

تقدير انموذج انحدار داربن المكاني شبه المعلمي باستعمال بعض الطرائق الالاعلمية

Estimating the Semi Parametric Durbin spatial regression model using some Non-Parametric methods

أ.م.د. وفاء جعفر حسين⁽²⁾

مريم حازم رزاق⁽¹⁾

كلية الادارة والاقتصاد/جامعة واسط

المستخلص

تناول هذا البحث دراسة وتحليل البيانات المكانية، حيث ركز على تقدير انموذج انحدار ديربن المكاني شبه المعلمي (SP-SDM)، اذ تم تقدير معلمة الاعتماد المكاني (ρ) في الانموذج باستعمال طريقة الامكان الاعظم (MLE) أما دالة التمهيد $m(\bar{X})$ فقد تم تقديرها باستعمال طريقتين لاعلمية، وهي (طريقة الأوراكل Oracle، وطريقة انحدار النواة من نوع الالتفاف ConK)، كما اجريت تجارب المحاكاة باستعمال برنامج MATLAB اذ تم اخذ (9) أحجام من العينات المختلفة وبالاعتماد على معيار متوسط مربعات الخطأ MSE لمعرفة كفاءة الطرائق المستعملة. من اهم الاستنتاجات التي توصل اليها ان القيم التي تعبر عن المسافة الاقليدية تظهر انخفاضاً ملحوظاً حيث كلما كانت القيم أصغر، كانت الطريقة أفضل وأكثر دقة حيث نلاحظ كلما تغير حجم العينة تتغير هذه القيم، ونلاحظ ايضاً أن أداء طريقة الأوراكل (Oracle) يظهر دائماً نتائج متفوقة (قيم اقل) مقارنة بطريقة (ConK).

الكلمات الرئيسية: الاعتماد المكاني، مصفوفة الأوزان المكانية، مصفوفة الأوزان المعتمدة على المسافة، نموذج انحدار داربن المكاني شبه المعلمي (Sp-SDM).

Abstract

where it focused on 'This research dealt with the study and analysis of spatial data where the spatial 'estimating the semi-parametric spatial regression model (SP-SDM) dependence parameter (ρ) in the model was estimated using the maximum likelihood while the bootstrap function (X) was estimated using two non-parametric 'method (MLE) which are the Oracle method and the convolution kernel regression method 'methods where (9) sizes of '(ConK). Simulation experiments were also conducted using MATLAB different samples were taken and based on the mean square error (MSE) criterion to know the efficiency of the methods used. One of the most important conclusions reached is that where the smaller 'the values expressing the Euclidean distance show a noticeable decrease where we notice that these values 'the better and more accurate the method is 'the values

and we also notice that the performance of the 'change whenever the sample size changes'. Oracle method always shows superior results (lower values compared to the Conk method).

Keywords:

semi-، distance-dependent weight matrix، spatial weight matrix، spatial dependence parametric spatial Durbin regression model (SP-SDM)

1-المقدمة

تؤدي الأساليب الحديثة للقياس الاقتصادي المكاني دورا مهما في تحليل العديد من الظواهر الاقتصادية والاجتماعية والصحية وغيرها ، خاصة التي تعتمد على البيانات المكانية ، ويعد الانحدار المكاني احد هذه النماذج التي تسعى لفهم الترابطات المكانية بين المشاهدات المختلفة للظواهر المدروسة. تظهر اهمية دراسة التفاعلات المكانية لأنها تمثل عاملا اساسيا يؤثر على دقة النماذج المستعملة ، وان من اهم النماذج الاحصائية التي تمثل الظواهر التي تعتمد على المكان هو نموذج الانحدار المكاني الذي يقوم بتحليل العلاقة بين المتغير المعتمد والمتغيرات التوضيحية في ظل وجود الاعتماد المكاني ، حيث يعتمد بصورة كبيرة على البيانات التي يحصل عليها الباحث . فان هذه البيانات ليست مستقلة بذاتها وانما تعتمد على المكان الذي تم جمع البيانات منه ، يعد تحليل تأثير الموقع على البيانات محورا اساسيا في الدراسات الحالية ، خاصة عند التعامل مع نماذج شبه معلمية التي تتميز بمرونة عالية .

في عام (2005)، قامت الباحثة (Daniela،Gumprecht) [8]، بدراسة تناولت فيها اهمية الانحدار المكاني وخصائص البيانات المكانية بالإضافة إلى الاساليب المستعملة في الكشف عن الاعتماد المكاني والارتباط الذاتي المكاني في بيانات البحث والتطوير المستعملة في البحث لمعرفة ما اذا كان الانفاق المحلي والاجنبي على البحث والتطوير له تأثير على اجمالي انتاجية العوامل في بلد ما . اذ قامت الباحثة بتقدير نموذج الانحدار الذاتي المكاني (SAR) ونموذج الخطأ المكاني (SEM) باستعمال طريقتين هما طريقة المربعات الصغرى ذات المرحلتين (2SLS) وطريقة الامكان الاعظم (MLE) وبالاعتماد على اختبار موران حيث بينت النتائج ان الانفاق المحلي على البحث والتطوير له تأثير ايجابي على اجمالي انتاجية العوامل

في عام (2011) ، قدم الباحث (عطره ،سامي غني خضير) [1] ، دراسة حول طرائق يبرز في تحليل نموذج القياس الاقتصادي المكاني (SAR) ونموذج ديرين المكاني (SDM) ونموذج الخطأ المكاني (SEM)، حيث استخدم الباحث حجم العينة (61) مريضا من الاطفال المصابين بفقر الدم الذين يرقدون في مستشفيات جانب الكرخ في بغداد وبواقع خمس مناطق جغرافية ، واقتراح حساب العناصر في المصفوفة المعدلة بناء على نسبة طول الحدود المشتركة الفعلية بين المواقع المختلفة ، مما يؤدي إلى الحصول على القيمة التقديرية الدقيقة لمعلمة الاعتماد المكاني .

2 - مشكلة البحث

في بعض الاحيان تكون هناك حاجة للتعامل مع علاقات غير خطية أو معقدة بين المتغيرات التي لا يمكن التعبير عنها بشكل دقيق باستعمال النماذج الخطية المعلمية وخاصة عندما يكون النموذج المعلمي غير كاف لتعريف العلاقات في البيانات، فعند دراسة الظواهر المختلفة نلاحظ عدم الاخذ بنظر الاعتبار التأثير المكاني واهماله مما يؤدي إلى فقدان معلومات مهمة لها الاثر الكبير على دقة التقدير لمعلمات الانموذج والحصول على نتائج غير دقيقة؛ وذلك لوجود الاعتماد المكاني بين مفردات الظاهرة.

3-هدف البحث

يهدف البحث إلى تقدير العلاقة بين المتغيرات دون افتراض شكل معين لهذه العلاقة مقدما وهذا يسمح للنموذج (نموذج انحدار ديربن الشبه معلمي Durbin Semi-Parametric Spatial Regression Model) التعرف على الانماط والاتجاهات في البيانات (التي تعاني من الاعتماد المكاني) بشكل أكثر مرونة ودقة وخاصة إذا كانت العلاقة بين المتغيرات معقدة وغير خطية، وكذلك معالجة مشكلة العلاقات اللاخطية بين المتغير المستقل والمتغير التابع التي قد تختلف حسب الموقع الجغرافي.

4-الاعتماد المكاني: Spatial Dependent

عُرفت الاعتماد المكاني من لدن (Anselin) على أنه " وجود علاقة دالية بين ما يحدث في نقطة معينة في الفضاء وبين ما يحدث في مكان آخر " [3] ففي التحليل الاحصائي يعني ان القيم المرتبطة بمواقع جغرافية قريبة ليست مستقلة عن بعضها عندها يجب اخذ هذا الاعتماد في الاعتبار عند بناء النماذج. إن الاعتماد المكاني في مجموعة من بيانات العينة يعني ان المشاهدة في الموقع (i) تعتمد على المشاهدة في الموقع (j) حيث ان $(i \neq j)$ وتكتب بالصيغة الآتية [3]:

$$y_i = f(y_j) \dots (2 - 1), i = 1, 2, \dots, n \quad i \neq j \quad (1)$$

ويلاحظ من الصيغة اعلاه ان يكون الاعتماد بين عدة مشاهدات اذ ان الموقع (i) يمكن ان يتخذ اي قيمة من قيم (n) وكذلك نلاحظ أن بيانات العينة المشاهدة في موقع ما في الفضاء تعتمد على القيم التي شوهدت في مواقع أخرى [4].

5- مصفوفة الأوزان المكانية Spatial Weight Matrix

هي وسيلة رياضية تستعمل في تحليل البيانات والاحصاءات المكانية والانحدار المكاني حيث يتم من خلالها ادخال العلاقات المكانية بين المشاهدات ضمن مساحة جغرافية معينة في الانموذج المكاني وتدعى ايضا مصفوفة الارتباط المكاني، وتحدد تأثير كل موقع على المواقع الاخرى المجاورة له، ومن اهم صفاتها عناصر قطرها الرئيسي اصفار، وموجبة (لا تحتوي قيم سالبة) [8]، مربعة ابعادها $(n \times n)$ وان n تمثل عدد المشاهدات المستعملة في الانموذج المكاني ويرمز لمصفوفة التجاور المكاني بالرمز W ، حيث إن كل صف وعمود فيها يمثل وحدة جغرافية والقيم فيها تعكس العلاقة المكانية بين الوحدات. ويمكن كتابة الصيغة العامة لمصفوفة الأوزان المكانية كما يأتي [10]:

$$W = \begin{bmatrix} W_{11} & \dots & W_{1n} \\ \vdots & \ddots & \vdots \\ W_{n1} & \dots & W_{nn} \end{bmatrix}$$

6 - الأوزان المعتمدة على المسافة: Weight Based on Distance

تُعدُّ الأوزان التي تعتمد على المسافة أحد الأساليب المهمة لتقييم العلاقات بين نقطتين أو خليتين في الفضاء الجغرافي أو الهندسي. حيث تعبر هذه الأوزان عن التأثير المتبادل بين الخليتين بناءً على المسافة بينهما حيث يرمز للمسافة عادة بالرمز d_{ij} ويتم حسابها باستعمال المعادلات الجغرافية المناسبة ومن أهمها المسافة الإقليدية (Euclidean Distance). وتمثل أقصر مسافة مستقيمة بين نقطتين في الفضاء، ويمكن حساب المسافة الإقليدية بين نقطتين حسب الصيغة الآتية [2] :

$$d_{ij} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

ويتم بناء مصفوفة الأوزان المكانية هنا بناءً على حساب المسافة العكسية *Inverse Distance* حيث تستعمل هذه الطريقة كثيراً في تحليل البيانات المكانية *Spatial Analysis*، ويعتمد الوزن أو التأثير بين نقطتين على المسافة بينهما بشكل عكسي، أي بمعنى أنه كلما ازدادت المسافة يقل الوزن أو التأثير والعكس صحيح والصيغة العامة لحساب الوزن باستعمال المسافة العكسية هي :

$$W_{ij} = \frac{1}{d_{ij}^\alpha}$$

حيث أن d_{ij} تمثل المسافة بين وحدتين، و α تمثل معامل القوة.

7-انموذج انحدار ديربن المكاني: Durbin Spatial regression model

يعد انموذج انحدار ديربن المكاني (SDM) أحد نماذج الانحدار الذاتي المكاني (SAR) ويعتبر نوعاً متقدماً من نماذج الانحدار المكاني الذي يأخذ بالحسبان التأثيرات المكانية لكل من المتغير التابع والمتغيرات المستقلة. في نموذج الانحدار الذاتي المكاني (SAR) العلاقة المكانية تكون مقتصرة على تأثير المتغير التابع بين المواقع أما في نموذج انحدار داربن المكاني (SDM) فإن العلاقة المكانية تكون أشمل حيث تمتد لتشمل تأثير المتغيرات المستقلة في المواقع المجاورة [1]، وهذا يؤدي إلى إضافة مستوى أعمق من التفاعل المكاني. تكون مصفوفة المتغيرات المستقلة في انموذج (SAR) هي X أما في انموذج (SDM) فتكون $[X \quad WX]$ حيث يلحظ أن هناك متغيراً تفسيرياً متأخراً مكانياً، زيادة عن ذلك، متغير معتمد متأخر مكانياً في النموذج. وان الصيغة الرياضية لنموذج انحدار ديربن المكاني المعلمي تكون كالآتي [5] :

$$y = \rho W y + X \beta_1 + X \beta_2 + \varepsilon \quad (2)$$

$$\varepsilon \sim N(0, \sigma^2 I_n)$$

حيث أن ρ تمثل معلمة الاعتماد المكاني للمتغير المعتمد، Wy يمثل متجه المتغير المعتمد المتخلف مكانياً، أما β_1 تمثل متجه المعالم. ولو افترضنا

$$\tilde{X} = [X \quad WX], \theta = [\beta_1' \quad \beta_2']'$$

فإن المعادلة (2) تصبح بالشكل الآتي [6]:

$$\underline{Y} = \rho W \underline{y} + \tilde{X} \theta + \underline{\varepsilon} \quad (3)$$

إن نموذج ديرين المكاني شبه المعلمي (Sp-SDM) هو توسيع إلى أنموذج دارين المكاني المعلمي (SDM) (بأشكال دالية مرنة للمتغيرات الخارجية حيث نستبدل الصيغة الخطية θ بالدالة $m(\tilde{X})$ حيث يصبح النموذج بالشكل الآتي [6]:

$$\underline{Y} = \rho W \underline{y} + m(\tilde{X}) + \underline{\varepsilon} \quad (4)$$

8- طريقة أوراكل نوع عدم المساواة (Oracle-type Inequality)

وتعد هذه الطريقة إحدى الطرائق المهمة لتحليل البيانات التي تتضمن تفاعلات مكانية، إذ تقوم بتحديد المتغيرات التي تسهم بشكل كبير في التنبؤ سواء كانت معلمية، أو شبه معلمية ويتم هذا عبر خطوات انتقائية تعتمد على تحسين التقديرات وتقليل الأخطاء، ويعد الباحثان (Donoho and Johnstone) أول من قدموا مفهوم (Oracle-type Inequality) في عام (1994). يتم في هذه الطريقة تحديد فضاء الإسقاط (V_{a_1}, ∞) يتم باختيار أساساً مناسباً (basis function) مثل φ_k, φ_j (دوال فورير أو دوال موجيه)، أي أنه مجموعة دوال يتم انشاؤها باستعمال دوال أساس وحاصل الضرب التنتوري بينها حيث يتم استعمال هذه الفضاءات لتقريب الدالة $m(\tilde{X})$ وتحقيق التوازن بين الانحياز والتباين مع التحكم في تعقيد النموذج، ويعد فضاء الإسقاط (V_{a_1}, ∞) فضاء متجهات (vector space) يتم انشاؤه باستعمال مجموعة من الدوال التي يتم اختيارها مسبقاً والهدف منه هو بناء تمثيل تقريبي للدالة $m(\tilde{X})$ الذي نريد تقديرها ضمن هذا الفضاء: [7]

$$V_{a_1, \infty} = \text{Span}\{\hat{\varphi}_k \otimes \hat{\varphi}_j, 1 \leq j \leq a_1, a_2 \geq 1\} \quad (5)$$

حيث أن :

a_1 : تمثل عدد الدوال الأساسية في الاتجاه الأول، a_2 تمثل عدد الدوال الأساسية في الاتجاه الثاني (غير محدد)، يتم اختيار a_1, a_2 بناء على مبدأ الانحياز والتباين

Span: يشير إلى الفضاء الخطي المتولد (linear span) بواسطة مجموعة من الدوال أما الضرب التنتوري $\otimes$ هو طريقة لبناء دوال جديدة باستعمال ضرب القيم كما يلي

$$(\varphi_k \otimes \varphi_j)(x, y) = \varphi_k(x) * \varphi_j(y) \quad (6)$$

حيث أن y, x قد يمثلان متغيرين منفصلين في نفس المجال الناتج هو دالة في متغيرين ويستخدم لتقريب الدوال ذات البعدين أو أكثر. وتعد دوال الأساس φ_j, φ_k هي المكونات التي تم استعمالها لبناء فضاء الإسقاط ويمكن أن تكون هذه الدوال مختلفة الأنواع حسب المشكلة قيد الدراسة. وبما أن الدالة $m(\tilde{X})$ لا توجد لها معلومات مسبقة يمكن استعمال دوال عامة مثل دوال فورير (fourier basis) وتكون هذه الدوال مناسبة لتقريب الدوال الدورية. أما كيفية بناء الفضاء $V_{a_1, \infty}$ يمكننا تعريف كيفية بناء هذا الفضاء حسب المثال الآتي :

$$a_1 = 1, a_2 = 2, \varphi_k = \sin(kX), \varphi_j(y) = \cos(jy)$$

الضرب التنتوري للدوال الأساسية سيكون كالآتي:

$$\varphi_1 \otimes \varphi_1, \varphi_1 \otimes \varphi_2, \varphi_2 \otimes \varphi_1, \varphi_2 \otimes \varphi_2$$

وعندئذ سيكون الفضاء المتولد كما يأتي:

$$V_{a_1, \infty} = \text{span}\{\sin(x) \cos(y), \sin(x) \cos(2y), \sin(2x) \cos(y), \sin(2x) \cos(2y)\}$$

وبصورة عامة عند ضرب $\varphi_k \otimes \varphi_j$ ستكون كل قيمة إلى k, j تحدد دالة جديدة حيث ان الفضاء $V_{a_1, \infty}$ يتضمن جميع التوليفات الخطية لهذه الدوال: [7]

$$f(x, y) = \sum_{j=1}^{a_1} \sum_{k=1}^{a_2} c_{jk} (\varphi_k \otimes \varphi_j)(x, y) \quad (7)$$

ان الغرض الاساسي من استعمال فضاء الاسقاط هو التقليل من تعقيد تقدير الدالة $m(\tilde{X})$ عبر تقريبها بدالة موجودة داخل الفضاء $V_{a_1, \infty}$ وحيث ان الاسقاط العمودي المستعمل $\pi_{a_1, \infty}^\perp$ يضمن ان الدالة المقدرة هي الاقرب إلى $m(\tilde{X})$ ضمن هذا الفضاء. ويتم حساب المعيار التجريبي باستعمال البيانات $x_1, \dots, x_n$ وهو معيار رياضي يستخدم لتقييم جودة التقدير في حالة استعمال الاسقاط حيث يقيم مدى دقة الدالة المقدرة $\hat{m}(\tilde{X})$ بالمقارنة مع الدالة الحقيقية $m(\tilde{X})$ وحسب البيانات المشاهدة ويعتبر من الادوات الاساسية في تقدير الدوال اللامعلمية باستعمال فضاء الاسقاط ويتم حسابه كالآتي [7]:

$$\|T\|_n^2 = \frac{1}{n} \sum_{i=1}^n \|T(X_i)\|^2 \quad (8)$$

وعند تقدير الدالة $m(\tilde{X})$ باستعمال الاسقاط $\hat{m}(\tilde{X})_{a_1, \infty}$ سيكون المعيار التجريبي كالآتي :

$$\|m(\tilde{X}) - \hat{m}(\tilde{X})\|_n^2 = \frac{1}{n} \sum_{i=1}^n \|m(\tilde{X}) - \hat{m}(\tilde{X})_{a_1, \infty}\|_n^2 \quad (9)$$

ويتم اختيار حد الجزء $pen(a_1)$ الذي يضاف إلى معيار الخطأ التجريبي بعناية ، بهدف تحسين جودة التقدير وتكمن اهمية هذا الحد في تحقيق التوازن بين التحيز والتباين مما يساعد على ضبط أداء النموذج ، ويعمل حد الجزء $(penalty \text{ Term})$ على تقليل خطر الافراط في التكييف $(overfitting)$ وهي المشكلة التي تحدث عندما يكون النموذج معقد جدا على سبيل المثال يكون الفضاء الاسقاطي a_1 كبير جدا ومشكلة التبسيط المفرط $(under \text{ fitting})$ التي تحدث عندما يكون النموذج بسيطا جدا اي ان a_1 صغير جدا حيث تكتب الدالة بعد اضافة حد الجزء كالآتي :

$$E\|m(\tilde{X}) - \hat{m}(\tilde{X})_{a_1, \infty}\|_n^2 + c(\zeta) \cdot pen(a_1) \quad (10)$$

حيث ان $c(\zeta) \cdot pen(a_1)$ يمثل حد الجزء الذي يتم تعديله بالمعامل $c(\zeta)$ ويتم اختياره حسب المقدار الآتي :

$$\zeta > 0, \quad c(\zeta) = \frac{(2+\zeta)}{(1+\zeta)}$$

يتم اختيار حد الجزء $pen(a_1)$ بحيث يكون مرتبط مع تعقيد النموذج حيث ان تعقيد النموذج يتناسب مع عدد الأبعاد في فضاء الاسقاط حيث كلما زاد عدد الأبعاد زاد حد الجزء :

$$pen(a_1) \propto \frac{\dim V_{a_1, \infty}}{n}$$

نقوم بتحسين اختيار البعد a_1 وتُعدُّ هذه المرحلة من اهم المراحل لتقدير الدوال اللامعلمية باستعمال فضاءات الاسقاط حيث ان الهدف الاساسي من هذه المرحلة هو اختيار البعد الأفضل a_1 لفضاء الاسقاط $V_{a_1, \infty}$ الذي يحسن من جودة تقدير الدالة اللامعلمية $\hat{m}(\tilde{X})$ وكما هو معروف ان a_1 هو عدد دوال الاساس حيث كلما ازداد a_1 يزداد تعقيد النموذج أما اذا كان a_1 صغير جدا فان النموذج يكون خالياً من التعقيد حيث في هذه المرحلة سيتم اختيار القيمة المثلى a_1 بحيث يتم الموازنة بين التحيز والتباين من خلال تقليل الخطأ الكلي ويتم تحسين اختيار a_1 وفق الخطوات الآتية :

1- يتم اختيار مجموعة من القيم إلى a_1 وكالآتي مثلاً $a_1 \in \{1, 2, 3, \dots, N\}$ حيث ان N هو الحد الاعلى لعدد الابعاد في فضاء الاسقاط $V_{a_1, \infty}$.

2- حساب دالة الكلفة الآتية لكل قيمة من قيم المجموعة اعلاه وحسب الآتي:

$$c(a_1) = \|m(\tilde{X}) - \hat{m}(\tilde{X})_{a_1, \infty}\|_n^2 + c(\zeta).pen(a_1) \quad (11)$$

3- يتم اختيار البعد a_1^* الذي يقلل دالة الكلفة اعلاه:

$$a_1^* = \operatorname{argmin}_{a_1} c(a_1)$$

وبعد تحديد البعد الامثل a_1^* يتم تحديد الفضاء الامثل $V_{a_1^*, \infty}$ الذي يتكون من مجموعة من دوال الاساس φ_k

$$V_{a_1^*, \infty} = \operatorname{span} \{\varphi_1(x), \varphi_2(x), \dots, \varphi_{a_1^*}(x)\} \quad (12)$$

نجد التقدير الأفضل $\hat{m}(\tilde{X})$ للدالة $m(\tilde{X})$ باستعمال الفضاء الامثل الذي تم تحديده مسبقاً $V_{a_1^*, \infty}$ حيث تم استعمال الاسقاط العمودي لتقريب $m(\tilde{X})$ ضمن هذا الفضاء بطريقة تقلل الخطأ حيث يتم بناء $\hat{m}(\tilde{X})$ بوصفه عنصراً في الفضاء الامثل $V_{a_1^*, \infty}$ الذي يكون اقرب تقدير ممكن للدالة $m(\tilde{X})$ في هذا الفضاء . ان الاسقاط العمودي يجعل الفرق بين الدالة $m(\tilde{X})$ والتقدير $\hat{m}(\tilde{X})$ عمودياً على الفضاء $V_{a_1^*, \infty}$ ويمكن تمثيله بالمعادلة الآتية :

$$\langle m(\tilde{X}) - \hat{m}(\tilde{X}), \varphi_k \rangle = 0$$

$$\forall \varphi_k \in V_{a_1^*, \infty}$$

حيث ان المقدّر النهائي للدالة $m(\tilde{X})$ يمكن كتابته كالآتي :

$$\hat{m}(\tilde{X}) = \sum_{k=1}^{a_1^*} \hat{a}_k \varphi_k(x) \quad (13)$$

حيث ان a_k تمثل مقدار مساهمة كل دالة اساس $\varphi_k(x)$ في التقدير ويعبر عنها بمعاملات الاسقاط . ولإيجاد معاملات الاسقاط $\hat{a}_k$ يتم ذلك عن طريق تحقيق شرط الاسقاط العمودي

$$\langle m(\tilde{X}) - \hat{m}(\tilde{X}), \varphi_k \rangle = 0 \quad \forall k = 1, 2, \dots, a_1^*$$

وهذا بدوره سوف يؤدي إلى نظام من المعادلات الخطية وكالآتي:

$$\sum_{j=1}^{a_1^*} \hat{a}_j \langle \varphi_j, \varphi_k \rangle = (m(\tilde{X}), \varphi_k) \quad \forall k$$

ولضمان الأداء المتوقع للمقدر النهائي $\hat{m}(\tilde{X})_{a_1^*, \infty}$ واختيار البعد a_1^* بطريقة التوازن بين خطأ التقريب وخطأ التباين ولفهم أداء المقدر النهائي وكيفية تحسينه بناء على a_1 وحجم العينة يتم تطبيق المعادلة الآتية [7]:

$$E \|m(\tilde{X}) - \hat{m}_{a_1, \infty}(\tilde{X})\|_n^2 \leq (1 + \zeta) \inf_{a_1 \in A_n} [E \|m(\tilde{X}) - \pi_{a_1, \infty}^{op} m(\tilde{X})\|_n^2 + c(\zeta) Pen(a_1) + \frac{c_0}{n}] \quad \dots (14)$$

حيث ان $(\tilde{X})$ ، $\hat{m}_{a_1, \infty}$ تمثل المقدر النهائي للدالة $m(\tilde{X})$.

9- مقدر انحدار النواة من نوع الالتفاف_Convolution type kernel regression estimator

تعد طريقة التقدير باستعمال الالتفاف Convolution type kernel regression estimator من الطرائق المستعملة لتقدير دوال الانحدار اللامعلمية حيث تقوم بإدخال تعديلات على طريقة تقدير الانحدار التقليدية التي تعتمد على النواة (Kernel) والهدف منها هو تقليل التحيز والتباين في التقديرات. ومن مميزات هذه الطريقة هي مرونة التقدير حيث لا تحتاج إلى افتراض شكل معين للدالة إذ يمكنها التعامل مع العلاقات غير الخطية بسهولة ويمكن استعمالها عند حجوم العينات المختلفة حيث تعمل بشكل فعال مع احجام العينات الكبيرة والصغيرة. ان مقدر ناداريا واتسون (Nadaraya-Watson) هو من طرق التقدير الشائعة باستعمال النواة (Kernel) لتقدير دالة الانحدار دون افتراض شكل محدد للارتباط بين المتغيرات وهي من الطرائق البسيطة وسهلة الفهم ، لكنها قد لا تكون مثالية في البيانات ذات التوزيع الغير متجانس ويكون هذا المقدر معدل موزون ومحدد للقيم حيث ان دالة النواة (Kernel) تعطي أوزاناً أعلى للنقاط الأقرب إلى النقطة (x) وأوزاناً أقل للنقاط الأبعد وتكون صيغته كما يأتي :

$$\hat{m}(\tilde{X}) = \frac{\sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) y_i}{\sum_{i=1}^n K\left(\frac{x-x_i}{h}\right)} \quad (15)$$

يكون الالتفاف بالتعديل على دالة النواة وهو ما يسمى بمقدر غاسر ميلر Gasser-Muller Estimator ويتميز هذا المقدر بأنه يعتمد على طريقة التفاف معدلة وذلك للحصول على تقديرات أكثر دقة مقارنة بمقدرات النواة التقليدية مثل ناداريا واتسون، وخاصة عند التعامل مع بيانات غير موزعة بشكل متساو ، وتكون صيغته الرياضية بالشكل التالي: [9]

$$\hat{m}(\tilde{X}) = \sum_{i=1}^n c_i \int_{a_i}^{b_i} K\left(\frac{x-u}{h}\right) du \quad (16)$$

حيث في مقدر غاسر- ميلر نحتاج إلى تحديد حدود التكامل a_i, b_i بشكل مناسب يمكن ان تكون هذه الحدود مرتبطة بنقاط البيانات x_i مثلاً

$$a_i = 0.5(x_{i-1} + x_i)$$

$$b_i = a_i + 1$$

ولسهولة الحساب يمكن جعل $c_i = 1$ أما دالة النواة فيمكن استعمال نفس دالة النواة المستعملة في مقدر ناداريا - واتسون وبعد تعديل الحدود واختيار الأوزان يمكن كتابة مقدر غاسر – ميلر بالشكل التالي:[9]

$$\hat{m}(\tilde{X}) = \sum_{i=1}^n \int_{x_i-h}^{x_i+h} \frac{1}{h} K\left(\frac{x-u}{h}\right) du Y_i \quad (17)$$

ان هذا التحويل يساعد في تقليل التباين وتحسين دقة التقدير. ان مقدر ناداريا –واتسون يستخدم لتقدير القيم المتوقعة لدالة الانحدار بناءً على نقاط البيانات المعطاة وهو يعتمد على حساب المتوسط الموزون للقيم بناءً على المسافة من النقطة المستهدفة باستعمال دالة النواة، أما مقدر غاسر – ميلر فهو يعزز فكرة تقدير القيم المتوقعة عن طريق استعمال تكامل دالة النواة حول نقطة معينة مما يسمح بجمع المعلومات من نطاق أوسع من البيانات.

10 - المحاكاة

سوف يتم هنا استعمال أسلوب المحاكاة (Simulation Procedure) لغرض تطبيق طرائق التقدير اللامعلمية التي تم التطرق إليها في الجانب النظري وذلك من اجل الوصول إلى أفضل طريقة تقدير نموذج انحدار داربن المكاني شبه المعلمي (SPSDM) اذ تم استعمال معيار متوسط مربعات الخطأ (MSE). و من خلال استعمال برنامج (MATLAB) تم تنفيذ عدد من تجارب المحاكاة وبالاتماد على عينة حجمها (9)، وهي وذلك في توليد البيانات التي تخص المتغيرات العشوائية المتضمنة في نموذج انحدار داربن المكاني شبه المعلمي (SP-SDM)، واستعملت ثلاث قيم مختلفة لمصفوفة التباين والتباين المشترك والمتوسط العام وكما يأتي:

من اجل الوصول إلى نتائج أكثر دقة واتساق اذ تم الوصول إلى أفضل طريقة تقدير لأنموذج انحدار ديربن المكاني شبه المعلمي SP-SDM وكانت النتائج كما موضحة في الجداول التالية:


جدول (1-3) يمثل نتائج التقدير لجميع أحجام العينات والمقارنة بين الطرائق الالاعلمية المستعملة في تقدير النموذج

$\Sigma = I$ ، $\mu = \underline{0}$ عند

n	ConK	Oracle
10	7.8994	8.2726
15	6.3444	6.9664
20	5.0382	5.2872
25	3.3588	3.9808
30	2.5502	2.3014
35	1.9282	1.4928
40	1.4928	0.9334
45	1.2441	0.6226
50	1.1818	0.5598

جدول (2-3) يمثل المقارنة بين الطرائق الثلاثة المستعملة حسب معيار (MSE)

<i>n</i>	<i>ConK</i>	<i>Oracle</i>
10	5.2197	5.4663
15	4.1922	4.6032
20	3.3291	3.4935
25	2.2194	2.6304
30	1.6851	1.5207
35	1.2741	0.9864
40	0.9864	0.6165
45	0.8221	0.4113
50	0.7809	0.3699



شكل (3-1) يوضح مقارنة بين الطرائق باستعمال معيار (MSE)

من نتائج التحليل في الجدول رقم (1-3) و(2-3) يمكن ملاحظة الآتي:

1 - ان معيار المسافة الاقليدية Euclidean distance ينخفض تدريجيا بزيادة حجم العينة وللطريقتين (Oracle)، Conk وهذا يدل على ان دقة التقدير تتحسن مع زيادة عدد البيانات .


2- وكذلك هو الحال عند استعمال معيار متوسط مربعات الخطأ (MSE) يتضح عند زيادة حجم العينة تظهر جميع الطرائق انخفاضا في قيم (MSE) وهذا يدل على ان التقديرات تتحسن مع زيادة حجم العينة .

جدول (3-3) يمثل نتائج المقارنة بين الطرائق عند $\underline{\mu} = \underline{0}$ ، $\Sigma = 0.5^{|i-j|}$

<i>n</i>	<i>ConK</i>	<i>Oracle</i>
10	3.8227	4.0033
15	3.0702	3.3712
20	2.4381	2.5585
25	1.6254	1.9264
30	1.2341	1.1137
35	0.9331	0.7224
40	0.7224	0.4515
45	0.6020	0.3017
50	0.5719	0.2709

جدول (4-3) يمثل المقارنة بين الطريقتين حسب معيار المقارنة (MSE)

<i>n</i>	<i>ConK</i>	<i>Oracle</i>
10	3.1751	3.3252
15	2.5508	2.8353
20	2.0256	2.1255
25	1.3500	1.6634
30	1.0259	0.9254
35	0.7754	0.6200
40	0.6100	0.3759
45	0.5001	0.2523
50	0.4751	0.2251



شكل (3-2) يوضح مقارنة بين الطرائق باستعمال معيار (MSE)


نلاحظ من نتائج التحليل للجدولين (4-3) و (5-3) عند $\mu = 0$ ، $\Sigma = 0.5^{|i-j|}$ نلاحظ انه عند حجوم العينات الصغيرة فان طريقة نواة الالتفاف (Conk) هي الأفضل تليها طريقة الأوراكل (Oracle) بالمرتبة الثانية أما عند حجوم العينات الكبيرة فأن طريقة الأوراكل (Oracle) تتفوق في الأداء وهذا يدل على ان أداء طريقة الأوراكل يتحسن كلما يزداد حجم العينة ويصبح قريباً للأداء الامثل وكذلك بالنسبة لمعيار (MSE) نلاحظ عند زيادة حجم العينة تظهر جميع الطرائق انخفاضاً في (MSE) حيث ان التقديرات تتحسن بزيادة حجم العينة .

جدول (5-3) يمثل نتائج المقارنة بين الطريقتين عند $\mu = \hat{\mu}$ ، $\Sigma = \hat{\Sigma}$

<i>n</i>	<i>ConK</i>	<i>Oracle</i>
10	2.5425	2.6626
15	2.0420	2.2422
20	1.6216	1.7017
25	1.0810	1.2812
30	0.8208	0.7407
35	0.6206	0.4804
40	0.4804	0.3003
45	0.4004	0.2002
50	0.3803	0.1801

جدول (6-3) يمثل المقارنة بين الطريقتين حسب معيار المقارنة (MSE)

<i>n</i>	<i>ConK</i>	<i>Oracle</i>
10	1.4236	1.4909
15	1.1434	1.2555
20	0.9080	0.9528
25	0.6053	0.7174
30	0.4596	0.4147
35	0.3475	0.2690
40	0.2690	0.1681
45	0.2242	0.1121
50	0.2129	0.1008



شكل (3-3) يوضح مقارنة بين الطرائق باستعمال معيار (MSE)

من ملاحظة الجدولين (5-3)، (6-3) عند $\hat{\mu} = \underline{\mu}$ ، $\hat{\Sigma} = \underline{\Sigma}$ نلاحظ ان القيم التي تعبر عن المسافة الاقليدية تظهر انخفاضا ملحوظا حيث كلما كانت القيم اصغر ، كانت الطريقة أفضل واكثر دقة حيث نلاحظ كلما تغير حجم العينة تتغير هذه القيم ، ونلاحظ ايضا أن أداء طريقة الأوراكل (Oracle) يظهر دائما نتائج متفوقة (قيم اقل) مقارنة بطريقة (Conk) وكذلك بالنسبة لمعيار (MSE) في الجدول (6-3) ، فإن القيم تمثل معيار (MSE) لكل طريقة حيث كلما كانت القيمة اصغر ، كان أداء الطريقة أفضل وبهذا نتوصل إلى أن طريقة الأوراكل (Oracle) تظهر دائما الأداء الأفضل عبر جميع احجام العينات مما يجعله المرجح المثالي. أما طريقة نواة الال تفاف (Conk) فأنها تتمتع بأداء جيد ويقتررب من الأوراكل مع زيادة حجم العينة، ونجد أن زيادة حجم العينة يقلل من MSE ولجميع الطرائق مما يشير إلى ان زيادة حجم البيانات يحسن من دقة التقديرات.

الاستنتاجات

1- اظهرت نتائج الجداول (1-3) ، (2-3) و (3-3) انه كلما ازداد حجم العينة (n) تكون القيم الناتجة للمسافة الاقليدية اصغر ولجميع الطرائق المستعملة مما يعني ان أداء كل طريقة يتحسن بزيادة حجم العينة .

2- من خلال النتائج يتضح ان قيم معيار متوسط مربعات الخطأ (MSE) تقل كلما ازداد حجم العينة ولجميع الطرائق المدروسة وهذا يدل على جميع الطرائق تمتلك خاصية الاتساق .

3- أظهرت النتائج من خلال استعمال معيار المقارنة (MSE) ان طريقة الأوراكل (Oracle) هي الأفضل وخصوصا عند حجوم العينات الكبيرة لأنها حققت اقل قيمة لمعيار (MSE) وتليها طريقة انحدار النواة من نوع الالتفاف (ConK)

التوصيات

- 1- اجراء دراسات مستقبلية لأستعمال طرائق لامعلمية حصينة لتقدير انحدار ديربن المكاني شبه المعلمي.
- 2- استعمال نماذج مكانية اخرى في تمثيل ظاهر ملوحة التربة في المحافظات.
- 3- اجراء دراسات مستقبلية تتناول مقارنة طرائق لامعلمية أخرى مع الطرائق التي تم اعتمادها في الرسالة .
- 4- توفير قاعدة بيانات متاحة للباحثين في وزارة الزراعة لدراسة المشاكل التي تواجه التربة في كافة محافظات العراق.

المصادر العربية:

- 1- عطره ، سامي غني خضير ، (2011) "طرائق بيز في تحليل النموذج القياسي الاقتصادي المكاني مع تطبيق عملي" اطروحة دكتوراه احصاء ، كلية الادارة والاقتصاد ، جامعة بغداد.
- 2-- عكار ، أحمد عبيد علي ، (2019) "تقدير الانحدار شبه المعلمي للبيانات المعتمدة مكانيا مع تطبيق عملي"، أطروحة دكتوراه إحصاء ، كلية الادارة والاقتصاد ، جامعة بغداد.

المصادر الاجنبية:

- 3- Anselin ، L. (1988)، "Spatial Econometrics : Method and Models "، Kluwer Academic ، Publishers ، Dordrecht ، The Netherlands.
- 4- Anselin، L .(1992)، "Spatial Data Analysis With GIS:AN Introduction to Appalachian the Social Sciences "، National Center for Geographic Information and Analysis ، University of California ، Santa Barbara.
- 5- Atikah، N.، Widodo، B.، Rahardjo، S.، Kholifia، N.، & Afifah، D. L. (2021، March). " The efficiency of Spatial Durbin Model (SDM) parameters estimation on advertisement tax revenue in Malang City". In *Journal of Physics: Conference Series* (Vol. 1821، No. 1، p. 012012). IOP Publishing.
- 6-Basile، R. (2008). "Regional economic growth in Europe: A semiparametric spatial dependence approach". *Papers in Regional Science*، 87(4)، 527-545.
- 7- Chagny، G.، Meynaoui، A.، & Roche، A. (2022). "Adaptive nonparametric estimation in the functional linear model with functional output".
- 8- Gumprecht، D. (2005). " Spatial Methods in Econometrics. An Application to R&D Spillovers ".

9- Herrmann, E. (1996). "***On the convolution type kernel regression estimator***".
Preprints, Dept. Math., Tech. Univ. Darmstadt, 31 pp.

10- Lesage, James P. (1999), "**The Theory and Practice of Spatial Econometrics**", Department of Economics University of Toledo .