

تطبيق نماذج السلاسل الزمنية للتنبؤ بإجمالي مرتكبي جرائم الجنايات في دولة الكويت

طارق عبد العزيز الدوب*

dr.tareq9733@gmail.com

الملخص

تُعَدُّ طرق تحليل السلاسل الزمنية من الأساسيات الهامة في تطوير استراتيجيات التخطيط الأمني، خاصة في مجال مكافحة الجريمة والوقاية منها، حيث تساهم هذه الطرق في دعم عمليات اتخاذ القرارات الأمنية بشكل فعال. يهدف هذا البحث إلى دراسة تطبيق نماذج السلاسل الزمنية، مع التركيز على نموذج ARIMA، للتنبؤ بإجمالي مرتكبي جرائم الجنايات في دولة الكويت. اعتمد البحث على البيانات السنوية الصادرة عن مركز البحوث والدراسات التابع لوزارة الداخلية الكويتية، والتي تغطي الفترة من 1992 إلى 2022. تم تقييم أداء نماذج ARIMA المختلفة باستخدام معيار معامل التحديد (R-squared)، معيار معلومات بيزيان الموحد (NBIC)، ومعيار متوسط جذر مربع الخطأ (RMSE)، وخلصت الدراسة إلى أن النموذج الأمثل هو ARIMA (1,0,0). وبناءً على هذا النموذج، تم التنبؤ بإجمالي مرتكبي جرائم الجنايات خلال الفترة من 2023 حتى 2030.

الكلمات المفتاحية: الكويت، التنبؤ، مرتكبي جرائم الجنايات، نموذج ARIMA.

* أستاذ الإحصاء المشارك، أكاديمية سعد العبد الله للعلوم الأمنية، الكويت.

تاريخ قبول البحث: 2025/12/2 م.

تاريخ تقديم البحث: 2025/8/15.

© جميع حقوق النشر محفوظة لجامعة مؤتة، الكرك، المملكة الأردنية الهاشمية، 2025 م.

Forecasting the overall number of felony offenders in the State of Kuwait using time series models

Tareq Abdul-Aziz Aldoub*

dr.tareq9733@gmail.com

Abstract

Time Series Analysis Techniques are fundamental in developing effective strategies for security planning, particularly in the field of crime prevention and control, as these methods significantly support security decision-making processes. This study aims to explore the application of time series models, with a focus on the ARIMA model, to forecast the total number of felony offenders in the State of Kuwait. The researcher relies on annual data published by the Research and Studies Center of Kuwait Ministry of Interior, covering the period from 1992 to 2022. The performance of various ARIMA models was evaluated using R-squared, Bayesian Information Criterion – Normalized (NBIC), and Root Mean Squared Error (RMSE) criteria. The study concluded that the optimal model is ARIMA (1,0,0). Based on this model, forecasts were made for the total number of felony offenders for the period from 2023 to 2030.

Keyword: Kuwait, Forecasting, Felony Offenders, ARIMA Model.

* Associate Professor of Statistics, Saad Al-Abdullah Academy for Security Sciences, Kuwait.

Received: 15/8/2025 .

Accepted: 2/12 /2025 .

© All rights reserved to Mutah University, Karak, Hashemite Kingdom of Jordan, 2025.

المقدمة:

تُعتبر وزارة الداخلية في دولة الكويت من الركائز الأساسية في تحقيق الأمن والاستقرار في المجتمع، وهي تسعى باستمرار إلى تطوير استراتيجياتها الأمنية لمواكبة التحديات المعاصرة في مجال مكافحة الجريمة وتعزيز الأمن. وفي ظل التغيرات السريعة التي يشهدها العالم اليوم، بات استخدام البيانات والتحليل الإحصائي من الأدوات الحيوية التي تعتمد عليها المؤسسات الأمنية لتطوير خططها وبرامجها. ويلعب علم الإحصاء دورًا محوريًا في دعم تلك الجهود من خلال توفير أدوات دقيقة لتحليل البيانات الجنائية والتنبؤ بالاتجاهات المستقبلية للجريمة. فالبيانات الإحصائية المتعلقة بالجرائم، عند تحليلها بطرق علمية مدروسة، توفر فهمًا عميقًا للأنماط والاتجاهات السائدة، مما يُمكن الجهات الأمنية من اتخاذ قرارات قائمة على الأدلة. إن استخدام هذه الأدوات التحليلية يساعد في تعزيز التخطيط الأمني الفعال، حيث يُمكن للمؤسسات الأمنية، من خلال تحليل الاتجاهات الإحصائية، وضع سياسات وإجراءات تهدف إلى خفض معدلات الجريمة وتعزيز مستوى الأمن والسلامة في المجتمع (الدوب، 2013).

من خلال التحليل الإحصائي، يمكن للباحثين تحديد الأنماط الزمنية والمكانية للجريمة، مما يساعد في الكشف عن العوامل التي تؤثر على معدلات الجريمة. وبالتالي فإن الاعتماد على علم الإحصاء في مجال العلوم الأمنية يساهم في تحسين فعالية وكفاءة الخطط الأمنية، ويعزز من القدرة على الاستجابة للتحديات المتغيرة. لذلك، يُعد علم الإحصاء أداة حيوية لمتخذي القرار في وزارة الداخلية تحديدًا، حيث يمكنهم من خلاله تطوير استراتيجيات مبنية على بيانات دقيقة وموثوقة، مما يساهم في تحقيق أهداف الأمن الوطني بكفاءة وفعالية (عثمان، 2002).

على سبيل المثال، يمكن استخدام التحليل الزمني لدراسة التغيرات في معدلات الجريمة على مدار سنوات سابقة، بينما يمكن للتحليل الإحصائي الديموغرافي للجريمة تحديد المناطق التي تشهد فيها معدلات جريمة أعلى. وفي إطار هذا السياق، يتزايد الاعتماد على نماذج تحليل السلاسل الزمنية كأحد الأساليب الفعالة في تحليل البيانات الجنائية. تتيح هذه النماذج للمخططين الأمنيين التنبؤ بالاتجاهات المستقبلية للجريمة، مما يمكنهم من تطوير استراتيجيات استباقية لمكافحة الجرائم والحد من انتشارها. تهدف هذه الدراسة إلى استعراض دور نماذج السلاسل الزمنية، وعلى وجه الخصوص نموذج ARIMA، في التنبؤ بإجمالي جرائم مرتكبي الجنايات في دولة الكويت، وتبسيط الضوء على أهمية تطبيق التحليل الإحصائي في صياغة استراتيجيات أمنية فعالة تستجيب للتحديات الحالية والمستقبلية (الدوب، 2007).

مشكلة الدراسة:

إن التنبؤ بالجريمة وتحليل معدلاتها ومؤشراتها يُعدُّ أحد الركائز الأساسية في مجال الإحصاء الجنائي. يُساهم هذا الجانب بشكلٍ فعّالٍ في تعزيز السياسات الأمنية وتوجيهها بشكل صحيح، من خلال وضع استراتيجيات وخطط فعّالة لمكافحة الجريمة. وفي إطار تحقيق هذا الهدف، تعتمد الدراسات الحديثة بشكل متزايد على نماذج السلاسل الزمنية، ولا سيما النماذج غير الموسمية منها، حيث تتيح هذه النماذج للمسؤولين عن الأمن إمكانية تحديد المناطق الأكثر عرضة للجريمة وتوجيه الجهود نحوها بفعالية أكبر، مما يساهم في اتخاذ التدابير الوقائية والتدخلات القانونية المناسبة للحد من انتشار الجريمة في المستقبل. وتتمثل إشكالية هذه الدراسة في محاولة الإجابة على السؤال التالي: "ما هو النموذج الأكثر دقة وفعالية من بين نماذج السلاسل الزمنية للتنبؤ بإجمالي عدد مرتكبي جرائم الجنايات في دولة الكويت؟"

أهمية الدراسة:

تتبع أهمية هذه الدراسة من الحاجة المتزايدة إلى بناء استراتيجيات أمنية قائمة على التحليل الكمي والنهج الاستباقي، خاصة في ظل التغيرات الاجتماعية والاقتصادية المتسارعة التي تؤثر في معدلات وأنماط الجريمة. تُعتبر السلاسل الزمنية، ونماذج ARIMA تحديداً، من الأدوات الإحصائية الفعّالة في التنبؤ بالاتجاهات المستقبلية للظواهر الأمنية، حيث تتيح لصناع القرار القدرة على استباق المخاطر وتوجيه الموارد الأمنية بفعالية نحو المواقع الأكثر عرضة للتهديدات. ويكتسب هذا البحث أهمية خاصة في السياق الكويتي، نظراً لاعتماده على بيانات رسمية طويلة الأمد تمتد من عام 1992 إلى عام 2022، وتطبيقه العلمي على جرائم الجنايات التي يُعدُّ من أخطر أنماط الجريمة. كما أن نتائج التنبؤ للفترة 2023-2030 من شأنها أن تزود وزارة الداخلية بأداة علمية دقيقة لرصد التغيرات المستقبلية في السلوك الإجرامي، وتوجيه السياسات الأمنية على نحو أكثر فاعلية واستدامة.

الدراسات السابقة:

اقترحت دراسة (Wang & Brown, 2012) نموذجاً مكانياً زمنياً للتنبؤ بالجرائم، حيث تم استخدام بيانات جغرافية وزمنية لأحداث إجرامية سابقة في مدينة أمريكية. تم تطوير خوارزمية تنبؤية تدمج خصائص الحدث (الزمان والمكان) مع أنماط الجريمة السابقة لتحديد احتمالية حدوث جريمة في موقع وزمان معينين. أظهرت النتائج تفوق هذا النموذج على النماذج التقليدية التي تتجاهل البعد

المكاني. تبرز أهمية الدراسة في تأكيدها على أهمية البعد المكاني في توقع الجرائم، ما يفتح المجال أمام تطوير أدوات أكثر كفاءة لتوزيع الموارد الأمنية.

تهدف دراسة (Butt et al., 2020) إلى مراجعة منهجية شاملة للأبحاث المتعلقة بالكشف والتنبؤ بالنقاط الساخنة للجريمة باستخدام البيانات الزمانية والمكانية. اشتملت المراجعة على تحليل 49 دراسة علمية لتقييم فعالية النماذج المستخدمة في تحديد المواقع والتوقيتات الحساسة للجريمة. أظهرت النتائج أن دمج البعدين الزماني والمكاني يعزز من دقة التنبؤات، كما أوصت الدراسة بدمج تقنيات تعلم الآلة مع النماذج الإحصائية مثل ARIMA للحصول على نتائج أكثر موثوقية. تميزت الدراسة بإتاحتها إطاراً تحليلياً لتقييم الأدبيات السابقة، وتحديد التحديات والفرص في التنبؤ الجغرافي-الزماني بالجريمة. استعرضت دراسة (Kounadi et al., 2020) أكثر من 30 بحثاً حول التنبؤ المكاني للجريمة، وركزت على الجوانب المنهجية والتقنية لتلك الدراسات، مثل اختيار نوع البيانات، ومستوى التحليل، ونوع النموذج المستخدم. والدراسة سلطت الضوء على التحديات المتعلقة بجودة البيانات وعدم تجانسها، بالإضافة إلى الحاجة إلى مزيد من التفاعل بين الباحثين وصانعي السياسات. تقدم هذه الدراسة إطاراً نقدياً شاملاً يمكن أن يُستخدم كمرجعية في تطوير نماذج التنبؤ المكاني في الأبحاث المستقبلية.

طبقت دراسة (Faujdar et al., 2021) تحليل السلاسل الزمنية باستخدام نموذج ARIMA للتنبؤ بمعدلات الجريمة في إحدى المدن الهندية. تم جمع بيانات سنوية عن الجرائم وتحليلها لتحديد النمط الزمني، مع اختبار استقرار السلسلة قبل بناء النموذج. بعد المقارنة بين النماذج المختلفة باستخدام RMSE، تبين أن ARIMA (1,1,0) هو الأكثر دقة في التنبؤ خلال السنوات القادمة. أهمية الدراسة تكمن في تقديمها نموذجاً تنبؤياً بسيطاً لكنه فعال يمكن استخدامه من قبل السلطات المحلية في التخطيط الأمني.

أجرى (Rahman et al., 2021) تحليلاً منهجياً لبيانات تقارير الجرائم في بنغلادش بهدف تحديد الأنماط الإحصائية والتنبؤ بالاتجاهات المستقبلية للجريمة. اعتمدت الدراسة على بيانات رسمية تاريخية تم جمعها من مصادر شرطية ووطنية موثوقة، وقام الباحثون بتطبيق مجموعة من أساليب التحليل الإحصائي وتقنيات النمذجة، بما في ذلك نماذج السلاسل الزمنية وتقنيات التعلم الآلي، لقياس كفاءة النماذج في التنبؤ بمعدلات الجريمة. أظهرت النتائج قدرة النماذج المستخدمة على تحقيق دقة تنبؤية عالية، مما يعزز إمكانية توظيفها كأدوات داعمة لعمليات التخطيط الأمني وصنع القرار. وتكمن أهمية هذه الدراسة في دمجها بين التحليل الإحصائي الكلاسيكي والأساليب الحاسوبية المتقدمة ضمن سياق أمني حقيقي، بما يساهم في تحسين فعالية السياسات الوقائية.

طُرحت دراسة (Alghamdi, 2024) في الولايات المتحدة الأمريكية نموذجاً يعتمد على شبكة عصبية عميقة (Deep Neural Network) مُحسن باستخدام Keras Tuner، للتنبؤ ليس فقط بموعد ومكان الجريمة، بل أيضاً للتنبؤ بنوع الجريمة بطريقة دقيقة وفعالة. وتؤكد الدراسة على أهمية تحليل البيانات الكبيرة باستخدام تقنيات الذكاء الاصطناعي لتعزيز التنبؤ وتكلفة التطبيق المنخفضة.

تُقدّم دراسة (Fan et al., 2025) نموذجاً هجيناً يجمع بين Spatiotemporal و Informer و Graph Convolutional Network (ST-GCN) للتنبؤ بدقة بمعدلات الجرائم على مستوى المجمعات السكنية في شيكاغو خلال الفترة من 2015 إلى 2020. وهذا النموذج يأخذ في الحسبان شبكة المجتمعات، بالإضافة إلى بيانات الطقس، والأعياد، والتاريخ الزمني للجريمة. أظهرت النتائج أداءً متفوقاً من حيث قيمة (Mean Absolute Error: MAE) وهو معيار متوسط الخطأ المطلق؛ مثلاً، متوسط الخطأ للسرقات (1.36)، وللانتهاكات الجنائية (1.05).

حللت دراسة (İlgün & Dener, 2025) بيانات الجرائم في عدة مناطق للشرطة لمدن في الولايات المتحدة الأمريكية، واستخدمت مزيجاً من أساليب: XGBoost، Random Forest، LSTM، BLSTM، Holt-Winters، Prophet، و SARIMA. هدفت الدراسة إلى التنبؤ بمواقع الجرائم الساخنة مستقبلاً، وبيّنت أن نماذج LSTM و SARIMA كانت الأدق وفق RMSE الأَدنى، بالإضافة إلى توقع الاتجاهات الخمسة القادمة للجريمة.

منهج الدراسة:

أولاً: السلسلة الزمنية

تُمثل السلسلة الزمنية مجموعة من البيانات التي يتم تسجيلها بانتظام في فترات زمنية متعاقبة، وتُصنف إلى نوعين رئيسيين: السلاسل الزمنية المتقطعة والسلاسل الزمنية المستمرة. تُظهر هذه السلاسل في بعض الأحيان تغيرات موسمية، والتي تشير إلى نمط متكرر في البيانات خلال فترات زمنية محددة. بمعنى آخر، تعود السلسلة الزمنية لتكرار نفس النمط بعد مدة ثابتة تُعرف بالفترة الموسمية، والتي يُرمز لها بالرمز S . وقد تمثل هذه الفترة سنة، فصلاً، شهراً، أو حتى أسبوعاً، حسب طبيعة البيانات والتغيرات المرصودة (Brockwell & Davis, 1991).

السكون (الاستقرار)

تُعتبر السلسلة الزمنية ساكنة عندما لا تظهر فيها تغيرات منتظمة في المتوسط أو التباين، وعندما يتم إزالة الاختلافات الدورية بشكل دقيق. يتم تحقيق السكون في المتوسط من خلال أخذ الفروق

للسلسلة الزمنية، في حين يتم تحقيق السكون في التباين عبر استخدام التحويلات الرياضية، وأبرزها تحويل اللوغاريتم. يُعد استقرار السلسلة الزمنية شرطاً أساسياً لتحليلها بطرق إحصائية دقيقة، حيث يساهم في تحسين دقة النماذج التنبؤية وتقليل تأثير التغيرات العشوائية على النتائج.

ثانياً: نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية ARIMA

لا بد من التعرف على أحد نماذج بوكس - جينكنز المستقرة، وهو نموذج الانحدار الذاتي والمتوسطات المتحركة التكاملية والذي يرمز له بالرمز $ARIMA(p,d,q)$ ، وهو ناتج من دمج نماذج الانحدار الذاتي (AR) Autoregressive مع نماذج المتوسطات المتحركة Moving Average (MA)، حيث إن في البحث الحالي قيمة $(d=q=0)$ ، والشكل العام للمعادلة يكتب بالصيغة التالية (Priestley, 1982):

$$\phi_p(B) \Delta^d Y_t = \theta_q(B) \varepsilon_t$$

حيث: ϕ_p : متعددة حدود الانحدار الذاتي من الدرجة p .

(B) : مُعامل الإزاحة للخلف.

Δ^d : مُعامل التفاضل من الدرجة d .

Y_t : المتغير العشوائي لقيمة السلسلة الزمنية عند الزمن t .

θ_q : متعددة حدود المتوسطات المتحركة من الدرجة q .

ε_t : حد الخطأ (أو الضوضاء) عند الزمن t .

1. منهجية بوكس - جينكنز

تنقسم منهجية بوكس - جينكنز (Box & Jenkins, 1976) إلى أربعة مراحل أساسية، وهي:

- **مرحلة التعرف:** وفيها يتم التعرف على النموذج الأكثر توافقاً مع السلسلة الزمنية وذلك من خلال دراسة دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي وتحليل منحنياتها البيانية، حيث يتم تحديد كل من (p,d,q) في النماذج غير الموسمية.
- **مرحلة التقدير:** وفيها يتم تقدير معالم النموذج $(\phi_p, \varphi_p, \theta_q, \vartheta_q)$ المقترح في مرحلة التعرف.
- **مرحلة التشخيص:** وفيها يتم فحص بواقي النموذج والتأكد من مدى ملائمتها أو صلاحيتها لتمثيل بيانات السلسلة الزمنية.
- **مرحلة التنبؤ:** وهي تمثل المرحلة الأخيرة في بناء نماذج بوكس - جينكنز، وتُمثل أحد الأهداف النهائية لتحليل السلاسل الزمنية.

2. معايير المقاضلة بين النماذج

معامل التحديد (R-squared): يُعدُّ معامل التحديد (R-squared) من أكثر المقاييس الإحصائية استعمالاً في تقييم جودة النماذج الإحصائية، ويُحسب باستخدام المعادلة التالية (Montgomery et al., 2012):

$$R^2 = \frac{SS(res)}{SS(tot)}$$

علمًا بأن $SS(res)$ هو مجموع مربعات الأخطاء (Sum of Squares Residuals)، و $SS(tot)$ هو المجموع الكلي لمربعات الانحراف (Total Sum of Squares) وهو التباين الكلي في البيانات. ويعكس معامل التحديد (R-squared) نسبة التباين في المتغير الاعتمادي (المتغير المُتوقع) التي يمكن تفسيرها بواسطة المتغيرات المستقلة (المتغيرات المستخدمة في النموذج). وتُشير القيمة العالية لمعامل التحديد (R-squared) إلى أن النموذج يقدم تفسيرًا جيدًا للبيانات، حيث إنه يستطيع تفسير نسبة عالية من التباين.

يجب ملاحظة أن قيمة معامل التحديد (R-squared) تتراوح بين 0 و1؛ حيث تدل القيمة 1 على أن النموذج يفسر جميع التباين في البيانات تفسيرًا كاملاً، بينما تدل القيمة 0 على أن النموذج لا يمكنه تفسير أي تباين في البيانات.

مقياس معلومات بيزيان المُوحَّد Bayesian Information Criterion – Normalized (NBIC)

وتُعطى صيغته كالتالي (Raftery, 1995):

$$NBIC = BIC - \frac{1}{2} \cdot k \cdot \ln(n)$$

حيث إن (BIC) هو مقياس معلومات بيزيان، و k هو عدد المتغيرات في النموذج، و n هو حجم العينة. إن القيمة المُثلَى لـ (NBIC) هي تلك التي تكون أقل قيمة ممكنة بين النماذج المختلفة في المقارنة. وعند مقارنة النماذج المختلفة باستخدام (NBIC) يجب اختيار النموذج الذي يعطي أقل قيمة لـ (NBIC)، وهذا يشير إلى أن النموذج يوفر توازنًا مثاليًا بين تناسب البيانات وبساطة النموذج.

معيار متوسط جذر مربع الخطأ (RMSE)

وصيغته كالتالي وفقاً لـ (Hodson, 2022):

$$RMSE = \sqrt{\sum_{i=1}^n \frac{1}{n} (\hat{y}_i - y_i)^2}$$

حيث إن n هي عدد العينات في البيانات، y_i هي القيمة الفعلية للعينات i ، وتعتبر \hat{y}_i هي القيمة التي تم التنبؤ بها للعينات، ويُعدُّ متوسط جذر مربع الخطأ (RMSE) مقياساً لدقة نموذج التنبؤ، حيث يُستخدم لتقييم مدى التباين بين القيم المتوقعة من النموذج والقيم الفعلية الملاحظة في البيانات. وكلما كانت قيمة (RMSE) أقل كلما كانت أفضل، حيث يشير (RMSE) الأقل إلى أن النموذج ينبغي أن يكون قادراً على التنبؤ بقيم أقرب إلى البيانات الفعلية.

الجانب التطبيقي:

سيتم الاعتماد في التحليل على بيانات إجمالي مرتكبي جرائم الجنايات السنوية الصادرة عن مركز البحوث والدراسات التابع لوزارة الداخلية بدولة الكويت، وذلك خلال الفترة من 1992 حتى 2022، ولإجراء التحليل والتنبؤ المستقبلي سنتناول في هذا الجانب مراحل منهجية بوكس - جينكينز، على النحو التالي:

1. وصف السلسلة من حيث الاستقرار

وتتمثل أولى خطوات تلك المرحلة في فحص استقرار السلسلة الزمنية لإجمالي مرتكبي جرائم الجنايات في دولة الكويت خلال الفترة من 1992 حتى 2022، من خلال فحص مركبات السلسلة، وتحليلها كالتالي:

الفحص البصري للاتجاه العام (Trend Analysis)

- يُظهر الرسم وجود اتجاه تصاعدي واضح من بداية الفترة (1992) حتى ذروة ملحوظة في منتصف الفترة تقريباً (حوالي 1998-2000)، حيث وصلت القيم إلى أكثر من 12,500 جريمة.
- بعد الذروة، حدث انخفاض حاد خلال أوائل العقد الأول من الألفية (2002-2003 تقريباً)، مما يشير إلى تغيرات محتملة في البيئة الأمنية، أو التشريعات، أو مستوى الرقابة.
- الفترة اللاحقة (2004-2022) اتسمت بالتذبذب المعتدل مع وجود فترات ارتفاع وانخفاض، ولكن ضمن نطاق أضيق، مقارنة بالذروة السابقة، مع ميل بسيط للصعود في السنوات الأخيرة.

فحص الاستقرار (Stationarity Check)


من الفحص البصري يتضح أن:

- المتوسط (Mean): لا يبدو ثابتاً على امتداد الفترة، إذ تظهر مستويات مختلفة بوضوح قبل وبعد عام 2002، مما يوحي بوجود تغير هيكلي (Structural Break).
 - التباين (Variance): يبدو متقلباً في بداية الفترة، خاصة في السنوات التي شهدت الذروة، ثم أصبح أكثر استقراراً لاحقاً.
- تُشير هذه الملاحظات إلى أن السلسلة غير مستقرة (Non-stationary) على الأرجح، وتتطلب تحويلات، مثل: الفرق الأول (First Differencing) أو التحويل اللوغاريتمي (Log Transformation)، قبل تطبيق نماذج ARIMA.

تحليل المكونات (Time Series Components)

بالنظر إلى الشكل (1) أدناه، يتضح ما يلي:

- المكون الاتجاهي (Trend Component): يظهر كاتجاه تصاعدي قوي حتى الذروة، يعقبه اتجاه تنازلي ثم استقرار نسبي.
- المكون الدوري / التقلبات (Cyclic Component): تتمثل في فترات صعود وهبوط تمتد لعدة سنوات، مما قد يشير إلى دورات اقتصادية أو اجتماعية أو أمنية تؤثر على معدل الجريمة.
- المكون العشوائي (Irregular Component): يظهر على شكل تقلبات حادة في بعض السنوات (خاصة الذروة ومن ثم الانخفاض المفاجئ)، وهي قد تعكس أحداثاً استثنائية مثل التغيرات في القوانين أو شن حملات أمنية واسعة.



شكل رقم (1): السلسلة الأصلية لإجمالي مرتكبي جرائم الجنايات في الكويت

من الشكل (1) نلاحظ أن سلسلة مرتكبي جرائم الجنايات منتظمة، ولا نحتاج أخذ الفروق لتسكينها.

2. مرحلتى التعرف والتقدير:

هذه المرحلة تهدف إلى التعرف على نموذج ARIMA المناسب لتمثيل البيانات، ولتوفير أفضل نموذج للسلسلة تم العمل على تحديد النموذج الملائم ورتبته من خلال قيم المعايير الإحصائية NBIC، R-squared و RMSE، حيث تمت ملائمة مجموعة من نماذج ARIMA (p,d,q) لاختيار النموذج الأفضل والذي يُعطي أقل قيمة للمعايير NBIC و RMSE وأعلى قيمة لـ R-squared، كما هو مبين في الجدول (1) أدناه.

جدول (1): مقارنة بين النماذج المطروحة

النماذج	R-squared	NBIC	RMSE
ARIMA (0,0,1)	0.286	14.868	1515.364
ARIMA (1,0,1)	0.350	14.920	1471.457
ARIMA (1,1,1)	0.255	14.917	1463.563
ARIMA (1,0,0)	0.350	14.774	1445.865

نلاحظ من الجدول (1) أعلاه أن النموذج الأفضل هو نموذج ARIMA (1,0,0)، وذلك لأن لديه أفضل معايير مقارنة بالنماذج الأخرى. وبالرغم من تشابه قيمة R-squared مع نموذج ARIMA (1,0,1)، إلا أن المعايير الأخرى، وهي: NBIC و RMSE تمثل أقل قيم مقارنة بجميع النماذج، وتم تقدير معاملات النموذج كما في الجدول (2) التالي:

جدول (2): تقديرات معاملات النموذج ARIMA (1,0,0)


المعالم	AR (1) ϕ_1	constant
التقدير	0.626	14.58

3. مرحلة التشخيص:

تُعتبر هذه المرحلة من التحليل من أهم المراحل، حيث يتم خلالها مواءمة النموذج مع البيانات. ويُعد التحقق من شرطي الاستقرار والانعكاس في تقديرات النموذج مؤشرًا رئيسيًا على مدى ملاءمته، ومن بين هذه الشروط:

$$|\phi_1| < 1$$


يظهر من الشكل رقم (2) أن البواقي تنتوزع بشكل عشوائي حول الصفر، كما يتضح من نفس الشكل أن قيم معاملات الارتباط الذاتي تقع ضمن حدود فترة الثقة، مما يشير إلى عدم وجود ارتباط ذاتي بين البواقي. وبذلك نستنتج أن أفضل نموذج يمكن اعتماده لتمثيل السلسلة الزمنية محل الدراسة واستخدامه في التنبؤ هو ARIMA (1,0,0). وبالرغم من تشابه قيمة R-square مع نموذج ARIMA (1,0,0)، إلا أن هناك أفضلية للمعايير الأخرى للنموذج ARIMA (1,0,0).



شكل رقم (2): رسم البواقي ودالة الارتباط الذاتي لنموذج $ARIMA(1,0,0)$

4. التنبؤ باستخدام نموذج $ARIMA(1,0,0)$:

في هذه المرحلة، تم التنبؤ بإجمالي مرتكبي جرائم الجنايات من عام 2023 حتى عام 2030، في شكل رقم (3) وجدول (3)، على النحو التالي:



شكل رقم (3): رسم بياني للقيم المشاهدة والتنبؤية لنموذج $ARIMA(1,0,0)$

جدول (3): القيم التي تم التنبؤ بها باستخدام النموذج ARIMA (1,0,0)

التاريخ	2023	2024	2025	2026	2027	2028	2029	2030
التنبؤ	8641	8330	8117	7970	7870	7801	7753	7720

نتائج الدراسة:

يُعد تحليل السلاسل الزمنية لعدد مرتكبي جرائم الجنايات في دولة الكويت خلال الفترة من 1992 حتى 2022، باستخدام منهجية بوكس-جينكنز ونموذج ARIMA، مثالاً عملياً واضحاً على أهمية الإحصاء الجنائي في دعم منظومة التخطيط الأمني واتخاذ القرارات المستندة إلى الأدلة. فقد مكن هذا التحليل من استيعاب التطورات التاريخية في معدلات ارتكاب الجريمة، ورصد التحولات الهيكلية التي طرأت عليها، وصولاً إلى بناء نموذج تنبؤي قادر على استشراف الاتجاهات المستقبلية حتى عام 2030.

كشفت النتائج أن نموذج ARIMA (1,0,0) هو الأنسب من بين النماذج الأخرى التي خضعت للمقارنة، استناداً إلى معايير R-squared و NBIC و RMSE. هذا الاختيار لم يكن مجرد نتيجة حسابية، بل هو انعكاس لمدى توافق خصائص النموذج مع طبيعة البيانات وخصائصها الإحصائية. فقد أظهر الفحص البصري للسلسلة الزمنية أنماطاً من عدم الاستقرار في المتوسط خلال الفترة ما قبل عام 2002، متبوعة بفترة استقرار نسبي مع تذبذب محدود، وهو ما يتناسب مع نموذج منخفض التعقيد من حيث الرتب (p,d,q) ، ويميل إلى الاعتماد على القيم السابقة كمؤشر قوي للتنبؤ بالقيم المستقبلية. من منظور أمني، فإن ما يميز هذه النتائج ليس فقط التنبؤ العددي بمستويات الجريمة، وإنما القدرة على تحويل تلك التوقعات إلى أدوات عملية للتخطيط الاستباقي. إذ تشير النتائج إلى اتجاه عام نحو الانخفاض التدريجي في عدد مرتكبي جرائم الجنايات خلال السنوات القادمة، وهو ما يمكن أن يُترجم إلى إعادة توزيع الموارد الأمنية والتركيز على برامج وقائية مستهدفة، بدلاً من الاعتماد على الاستجابة التقليدية بعد وقوع الجريمة. هذا التحول من "رد الفعل" إلى "العمل الوقائي المبني على البيانات" يُمثل جوهر الإحصاء الجنائي الحديث.

تظهر أهمية هذه الدراسة أيضًا في قدرتها على الكشف عن التأثيرات المحتملة للعوامل الخارجية (التشريعية، الاقتصادية، الاجتماعية) على معدلات الجريمة، رغم أن هذه العوامل لم تُدرج صراحة في النموذج الرياضي المستخدم. على سبيل المثال، التغيرات الحادة في بداية الألفية قد ترتبط بإصلاحات قانونية أو حملات أمنية واسعة النطاق، وهو ما يبرز الحاجة إلى دمج البيانات الإحصائية مع التحليل النوعي لفهم السياق الأوسع للجريمة.

ومن الجوانب البارزة في هذا البحث، الاعتماد على بيانات رسمية موثوقة صادرة من وزارة الداخلية في دولة الكويت، تغطي فترة زمنية طويلة نسبياً (31 عاماً). هذا الامتداد الزمني يُعد من العناصر الجوهرية التي تمنح التنبؤات درجة عالية من الموثوقية، مقارنة بالدراسات التي تعتمد على فترات زمنية قصيرة. كما أن طول السلسلة يُمكن من التقاط الدورات الزمنية المحتملة للجريمة، حتى وإن لم تكن موسمية واضحة، مما يدعم دقة النمذجة.

إن توظيف نموذج ARIMA في هذا السياق يُبرز أيضاً أهمية ملائمة النموذج الإحصائي لطبيعة الظاهرة قيد الدراسة. فعلى الرغم من انتشار نماذج أكثر تعقيداً (مثل: نماذج الشبكات العصبية أو النماذج الهجينة)، إلا أن اختيار نموذج بسيط وفعال مثل ARIMA (1,0,0) يُثبت أن التعقيد ليس بالضرورة مرادفاً للدقة، وأن الفهم العميق لخصائص البيانات قد يؤدي إلى حلول تنبؤية أكثر واقعية وقابلية للتطبيق.

وعلى الصعيد العملي، يمكن ترجمة نتائج هذه الدراسة إلى عدد من المسارات الاستراتيجية، على النحو التالي:

- إعادة هيكلة توزيع القوى الأمنية بحيث تتناسب مع الانخفاض المتوقع في بعض المناطق أو الفترات الزمنية، مع الحفاظ على مستوى الجاهزية في مواجهة أي طفرات مفاجئة.
- تطوير برامج وقائية موجهة تركز على الفئات والمناطق التي لا تزال تظهر معدلات مرتفعة من الجريمة، اعتماداً على التحليل المكاني المكمل للتحليل الزمني.
- تعزيز التعاون المؤسسي بين الأجهزة الأمنية والمؤسسات الاجتماعية والتعليمية والصحية، استناداً إلى مؤشرات التغيرات المستقبلية في أنماط الجريمة.
- دمج التنبؤات في أنظمة الإنذار المبكر للأمن العام، بحيث تُستخدم نتائج النماذج الإحصائية في دعم القرارات الفورية والاستراتيجية.

كما أن هذا البحث يقدم نموذجاً يمكن تطبيقه على أنواع أخرى من الجرائم في الكويت، سواء كانت جنحاً أو مخالفات مروية أو جرائم إلكترونية. ومن خلال تكرار المنهجية على أكثر من فئة جنائية،

يمكن بناء لوحة قيادة تنبؤية شاملة (Predictive Dashboard) تُحدّث باستمرار وتوفر رؤية متكاملة لصناع القرار.

من الناحية الأكاديمية، يضيف هذا البحث إلى الأدبيات في مجال الإحصاء الجنائي العربي، الذي لا يزال بحاجة إلى مزيد من الدراسات التطبيقية المتعمقة. فمعظم الدراسات في المنطقة العربية تركز على التحليل الوصفي أو الإحصاء الاستدلالي، بينما التنبؤ الإحصائي طويل المدى لا يزال قليل الحضور نسبياً. وهنا تأتي أهمية هذا العمل في سد جزء من هذه الفجوة المعرفية، وتقديم مثال على تطبيقات النماذج الإحصائية في بيئة أمنية عربية.

وفي ضوء التطورات التكنولوجية، يمكن اعتبار هذا البحث خطوة أولى نحو دمج النماذج الإحصائية التقليدية مع تقنيات الذكاء الاصطناعي وتعلم الآلة. فعلى سبيل المثال، يمكن مستقبلاً توسيع النموذج ليصبح هجيناً يجمع بين ARIMA ومعالجات الشبكات العصبية (مثل: LSTM) لتحسين دقة التنبؤ، خاصة في الفترات التي تشهد تقلبات غير خطية أو أنماط معقدة.

كذلك، فإن اعتماد هذا النموذج على بيانات سنوية لا يلغي إمكانية تطويره باستخدام بيانات شهرية أو ربع سنوية، وهو ما قد يسمح بالكشف عن أنماط موسمية أو دورية قصيرة المدى، وبالتالي تحسين الاستجابة التكتيكية للأجهزة الأمنية. فكلما كانت البيانات أكثر تفصيلاً، كان بالإمكان تصميم تدخلات أكثر تحديداً وتوقيتاً.

إن القيمة الحقيقية لهذا البحث لا تكمن فقط في نتائجه الرقمية، بل في تغيير عقلية التعامل مع الجريمة لدى الأجهزة الأمنية، من نهج يعتمد على الخبرة الشخصية والانطباعات، إلى نهج يعتمد على الأدلة والتحليل الإحصائي الصارم. وهذا التحول يعزز من كفاءة استخدام الموارد، ويزيد من فعالية الإجراءات الوقائية، ويمنح صناع القرار القدرة على التخطيط بعيد المدى بثقة أكبر.

يمكن القول إن هذا البحث يجسد بوضوح التكامل بين النظرية والتطبيق في مجال الإحصاء الجنائي. فمن خلال التحليل الدقيق للسلاسل الزمنية، وتطبيق المنهجية العملية في اختيار النموذج الأمثل، ثم تحويل النتائج إلى رؤى استراتيجية قابلة للتنفيذ، يقدم هذا العمل مثلاً يُحتذى به في كيفية توظيف الإحصاء في خدمة الأمن الوطني. وهو بذلك لا يقتصر على تقديم إجابة عن سؤال أكاديمي حول أفضل نموذج للتنبؤ بالجريمة، بل يضع بين أيدي صناع القرار أداة عملية قادرة على إحداث فرق حقيقي في الواقع الأمني للكويت.

الخلاصة والتوصيات

تهدف هذه الدراسة إلى تسليط الضوء على أهمية الإحصاء الجنائي في الكويت، وخاصة فيما يتعلق بإجمالي مرتكبي جرائم الجنايات، حيث تركز على دور البيانات في تحسين استراتيجيات مكافحة الجريمة. وتعتمد الدراسة على التحليل الدقيق للبيانات الجنائية وتوظيفها في التنبؤ بالاتجاهات المستقبلية لعدد مرتكبي جرائم الجنايات. تم اختيار نموذج $ARIMA(1,0,0)$ كأداة تنبؤية مثلى بعد مقارنته مع نماذج أخرى باستخدام معايير، مثل: R -squared، NBIC و RMSE. وقد أظهرت النتائج الانخفاض المتوقع مستقبلاً لجرائم مرتكبي الجنايات، مما يعزز دقة التنبؤات المستخلصة من النموذج. بناءً على هذه النتائج، قدمت الدراسة مجموعة من التوصيات للمسؤولين في المجال الأمني بهدف تعزيز فعالية القرارات الأمنية مع الانخفاض المتوقع مستقبلاً، على النحو التالي:

1. تعزيز أهمية الإحصاء الجنائي: يجب زيادة الاهتمام بالإحصاء الجنائي لدوره الحيوي في تقديم معلومات دقيقة تدعم صناع القرار في تحديد التوجهات وتطوير الخطط الأمنية الفعالة.
 2. التركيز على جودة البيانات: لضمان نجاح التحليلات الإحصائية، ينبغي التأكيد على جودة ودقة البيانات المتعلقة بالجرائم، نظرًا لأنها تشكل الأساس الذي يُبنى عليه التحليل.
 3. تطوير منهجيات جمع البيانات: الحاجة إلى توسيع نطاق جمع البيانات ليشمل متغيرات متعددة تتعلق بالجاني، الضحية، والعوامل البيئية المحيطة بالجريمة، وذلك لتوفير فهم أكثر شمولية للجريمة ودوافعها.
 4. تحسين منظومة الإحصاء الجنائي: يجب العمل على تحسين البنية الكلية لمنظومة الإحصاء الجنائي، مع إعطاء أولوية لكافة مراحل جمع وتحليل البيانات، بما يضمن الوصول إلى نتائج تساهم بفعالية في تعزيز الأمن.
 5. تحليل الاتجاهات الإجرامية بمرور الوقت: من المهم مراقبة وتحليل الاتجاهات الإجرامية على فترات زمنية مختلفة لفهم التحولات في أنماط الجريمة، مما يساعد في تطوير استراتيجيات مكافحة الجريمة بشكل أكثر دقة.
 6. استخدام التكنولوجيا المتقدمة: الاستفادة من التقنيات الحديثة مثل الذكاء الاصطناعي وتحليل البيانات الكبيرة في جمع وتحليل البيانات الجنائية، بهدف تحقيق دقة أكبر في التنبؤ بالجرائم وتعزيز الاستجابة الأمنية.
- تسعى هذه التوصيات إلى تحسين أداء الجهات الأمنية في الكويت وتعزيز قدرتها على مواجهة التحديات الأمنية، من خلال الاستفادة من أدوات التحليل الإحصائي والتكنولوجي الحديث.

المراجع

- الدوب، طارق عبد العزيز. (2007). مقارنة دقة التنبؤ بأسلوبي بوكس - جينكينز والشبكات العصبية لنماذج أرما الموسمية. جامعة القاهرة، كلية الاقتصاد والعلوم السياسية، جمهورية مصر العربية.
- الدوب، طارق عبد العزيز. (2013). المعلومة الأمنية والإحصاء الجنائي. وزارة الداخلية، أكاديمية سعد العبد الله للعلوم الأمنية، الكويت.
- عثمان، الحسن محمد (2002). تطور مفهوم الإحصاء الجنائي واستخدام الحاسوب في تسجيل الجرائم وتحليلها. جامعة نايف العربية للعلوم الأمنية، السعودية.
- Alghamdi, J., & Al-Dala'in, T. (2024). Towards spatio-temporal crime events prediction. *Multimedia Tools and Applications*, 83(7), 18721–18737. <https://doi.org/10.1007/s11042-023-16188-x>
- Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control* (2nd ed.). San Francisco: Holden-Day.
- Brockwell, P. J., & Davis, R. A. (1991). *Time Series: Theory and Methods* (2nd ed.). New York: Springer-Verlag.
- Butt, U. M., Letchmunan, S., Hassan, F. H., Ali, M., Baqir, A., & Sherazi, H. H. R. (2020). Spatio-temporal crime hotspot detection and prediction: A systematic literature review. *University of West London Repository*, in IEEE Access, 8, 166553–166574. <https://doi.org/10.1109/ACCESS.2020.3022808>
- Fan, Y., Hu, X., & Hu, J. (2025). Research on a crime spatiotemporal prediction method integrating informer and ST-GCN: A case study of four crime types in Chicago. *Big Data and Cognitive Computing*, 9(7), 179. <https://doi.org/10.3390/bdcc9070179>
- Faujdar, N., Verma, Y. Rathore, Y. S., & Rohatgi, P. K. (2021). Crime forecasting using time series analysis. In P. K. Kapur, G. Singh, & S. Panwar (Eds.), *Advances in Interdisciplinary Research in Engineering and Business Management (Asset Analytics)*, pp. 253–262. Springer. https://doi.org/10.1007/978-981-16-0037-1_20

- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- İlgün, E. G., & Dener, M. (2025). Exploratory data analysis, time series analysis, crime type prediction, and trend forecasting in crime data using machine learning, deep learning and statistical methods. *Neural Computing and Application*, 37, 11773–11798. <https://doi.org/10.1007/s00521-025-11094-9>
- Kounadi, O., Ristea, A., Araujo, A., & Leitner, M. (2020). A systematic review on spatial crime forecasting. *Crime Science*, 9(7). <https://doi.org/10.1186/s40163-020-00116-7>
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to Linear Regression Analysis* (5th ed.). Hoboken, NJ: John Wiley & Sons.
- Priestley, M. B. (1982). *Spectral Analysis and Time Series*. London: Academic Press.
- Raftery, A. E. (1995). Bayesian model selection in social research. *Sociological Methodology*, 25, 111–163. Retrieved from: <https://sites.stat.washington.edu/raftery/Research/PDF/socmeth1995.pdf>
- Rahman, M. P., Hoque, A. K. M., Ahmed, M. F., Iftekhurul, I., Alam A., & Hossain, N. (2021). Bangladesh Crime Reports Analysis and Prediction. *International Conference on Software Engineering & Computer Systems and 4th International Conference on Computational Science and Information Management (ICSECS-ICOCSIM)*, Pekan, Malaysia, pp. 453–458. <https://doi.org/10.1109/ICSECS52883.2021.00089>
- Wang, X., & Brown, D. E. (2012). The spatio-temporal modeling for criminal incidents. *Security Informatics*, 1(2), 1–12. <https://doi.org/10.1186/2190-8532-1-2>