



Using Clustering Techniques in Quantile Regression for Fixed Effect Model

Simulation Study

Haider Zuham Jabor⁽¹⁾, Prof. Dr. Lekaa Ali Al-Alawy⁽²⁾

University of Baghdad⁽¹⁾, University of al-shaab⁽²⁾

(1) haidar.jabr2101p@coadec.uobaghdad.edu.iq (2) lekaa.alalawy@alshaab.edu.iq

Key words:

Panel Data, Quantile Regression, Fixed Effects, Clustering Technique, K-Medoids, K-means.

ARTICLE INFO

Article history:

Available online | 25 May. 2025

© 2025 THE AUTHOR(S). THIS IS AN OPEN ACCESS ARTICLE DISTRIBUTED UNDER THE TERMS OF THE CREATIVE COMMONS ATTRIBUTION LICENSE (CC BY 4.0).

<https://creativecommons.org/licenses/by/4.0/>



*Corresponding author:

Lekaa Ali Al-Alawy

University of al-shaab

Abstract:

This study explores the use of quantile regression as an analytical approach for panel data with fixed effects, integrating it with clustering techniques to identify latent subgroups (clusters) of units that share similar characteristics or behaviors. To achieve this, two popular clustering algorithms—K-Means and K-Medoids—were employed and compared in terms of their effectiveness in uncovering hidden clusters among units. Quantile regression is a flexible and powerful statistical tool that allows the analysis of relationships between variables at different points of the distribution of the dependent variable, rather than focusing solely on the conditional mean as in traditional regression models. This flexibility enables a deeper understanding of heterogeneity in the data, especially in the presence of non-uniform distributions or outliers.

In this study, a Monte Carlo simulation approach was adopted to evaluate the performance of integrating quantile regression with the aforementioned clustering methods under various scenarios. The Mean Squared Error (MSE) criterion was used to compare model accuracy across different settings, including variations in time periods and proportions of outliers. The results demonstrated that selecting an appropriate clustering technique and properly tuning the number of clusters can significantly improve the accuracy of estimating quantile regression parameters. In particular, the K-Medoids method outperformed K-Means in scenarios with a high proportion of outliers, while the median quantile level (Q50) proved to be the most stable among the quantiles studied.

استعمال تقنيات العنقدة في الانحدار التقسيمي لنموذج الأثر الثابت دراسة محاكاة

أ.د. لقاء علي العلوى

جامعة الشعب

ekaa.alalawy@alshaab.edu.iq

الباحث: حيدر زحام جبر

جامعة بغداد – كلية الادارة والاقتصاد

haidar.jabr2101p@coadec.uobaghdad.edu.iq

المستخلص

يتناول هذا البحث استخدام الانحدار التقسيمي كأحد أساليب تحليل البيانات الطولية لنموذج الأثر الثابت، ودمجه مع تقنيات العنقدة بهدف تحديد مجموعات فرعية (عنقides) من الوحدات ذات الخصائص أو السلوكيات المتشابهة، لتحقيق ذلك، تم توظيف خوارزمي التجميع K-Means و K-Medoids و مقارنة فاعليتهما في الكشف عن هذه العناقيد الكامنة بين الوحدات. يُعد الانحدار التقسيمي أداة إحصائيةً مرنّةً وقويةً تتيح لنا تحليل العلاقة بين المتغيرات عند موقع مختلف من توزيع المتغير التابع، بدلاً من الاقتصار على تقدير المتوسط الشرطي كما في الانحدار التقليدي. تُمكّن هذه المرونة من الحصول على فهم أعمق للبيانات في البيانات، خاصةً في حالة التوزيعات غير المتجانسة أو وجود قيم شاذة (Outliers). في هذا البحث، تم اعتماد منهجية المحاكاة Monte Carlo لتقدير أداء الدمج بين الانحدار التقسيمي وطرق التجميع المذكورة تحت ظروف مختلفة. استُخدم معيار متوسط مربعات الخطأ (MSE) لمقارنة دقة النماذج عبر سيناريوهات متعددة من حيث طول الفترة الزمنية ونسبة القيم الشاذة. أظهرت النتائج أن اختيار تقنية التجميع المناسبة وضبط عدد العناقيد يمكن أن يحسن بشكل ملحوظ من دقة تقدير معالم النموذج التقسيمي، حيث تفوقت طريقة K-Medoids في حالة وجود نسبة مرتفعة من القيم الشاذة، في حين أثبتت الوسيط (الانحدار عند Q50) أنه الأكثر استقراراً بين الشرائح الكمية المدرستة.

الكلمات المفتاحية: بيانات بازل، الانحدار الكمي، التأثيرات الثابتة، تقنية التجميع، كـ-ميدويذز، كـ-مينز.

1- مقدمة

شهدت السنوات الأخيرة تزايداً ملحوظاً في الاهتمام بتحليل البيانات الطولية في العديد من المجالات الأكademية كعلم الاقتصاد والعلوم الاجتماعية والبحوث الصحية. تمتاز البيانات الطولية بأنها تجمع بين خصائص البيانات المقطعة والسلسل الزمنية، إذ تتضمن مشاهدات متعددة لمجموعة من الوحدات (مثل الدول أو الشركات) عبر فترات زمنية مختلفة. يتيح هذا النوع من البيانات تتبع التغيرات الديناميكية في العلاقات بين المتغيرات عبر الزمن وبين الوحدات المختلفة، مما يوفر فهماً أعمق للبيانات الفردية التي قد لا تكون مرئية في التحليلات التقليدية. على سبيل المثال، قد تختلف استجابات الشركات للتغيرات الاقتصادية بمرور الزمن وبين الصناعات المختلفة، الأمر الذي يجعل التحليل الطولي أكثر ملاءمة لالتقاط هذه الفروقات مقارنةً بالتحليل المقطعي أو الزمني منفرداً.

تعد النماذج المعتمدة على التأثيرات الثابتة من أهم الأساليب المستخدمة لتحليل البيانات الطولية، حيث تساعد هذه النماذج في التقليل من التحيز الناجم عن تأثيرات غير مرصودة تؤثر على المتغير التابع. ومن خلال ذلك، تتيح نماذج التأثيرات الثابتة فهماً دقيقاً للعلاقات بين المتغيرات عبر الزمن وداخل الكيانات المتعددة. ومع تزايد تعقيد البيانات، أصبح من الضروري تطبيق تقنيات تحليلية تأخذ في الاعتبار هذا التفاوت في البيانات بين الكيانات وبين الزمن. من هنا يأتي دور الانحدار التقسيمي كأداة قوية لتحليل العلاقات بين المتغيرات في البيانات الطولية. يُعد الانحدار التقسيمي أداة إحصائية

مرنة تتيح تحليل العلاقات بين المتغيرات عند مستويات مختلفة من توزيع المتغير التابع. بدلاً من التركيز على المتوسط الشرطي كما يحدث في الانحدار التقليدي، يتيح الانحدار التقسيمي تحليل تأثير المتغيرات المستقلة على مختلف النقاط في توزيع المتغير التابع، مثل الربع الأدنى، الربع الأعلى، أو الوسيط. هذه الميزة تجعل الانحدار التقسيمي مناسباً لتحليل البيانات ذات التوزيعات غير المتتجانسة أو التي تحتوي على نقاط شاذة. على سبيل المثال، في دراسة أثر الدخل على الإنفاق الاستهلاكي، قد نجد أن العلاقة بين الدخل وإنفاق تختلف بين الأشخاص ذوي الدخل المنخفض والأشخاص ذوي الدخل المرتفع، وهو ما يمكن تحليله باستخدام الانحدار التقسيمي. أعمال مثل Bassett وKoenker (1978) قدمت أساس الانحدار التقسيمي، حيث ركزت على استخدامه لفهم العلاقات المختلفة عبر التوزيع الشرطي. كما أن Koenker (2004) طبق الانحدار التقسيمي على البيانات الطولية، مما مهد الطريق لاستخدامه في سياقات جديدة تتعلق بالتغييرات الهيكيلية عبر الزمن داخل الوحدات.

ومع تطبيق الانحدار التقسيمي على البيانات الطولية، أصبح بإمكان تحليل العلاقة بين المتغيرات عبر الزمن وبين الكيانات المختلفة. يمكن للنمذجة المستخدمة في الانحدار التقسيمي أن تأخذ في الاعتبار التأثيرات الثابتة التي تخص كل كيان (مثل الدولة أو الشركة) وتقدير تأثير هذه المتغيرات عبر نقاط مختلفة من توزيع المتغير التابع. أحد التحديات التي يواجهها التحليل باستخدام الانحدار التقسيمي في البيانات الطولية هو كيفية التعامل مع التأثيرات الثابتة لكل كيان. الحلول الشائعة تشمل استخدام نماذج الانحدار التقسيمي للأثر الثابت، التي تتيح تقدير التأثيرات الفردية لكل كيان على حدة مع الحفاظ على تأثير المتغيرات المستقلة مشتركاً بين جميع الكيانات. هناك العديد من الباحثين والدراسات التي تناولوا هذا الجانب واستخدموه في عدة مجالات اذ يعد أداة متعددة الاستخدامات يمكنها معالجة العديد من التحديات في تحليل البيانات الطولية على سبيل المثال، قدم (Galvao,A., 2011) نموذجاً للانحدار التقسيمي الديناميكي مع تأثيراته الثابتة، واقتصر (Lamarche 2010) طرفاً لمقاومة التأثيرات الشاذة من خلال طرق جزائية في تقدير الانحدار للبيانات الطولية. كما تناول (Kato et al. , 2012) الخصائص الإحصائية الكبيرة لتقييرات الانحدار التقسيمي في ظل التأثيرات الفردية، وطور (Galvao et al. 2013) طرفاً لتقدير نماذج الانحدار التقسيمي المراقب مع تأثيرات ثابتة. لاحقاً اقترح (Galvao & Wang , 2015) مقدرات فعالة بالاعتماد على منهجية المسافة الدنيا. من جهة أخرى، اهتمت أبحاث حديثة بمعالجة حالات خاصة مثل النماذج المكانية (Spatial) والتقاعلات غير الخطية ; فقدم (Dai & Jin , 2021) انحداراً تقسيمياً بعدياً للنماذج المكانية مع تأثيرات ثابتة، بينما ركز (Powell , 2022) على تطوير تقييرات للانحدار التقسيمي مع تأثيرات ثابتة غير إضافية (non-additive). وفي سياق أحد، طور (Chen,2024) أسلوب التقدير بخطوتين لنموذج الانحدار التقسيمي مع تأثيراته الثابتة وتدخلات زمنية (interactive effects)، كما قدم (Yang et al. , 2024) اطاراً يجمع بين النماذج ذات المعاملات الدالية (functional-coefficient models) والتجميع الكامن في الانحدار التقسيمي للبيانات الطولية ، حيث استخدم خوارزميات عقوبية لكشف البنية التجميعية الكامنة بين الكيانات. هذه التطورات الحديثة تؤكد الحيوية المستمرة لمجال الانحدار التقسيمي للبيانات الطولية وأهمية دمج التقنيات المختلفة لتعزيز دقة النماذج.

على الرغم من تعدد الدراسات السابقة في مجال الانحدار التقسيمي للبيانات الطولية، هناك فجوة بحثية تتعلق بتحديد المجموعات الفرعية ضمن البيانات الطولية بناءً على أنماط التأثيرات المقدرة. التعرف على هذه المجموعات (العناقيد) يساهم في زيادة مرونة النمذجة وتحسين كفاءة التقدير عن طريق تجميع الوحدات ذات السلوك المتشابه. اقترح (Zhang et al. , 2019) منهجية للتجميع قائمة على الانحدار التقسيمي بهدف تحديد المجموعات الكامنة من الوحدات ذات المعاملات المتتجانسة، وبيّنت نتائجهم إمكانية تحسين دقة التقدير من خلال عملية جمع المعلومات داخل كل مجموعة. المنهجية المتبعة في هذه الدراسة تتفاقع مع عمل Zhang وزملائه من حيث المبدأ العام (دمج التجميع مع الانحدار التقسيمي)، لكنها تختلف في اعتماد خوارزميات تجميع بسيطة وشائعة

(K-means) و (K-medoids) اختبارها تحت ظروف تتضمن نسب مختلفة من القيم الشاذة لم تُفحص بعمق في الدراسات السابقة. حيث تُعد خوارزمية k-means واحدة من أكثر طرق العنقدة شيوعاً وسهولة في الاستخدام. تعتمد هذه الطريقة على تقسيم البيانات إلى عدد من المجموعات بحيث يتم تقليل المسافة بين النقاط داخل كل مجموعة. تتميز هذه الطريقة ببساطتها وكفاءتها، لكنها تعاني من الحساسية لقيم الشاذة، مما يجعل استخدامها في بعض الحالات غير مثالي. في حين تُعد k-medoids تحسيناً على طريقة k-means، حيث تعتمد على اختيار النقاط المركزية (medoids) من بين نقاط البيانات الفعلية، بدلاً من استخدام متوسط المسافات كما هو الحال في k-means. هذه الطريقة أكثر متانة في التعامل مع البيانات التي تحتوي على نقاط شاذة أو توزيعات غير متماثلة. بناءً على ما نقدم تهدف دراستنا إلى دمج تقنية الانحدار التقسيمي مع أساليب التجميع لتحديد العاقيد الكامنة بين الوحدات وتحليل سلوكها المختلف عبر الشرائح الكمية، مع التركيز بشكل خاص على تأثير القيم الشاذة على أداء كل من خوارزميتي K-medoids و K-means في هذا السياق.

2- نماذج البيانات الطولية

البيانات الطولية تمثل نوعاً من البيانات التي تجمع بين خصائص البيانات المقطعة والبيانات الزمنية. هذا يعني أن البيانات الطولية تحتوي على بعدين: الأول يمثل الزمن، والثاني يمثل الوحدات المقطعة (مثل الدول أو الشركات) (Muslim, 2009). يتم الحصول على هذه البيانات من خلال مراقبة ظاهرة معينة عبر عدة وحدات على مدى فترات زمنية متعددة. وبعد هذا النوع من البيانات مهماً جدًا لأنَّه يسمح بتحليل العلاقة بين المتغيرات عبر الزمن والوحدات المختلفة بشكل أعمق من البيانات المقطعة أو الزمنية بمفردها (Wooldridge, J. M. 2010).

تُكمن أهمية البيانات الطولية في أنها توفر معلومات غنية عن سلوك الأفراد أو الوحدات على مر الزمن، وتأخذ في الاعتبار التباينات بين الوحدات المختلفة. تتمثل بعض المزايا الرئيسية لهذه البيانات في أنها تسمح بالتحكم في التباين الفردي الذي قد يؤدي إلى نتائج منحازة إذا ما تم تجاهله. كما أنها توفر عدداً أكبر من درجات الحرية وتحسن من كفاءة التقديرات الإحصائية، مما يجعلها أداة قوية في دراسة تأثير المتغيرات غير الملحوظة (Baltagi, B. H. 2008).

نماذج البيانات الطولية تتضمن دمج النماذج المقطعة والزمنية في معادلة واحدة، حيث يمكن تمثيل نموذج البيانات المقطعة بالمعادلة التالية:

البيانات المقطعة بالمعادلة التالية:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \epsilon_i \quad (1)$$

وتمثيل نموذج السلسل الزمنية بالمعادلة:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \epsilon_t \quad (2)$$

أما نموذج البيانات الطولية فيدمج المعادلتين (1) و (2) على النحو التالي: (Abdulrazak, 2012):

$$Y_{it} = \beta_{0(i)} + \sum_{j=1}^k \beta_j X_{j(it)} + \epsilon_{(it)} \quad (3)$$

حيث ان:

Y_{it} : تمثل متغير الاستجابة للمقطع العرضي i عند الفترة الزمنية t .

$\beta_{0(i)}$: يمثل الحد الثابت للمقطع العرضي i .

β_j : يمثل معاملات الميل للأنموذج.

$X_{j(it)}$: تمثل المتغيرات التوضيحية للمقطع العرضي i عند الفترة الزمنية t .

$\epsilon_{(it)}$: يمثل الخطأ العشوائي للمقطع العرضي i عند الفترة الزمنية t .

يؤدي دمج الأبعاد المقطعة والزمنية في نماذج البيانات الطولية إلى ظهور تحديات مثل مشكلة عدم التباين (heteroscedasticity) أو مشكلة الارتباط بين الأخطاء وعدم استقرار البيانات. تنشأ هذه المشاكل لأن الجمع بين هذين البعدين يؤدي إلى تداخل في التباين على مر الزمن وفي الوحدات المقطعة المختلفة. على سبيل المثال، تشير مشكلة عدم التباين إلى الحالة التي يختلف فيها تباين الأخطاء بين الوحدات المقطعة أو على مدار الزمن، مما يعقد حسابات الخطأ المعياري ويجعل النتائج أقل موثوقية. بالإضافة إلى ذلك، قد تظهر مشكلة ارتباط الأخطاء عندما تكون الأخطاء في نفس الوحدة الزمنية أو بين الوحدات غير مستقلة عن بعضها البعض، مما قد يؤدي إلى نتائج منحازة إذا لم يتم التعامل معها بشكل صحيح.

أما فيما يتعلق بالمعاملات في نماذج البيانات الطولية، فهي تعكس العلاقة بين المتغيرات المستقلة والمعتمدة. وتكون المشكلة في كيفية التعامل مع هذه المعاملات، فهل يتم التعامل معها على أنها ثابتة (أي أنها لا تتغير بين الوحدات الزمنية والمقطعة) أم أنها عشوائية (أي أنها قد تختلف بين الوحدات أو على مدار الزمن). وفي نموذج التأثيرات الثابتة، يفترض أن تكون المعاملات ثابتة لكل وحدة، مما يساعد في التحكم في التغایر غير المرصود بين الوحدات. بينما في نموذج التأثيرات العشوائية، يفترض أن الفروقات بين الوحدات عشوائية وغير مرتبطة بالمتغيرات التوضيحية، مما قد يؤدي إلى تقديرات أكثر كفاءة إذا كان الافتراض صحيحاً (Wooldridge, J. M. 2010).

سلط هذه المشاكل الضوء على أهمية الاختيار الدقيق بين نماذج التأثيرات الثابتة أو العشوائية، استخدام اختبارات مثل اختبار المضاعف لاجرانج (Lagrange Multiplier Test) لمقارنة نموذج الانحدار التجمعي مع نماذج التأثيرات الثابتة والعلوائية. كما يتم استخدام اختبار هاسمان (Hausman Test) لاختيار النموذج الأقرب بين التأثيرات الثابتة والعلوائية. يمثل معالجة هذه التحديات عاملًا أساساً لتحسين قوة ودقة التحليل باستخدام البيانات الطولية (Baltagi, B. H. 2008).

3- الانحدار التقسيمي:

الانحدار التقسيمي هو طريقة إحصائية حديثة توفر فهماً شاملًا للعلاقة بين المتغيرات المستقلة والمتغير التابع عبر عدة نقاط مختلفة من توزيع الاستجابة. على عكس الانحدار الخطي الذي يتبع بالمتوسط الشرطي، يمكن للانحدار التقسيمي تقيير التأثيرات في نقاط مختلفة مثل الوسيط أو القيم العليا والدنيا للتوزيع، مما يجعله أداة تحليلية مرنّة وقوية (Majid, 2018). ويعتبر الانحدار التقسيمي مفيدًا بشكل خاص عندما تختلف تأثيرات المتغيرات المستقلة في قيم عالية أو منخفضة من المتغير التابع. ويُستخدم على نطاق واسع في مجالات مثل العلوم الاقتصادية، المالية، البيولوجيا، والعلوم الاجتماعية، حيث من الضروري فهم التأثيرات عبر توزيع البيانات بالكامل وليس فقط المتوسط.

تعود أصول تحليل الكميات إلى القرن التاسع عشر عندما قدم فرانسيس غالتون الكميات كطريقة لدراسة توزيع البيانات بشكل أكثر تفصيلاً من المتوسطات البسيطة. ومع ذلك، لم يتم تطوير مفهوم الانحدار بناءً على الكميات خلال ذلك الوقت، حيث هيمن الانحدار الخطي على التحليل الإحصائي في القرنين التاسع عشر والعشرين. في أواخر السبعينيات، وضع Bassett وKoenker مفهوم الانحدار التقسيمي في ورقة بحثية نشرت عام 1978، والتي وضعت إطاراً رياضياً قوياً للانحدار التقسيمي، ومنذ ذلك الحين، اكتسح الانحدار التقسيمي انتشاراً واسعاً في مجالات مثل الاقتصاد والصحة العامة.

تعرف الكميات على أنها نقاط إحصائية تقسم البيانات إلى أجزاء متساوية، وتتوفر فهماً أعمق لتوزيع البيانات. من أشهر هذه الكميات الوسيط والذي يقسم البيانات إلى نصفين متساوين. تشمل الأنواع الشائعة للكميات الأربع التي تقسم البيانات إلى أربعة أجزاء متساوية، والمئينات التي

تقسمها إلى 100 جزء متساوٍ، والعشيرات التي تقسمها إلى عشرة أجزاء. لكل نوع من هذه الكميات استخدامات محددة، حيث توفر كل منها نظرة مختلفة على توزيع البيانات (Ibrahim, 2021). تمثل الفائدة الرئيسية لاستخدام الكميات في قدرتها على تقييم فهم أعمق وأكثر دقة للبيانات، خاصة عندما تكون البيانات منحرفة أو تحتوي على قيم متطرفة، مما يجعلها تمثل التوزيع بشكل أفضل.

لنفترض أن دالة التوزيع التراكمي (CDF) للمتغير العشوائي Y هي $F(y) = p(Y \leq y)$ وتحتوي على دالة الكثافة الاحتمالية $f(y)$ يتم تعريف الكمي $th - \tau$ على النحو التالي (Huang and Nguyen, 2018)

$$Q_\tau(y|x) = F^{-1}(\tau) = \inf\{v: F(v) > \tau\} \quad (4)$$

حيث $0 < \tau < 1$ ، في حالة النموذج الانحدار التقسيمي في الربع الثاني والذي يمثل الوسيط $Q_{\tau=0.5}(y|x)$. من ناحية أخرى، تهدف نماذج الانحدار التقليدية (مثل الانحدار المتوسط) إلى تقدير القيمة المتوقعة L عن طريق تقليل دالة فقدان الخاصة بالخطأ التربيعي $E(y - E(y|x))^2$ ، في حين يهدف نموذج الانحدار التقسيمي إلى تقليل دالة فقدان الخطأ المطلق $E|y - E(y|x)|$.

لكن الانحدار التقسيمي يركز على نمذجة الكم الشرطي $Q_\tau(y|x)$ بحيث يتحقق الشرط التالي:

$$P(Y \leq Q_\tau) = \tau \quad (5)$$

لتلبية هذا الشرط، تتضمن الطريقة تقليل الفرق بين Q_τ و Y باستخدام دالة فقدان كما يلي:

$$\begin{aligned} \rho_\tau(e) &= e \cdot (\tau - I\{e \leq 0\}) = \begin{cases} \tau|e| & ; e > 0 \\ (1 - \tau)|e| & ; e < 0 \end{cases} \quad (6) \\ &= \frac{|e| + (2\tau - 1)e}{2} \end{aligned}$$

حيث ان:

$I\{\cdot\}$: يمثل دالة المؤشر القياسية

لحساب الكميات المرصودة Q_τ ، نقوم بقليل القيمة المتوقعة لدالة الخسارة:

$$\begin{aligned} E[\rho_\tau(e)] &= E[\rho_\tau(Y - Q_\tau(y|x))] = F^{-1}(\tau)\mu = \\ &= \int_{-\infty}^{\infty} \rho_\tau(y - \mu) f(y) dy \\ &= \frac{1}{n} \sum_{i=1}^n \rho_\tau(y_i - \mu) \quad (7) \end{aligned}$$

في هذه الصيغة، نبحث عن القيمة المثلثي L μ التي تقلل القيمة المتوقعة لدالة الخسارة. يمكن صياغة نموذج الانحدار التقسيمي على النحو التالي:

$$y_i = x_i^T \beta(\tau) + e_i(\tau), i = 1, 2, \dots, n \quad (8)$$

حيث يمثل e_i الخطأ العشوائي، وتكون كثافته $f_\tau(e_i)$ تحقق الشرط الاحتمالي التالي:

$$P(e_i(\tau) < 0) = \int_0^{-\infty} f_\tau(e_i) de_i = \tau \quad (9)$$

للحصول على تقديرات معلمات الانحدار التقسيمي $\beta(\tau)$ ، يتم حل مشكلة التقليل التالية:

$$\hat{\beta}(\tau) = \arg \min_{\beta} \sum_{i=1}^n \rho_\tau(y_i - x_i^T \beta(\tau)) \quad (10)$$

تسمح هذه العملية بتحديد معلمات الانحدار التي تقلل الخطأ الخاص بالكم، مما يوفر إطاراً متيناً لفهم النقاط المختلفة في توزيع المتغير التابع.

4- الانحدار التقسيمي للبيانات الطولية

ان اختيار نموذج التأثيرات الثابتة في هذه الدراسة مبني على الرغبة في السيطرة على الخصائص النوعية الثابتة وغير المشاهدة لكل وحدة، كما أن استخدام التأثيرات الثابتة مناسب لأن افتراضات التأثيرات العشوائية قد لا تكون صحيحة في سياق الانحدار التقسيمي، إذ تتطلب استقلالية التأثيرات عن المتغيرات المستقلة وهو شرط يصعب تحقيقه عملياً. يوفر نموذج التأثيرات الثابتة قدرأً أكبر من الموثوقية في تقدير تأثير المتغيرات عبر مختلف الكميات مع التخلص من تأثير الفروق الثابتة بين الوحدات (مثل الحجم أو النقاقة في حالة الشركات أو الدول) مما يقلل التحيز في التقدير من التحديات المعروفة في تقدير نماذج الانحدار التقسيمي ذات التأثيرات الثابتة ، فعلى الرغم من أن طريقة "تحويل داخل الوحدة" (Within-Transformation) يمكن تطبيقها بسهولة في النماذج الخطية من خلال إزالة المتوسط لكل وحدة، إلا أن هذا النهج يصبح أكثر تعقيداً في الانحدار التقسيمي نظراً للطبيعة غير المتماثلة لدالة خسارة الكميات (Check Function). تعني عدم الخطية في هذه الدالة، لذا فإن إزالة المتوسط أو توسيط البيانات لكل وحدة قد يؤدي إلى تشويه توزيع الأخطاء أو شكل دالة الانحدار التقسيمي (Galvao et al., 2018).

بالإضافة إلى ذلك، يظهر ما يُعرف بمشكلة "المعلمات العرضية" (Incidental Parameters) عند تقدير التأثيرات الثابتة الفردية لكل وحدة، خاصة في النماذج غير الخطية مثل الانحدار التقسيمي. تنشأ هذه المشكلة بسبب العدد الكبير من المعلمات مقارنة بحجم العينة لكل وحدة، مما يؤدي إلى انحياز في التقدير، لا سيما عندما يكون عدد الوحدات كبيراً (Arellano & Bonhomme, 2016). علاوة على ذلك، فإن التحويلات الخطية الشائعة في الانحدار الخطى، مثل طرح المتوسط الخاص بكل وحدة، لا يمكن تطبيقها بسهولة في الانحدار التقسيمي بسبب القيود المنهجية المتعلقة بالمتغيرات التفسيرية وتوزيع الأخطاء (Zhang et al., 2019).

تتطلب هذه التحديات استخدام تقنيات تقدير مبتكرة للتغلب على القيود الكامنة في الانحدار التقسيمي مع التأثيرات الثابتة لبيانات السلسل الزمنية المقطعة (البيانات الطولية). ومن بين هذه التقنيات، استخدام منهجية التقدير بخطوتين لتقدير نماذج الانحدار التقسيمي للبيانات الطولية مع تأثيرات ثابتة وهي مشابه لما قدمه (Canny, 2011) و (Chen et al. , 2019) و (Zhang et al., 2019) (2024).

تقدم طريقة التقدير بخطوتين حلأً عملياً للتغلب على مشكلة المعلمات العرضية في إطار الانحدار التقسيمي. تقوم هذه الطريقة بتبسيط عملية التقدير من خلال فصل إزالة التأثيرات الثابتة عن تقدير نموذج الانحدار التقسيمي نفسه، مما يساعد على تجنب التعقيبات النظرية والحسابية. لذا ولتقدير معلم نموذج الانحدار التقسيمي ذو التأثيرات الثابتة، سيتم اتباع اسلوب التقدير المكون من خطوتين:

الخطوة الأولى: يتم تقدير التأثيرات الثابتة لكل وحدة مقطع عرضي (كيان) بشكل مستقل. ويتم تقدير التأثيرات الثابتة باستخدام طريقة المربعات الصغرى، حيث يتم فصل التباين الناتج عن التأثيرات الثابتة عن المتغيرات الأخرى.

$$\hat{\alpha}_i = \frac{1}{T} \sum_{t=1}^T (y_{it} - x'_{it} \hat{\beta}_{OLS}) \quad (11)$$

الخطوة الثانية: بعد تقدير التأثيرات الثابتة في الخطوة الأولى، يتم دمج هذه التأثيرات مع القيم الأصلية للمتغير التابع لإزالة التباين الناتج عن التأثيرات الثابتة أي ان ($y_{it} - \hat{\alpha}_i = \hat{y}_{it}$) بعد ذلك، يتم تطبيق نموذج الانحدار التقسيمي لتقدير معاملات الميل أو الانحدار وفق المعادلة الآتية:

$$\hat{\beta}(\tau) = \arg \min_{\beta} \frac{1}{nT} \sum_{i=1}^n \sum_{t=1}^T \rho_{\tau}(\hat{y}_{it} - x'_{it} \tilde{\beta}) \quad (12)$$

حيث ان:

$$\rho_{\tau}(u) = u(\tau - I(u < 0))$$

(ρ_{τ}) دالة الخسارة الخاصة بالانحدار التقسيمي.
 بانتهاء هذه العملية المكونة من خطوتين، نتجنب التحيز الناتج عن التقدير المشترك لعدد كبير من العمالء العرضية مع المعامل الآخر. لقد أظهرت بحوث سابقة أن مثل هذه الإستراتيجية توفر تقييرات أكثر اتساقاً لمعامل الانحدار التقسيمي في البيانات الطولية. بعد تقيير معاملات الانحدار التقسيمي عبر مختلف الكمييات لكل وحدة، سنحصل على مجموعة من المعاملات تصف كيفية تأثير المتغيرات المستقلة على المتغير التابع عند كل كمية. عند هذه المرحلة، يمكن أن تبدأ عملية تجميع الوحدات المتشابهة بناءً على هذه المعاملات المقدرة، كما سنوضح في القسم التالي.

5- تقنيات التجميع (العنقدة)

بعد الحصول على معاملات الانحدار التقسيمي المقدرة للوحدات، يأتي دور تقنيات التجميع (Clustering) لتحديد المجموعات الفرعية من الكيانات التي تظهر أنماطاً متشابهة. في هذه الدراسة، تم اختيار خوارزميتين شهيرتين للتجميع هما K-Medoids و K-Means. يعود اختيارنا لهاتين الطريقتين إلى كونهما من أكثر الخوارزميات استخداماً وانتشاراً، فضلاً عن اختلاف خصائصهما فيما يتعلق بالتأثير بالقيم الشاذة:

عندما يُستخدم تحليل التجميع لتصنيف الحالات حيث يشتراك أعضاء المجموعات في خصائص مشتركة، يصبح من السهل على الباحث التنبؤ بسلوك هذه الحالات بناءً على عضويتها في المجموعة، نظراً لتشابه خصائص أعضاء كل مجموعة. في العادة، لا يكون عدد المجموعات أو عضوية الحالات في هذه المجموعات معروفاً مسبقاً في تحليل التجميع. ولهذا السبب، يُعتبر التجميع عملية تصنيف غير موجهة أو تعلم غير موجه (Unsupervised Learning). هذا النهج يساعد الباحث على فهم البنية الطبيعية للمجموعات واكتشاف الأنماط الكامنة بينها (Tan, Steinbach, & Kumar, 2006).

أ- طريقة K-means: هي خوارزمية شائعة وبسيطة للتعلم غير الموجه تُستخدم لتقسيم مجموعة بيانات إلى مجموعات عنقودية، حيث تنتهي كل نقطة بيانات إلى مجموعة التي يكون

متوسطها (centroid) الأقرب للنقطة. يعمل هذا المتوسط كنموذج أولي (Prototype) للمجموعة العنقدية (Jambudi, T., & Gandhi, S., 2021). تهدف الخوارزمية إلى تقليل التباين داخل المجموعة (Within-Cluster Variance)، والذي يُقاس من خلال مجموع المسافات المربعة بين نقاط البيانات ومركز المجموعات العنقدية الخاصة بها. تتميز خوارزمية K-means بالبساطة والفعالية، ويمكن تلخيص خطواتها الرئيسية كالتالي:

1. تحديد المراكز الأولية(Initial Centroids): في البداية، يتم اختيار كمراكز أولية، حيث k هو عدد المجموعات المطلوب تحديده، وهو معطى يحدده المستخدم.

2. تعيين النقاط إلى المجموعات: يتم تعيين كل نقطة بيانات إلى المركز الأقرب لها بناءً على مسافة محددة (عادةً المسافة الإقليدية). النقاط المخصصة لكل مركز تُشكل مجموعة عنقدية(Cluster).

3. تحديث المراكز(Centroid): بعد تعيين النقاط، يتم تحديث مركز كل مجموعة بناءً على متوسط النقاط في المجموعة.

4. التكرار حتى الاستقرار: تكرر الخطوات السابقة (التعيين والتحديث) حتى لا تتغير عضوية النقاط بين المجموعات، بمعنى أن مراكز المجموعات تصبح مستقرة ولا تتغير.

بـ- طريقة **K-medoids**: خوارزمية k-Medoids ، والمعروفة أيضاً باسم Partitioning Around Medoids (PAM) هي خوارزمية للتجميع مشابهة لخوارزمية k-means. بدلاً من استخدام متوسط النقاط في المجموعة كمركز (centroid) ، تختار k-medoids نقاط بيانات فعلية كمراكز (medoids). هذا يجعل الخوارزمية أكثر قوة في التعامل مع الضوضاء والقيم الشاذة مقارنة بـ k-means. تهدف هذه الخوارزمية إلى تقليل مجموع الفروقات بين نقاط البيانات والمراكز الخاصة بها. تم اقتراح طريقة k-medoids للتجميع من قبل Rousseeuw (1987) و Kaufman (1987) . تسعى الطريقة إلى العثور على k أعضاء ممثلين من مجموعة البيانات لعكس هيكل البيانات. لتطبيق هذه الطريقة، صمم المؤلفون برنامج PAM (Partitioning Around Medoids) الذي يتكون من مرحلتين، البناء والتبديل (Maechler et al., 2017).

تهدف مرحلة البناء إلى الحصول على المجموعة الأولية من (medoids) عن طريق تقليل متوسط المسافات بين الكائنات والنقطة الممثلة لها. يتم اختيار أول نقطة ممثلة على أنها الأكثر تركزاً في البيانات، ثم تحدد النقاط الأخرى بشكل تكراري. في مرحلة التبديل، يتم تحسين المجموعة الأولية من (medoids) عن طريق استبدال كل (medoid) بكافئ غير مختار وتقليل متوسط المسافات لجميع (medoids) الممثلة.

6- التجميع اعتماداً على معاملات الانحدار التقسيمي

بينما يساعد الانحدار التقسيمي في فهم تأثير المتغيرات عبر كميات مختلفة من التوزيع، إلا أنه لا يحدد تفاصيل المجموعات الفرعية داخل البيانات التي قد تظهر سلوكيات أو خصائص مختلفة. وهنا يأتي دور تقنيات التجميع. تتيح هذه التقنيات تجميع الكيانات (مثل الأفراد أو الشركات أو الدول) في مجموعات فرعية بناءً على الشابه في خصائصها أو سلوكياتها. في سياق البيانات الطولية مع الانحدار التقسيمي، يمكن تطبيق التجميع على معاملات الانحدار التقسيمي المقدرة. من خلال تجميع هذه المعاملات، يمكننا تحديد مجموعات فرعية مميزة داخل البيانات المقطعة تستجيب بشكل مختلف لنفس المتغيرات التقسيمية.

الخطوة الأولى لتطبيق الانحدار التقسيمي على البيانات الطولية هي تعريف النموذج. لفترض أن y_{it} يمثل المتغير التابع للوحدة i في الزمن t ، وأن x_{it} هو متوجه ذو أبعاد N من المتغيرات المستقلة للوحدة i في الزمن t يتم تعريف نموذج الانحدار التقسيمي الخطي للبيانات الطولية والنتائج من المعادلة (3) و (8) كما يلي:

$$Q_{\tau}(y_{it} | x_{it}) = \alpha_i + x'_{it} \beta_{g_i}(\tau) \quad (13)$$

حيث ان:

$$i = 1, 2, \dots, N \quad , \quad t = 1, 2, \dots, T \quad , \quad g = \{1, 2, \dots, G\}$$

$Q_{\tau}(y_{it} | x_{it})$: تمثل الكمية الشرطية τ^{th} للمتغير التابع y_{it} بشرط المتغيرات المستقلة x_{it} .

α_i : تمثل التأثيرات الثابتة الفردية للمقطع العرضي i .

$\beta_{g_i}(\tau)$: تمثل معاملات المجموعة عند العنفود g_i للكمية τ .

g_i : تمثل المجموعة التي تنتهي إليها المقطع العرضي i .

G : تمثل العدد الإجمالي للعنفود.

بعد إجراء الانحدار التقسيمي عبر كميات مختلفة للبيانات المقطعة، يتم الحصول على مجموعة من المعاملات لكل كمية. تصف هذه المعاملات كيف تؤثر المتغيرات المستقلة على المتغير التابع عند نقاط مختلفة من توزيعه.

الخطوة التالية هي تطبيق تقنيات التجميع على هذه المعاملات المقدرة لتحديد المجموعات الفرعية داخل البيانات المقطعة. الفكرة هي تجميع الكيانات (مثل الأفراد أو الشركات أو الدول) بناءً على التشابه في معاملات الانحدار التقسيمي عبر الكميات المختلفة. ويتم تقديم الخوارزميات المستخدمة كالتالي:

الخطوة الأولى - تعريف النموذج: استخدم نموذج الانحدار التقسيمي الخطي للبيانات الطولية مع التأثيرات الثابتة وفقاً للمعادلة (13).

الخطوة الثانية - تقدير نماذج الانحدار التقسيمي: لكل مقطع في البيانات، يتم تقدير نموذج الانحدار التقسيمي عند كميات مختلفة (مثل النسبة 25%， 50%， 75%). هذا يؤدي إلى مجموعة من المعاملات لكل كمية وكل مقطع. حيث يتم إيجاد المعلم باستخراج المعدلات (11) و (12).

الخطوة الثالثة - إعداد بيانات المعاملات للتجميع: جمع المعاملات لكل مقطع عبر الكميات المختلفة في مصفوفة β ، بحيث تمثل الصفوف المقاطع العرضية وتتمثل الأعمدة المعاملات المتعلقة بكل كمية.

الخطوة الرابعة - تطبيق خوارزميات التجميع:

أولاً: **تطبيق خوارزمية K-means للتجميع:**

❖ التهيئة: اختيار كمراكز أولية عشوائياً من مجموعة البيانات.

❖ خطوة التعيين: يتم تعين كل نقطة بيانات β_i إلى أقرب مجموعة c_i بناءً على المسافة الإقليلية

$$\diamond \quad c_i = \arg \min_j \|\beta_i - \text{mean}(\beta)_j\|^2 \quad (14)$$

حيث أن $\text{mean}(\beta)$ مركز العنود β .

❖ خطوة التحديث: يتم تحديث مركز كل مجموعة β كمتوسط النقاط المخصصة للمجموعة

$$\text{mean}(\beta)_j = \frac{1}{|C_j|} \sum_{\beta_i \in C_j} \beta_i \quad (15)$$

❖ التقارب: يتم التتحقق مما إذا كانت المراكز قد استقرت. إذا استقرت، تكون الخوارزمية قد تقارب؛ وإلا، عُد إلى خطوة التعيين.

ثانياً: **تطبيق خوارزمية K-medoids للتجميع:**

❖ التهيئة: اختيار k عشوائياً كمراكز أولية من مجموعة البيانات.

❖ خطوة التعيين: تعين كل نقطة بيانات β_i إلى أقرب مركز c_i لتقليل إجمالي المسافة

$$c_i = \arg \min_j \|\beta_i - \text{medoid}(\beta_j)\|^2 \quad (16)$$

❖ خطوة التحديث: لكل مجموعة β ، يتم تحديد medoid جديداً عن طريق تقليل المسافة الإجمالية بين جميع النقاط داخل المجموعة:

$$\text{medoid}(\beta_j) = \arg \min_{\beta_k \in C_j} \sum_{\beta_i \in C_j} \|\beta_i - \beta_k\|^2 \quad (17)$$

❖ التقارب: التتحقق مما إذا كانت medoids قد استقرت (أي لم تحدث تغييرات كبيرة في مواقعها). إذا لم تستقر، يتم تكرار خطوات التعيين والتحديث حتى يتم الوصول إلى التقارب.

الخطوة الخامسة - تحديد المجموعات الفرعية وحساب المتغير المتوقع: بعد التجميع، يتم تعين كل مقطع إلى مجموعة محددة β ، مما يشير إلى أن المقاطع داخل نفس المجموعة تشتراك في أنماط مشابهة للانحدار التقسيمي. يتم حسب القيم المتوقعة $\hat{\beta}$ لكل مجموعة β باستخدام المعاملات الخاصة بالمجموعة:

حيث $\hat{\beta}_t$ هو مركز المجموعة β .

الخطوة السادسة - حساب متوسط مربعات الخطأ: (MSE) احسب متوسط مربعات الخطأ لكل كمية، باستعمال المعادلة:

$$MSE(\tau_i) = \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T (y_{it} - \hat{y}_{it}(\tau_i))^2 \quad (19)$$

الخطوة السابعة - اختيار أفضل نموذج: يتم تحديد المعاملات الخاصة بالمجموعة β_t التي تقلل من متوسط مربعات الخطأ (MSE) لكتيبة معينة، ويتم اعتبار النموذج المحدد هو الأفضل لتمثيل أنماط البيانات المرتبطة بالكميات.

7- المحاكاة

في هذا البحث، تم اعتماد المحاكاة كمنهج أساسى لتقييم أداء نماذج الانحدار التقسيمي للبيانات الطولية مع الأخذ بعين الاعتبار تأثير تطبيق طرق تجميع هي K-Means، K-Medoids كإطار محاكاة محكم نظرًا لقدرته على تمثيل سلوك الظواهر بشكل دقيق ويسطير عليه. تم تصميم برنامج المحاكاة باستخدام لغة MATLAB ، حيث شملت التجربة خطوات تفصيلية لضمان دقة التقدير والتقييم.

بدأت المحاكاة بتحديد حجم العينة بناءً على سيناريوهات مختلفة لأحجام المقاطع العرضية (20،30) وفترات زمنية (6،18)، بهدف تمثيل سيناريوهات متنوعة وتحليل تأثير تغيير الأبعاد على أداء النماذج. ولتطبيق طرق العنقدة، تم تحديد عدد العناقيد مسبقاً بخمسة مستويات (2،3،4،5،6). كما تم اعتماد قيم أولية للمعلم $\alpha_0 = -0.70$ ، $\beta_1 = 0.166$ ، $\beta_2 = 0.0022$ ، $\beta_3 = -0.182$.

افتراض أن المتغيرات التوضيحية تتبع توزيعات مختلفة لضمان تمثيل سيناريوهات متنوعة، حيث ولد المتغير الأول من توزيع طبيعي $x_1 \sim N(7.19, 4.1)$ ، والمتغير الثاني من توزيع بواسون $x_2 \sim P(6.483)$ ، والمتغير الثالث من توزيع منتظم $x_3 \sim U(0, 0.22)$.

أما الأخطاء العشوائية، فقد ولدت من توزيع طبيعي أساسى $\epsilon_{it} \sim N(0, 0.2)$ مع إضافة نسبة من القيم الشاذة المولدة من توزيع طبيعي مختلف $\theta \sim N(2, 3)$ لتحقيق التوزيع العشوائي للأخطاء، تم دمج القيم الأساسية والشاذة بطريقة تضمن تمثيل الظاهرة بدقة. تم توليد المتغير التابع باستخدام القيم الأولية المفترضة للمعلم والمتغيرات التوضيحية والخطأ العشوائي وفق المعادلة: أجريت عملية المحاكاة لتقدير معلم الانحدار التقسيمي واستخدام طرق العنقدة لتحديد المجموعات الفرعية ذات الخصائص المتشابهة. كما تم اعتماد معيار متوسط مربعات الخطأ (MSE) كأداة للمقارنة بين الطرق المختلفة لتحديد الطريقة المثلثى. لضمان استقرار النتائج، تكررت المحاكاة 1000 مرة لكل سيناريو.

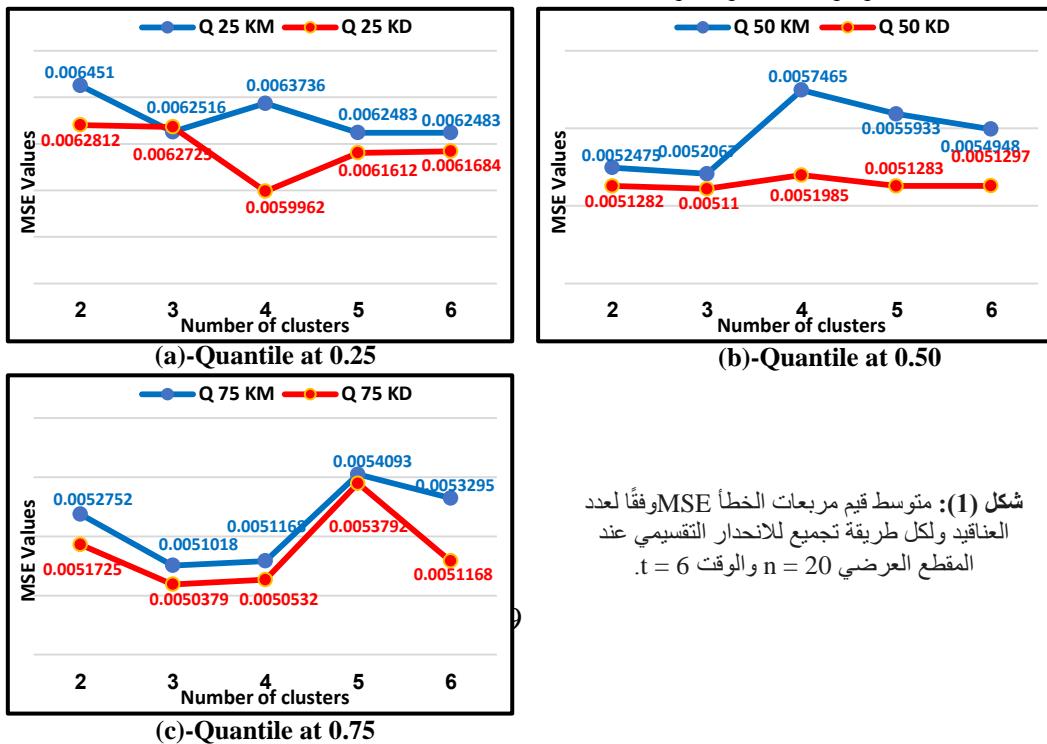
جدول (1): متوسط مربعات الخطأ (MSE) لنموذج الانحدار التقسيمي بالاعتماد على العنقدة لـ K من العناقيد وعدد المقاطع العرضية n=20 ولفترات زمنية (t=6,18) ونسبة شواز (%) 40

time	K	Q 25		Q 50		Q 75	
		KM	KD	KM	KD	KM	KD
6	2	0.006451	0.0062812	0.0052475	0.0051282	0.0052752	0.0051725
	3	0.0062516	0.0062725	0.0052067	0.00511	0.0051018	0.0050379
	4	0.0063736	0.0059962	0.0057465	0.0051985	0.0051168	0.0050532
	5	0.0062483	0.0061612	0.0055933	0.0051283	0.0054093	0.0053792
	6	0.0062483	0.0061684	0.0054948	0.0051297	0.0053295	0.0051168
	18	2	0.0047799	0.0046146	0.0040611	0.004387	0.0041827

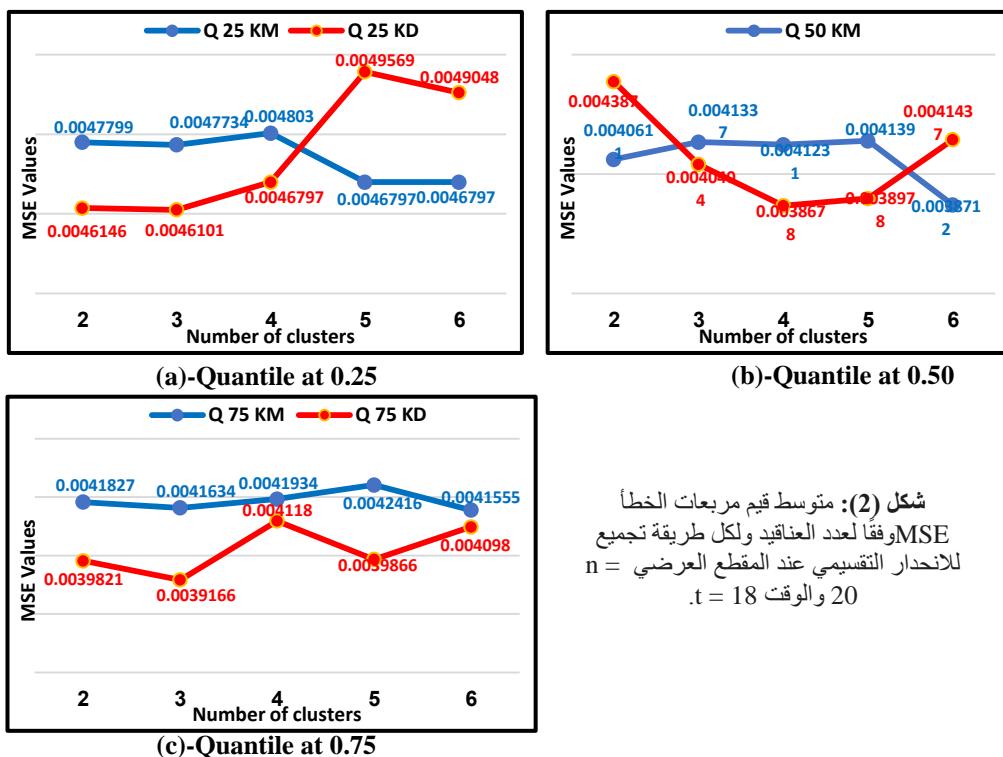
	3	0.0047734	0.0046101	0.0041337	0.0040404	0.0041634	0.0039166
	4	0.004803	0.0046797	0.0041231	0.0038678	0.0041934	0.0041118
	5	0.0046797	0.0049569	0.004139	0.0038978	0.0042416	0.0039866
	6	0.0046797	0.0049048	0.0038712	0.0041437	0.0041555	0.004098

يتضح من خلال الجدول رقم (1) ولعدد مقاطع عرضية (n=20) ان في الفترة الزمنية $t=6$ تتفاوت دقة الطرقتين (KM و KD) عبر الكميات المختلفة، مع ملاحظة تفوق KD بشكل عام، خصوصاً عند نسبة شواز مرتفعة (40%). عند الكمية (Q25) ، تكون قيم متوسط مربعات الخطأ (MSE) مرتفعة نسبياً لكلا الطريقتين بسبب تأثير القيم الدنيا وتوزيع البيانات غير المنتظم. ومع ذلك، تظهر KD أداءً أفضل قليلاً من KM ، حيث تظهر مقاومة أكبر للقيم الشاذة. عند الكمية (Q50)، تكون القيم أقل بشكل عام، مما يعكس استقرار الوسيط كمية مركبة أقل تأثراً بالقيم الشاذة، وتظهر KD تفوقاً طفيفاً على KM عند نسب الشواز العالية. أما عند الكمية (Q75)، ف تكون القيم أقل من (Q25) وقريبة من (Q50)، مع تفوق ملحوظ لـ KD مقارنة بـ KM ، مما يعكس قدرتها على التعامل بشكل أفضل مع القيم المرتفعة في التوزيع. من ناحية عدد العناقيد K، تكون القيم الأقل لـ MSE عند عدد عناقيد منخفض مثل K=2 أو K=3، مما يعكس قدرة هذه الإعدادات على تجميع البيانات بشكل أكثر دقة في ظل فترة زمنية قصيرة، بينما يؤدي زيادة عدد العناقيد إلى ارتفاع القيم نسبياً، مما يعكس تشتتاً أكبر داخل المجموعات.

في الفترة الزمنية $t=18$ ، تصل النماذج إلى أقصى درجات الدقة والاستقرار، مع تحقيق أقل قيم لمتوسط مربعات الخطأ (MSE) مقارنة بالفترات الزمنية الأقصر. عند الكمية (Q25)، تُظهر KD أداءً مسقراً وأفضل من KM ، مما يعكس قدرتها على التعامل مع التعامل مع التوزيع غير المتوازن للقيم الدنيا، خاصة عند نسب الشواز المرتفعة. عند الكمية (Q50)، تكون القيم الأدنى لكلا الطريقتين، مع تفوق طفيف ومستمر لـ KD ، مما يؤكّد قدرتها على تقديم نتائج دقيقة عند الكمية المركبة. عند الكمية (Q75)، تتحسن القيم بشكل كبير وتُظهر KD أداءً أفضل مقارنة بـ KM ، حيث تكون أكثر استقراراً في مواجهة القيم المرتفعة والشواز. بالنسبة لعدد العناقيد K، يظهر أن K=3 و K=4 يحققان أداءً متوازناً، مع انخفاض قيم MSE ، بينما يؤدي زيادة K إلى تشتت أكبر في العناقيد، خاصة عند وجود نسب شواز مرتفعة.



شكل (1): متوسط قيمة مربعات الخطأ MSE وفقاً لعدد العناقيد ولكل طريقة تجميع للانحدار التقسيمي عند المقطع العرضي $n = 20$ والوقت $t = 6$.



شكل (2): متوسط قيم مربعات الخطأ
 وفقاً لعدد العناقيد ولكل طريقة تجميع
 للانحدار التقسيمي عند المقاطع العرضية =
 $n=18$.
 . $t=20$.
 . $k=4$.
 . $n=30$.
 . $t=6,18$.

من خلال مقارنة الطريقتين (KD و KM) عبر الكميّات الثلاث (Q25، Q50، Q75)، يتضح تفوق KD في جميع الكميّات، يظهر هذا التفوق بشكل أكثر وضوحاً عند الكميّات (Q25 و Q50)، حيث تكون البيانات أكثر عرضة للتأثير بالقيم الشاذة. أما عند (Q75)، فتكون الفروقات بين الطريقتين أقل، مع استمرار التفوق الطفيف لـ KD. يعكس ذلك أن KD هي الخيار الأمثل عند التعامل مع البيانات التي تحتوي على قيم شاذة أو توزيعات غير متجانسة، مما يجعلها أكثر ملاءمة لتحليل البيانات الطولية المعقّدة عند (n=20). الشكل (1) و (2) يوضحان القيم المثلثيّة لـ MSE عند كل مجموعة ويلاحظ أن أفضل القيم تقع بين k=3 و k=4.

جدول (2): متوسط مربعات الخطأ (MSE) لنموذج الانحدار التقسيمي بالاعتماد على العنقدة (K-medoids, means) لـ K من العناقيد وعدد المقاطع العرضية n=30 ولفترات زمنية (t=6,18) ونسبة شواد (40%).

جدول (2): متوسط مربعات الخطأ (MSE) لنموذج الانحدار التقسيمي بالاعتماد على العنقدة (K-medoids, means) لـ K من العناقيد وعدد المقاطع العرضية n=30 ولفترات زمنية (t=6,18) ونسبة شواد (40%).

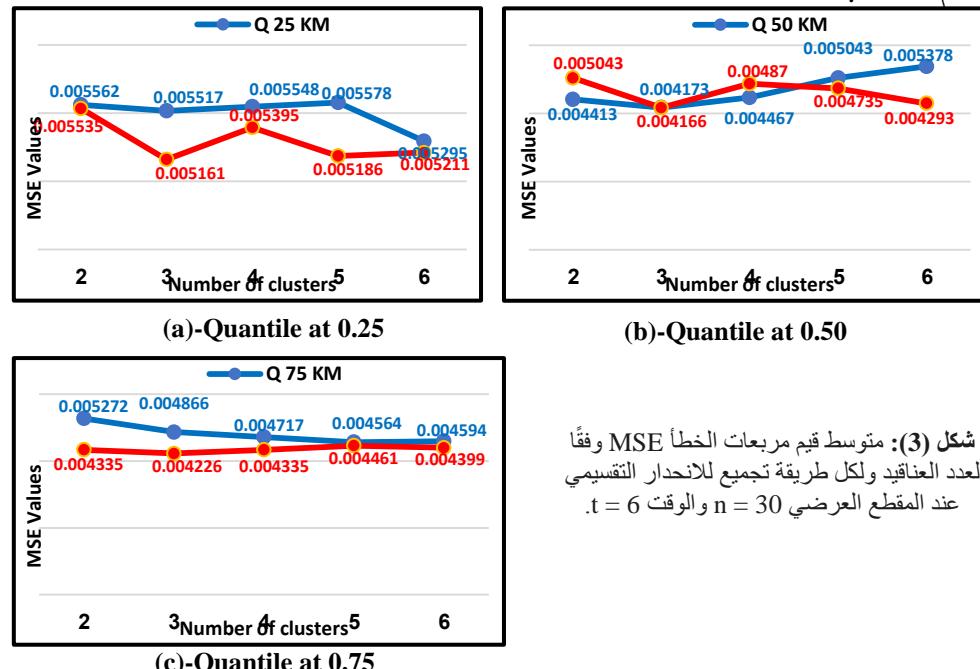
time	K	Q 25		Q 50		Q 75	
		KM	KD	KM	KD	KM	KD
6	2	0.005562	0.005535	0.004413	0.005043	0.005272	0.004335
	3	0.005517	0.005161	0.004173	0.004166	0.004866	0.004226
	4	0.005548	0.005395	0.004467	0.004870	0.004717	0.004335
	5	0.005578	0.005186	0.005043	0.004735	0.004564	0.004461
	6	0.005295	0.005211	0.005378	0.004293	0.004594	0.004399
	18	0.003955	0.003865	0.003441	0.003693	0.003486	0.003363

3	0.003949	0.003853	0.003527	0.003385	0.003454	0.003218
4	0.003994	0.003855	0.003547	0.003394	0.003497	0.003235
5	0.003932	0.003921	0.003388	0.003422	0.003488	0.003278
6	0.003929	0.003929	0.003533	0.003432	0.003318	0.003264

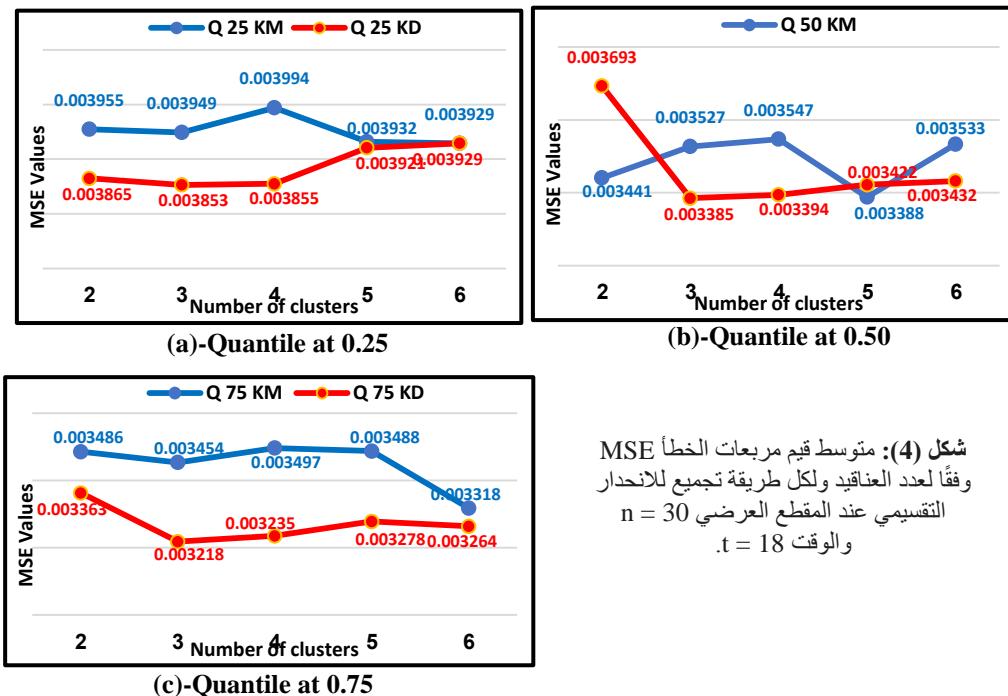
من الجدول رقم (2) ولعدد مقاطع عرضية ($n=30$) يتضح انه في الفترة الزمنية $t=6$ ، تظهر القيم الأعلى لمتوسط مربعات الخطأ (MSE) مقارنة بالفترات الزمنية الأطول، مما يعكس تأثير قصر الفترة الزمنية على دقة النماذج. بالنسبة للكمية (Q25)، تكون القيم مرتفعة نسبياً، لكن KD تُظهر تفوقاً بسيطاً على KM ، مما يعكس مقاومتها الأفضل لتأثير الشواد. عند الكمية (Q50)، تكون القيم أقل وتنبئ أداءً أكثر استقراراً، مع تفوق ملحوظ لـ KD، أما عند (Q75)، تكون القيم أقل مقارنة بـ KM، مع استمرار تفوق KD الذي يظهر قدرتها على التعامل مع القيم الأعلى في التوزيع. بالنسبة لعدد العناقيد K، تحقق القيم المثلث عند $K=3$ أو $K=4$ ، حيث يتم ملاحظة انخفاض في القيم، بينما تؤدي زيادة K إلى ارتفاع طفيف بسبب زيادة شتت العناقيد.

في الفترة الزمنية $t=18$ ، تصل القيم إلى أدنى مستوياتها عبر الفترات الزمنية، مما يشير إلى تحسين كبير في دقة النماذج واستقرارها مع زيادة طول الفترة الزمنية. عند نسبة شواد 40%， تظل KD متفوقة على KM في جميع الكميات تقريباً، مما يعكس مقاومتها الأفضل لتأثير القيم الشديدة. بالنسبة لعدد العناقيد K، يلاحظ أن $K=3$ أو $K=4$ يحققان الأداء الأفضل، مع انخفاض كبير في قيمة MSE.

عبر الفترات الزمنية المختلفة، يظهر أن زيادة طول الفترة الزمنية تؤدي إلى تحسين كبير في دقة النماذج وتقليل متوسط مربعات الخطأ (MSE). يظهر تفوق KD بشكل ملحوظ على KM، عند نسب الشواد المرتفعة (40%) ، مما يعكس قدرتها على التعامل مع القيم الشديدة وتقليل تأثيرها. بالنسبة للكميات المختلفة، يُعد (Q50) الأكثر استقراراً ودقة، بينما تتأثر (Q25) بالقيم العليا للتوزيع، وتنبئ (Q75) قدرة جيدة للنماذج على التعامل مع القيم العليا. من حيث عدد العناقيد، تحقق $K=3$ أو $K=4$ توازناً مثالياً بين دقة التجميع واستقرار النتائج، مما يجعلها الخيار الأمثل في معظم الحالات.



شكل (3): متوسط قيم مربعات الخطأ MSE وفقاً لعدد العناقيد ولكل طريقة تجميع للاحذار التقسيمي عند المقطع العرضي $n=30$ والوقت $t=6$.



شكل (4): متوسط قيم مربعات الخطأ MSE وفقاً لعدد العناقيد وكل طريقة تجميع للانحدار التقسيمي عند المقطع العرضي 30 n = 30 والوقت t = 18.

في الشكل (3) و(4)، فنلاحظ نمطاً مشابهاً للحالة السابقة: القيم الأقل لـ MSE تحقق عند $K=3$ ، بينما تؤدي زيادة K فوق ذلك إلى ارتفاع طفيف في MSE. ويمكن تفسير ذلك بأن تقسيم الوحدات إلى 3 مجموعات يوازن بين الحصول على تجانس كافٍ داخل كل مجموعة وعدم الإفراط في التقسيم.

8- الاستنتاجات

بناءً على تحليل نتائج تجارب المحاكاة، تكشف نتائج الجداول (1) و(2) أن أداء نماذج الانحدار التقسيمي يتأثر بشكل واضح بعوامل متعددة، أبرزها طول الفترة الزمنية، نسبة القيم الشاذة، عدد العناقيد، ومستوى الكمية المدروسة. يظهر تأثير طول الفترة الزمنية في انخفاض متوسط مربعات الخطأ (MSE) بشكل ملحوظ مع زيادة t من 6 إلى 18، مما يشير إلى أن الفترات الزمنية الأطول تساهم في تحسين دقة النماذج واستقرارها.

كما تُظهر نسبة القيم الشاذة تأثيراً كبيراً على دقة النماذج، حيث تؤدي النسبة العالية (40%) إلى زيادة القيم غير المتوقعة وتشتيت النتائج. رغم ذلك، أثبتت طريقة KD تفوقها في معالجة البيانات ذات النسب المرتفعة من القيم الشاذة مقارنة بطريقة KM، حيث سجلت قيمة أقل وأكثر استقراراً لمتوسط مربعات الخطأ عبر مختلف السيناريوهات.

أما بالنسبة لتأثير مستويات الكمية، فإن الوسيط (Q50) أثبت أنه المستوى الأكثر استقراراً ودقة، حيث سجل أدنى قيمة لمتوسط مربعات الخطأ، مما يجعله الخيار الأمثل لتحليل تأثير مستويات المتغيرات المستقلة على البيانات. من جهة أخرى، أظهرت الكمية (Q25) تأثيراً نسبياً أكبر بالقيم الدنيا، في حين حققت (Q75) أداءً جيداً خاصة في تحليل القيم العليا للتوزيع.

وفيمما يتعلق بعدد العناقيد، فإن الإعدادات المثلثية تتراوح بين $K=3$ و4، حيث أظهرت هذه القيم توازناً مناسباً بين دقة التجميع وثبات النتائج. بينما يؤدي زيادة عدد العناقيد عن هذا النطاق إلى تشتت أكبر داخل المجموعات وارتفاع في قيمة متوسط مربعات الخطأ.

بناءً على هذه النتائج، يمكن استنتاج أن فعالية نماذج الانحدار التقسيمي تتعزز من خلال اختيار تقنيات التجميع المناسبة مع ضبط العوامل المؤثرة. تظهر طريقة KD كخيار أكثر موثوقية عند التعامل مع البيانات التي تحتوي على نسب مرتفعة من القيم الشاذة، بينما يمثل الوسيط (Q50) المستوى الأنسب لتحليل الأنماط العامة.

كما نوصي اعتماد الانحدار التقسيمي في الدراسات الاقتصادية لتحليل تأثير المتغيرات (مثل الدخل، الاستثمار، أو التجارة) عبر شرائح مختلفة من التوزيع، مما يوفر فهماً أدق للنقاوت بين الدول أو الأفراد. واستخدام تقنيات العنقة لتصنيف الدول أو الشركات ضمن مجموعات متGANسة سلوكياً، مما يساعد في تحصيص السياسات الاقتصادية وتوجيه الدعم أو القرارات بناءً على خصائص كل مجموعة. كذلك التركيز على تحليل الوسيط (Q50) عند دراسة متغيرات اقتصادية غير متGANسة، مثل الناتج المحلي الإجمالي أو الاستهلاك، كونه يعكس الواقع الاقتصادي بشكل أكثر استقراراً من المتوسط الذي يتأثر بالقيم الشاذة.

المصادر

- 1 Abdulrazak, ali S. (2012). Estimation of Missing Data in Panel Data Model with Practical Application. A thesis to the College of Administration and Economics, University of Baghdad.
- 2 Canay, I. A. (2011). A simple approach to quantile regression for panel data. *Econometrics Journal*, 14(3), 368-386.
- 3 Chen, L. (2024). Two-step estimation of quantile panel data models with interactive fixed effects. *Econometric Theory*, 40(2), 419-446.
- 4 Dai, X., & Jin, L. (2021). Minimum distance quantile regression for spatial autoregressive panel data models with fixed effects. *Plos one*, 16(12), e0261144.
- 5 Galvao, A. F. (2011). Quantile regression for dynamic panel data with fixed effects. *Journal of Econometrics*, 164(1), 142-157.
- 6 Galvao, A. F. and Wang, L. (2015) Efficient minimum distance estimator for quantile regression fixed effects panel data. *Journal of Multivariate Analysis*, 133, 1-26.
- 7 Galvao, A. F., Lamarche, C., & Lima, L. R. (2013). Estimation of censored quantile regression for panel data with fixed effects. *Journal of the American Statistical Association*, 108(503), 1075-1089.
- 8 Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques* (3rd ed.). Morgan Kaufmann.
- 9 Huang, M. L., & Nguyen, C. (2018). A nonparametric approach for quantile regression. *Journal of Statistical Distributions and Applications*, 5, 1-14.
- 10 Ibrahim, Marwa Khalil. (2021). Bivariate Quantile regression model Estimation for Children Growth in Iraq. The Ph. D to the College of Administration and Economics, University of Baghdad
- 11 Jambudi, T., & Gandhi, S. (2021). Analysing the effect of different Distance Measures in K-means Clustering Algorithm. *GLS KALP: Journal of Multidisciplinary Studies*, 1(3), 49-57.

- 12 Kato, K., Galvao Jr, A. F., & Montes-Rojas, G. V. (2012). Asymptotics for panel quantile regression models with individual effects. *Journal of Econometrics*, 170(1), 76-91.
- 13 Koenker, R. (2004) Quantile regression for longitudinal data. *Journal of Multivariate Analysis*, 91, 74-89.
- 14 Koenker, R. (2005). *Quantile Regression*. Cambridge University Press.
- 15 Koenker, R., & Bassett, G. (1978). Regression quantiles. *Econometrica*, 46(1), 33-50.
- 16 Lamarche, C. (2010). Robust penalized quantile regression estimation for panel data. *Journal of Econometrics*, 157(2), 396-408.
- 17 M. Arellano, and S. Bonhomme, (2016). Nonlinear panel data estimation via quantile regressions. *The Econometrics Journal*, Vol. 19, no. 3, pp. C61–C94.
- 18 Majid, Haytham H. (2018). Modified Estimators for parameters in TQR Model by using Hierarchical Bayesian method With practical Application. The Ph. D to the College of Administration and Economics, University of Baghdad.
- 19 Muslim, Basim .S. (2009). Bayesian Analysis For Regression Panel Data Models. The Ph. D to the College of Administration and Economics, University of Baghdad.
- 20 Powell, D. (2022). Quantile regression with nonadditive fixed effects. *Empirical Economics*, 63(5), 2675-2691.
- 21 Schubert, E., & Rousseeuw, P. J. (2019). Faster k-medoids clustering: improving the PAM, CLARA, and CLARANS algorithms. In *Similarity Search and Applications: 12th International Conference, SISAP 2019, Newark, NJ, USA, October 2–4, 2019, Proceedings* 12 (pp. 171-187). Springer International Publishing.
- 22 Tan, P. N., Steinbach, M., & Kumar, V. (2006). *Introduction to Data Mining*. Addison-Wesley.
- 23 Wooldridge, J. M. (2010). *Econometric Analysis of Cross Section and Panel Data* (2nd ed.). MIT Press.
- 24 Xiaorong Yang & Jia Chen & Degui Li & Runze Li, (2024). Functional-Coefficient Quantile Regression for Panel Data with Latent Group Structure. *Journal of Business & Economic Statistics*, Taylor & Francis Journals, vol. 42(3), pages 1026-1040, July.
- 25 Zhang, Y., Wang, H. J., & Zhu, Z. (2019). Quantile-regression-based clustering for panel data. *Journal of Econometrics*, 213(1), 54-67.