	0.087837	0.93001	Not Significant

تُظهر نتائج الجدول (3) أن جميع قيم أصبحت أكبر من مستوى الدلالة ، كما أن قيم أصبحت أقل من القيمة الجدولية ، مما يعني قبول فرضية العدم التي تنص على عدم وجود اتجاه عام في السلسلة، وبذلك تصبح البيانات مناسبة لتقدير أنموذج STARIMA بدرجة فرق.

4-8 اختبار موران

وبعد التأكد من استقرار السلاسل الزمنية المكانية زمنيًا، أصبح من الضروري اختبار وجود اعتماد مكاني بين قطاعات محافظة ديالى، أي التحقق مما إذا كانت إصابات الحصبة في قطاع معين تتأثر بإصابات القطاعات المجاورة له. ولهذا الغرض، تم استخدام مقياس موران (Moran's I)، إذ يتم اختبار معنوية هذا المقياس باستخدام إحصائية وفق الفرضيتين:

H_0 : لا يوجد ارتباط ذاتي مكاني

H_1 : يوجد ارتباط ذاتي مكاني

وقد أسفرت نتائج الاختبار عن القيم الموضحة في الجدول (4).

الجدول (4): نتائج اختبار موران للترابط المكاني

I	E(I)	V(I)	Zcal	Ztab
0.38922	-0.14286	0.027354	3.2171	1.96

تُظهر نتائج الجدول (4) أن قيمة أكبر من القيمة الجدولية عند مستوى معنوية ، مما يؤدي إلى رفض فرضية العدم وقبول الفرضية البديلة ، أي أن بيانات إصابات الحصبة في قطاعات محافظة ديالى تُظهر ترابطًا مكانيًا معنويًا، وهو ما يبرر استخدام أنموذج STARIMA الذي يأخذ البعد المكاني بنظر الاعتبار.

5-8 تحديد رتبة أنموذج STARIMA باستعمال خوارزمية سرب القطط

لتحديد رتبة أنموذج STARIMA من الشكل ، تم فحص مجموعة من النماذج ذات الرتب المختلفة، اعتمادًا على البيانات المستقرة بعد أخذ الفرق الأول . وقد أُجريت عملية التقدير باستخدام خوارزمية سرب القطط (Cat Swarm Optimization – CSO) من خلال برنامج حاسوبي بلغة MATLAB ، حيث استُخدمت دالة الهدف المبنية على تقليل معايير المفاضلة الإحصائية، وهي معيار أكايكي (AIC) ، ومعيار شوارتز البيزي (BIC) ، ومعيار هانان-كروين (HQ) .

وقد أُجريت المقارنات بين نماذج STARIMA في حالتين:

وجود ترابط مكاني وعدم وجود ترابط مكاني ، كما هو موضح في الجدولين (5) و(6).

الجدول (5): مقارنة نماذج STARIMA عند وجود ترابط مكاني (Lag = 1) باستخدام CSO

P	d	Q	AIC	BIC	H-Q
0	1	1	16472.069	16481.901	16475.804
0	1	2	16432.612	16452.275	16440.082
0	1	3	15391.522	15421.017	15402.728
1	1	0	17427.815	17437.647	17431.550
1	1	1	16469.840	16489.503	16477.311
1	1	2	15525.404	15554.899	15536.610
1	1	3	15040.357	15079.682	15055.297
2	1	0	15939.426	15959.089	15946.896
2	1	1	15925.997	15955.492	15937.203
2	1	2	14971.157	15010.483	14986.098
2	1	3	14655.246	14704.404	14673.922
3	1	0	15769.349	15798.843	15780.554
3	1	1	15207.841	15247.167	15222.782
3	1	2	14633.469	14682.626	14652.145
3	1	3	14784.012	14843.001	14806.423

الجدول (6): مقارنة نماذج STARIMA عند عدم وجود ترابط مكاني (Lag = 0) باستخدام CSO

P	d	Q	AIC	BIC	H-Q
0	1	1	17194.692	17199.608	17196.560
0	1	2	17152.478	17162.309	17156.213
0	1	3	15698.956	15713.704	15704.559
1	1	0	17694.770	17699.686	17696.638
1	1	1	17194.704	17204.535	17198.439
1	1	2	16086.223	16100.970	16091.826

1	1	3	15326.456	15346.118	15333.926
2	1	0	16601.862	16611.693	16605.597
2	1	1	16538.901	16553.648	16544.503
2	1	2	15627.818	15647.481	15635.288
2	1	3	15308.884	15333.463	15318.222
3	1	0	16427.904	16442.651	16433.507
3	1	1	15869.450	15889.113	15876.920
3	1	2	15349.575	15374.154	15358.913
3	1	3	15291.450	15320.944	15302.655

ولغرض اختيار الأنموذج الأمثل، تمت مقارنة أفضل أنموذجين ناتجين عن الحالتين السابقتين باستخدام معايير المفاضلة الإحصائية، كما هو موضح في الجدول (7).

الجدول (7): مقارنة أفضل أنموذجين مقدرين

STARIMA Models	AIC	BIC	HQ
<i>STARIMA</i> (3 ₁ , 1, 2 ₁)	14633.469	14682.626	14652.145
<i>STARIMA</i> (3 ₀ , 1, 3 ₀)	15291.450	15320.944	15302.655

تشير نتائج الجدول (7) إلى أن الأنموذج الذي يأخذ البعد المكاني بنظر الاعتبار حقق قيماً أقل لمعايير AIC و BIC و HQ مقارنة بالأنموذج الذي يهمل البعد المكاني، مما يدل على أن إدخال البنية المكانية في أنموذج STARIMA يُحسن من ملاءمة الأنموذج للبيانات المدروسة ويؤكد أن انتشار مرض الحصبة في محافظة ديالى يتم وفق نمط ز مكاني مترابط.

6-8 تقدير معاملات الأنموذج باستخدام خوارزمية سرب القطط (COS)

بعد تحديد رتب الأنموذج الزمني المكاني، وتشخيصه بناءً على المعايير الإحصائية المذكورة أعلاه، ومن أجل الحصول على تقديرات مثالية لمعاملات الأنموذج الأفضل، يتم تقدير معاملات الأنموذج *STARIMA*(3₁,1,2₁) باستخدام خوارزمية سرب القطط (COS). كما هو موضح في الجدول (8)

الجدول (8): تقدير معاملات الأنموذج باستخدام خوارزمية سرب القطط (COS)

Parameter	Estimate	Std. Error	p-Value
ϕ_{10}	0.39	0.03	0.00
ϕ_{11}	0.59	0.04	0.00
ϕ_{20}	-0.21	0.02	0.00
ϕ_{21}	-0.20	0.02	0.00
ϕ_{30}	0.20	0.01	0.00
ϕ_{31}	-0.02	0.02	0.24
θ_{10}	0.85	0.04	0.00
θ_{11}	0.45	0.04	0.00
θ_{20}	-0.27	0.03	0.00
θ_{21}	-0.40	0.03	0.00

وضح الجدول نتائج تقدير معاملات نموذج STARIMA باستخدام خوارزمية سرب القطط (CSO)، حيث تبين أن أغلب المعلمات كانت معنوية إحصائياً عند مستوى معنوية (0.05)، مما يدل على كفاءة الخوارزمية في تقدير معاملات النموذج. في المقابل، ظهرت المعلمة ϕ_{31} غير معنوية إحصائياً، الأمر الذي أخذ بنظر الاعتبار عند تقييم ملاءمة النموذج

7-8 تحليل البواقي

لغرض تقييم ملاءمة النموذج المقدر والتحقق من صحة افتراضاته، تم إجراء تحليل تشخيصي لبواقي النموذج باستخدام عدد من الاختبارات الإحصائية، وتُعرض نتائج هذه الاختبارات في الجدول (9).

الجدول (9): جدول تحليل البواقي

الاختبار	احصاءة الاختبار	p-Value	القرار عند مستوى معنوية 0.05	التفسير
Ljung-Box (lag = 20)	526.04	0.00	رفض H_0	وجود ارتباط ذاتي معنوي في البواقي
Jarque-Bera	132 815.97	0.00	رفض H_0	البواقي لا تتبع التوزيع الطبيعي
ARCH-LM (lag = 5)	117.27	0.00	رفض H_0	وجود مشكلة عدم تجانس التباين
Moran's I	0.46	0.00	رفض H_0	وجود ارتباط ذاتي مكاني في البواقي

يوضح الجدول (9) نتائج اختبارات تحليل بواقي النموذج المقدر، وتشير نتائج اختبار Ljung-Box إلى وجود ارتباط ذاتي معنوي في البواقي، مما يدل على أن البواقي ليست مستقلة زمنياً. كما أظهر اختبار Jarque-Bera أن البواقي لا تتبع التوزيع الطبيعي. بالإضافة إلى ذلك، بين اختبار ARCH-LM وجود أثر ARCH، مما يشير إلى عدم تجانس التباين في البواقي، وهو ما يؤكد أن تباين الأخطاء يتغير عبر الزمن. كما أظهر اختبار Moran's I وجود ارتباط ذاتي مكاني معنوي في البواقي، مما يدل على أن التأثيرات المكانية لم تُلتقط بالكامل بواسطة النموذج.

وبناءً على هذه النتائج، يتضح أن النموذج المقدر لا يحقق جميع الافتراضات الإحصائية المطلوبة، مما يستدعي استخدام نموذج أكثر ملاءمة، مثل النموذج الهجين STARIMA-GARCH، لمعالجة مشكلة عدم تجانس التباين وتحسين كفاءة النموذج.

8-8 معالجة مشكلة عدم تجانس التباين باستخدام نماذج GARCH

أظهرت نتائج اختبارات تحليل البواقي وجود مشكلة عدم تجانس التباين والتي تُعد من المشكلات الشائعة في السلاسل الزمانية، خاصة في البيانات التي تتسم بالتقلبات العالية. ولمعالجة هذه المشكلة، تم الاستعانة بنماذج الانحدار الشرطي الذاتي للتباين من نوع GARCH، لما لها من قدرة عالية على نمذجة التباين المتغير مع الزمن.

ولمعالجة هذه المشكلة، تم توظيف البواقي في نماذج GARCH بعدة رتب مختلفة. ولغرض اختيار النموذج الأمثل، تمت مقارنة النماذج المقترحة باستعمال معايير المعلومات (AIC، BIC، HQ)، حيث يُعد النموذج الذي يحقق أقل قيمة لهذه المعايير هو النموذج الأفضل.

الجدول (10): نتائج مقارنة نماذج GARCH المقترحة

Models	AIC	BIC	HQ
GARCH(1,1)	2.964207	2.984124	2.96424
GARCH(2,1)	2.969247	2.994154	2.969298
GARCH(1,2)	2.969023	2.99393	2.969075
GARCH(2,2)	2.968803	2.998704	2.968877

تبرز نتائج الجدول (10) أن نموذج GARCH(1,1) قد حقق أقل قيم لمعايير المفاضلة (AIC، BIC، HQ) مقارنةً ببقية النماذج المقترحة، مما يشير إلى تفوقه من حيث جودة الملاءمة الإحصائية. وبناءً على ذلك، تم اعتماد نموذج GARCH(1,1) بوصفه النموذج الأفضل لمعالجة مشكلة عدم تجانس التباين في بواقي النموذج.

وبعد تحديد النموذج الأفضل من نماذج GARCH اعتماداً على معايير المعلومات (AIC، BIC، HQ)، تم تقدير معاملات نموذج GARCH(1,1) المختار، وذلك لغرض التأكد من معنوية المعلمات والتحقق من ملاءمة النموذج إحصائياً، كما هو موضح في الجدول (11).

الجدول (11): تقدير معاملات النموذج الأفضل GARCH(1,1)

Significance	p-Value	الخطأ المعياري	التقدير	المعلمة
**	0.001939	0.00078535	0.00243409	ω
***	(< 0.001)	0.03580154	0.43437288	α_1
***	(< 0.001)	0.02482398	0.56462712	β_1
***	(< 0.001)	0.14165350	3.28379446	Shape ν

ملاحظة: تشير الرموز (*), (**), (***) إلى مستويات المعنوية الإحصائية، حيث يدل

(*) على المعنوية عند مستوى دلالة 0.05،

(**) على المعنوية عند مستوى دلالة 0.01،

(***) على المعنوية عند مستوى دلالة 0.001

يتضح من الجدول (11) أن جميع معاملات أنموذج GARCH(1,1) كانت معنوية إحصائياً عند مستويات دلالة مختلفة، إذ إن قيم الاحتمال (p-value) أقل من 0.05، مما يشير إلى كفاءة الأنموذج في توصيف التباين الشرطي لبواقي الأنموذج. كما نلاحظ أن مجموع معاملي الاستجابة للصدمات السابقة والتباين السابق أقل من الواحد الصحيح، الأمر الذي يدل على استقرارية التباين الشرطي للأنموذج. إضافة إلى ذلك، كان معامل الشكل معنوياً، مما يشير إلى أن توزيع الأخطاء يتميز بذيول سميكة، وهو ما يتلاءم مع طبيعة البيانات المدروسة.

وبعد التأكد من معنوية معاملات أنموذج GARCH(1,1) واستقرارية التباين الشرطي للأنموذج، تم إجراء مجموعة من اختبارات تشخيص البواقي للتحقق من مدى كفاءة الأنموذج بعد نمذجة التباين، وذلك كما موضح في الجدول (12).

الجدول (12): اختبارات خيص بواقي الأنموذج بعد نمذجة GARCH(1,1)

الاختبار	احصاءة الاختبار	p-Value	القرار عند مستوى معنوية 0.05	التفسير
Ljung-Box (lag = 20)	11.7621	0.3013	عدم رفض H_0	عدم وجود ارتباط ذاتي
ARCH-LM (lag = 5)	0.9049	0.9699	عدم رفض H_0	عدم وجود عدم تجانس تباين

يتضح من الجدول (12) أن بواقي الأنموذج بعد تطبيق أنموذج GARCH(1,1) لا تعاني من مشكلات إحصائية، إذ تشير نتائج اختبار Ljung-Box إلى عدم وجود ارتباط ذاتي في البواقي، كما أظهرت نتائج اختبار ARCH-LM اختفاء مشكلة عدم تجانس التباين، مما يدل على كفاءة أنموذج GARCH في معالجة المشكلات التي ظهرت في بواقي الأنموذج الأصلي.

وبناءً على ذلك، يمكن القول إن الأنموذج المركب STARIMA-GARCH كان ملائماً إحصائياً وقادراً على توصيف كل من المتوسط والتباين للبيانات المدروسة.

9- الاستنتاجات والتوصيات

1-1 الاستنتاجات

1- أظهرت بيانات مرض الحصبة في محافظة ديالى وجود اتجاه زمني غير مستقر في جميع القطاعات الصحية، وهو ما تم إثباته باستخدام اختبار Mann-Kendall، مما استلزم أخذ الفرق الأول لتحقيق الاستقرار اللازمة لتقدير أنموذج STARIMA.

2- أثبت اختبار موران وجود ترابط مكاني معنوي بين قطاعات محافظة ديالى، مما يدل على أن انتشار مرض الحصبة في أي قطاع يتأثر بالقطاعات المجاورة، ويبرر استخدام النماذج الزمانية المكانية بدلاً من النماذج الزمنية التقليدية.

3- أظهرت نتائج المقارنة بين نماذج STARIMA أن النماذج التي تأخذ البعد المكاني (Lag = 1) تحقق أداءً أفضل من النماذج التي تهمله، وفقاً لمعايير AIC وHQ، مما يؤكد أهمية إدخال البنية المكانية في نمذجة الأمراض الوبائية.

4- أثبتت خوارزمية سرب القطط (CSO) كفاءتها العالية في تقدير معاملات أنموذج STARIMA، نظراً لقدرتها على التعامل مع المسائل متعددة المعلمات وغير الخطية بكفاءة أعلى من طرائق التقدير التقليدية.

5- أظهرت سلسلة البواقي وجود تغير ديناميكي في التباين عبر الزمن، وهو ما استدعى استخدام أنموذج GARCH لتمثيل هذا السلوك، مما حسن من توصيف عدم اليقين المرتبط بتنبؤات الأنموذج.

6- إن دمج STARIMA مع GARCH ضمن أنموذج هجين واحد أتاح توصيفاً أدق لكل من المتوسط الشرطي والتباين الشرطي لسلسلة إصابات الحصبة، مما يجعل الأنموذج المقترح مناسباً للتنبؤ قصير ومتوسط الأجل.

2-9 التوصيات

- 1- اعتماد الأنموذج الهجين STARIMA–GARCH من قبل دائرة صحة ديالى في تحليل ومراقبة تطور إصابات الحصبة.
- 2- إنشاء نظام إنذار مبكر يعتمد على مخرجات الأنموذج للتنبؤ بموجات التفشي المحتملة.
- 3- دمج نظم المعلومات الجغرافية (GIS) مع نماذج STARIMA لإنتاج خرائط ديناميكية لانتشار المرض.
- 4- توسيع تطبيق هذا الإطار المنهجي ليشمل أمراضاً وبائية أخرى.
- 5- استخدام خوارزميات تحسين إضافية مستقبلاً للمقارنة مع CSO وتحسين دقة النماذج.

تضارب المصالح

لا يوجد أي تضارب في المصالح.

الموافقة على النشر

"لقد قرأنا ووافقنا على النسخة النهائية من المخطوطة للنشر".

توافر البيانات والمواد

جميع البيانات قد تم تضمينها ضمن المخطوطة.

مساهمات المؤلفين

أ.هـ. تنفيذ الدراسة، وكتابة المقال.

ف.أ. تصميم الفكرة وتحليل النتائج

التمويل

لا يوجد أي جهة ممولة للبحث، سواء كانت شركة أو مؤسسة أو منظمة.

الشكر والتقدير

شكر لكل الأشخاص أو المؤسسات التي قدّمت لنا مساعدة علمية أو مادية في إنجاز الدراسة وكتابة المقال.

المراجع

- [1] Ahmed, A. M., Rashid, T. A., & Saeed, S. M. (2021). Dynamic Cat Swarm Optimization algorithm for backboard wiring problem. *Neural Computing and Applications*, 33(20), 13981–13997.
- [2] Cheng, T., & Wang, J. (2014). A dynamic spatial weight matrix and localized space-time autoregressive integrated moving average model for traffic flow forecasting. *Geographical Analysis*, 46(2), 112–132
- [3] Chu, S.-C., Tsai, P.-W., & Pan, J.-S. (2006). Cat swarm optimization. In *Proceedings of the Pacific Rim International Conference on Artificial Intelligence (PRICAI 2006)* (pp. 854–858). Springer.
- [4] Cliff, A. D., & Ord, J. K. (1975). Space-time modeling with an application to regional forecasting. *Transactions of the Institute of British Geographers*, 66, 119–128.
- [5] Congdon, P. (2022). A spatio-temporal autoregressive model for monitoring and predicting COVID infection rates. *Journal of Geographical Systems*, 24(4), 583–610.
- [6] Engle, R. (2001). GARCH 101: The use of ARCH/GARCH models in applied econometrics. *Journal of Economic Perspectives*, 15(4), 157–168.
- [7] Kundu, A., Chatterjee, S., Dutta, D., & Siddiqui, A. R. (2015). Meteorological trend analysis in Western Rajasthan using GIS and statistical techniques. *Journal of Environment and Earth Science*, 5(5), 90–99.

- [8] Pfeifer, P. E., & Deutsch, S. J. (1980). A three-stage iterative procedure for space-time modeling. *Technometrics*, 22(1), 35–47.
- [9] Pfeifer, P. E., & Deutsch, S. J. (1980). A STARIMA model-building procedure with application to description and regional forecasting. *Transactions of the Institute of British Geographers*, 5(3), 330–349.
- [10] Rathod, S., Gurung, B., Singh, K. N., & Ray, M. (2018). An improved STARMA model for modeling and forecasting spatio-temporal time-series data. *Journal of the Indian Society of Agricultural Statistics*, 72(3), 239–253.
- [11] Sakizadeh, M., Mohamed, M. M. A., & Klammler, H. (2019). Trend analysis and spatial prediction of groundwater levels. *Water Resources Management*, 33(4), 1425–1437.
- [12] Saummer, M. & Picard, R. W. (1996). Temporal texture modelling. In *Proceedings of the 3rd IEEE International Conference on Image Processing* (Accession No. 5780039). IEEE.
- [13] Sukarna, S., Syarif, N. F., Sanusi, W., Aswi, A., Abdy, M., & Irwan, I. (2023). Estimating and forecasting COVID-19 cases using GSTARIMA. *Media Statistika*, 15(2), 186–197.
- [14] Volatility analysis based on GARCH-type models. (2021). *Cogent Economics & Finance*.
- [15] Wang, R.-N., Zhang, Y.-C., Yu, B.-T., He, Y.-T., Li, B., & Zhang, Y.-L. (2022). Spatio-temporal evolution of infectious diseases in China. *BMC Public Health*, 22(1), 1208.