

مقارنة بين طرق الانحدار الخطّي الموضعي والجوار الأقرب في تقدير أنموذج الانحدار اللامعلمي دراسة محاكاة مع التطبيق

A Comparison Between Local Linear Regression and K- Nearest Neighbor Methods in Estimating the Nonparametric Regression Model with Simulation and Application

<https://doi.org/10.29124/kjeas.1650.07>

أ. م. د سعد صبر محمد⁽²⁾

حوراء ضياء جبوري الخطيب⁽¹⁾

ssabir@uowasit.edu.iq

hawraajabbori523@uowasit.edu.iq

جامعة واسط - كلية الإدارة والاقتصاد / قسم الإحصاء

المستخلص:

تم في هذا البحث تقييم أنموذج الانحدار اللامعلمي بطريقةين من طرائق التقدير الشائعة المتمثلة بكل من (مقدار الانحدار الخطّي الموضعي (LLRE)، ومقدار الجوار الأقرب (K- Nearest Neighbor Estimator (KNNE)). وقد أجريت عملية المحاكاة باستعمال لغة البرمجة الإحصائية R لهاتين الطريقتين، وتمت المقارنة بينهما باستعمال معيار معدل جذر متوسط مربعات الخطأ (ARMSE) على نتائج ثلاثة عينات (50,100,150)، وب أحجام ثالث عينة (150) وثلاثة مستويات لنطاق الخطأ (0.3, 0.7, 1) ولأنموذجين غير خطيين، إذ أظهرت النتائج بالنسبة لأنموذج الأول الأفضلية لطريقة مقدار الجوار الأقرب (KNNE) في معظم الحالات. ولأنموذج الثاني تفوق مقدار الانحدار الخطّي الموضعي (LLRE) عند جميع حجوم العينات جميعها ولمستويات التباين جميعها. أما في الجانب التطبيقي فقد تم دراسة اثر الهيموغلوبين (Hb) على حجم خلايا الحمر المكدة (PCV) باستعمال الطريقتين، وأجريت المقارنة بينها باستعمال معيار جذر متوسط مربعات الخطأ (RMSE) وقد تبين من خلال نتائج الجانب التطبيقي أن الأفضلية كانت لطريقة مقدار الجوار الأقرب (KNNE).

الكلمات المفتاحية: الانحدار اللامعلمي، مقدار الانحدار الخطّي الموضعي، مقدار الجوار الأقرب، طريقة التقاطع الشرعي.

Abstract:

In this paper, the nonparametric regression model was estimated using two common estimation methods (Local Linear Regression Estimator (LLRE) and K-Nearest Neighbor Estimator (KNNE). The simulation process was conducted using the statistical programming language, R, for these methods, and they were compared using the Average Root Mean Squares Error (ARMSE) criterion, with three sample sizes (50, 100, 150), three levels of error variance (0.3, 0.7, 1) and two non-linear models. The results for the first model showed the superiority of the nearest neighbor estimator (KNNE) method in most cases, and for the second model the local linear regression estimator (LLRE) was superior at all sample sizes and for all levels of variance. On the applied side, the effect of hemoglobin (Hb) on the packed cell volume (PCV) of 150 patients with chronic kidney disease was studied. The estimation process was made using the two methods, and the comparison between them was made using the root mean square error (RMSE) criterion. It was shown through the results of the applied side that the preference was for the nearest neighbor estimator (KNNE) method.

Key words: Non parametric Regression, Local Linear Regression Estimator, K- Nearest Neighbor Estimator, Cross Validation.

Introduction

1- المقدمة

من المعلوم لدراسة أيّة ظاهرة (اقتصادية، اجتماعية ، علمية، وغيرها) يتطلّب تحليل الظاهرة وايجاد العوامل التي ترتبط بها وتؤثّر فيها، وذلك من خلال ايجاد أنموذج يعبر عنها ويكون مدخلاً رئيسيّاً لفهمها، اذ يُعدّ هذا من اهم اهداف نماذج الانحدار إذ يُعرف تحليل الانحدار بأنه اسلوب إحصائي يستعمل لمعرفة العلاقة بين متغير يعرف بالمتغير المعتمد (متغير الاستجابة) ومتغير واحد أو متغيرات عدّة تعرف بالمتغيرات التفسيرية أو (التوضيحية)، فطرق الانحدار المعلمية Parametric Regression Methods كانت في السنوات الماضية موضوع نقاش الكثير من الباحثين والتي تفترض أن العينة تأتي من مجتمع معروف التوزيع مثل عائلة كاما أو العائلة الطبيعية ومن ثم العمل على تقدير المعالم المجهولة من خلال طرائق التقدير المتمثّلة بـ (الربعات الصغرى الانتydية، العزوم، الإمكان الأعظم، بيز) وغيرها من طرائق التقدير أو عن طريق الاختبارات أو الاشتتقاقات لحدود الثقة للمعلم غير المعلومة بالاعتماد على العينة، وفي معظم الأحيان تكون تلك الافتراضات صارمة ومن ثم فإن التوزيع المعلمي ليس بالضرورة أن يكون التوزيع المعني للمسألة المراد حلها لكون الافتراض الخاطئ للتوزيع المعلمي وللمسألة المراد حلها قد تؤدي بالطرق الإحصائية المستعملة إلى مقدّرات غير متسقة ونتائج غير صحيحة، ما يعني عدم امتلاك البيانات عائلة معلمية، وكون الطرائق المعلمية لا تتلاءم مع أحجام العينات الصغيرة و كذلك العينات غير معلومة التوزيع، وعلى الرغم أن الأنموذج المعلمية تعدّ أحد أهم أدوات تحليل البيانات، لأنّها فعالة و يمكن تفسيرها بسهولة، إلا أنها لم تستطع أن

تكون كافية في بعض الحالات ولا بد من التطرق إلى طرائق الامثلية ، ونظرًا للأسباب المذكورة آنفًا أجبرت الباحثين اللجوء إلى طرائق الإحصائية الحديثة والمتمثلة بالطرائق الامثلية والشبه المثلية في تحليل وتفسير البيانات.

ظهرت دراسة طرائق التقدير الامثلية في العديد من البحوث والدراسات من ابرزها في عام (1990) قدم الباحث (Hardle^[17]) كتاباً فيه طرائق لتقدير دالة الانحدار الامثلية وايضاً ناقش فيه طرائق لتقدير المعلمة التمهيدية وأسلوب اختيارها ومدى تأثيرها على اداء دالة الانحدار الامثلية، وفي عام (2007) قام الباحث^[5] (Aydin) بتقديم بحثاً ضمن استعمال الأتمادج الامثلية لبيانات الناتج القومي الإجمالي في تركيا وبيانات زراعة القلب في ستانفورد، إذ ناقش طريقتين لامثلية الأولى تمهيد الشريحة والثانية انحدار kernel، في عام (2011) قدم الباحثان (الصفاوي ومتى)^[4] بحثاً ضمن مقارنة لثلاث طرائق تمهيدية (طريقة الجوار الأقرب (KNN) K-Nearest Neighbor Method وطريقة الدالة الليبية (K) Kernel Function Method وطريقة الشرائح التمهيدية (SS) Smoothing Splines Method) باستعمال اسلوب المحاكاة بنموذجين مختلفين وثلاث قيم للتبaines. وفي عام (2016) قدم الباحثان (حسن ومجيد)^[3] بحثاً ضمن استعمال بعض طرائق التمهيد منها انحدار الشريحة (SR)، وشريحة الجزئية (PS)، وشريحة العشوائي (Penalized Spline)، والتعميد الليبي متعدد الحدود الموضعي (LPK)، وفي عام (2019) تطرق الباحثان (بدر وعبد)^[2] إلى مقارنة مقدرات أنموذج الانحدار الامثلية من خلال المقدر الانحدار الخطّي الموضعي (LLRE) Local Quadratic Regression Estimator ومقدر الانحدار التربيعي الموضعي (LQRE) Linear Regression Estimator باستعمال معيار التقاطع الشرعي (CV)، وايضاً استعمال مقدّر Regression Estimator الشريحة التمهيدية الحصينة (RSS) Robust Smoothing Splines وباستعمال المعيار الحصين (RCV) Robust Cross Validation وايضاً استعمال اسلوب المحاكاة كأدلة مثل لدراسة احجام العينات والتوزيعات المختلفة للخطّ العشوائي منها وجود بيانات شاذة ومنها حالتها الطبيعية وبمستويات لتباين ونمادج مختلفة، وفي عام (2023) قدم الباحث (الاشقر)^[11] بحثاً ضمن فيه تقديم بعض من طرائق شريحة التمهيد ودوال الأساس والمتممّلة بالشريحة الجزئية (PS) والشريحة التكميلية الطبيعية (NCS) والشريحة التكميلية (CS) وشريحة الأساس (BS) ثم مقارنة هذه الطرائق فيما بينها للوصول إلى معدلات الوفاة بشركات التأمين المصرية خلال المدة 2007-2010.

وسيتم تقسيم ما تبقى من هذا البحث إلى فقرات عدّة والمتمثلة بأنموذج الانحدار الامثلية وطرائق التقدير، يليه الجانب التجاري (المحاكاة)، ثم الجانب التطبيقي (بيانات الحقيقة للمرضى المصابين بأمراض الكلى المزمنة)، والاستنتاجات فالوصيات، وأخيراً المصادر.

2- أنموذج الانحدار الامثلية^[18]،^[19]

يتم تعريف أنموذج الانحدار الامثلية بما في ذلك متغير التنبؤ ومتغير الاستجابة على أنه :

$$y_i = m(x_i) + \epsilon_i \quad i = 1, 2, \dots, n \quad \dots \quad (1)$$

y_i : يمثل قيمة المتغير المعتمد (الاستجابة) للمشاهدة i .

$m(x_i)$: تمثل دالة التتميّز غير المعروفة.

x_i : تمثل قيمة المتغيّر المستقل للمشاهدة i .

ϵ_i : قيمة الخطأ العشوائي ذات التوزيع الطبيعي المستقل والمتماثل $\sim N(0, \sigma^2)$.

ومن خلال الأنماذج المذكورة إنّا بامكائنا استعماله كاداة لوصف اتجاه وتأثير المتغيّر التفسيري في متغيّر الاستجابة وذلك من خلال استعمال اسلوب التمهيد (Smoothing) والذي يمكن تمثيله كدالة بدلالة متغيّر واحد، أو أكثر من المتغيّرات التفسيرية لمنحنى الأنماذج $m(x_i)$ إذ يُعدّ اسلوباً بيانيّاً لتقدير اي دالة من الدوال الإحصائية، أنّ الهدف من هذا الأسلوب تقرّيب دالة الانحدار الامعليمي التقرّيبية دالة الانحدار الامعليمية الحقيقة ثمّ تأخذ البيانات بعد ذلك في تحديد ما يكون دالة الانحدار الحقيقة، وفي حالة غياب اي من المعلومات عن الدالة الحقيقة يعتبر تحليل الانحدار الامعليمي هو الأفضل دائماً، إذ تمثل آلية الانحدار الامعليمي بأنّها تعتمد كثيراً على البيانات في تحديد تلك الدالة أكثر من اعتمادها على افتراضات لغرض الحصول على معلومات عن الدالة m بدلًا من الصيغة الدالية، وأحياناً تحتاج إلى افتراضات أقلّ والتي تجعل من الأنماذج الانحدار خطّي، غير خطّي، لوجستي أو احتمالي ... الخ ولا سيّما عندما تكون بيانات العينة نسبوية أو رتبية أو بيانات وصفية، ومن المعروف أنّ الانحدار الامعليمي يجعل البيانات أكثر تأقلمًا وأقلّ تعقيداً من اسلوب الانحدار المعلملي لذلك تمّ اللجوء لهذا الأسلوب كبديل ملائم لمعالجة البيانات، ويُعدّ أدلة مرغوبة لدى معظم الباحثين كونه له القابلية في كشف تركيبة البيانات ولا سيّما عندما يكون حجم العينة صغيراً من النماذج المعلمليّة للاستدلال عن البيانات كون البيانات الفعلية ليست دوماً تتمّاك وصفاً ملائماً، كما يُعدّ الأنماذج الانحدار الامعليمي أدلة لإعطاء وصف عام للظاهرة وليس لدراسة التفاصيل الدقيقة لها.

3- طرائق تقدير الأنماذج الانحدار الامعليمي

Methods of Estimating the Nonparametric Regression Model

سيّئم في هذا البحث استعمال طرائقتين لتقدير الأنماذج الانحدار الامعليمي وكالاتي:

1-3 مقدر الانحدار الخطّي الموضعي [8],[9],[11],[12]

اقترحت فكرة الانحدار الخطّي الموضعي (LLR) في عام 1979 من قبل Cleveland، كطريقة لامعليمية تستعمل لمذكرة العلاقة بين متغيّر مستقل ومتغيّر معتمد، إذ تُعدّ تقنية مرنّة تسمح بتقدير العلاقة الموضعية عند كلّ نقطة في البيانات، بدلًا من افتراض وجود علاقة عامة بين المتغيّرات، يقوم المقدر الخطّي الموضعي بتقدير العلاقة عند كلّ نقطة عن طريق ملائمة الأنماذج انحدار خطّي مع مجموعة موضعية بجوار النقاط. يُعرّف هذا الجوار بأنه معلمة التمهيد (عرض الحزمة) والتي تحدد عدد النقاط القريبة المستعملة في هذا التقدير. يستعمل هذا المقدر أنماذج انحدار خطّي داخل الجوار الموضعي، وذلك من خلال تصغير مجموع مربعات الباقي الموزونة بدلالة kernel، ومن أهم مزايا هذا الأسلوب اكتشاف العلاقات غير الخطّية بين المتغيّرات ولا سيّما عندما تكون هناك تباينات كبيرة.

يُعَد مقدّر الانحدار الخطّي الموضعي نسخة لامعلمية من طريقة المربعات الصغرى الموزونة، إذ يمكن التعبير عنها على شكل تصغير للصيغة الآتية:

$$\sum_{i=1}^n \{y_i - \beta_0 - \beta_1(x_i - x)\}^2 K_\lambda(x_i - x) \quad \dots (2)$$

ويمكن كتابتها على شكل مصفوفات كما يأتي:

$$(y - X\beta)' W (y - X\beta) \quad \dots (3)$$

إذ أن y هو متجه قيم المتغير المعتمد، وإن:

$$X = \begin{bmatrix} \mathbf{1} & (x_1 - x) \\ \mathbf{1} & (x_2 - x) \\ \vdots & \vdots \\ \mathbf{1} & (x_n - x) \end{bmatrix}$$

$$W = \begin{bmatrix} K_\lambda(x_1 - x) & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & K_\lambda(x_2 - x) & \dots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & K_\lambda(x_n - x) \end{bmatrix}$$

وباستعمال طريقة المربعات الصغرى الموزونة فإن مقدّر المعلمات التي يقوم بجعل المعادلة (3) أصغر ما يمكن هو ما يأتي:

$$\hat{\beta} = (X'WX)^{-1}X'Wy = (QX)^{-1}Qy \quad \dots (4)$$

إذ أن $Q = X'W$ ، وتعرف كما يأتي:

$$Q = \begin{bmatrix} \mathbf{1} & \mathbf{1} & \dots & \mathbf{1} \\ (x_1 - x) & (x_2 - x) & \dots & (x_n - x) \end{bmatrix} \begin{bmatrix} K_\lambda(x_1 - x) & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & K_\lambda(x_2 - x) & \dots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & K_\lambda(x_n - x) \end{bmatrix}$$

$$= \begin{bmatrix} K_\lambda(x_1 - x) & K_\lambda(x_2 - x) & \dots & K_\lambda(x_n - x) \\ (x_1 - x)K_\lambda(x_1 - x) & (x_2 - x)K_\lambda(x_2 - x) & \dots & (x_n - x_0)K_\lambda(x_n - x) \end{bmatrix}$$

ويمكن إيجاد QX كما يأتي:

QX

$$= \begin{bmatrix} \mathbf{K}_\lambda(x_1 - x) & \mathbf{K}_\lambda(x_2 - x) & \dots & \mathbf{K}_\lambda(x_n - x) \\ (x_1 - x)\mathbf{K}_\lambda(x_1 - x) & (x_2 - x)\mathbf{K}_\lambda(x_2 - x) & \dots & (x_n - x_0)\mathbf{K}_\lambda(x_n - x) \end{bmatrix} \begin{bmatrix} 1 & (x_1 - x) \\ 1 & (x_2 - x) \\ \vdots & \vdots \\ 1 & (x_n - x) \end{bmatrix}$$

$$= \begin{bmatrix} \sum_{i=1}^n \mathbf{K}_\lambda(x_i - x) & \sum_{i=1}^n (x_i - x)\mathbf{K}_\lambda(x_i - x) \\ \sum_{i=1}^n (x_i - x)\mathbf{K}_\lambda(x_i - x) & \sum_{i=1}^n (x_i - x)^2\mathbf{K}_\lambda(x_i - x) \end{bmatrix}$$

كما يمكن إيجاد Qy كما يأتي:

Qy

$$= \begin{bmatrix} \mathbf{K}_\lambda(x_1 - x) & \mathbf{K}_\lambda(x_2 - x) & \dots & \mathbf{K}_\lambda(x_n - x) \\ (x_1 - x)\mathbf{K}_\lambda(x_1 - x) & (x_2 - x)\mathbf{K}_\lambda(x_2 - x) & \dots & (x_n - x_0)\mathbf{K}_\lambda(x_n - x) \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

$$= \begin{bmatrix} \sum_{i=1}^n y_i \mathbf{K}_\lambda(x_i - x) \\ \sum_{i=1}^n y_i (x_i - x) \mathbf{K}_\lambda(x_i - x) \end{bmatrix}$$

ومعكوس المصفوفة QX يمكن كتابتها كما يأتي:

$$(QX)^{-1} = \frac{1}{\det(QX)} \begin{bmatrix} \sum_{i=1}^n (x_i - x)^2 \mathbf{K}_\lambda(x_i - x) & -\sum_{i=1}^n (x_i - x) \mathbf{K}_\lambda(x_i - x) \\ -\sum_{i=1}^n (x_i - x) \mathbf{K}_\lambda(x_i - x) & \sum_{i=1}^n \mathbf{K}_\lambda(x_i - x) \end{bmatrix}$$

إذ $\det(QX)$ تمثل محددة QX وتعطى كما يأتي:

$$\det(QX) = \sum_{i=1}^n K_\lambda(x_i - x) \sum_{i=1}^n (x_i - x)^2 K_\lambda(x_i - x) - \left\{ \sum_{i=1}^n (x_i - x) K_\lambda(x_i - x) \right\}^2$$

$$= S_0 S_2 - S_1^2$$

إذ أن:

$$S_r = \sum_{i=1}^n (x_i - x)^r K_\lambda(x_i - x); \quad r = 0, 1, 2$$

وبناءً على ما سبق يمكن إعادة كتابة المعادلة (4) كما يأتي:

$\hat{\beta}$

$$\begin{aligned} &= \frac{1}{S_0 S_2 - S_1^2} \begin{bmatrix} S_2 & -S_1 \\ -S_1 & S_0 \end{bmatrix} \begin{bmatrix} \sum_{i=1}^n y_i K_\lambda(x_i - x) \\ \sum_{i=1}^n y_i (x_i - x) K_\lambda(x_i - x) \end{bmatrix} \dots (5) \\ &= \frac{1}{S_0 S_2 - S_1^2} \begin{bmatrix} S_2 \sum_{i=1}^n y_i K_\lambda(x_i - x) - S_1 \sum_{i=1}^n y_i (x_i - x) K_\lambda(x_i - x) \\ S_0 \sum_{i=1}^n y_i (x_i - x) K_\lambda(x_i - x) - S_1 \sum_{i=1}^n y_i K_\lambda(x_i - x) \end{bmatrix} \end{aligned}$$

ويكون مقدار β_0 معرفاً وفقاً للصيغة الآتية:

$$\begin{aligned} \hat{\beta}_0 &= \frac{S_2 \sum_{i=1}^n y_i K_\lambda(x_i - x) - S_1 \sum_{i=1}^n y_i (x_i - x) K_\lambda(x_i - x)}{S_0 S_2 - S_1^2} \\ &= \frac{\sum_{i=1}^n [S_2 - (x_i - x) S_1] K_\lambda(x_i - x) y_i}{S_0 S_2 - S_1^2} \end{aligned}$$

والمعادلة (6) تمثل مقدار الانحدار الخطّي الموضعي للدالة $m(x)$, بمعنى أن:

$$\begin{aligned} \hat{m}(x) &= \frac{\sum_{i=1}^n [S_2 - (x_i - x) S_1] K_\lambda(x_i - x) y_i}{S_0 S_2 - S_1^2} \dots (6) \end{aligned}$$

وتقدر معلمة التمهيد (λ) باستعمال معيار التقاطع الشرعي (CV) إذ يتلخص عمل هذه الطريقة أن في كلّ مرة تستبعد قيمة واحدة من قيم المتغيرات، وأن عملية تقدير هذه المعلمة تكون كالتالي:

1. يتم حساب تقيير الدالة $\hat{m}_i(x_i)$, إذ أن $\hat{m}_i(x_i)$ هي استبعاد مشاهدة واحدة في كلّ مرة، وأن المقدار $\hat{m}_i(x_i)$ يحسب وفق المعادلة (6)، أي أن:

$$\begin{aligned} \hat{m}_i(x_i) &= \frac{\sum_{j \neq i}^n [S_{2j} - (x_i - x_j) S_{1j}] K_\lambda(x_i - x_j) y_i}{S_{0j} S_{2j} - S_{1j}^2} \dots (7) \end{aligned}$$

$$i = 1, 2, \dots, n-1 , \quad j = 2, 3, \dots, n$$

إذ أن:

$$S_{rj} = \sum_{i=1}^n (x_i - x_j)^r K_\lambda(x_i - x_j); \quad r = 0, 1, 2$$

2. يتم حساب دالة العبور الشرعي (CV) باستبعاد مشاهدة واحدة في كل مرة وبالشكل الآتي:

$$CV_{(h)} = \frac{1}{n} \sum_{i=1}^n [y_i - \hat{m}_i(x_i)]^2 \quad \dots (8)$$

3. يتم حساب قيمة (λ_{cv}) المثلثي من خلال:

$$\lambda_{cv} = \arg \min_{\lambda} CV_{(\lambda)} \quad \dots (9)$$

2-3 مقدر الجوار الأقرب (K-NNE)

والتي تعد واحدة من أشهر الطرائق أو التقنيات الامثلية التقليدية والمستعملة لحل مشكل التصنيف والانحدار، إذ تطورت هذه الطريقة لأول مرة من قبل Joseph Hodges & Evelyn Fipbx في عام 1951، والتي لها القابلية على توليد التقديرات المحلية للنقطة ، ويعود هذا الأسلوب غير معقد في معظم الأحيان في حالة وجود قاعدة بيانات مثل عند توفر قاعدة بيانات تصنف الطريقة من ضمن الطرائق الدقيقة لمعرفة مقدر الجوار الأقرب بسهولة، وعندما تكون العملية معقدة ينتج قاعدة البيانات كبيرة جدا، يقيس الجوار الأقرب المسافة الأقلية بين كل نقطة والنقطة الأقرب إليها، إذ أن المسافة الأقلية تكون قليلة جدا عندما يكون أسلوب البيانات بشكل متجمع ، وكلما تبعثرت البيانات وتباعدت تصبح المسافة بين النقاط كبيرة، كما تم توسيعها من قبل Thomas Cover ، وايضا استخدم هذا المقدر من قبل Royal Stone في عام 1966 و Stone في عام 1977 و Mach لعام 1981 بموجب الأنماذج العشوائي بعد احتساب (x_{ni}).

$$W_{ni}(x) = \frac{k^{\frac{(xi-x)}{kn}}}{\sum_{i=1}^n k^{\frac{(xi-x)}{kn}}}$$

K(u)= 0 , for all |u| > 1 . (.)

حيث يعرف مقدر (K-NNE) بالصيغة الآتية:

$$\hat{m}_{KNN}(x) = \frac{\sum_{i=1}^n y_i k \left((H_n, k(x))^{-1} d(x_i, x) \right)}{\sum_{i=1}^n k \left((H_n, k(x))^{-1} d(x_i, x) \right)} \quad x \in F \quad \dots (10)$$

. K(): تمثل دالة kernel بالفترة [0,∞).

(x_1, x_2, \dots, x_n): تمثل متغيراً عشوائياً موجب يعتمد على قيم ($H_n, k(x)$)

ويُعرف كالتالي:

$$H_n, k(x) = \min \left\{ h \in R_+ : \sum_{i=1}^n I_{B(x,h)}(x_i) = k \right\}$$

. المسافة الأقلية Euclidian Distance بين x و k من بين قيم $d(x_i, x_j)$

ويتم حساب المسافة الأقلية وفق الصيغة الآتية:

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad ; i, j \\ = 1, 2, \dots, n \quad \dots (11)$$

ويكون المقدّر متسلقاً بموجب الأنماذج العشوائي بشرط ($k = k_n$) بحيث أن ($k_{n \rightarrow \infty} = 0$) وهذا يعني أن ($k = \sqrt{n}$).

The Experimental Side

4- الجانب التجريبي

Concept of Simulation

1-4 مفهوم المحاكاة

يتّم استعمال الجانب التجريبي من خلال تطبيق اسلوب المحاكاة Simulation لغرض تطبيق طائق التقدير اللامعلمية، والتي تم التطرق اليها في الجانب النظري، اذ يعرف هذا الأسلوب على أنه تقليد الواقع العملي إذ يقوم بتوظيف نماذج تتضمّن العديد من الحالات الافتراضية لضمان الحصول على نتائج أكثر شمولية، كما يستعمل في حالة عجز البرهان الرياضي في بيان أفضلية طائق تقدير معينة على حساب طائق أخرى وأيضاً في الحالات التي يصعب الحصول على بيانات دقيقة وواقعية لظاهرة ما.

Simulation Experiment Stages

2-4 مراحل تجربة المحاكاة

تم استعمال لغة البرمجة الإحصائية R بإصدارها (4.3.1) والتي تُعد واحدة من أكثر لغات البرمجة شعبية وأداة قوية كونها توفر وظائف وأدوات متعددة لتحليل البيانات في برمجة طائق التقدير.

المرحلة الأولى: مرحلة تحديد دوال الانحدار اللامعمي

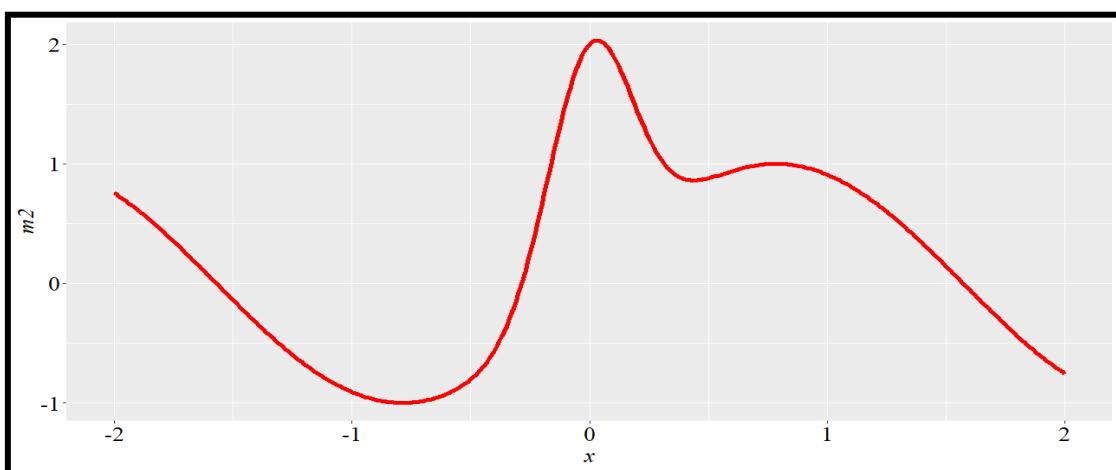
The Stage of Determining Nonparametric Regression Functions

إذ تم اختيار دالتين من دوال انحدار اللامعمي (غير الخطّي) وهما كما يأتي:

الأنموذج الأول [10]

$$m_1(x) = \sin(2x) + 2\exp^{-16x^2} , x \in [-2, 2] \quad \dots (12)$$

والشكل الآتي يبيّن رسم هذه الدالة:

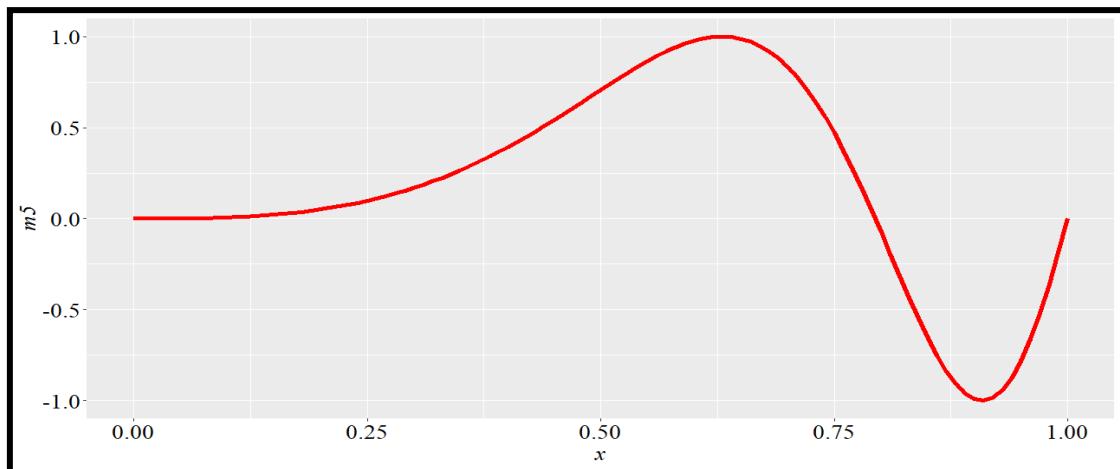


الشكل (1): رسم دالة الأنموذج الأول

الأنموذج الثاني [20]

$$m_2(x) = \sin(2\pi x^3) , x \in (0, 1) \quad \dots (13)$$

والشكل الآتي يعرض رسم هذه الدالة:



الشكل (2): رسم دالة الأنماذج الثاني

المرحلة الثانية: مرحلة تحديد القيم الافتراضية

وقد تم اختبار قيم افتراضية لتبابن الخطأ العشوائي ($\sigma^2 = 0.3, 0.7, 1$) ، وأحجام عينات هي (50, 100, 150)، وقد تم تكرار كل تجربة 1000 مرة.

Data Generation

المرحلة الثالثة: توليد البيانات

تم توليد قيم المتغير المستقل من التوزيع المنتظم ضمن الفترة [a,b] بالاعتماد على مدى كُل دالة، كما تم توليد الخطأ العشوائي (ϵ) من التوزيع الطبيعي بمتوسّط يساوي صفر، وتبابن يساوي σ^2 . وبناءً على المعادلة (1) تم توليد المتغير المعتمد.

Estimation

المرحلة الرابعة: التقدير

تم تقدير أنماذج الانحدار اللامعجمي باستعمال طرفيتين للتقدير وكما يأتي:

1. طريقة مقدر الانحدار الخطّي الموضعي (LLRE).
2. طريقة مقدر الجوار الأقرب (KNNE).

Comparison Phase Between Methods

المرحلة الخامسة: مرحلة المقارنة بين الطرائق^[7]

تم استعمال معيار معدل جذر متوجّز مربعات الخطأ Average Root Mean Squares (ARMSE) ، لغرض المقارنة بين الطرفيتين إذ أن الطريقة التي تمتلك أقل قيمة (ARMSE) تعدّ الأفضل.

$$ARMSE =$$

$$\frac{1}{r} \sum_{j=1}^r \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{ij}(x_i) - \hat{m}_j(x_i))^2} \quad \dots (14)$$

إذ إن :

$y_{ij}(x_i)$: تمثل المشاهدة i من التكرار j .

$\hat{m}_j(x_i)$: دالة الانحدار الامثل المقدّرة.

n : تمثل عدد المشاهدات.

r : تمثل عدد التكرارات.

Results of Simulations

3-4 نتائج عمليات المحاكاة

للغرض تطبيق الطريقتين لتقدير أنموذج الانحدار وتحديد الطريقة الأفضل، إذ سيتم عرض النتائج التي تمثل قيم (ARMSE) لكل طريقة وفقاً لأحجام العينات والقيم المختلفة لمعلمة σ^2 وكما يأتي:

الجدول (1): معيار المقارنة (ARMSE) للطريقتين وباختلاف التباين مع توليد (50) مشاهدة بالنسبة

$$(m_1(x) = \sin(2x) + 2\exp^{-16x^2})$$

Methods	KNNE	LLRE
σ^2		
0.3	0.64871	0.76604
0.7	0.97057	0.97511
1	1.15521	1.10659

يتبيّن من الجدول آنفًا عند حجم عينة (50) مشاهدة وتباين الخطأ ($\sigma^2 = 0.3$) فإن أفضل طريقة كانت هي طريقة مقدر الجوار الأقرب (KNNE) لامتلاكها أقل قيمة لمعيار معدّل جذر متوجّس مربعات الخطأ (ARMSE) والمساوية إلى (0.64871).

أما عندما تكون قيمة تباين ($\sigma^2 = 0.7$) الأفضلية كانت لطريقة مقدر الجوار الأقرب (KNNE) لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.97057).

وفي حالة ($\sigma^2 = 1$) كانت طريقة مقدر الانحدار الخطّي الموضعي (LLRE)، هي الأفضل، وذلك لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (1.10659).

أظهرت النتائج المذكورة آنفًا أن أفضل طريقة كانت بالنسبة لأنموذج الأول عند حجم عينة (50) مشاهدة وقيم تباين خطأ ($\sigma^2 = 0.3, 0.7$) هي مقدر الجوار الأقرب (KNNE)، وذلك لامتلاكها أقل قيمة بالنسبة لمعيار

المقارنة (ARMSE)، ماعدا ($\sigma^2 = 1$) تكون الأفضلية لطريقة مقدر الانحدار الخطّي الموضعي (LLRE) لكونها تمتلك أقل قيمة لمعيار (ARMSE).

الجدول (2): معيار المقارنة (ARMSE) للطريقتين وباختلاف التباين مع توليد (100) مشاهدة بالنسبة

$$(m_1(x) = \sin(2x) + 2\exp^{-16x^2})$$

Methods	KNNE	LLRE
σ^2		
0.3	0.63548	0.73584
0.7	0.96408	0.97438
1	1.13622	1.10462

يتضح من الجدول (2) عند حجم عينة (100) مشاهدة وتباین الخطأ ($\sigma^2 = 0.3$) فإن أفضل طريقة كانت هي طريقة مقدر الجوار الأقرب (KNNE) لامتلاكها أقل قيمة لمعيار معدّل جذر متوجّط مربعات الخطأ (ARMSE) والمساوية إلى (0.63548).

أمّا عندما تكون قيمة تباین ($\sigma^2 = 0.7$) الأفضلية كانت لطريقة مقدر الجوار الأقرب (KNNE) لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.96408).

وفي حالة ($\sigma^2 = 1$) كانت طريقة مقدر الانحدار الخطّي الموضعي (LLRE) هي الأفضل، وذلك لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (1.10462).

تم التوصل إلى أن الأفضلية كانت بالنسبة للأنموذج الأول عند حجم عينة (100) مشاهدة وقيم تباین خطأ ($\sigma^2 = 0.3, 0.7$) هي مقدر الجوار الأقرب (KNNE)، وذلك لامتلاكها أقل قيمة بالنسبة لمعيار المقارنة (ARMSE)، ماعدا ($\sigma^2 = 1$) تكون الأفضلية لطريقة مقدر الانحدار الخطّي الموضعي (LLRE)، لكونها تمتلك أقل قيمة لمعيار (ARMSE).

الجدول (3): معيار المقارنة (ARMSE) للطريقتين وباختلاف التباين مع توليد (150) مشاهدة بالنسبة

$$(m_1(x) = \sin(2x) + 2\exp^{-16x^2})$$

Methods	KNNE	LLRE
σ^2		
0.3	0.62980	0.70836
0.7	0.95244	0.95438
1	1.12036	1.00974

يتبيّن من الجدول (3) عند زيادة حجم العينة إلى (150) مشاهدة وبتباین خطأ ($\sigma^2 = 0.3$) فإنّ أفضل طريقة كانت هي طريقة مقدّر الجوار الأقرب (KNNE)، لامتلاكها أقل قيمة لمعيار معدّل جذر متوجّس مربعات الخطأ (ARMSE) والمساوية إلى (0.62980).

أمّا عندما تكون قيمة تباین الخطأ ($\sigma^2 = 0.7$) الأفضلية كانت لطريقة مقدّر الجوار الأقرب (KNNE) لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.95244).

وفي حالة ($\sigma^2 = 1$) كانت طريقة مقدّر الانحدار الخطّي الموضعي (LLRE)، هي الأفضل وذلك لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (1.00974).

أظهرت النتائج المذكورة إنّاً أفضل طريقة كانت بالنسبة للنموذج الأول عند حجم عينة (150) مشاهدة وقيم تباین خطأ ($\sigma^2 = 0.3, 0.7$) هي مقدّر الجوار الأقرب (KNNE)، لامتلاكها أقل قيمة بالنسبة لمعيار المقارنة (ARMSE)، ماعدا ($\sigma^2 = 1$) الأفضلية كانت لطريقة مقدّر الانحدار الخطّي الموضعي (LLRE)، لكونها تمثّل أدنى قيمة لمعيار (ARMSE).

الجدول (4): معيار المقارنة (ARMSE) للطريقتين وباختلاف التباين مع توليد (50) مشاهدة بالنسبة

$$(m_2(x) = \sin(2\pi x^3))$$

Methods	KNNE	LLRE
σ^2		

0.3	0.63650	0.58854
0.7	0.96891	0.85082
1	1.13960	0.98893

يتضح من الجدول (4) عند حجم عينة (50) مشاهدة وتباین الخطأ ($\sigma^2 = 0.3$) أنّ الأفضلية كانت لطريقة مقدّر الانحدار الخطّي الموضعي (LLRE) لامتلاكها أقل قيمة لمعيار معدّل جذر متوجّس مربعات الخطأ (ARMSE) والمساوية إلى (0.58854).

أما عندما تكون قيمة تباین الخطأ ($\sigma^2 = 0.7$) فإنّ أفضل طريقة كانت هي مقدّر الانحدار الخطّي الموضعي (LLRE) لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.85082).

وفي حالة ($\sigma^2 = 1$) كانت طريقة مقدّر الانحدار الخطّي الموضعي (LLRE) هي الأفضل وذلك لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.98893).

تم التوصل إلى أنّ أفضل طريقة بالنسبة للأنموذج الثاني عند حجم عينة (50) مشاهدة كانت هي طريقة مقدّر الانحدار الخطّي الموضعي (LLRE) لكونها تمتلك أقل قيمة لمعيار (ARMSE) قيم تباین الخطأ جميعها.

الجدول (5): معيار المقارنة (ARMSE) للطريقتين وباختلاف التباين مع توليد (100) مشاهدة بالنسبة للأنموذج الثاني ($m_2(x) = \sin(2\pi x^3)$)

Methods	KNNE	LLRE
σ^2		
0.3	0.63371	0.57812
0.7	0.96585	0.84724
1	1.13117	0.91912

يتبيّن من الجدول (5) عند حجم عينة (100) مشاهدة وتباین الخطأ ($\sigma^2 = 0.3$) فإنّ أفضل طريقة كانت هي طريقة مقدّر الانحدار الخطّي الموضعي (LLRE)، وذلك لامتلاكها أقل قيمة لمعيار معدّل جذر متوجّس مربعات الخطأ (ARMSE) والمساوية إلى (0.57812).

أما عندما تكون قيمة تباين ($\sigma^2 = 0.7$) الأفضلية كانت طريقة مقدر الانحدار الخطّي الموضعي (LLRE) لامتلاكها أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.84724).

وفي حالة ($\sigma^2 = 1$) كانت طريقة مقدر الانحدار الخطّي الموضعي (LLRE) هي الأفضل لكونها تمتلك أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.91912).

أظهرت النتائج المذكورة آنفًا أن أفضل طريقة بالنسبة للأنموذج الثاني عند حجم عينة (100) مشاهدة كانت هي طريقة مقدر الانحدار الخطّي الموضعي (LLRE) لامتلاكها أقل قيمة لمعيار (ARMSE) ولجميع قيم تباين الخطأ.

الجدول (6): معيار المقارنة (ARMSE) للطريقتين وباختلاف التباين مع توليد (150) مشاهدة بالنسبة

$$(m_2(x) = \sin(2\pi x^3)) \text{ لأنموذج الثاني}$$

Methods	KNNE	LLRE
σ^2		
0.3	0.62840	0.57684
0.7	0.96458	0.84150
1	1.13059	0.90578

يتضح من الجدول (6) عند زيادة حجم العينة إلى (150) مشاهدة وتباين خطأ ($\sigma^2 = 0.3$) فإن الأفضلية كانت لطريقة مقدر الانحدار الخطّي الموضعي (LLRE)، وذلك لامتلاكها أقل قيمة لمعيار معدّل جذر متوسّط مربعات الخطأ (ARMSE) والمساوية إلى (0.57684).

أما عندما تكون قيمة تباين الخطأ ($\sigma^2 = 0.7$) كانت الأفضلية لطريقة مقدر الانحدار الخطّي الموضعي، لكونها تمتلك أقل قيمة لمعيار (ARMSE) والمساوية إلى (0.84150).

وفي حالة ($\sigma^2 = 1$) كانت طريقة مقدر الانحدار الخطّي الموضعي (LLRE) هي الأفضل لامتلاكها أقل قيمة لمعيار المقارنة (ARMSE) والمساوية إلى (0.90578).

ثم التوصل إلى أن أفضل طريقة بالنسبة للأنموذج الثاني عند حجم عينة (150) مشاهدة كانت هي طريقة مقدر الانحدار الخطّي الموضعي (LLRE) وذلك لامتلاكها أقل قيمة لمعيار (ARMSE) (قيم تباين الخطأ جميعها).

5- التطبيق Application

في هذا الجانب سيتم دراسة اثر الهيمو غلوبين (Hb) Hemoglobin والمتمثل بالمتغير المستقل على حجم الخلايا الحمر المكثسة (PCV) Packed Cell Volume، والمتمثل بالمتغير التابع للمرضى المصابين بأمراض الكلى المزمنة، والتي تم الحصول عليها من مستودع التعلم الآلي (UCI Machine Learning Repository)⁽¹⁾، إذ تم استعمال معيار المقارنة بين الطريقتين، والمتمثل بمعيار جذر متوسط مربعات الخطأ (RMSE)، إذ أن الطريقة التي تمتلك أقل قيمة RMSE تعد أفضل والمعرفة بالمعادلة رقم (15):

RMSE

$$= \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i(x_i) - \hat{m}(x_i))^2} \quad \dots (15)$$

إذ أن:

y_i : تمثل المتغير التابع للمريض i .

$\hat{m}(x_i)$: دالة الانحدار الامثل المقدرة عند قيمة المتغير المستقل للمريض i .

n : تمثل عدد المشاهدات.

وقد تم تقدير أنموذج الانحدار الامثل للبيانات الحقيقية بطريقتين للتقدير والتي تم ذكرهما سابقاً لمعرفة سلوكها عند أنماذج وأحجام عينات مختلفة وقيم مختلفة للانحراف المعياري للخطأ، إذ وضعت قيم المتغير التابع المقدرة باستعمال هذه الطرائق في الجدول (7)، في حين كانت نتائج معايير المقارنة كما في الجدول (8)، ورسمت هذه القيم مع القيم الحقيقة كما في الأشكال (3) إلى (4).

الجدول (7): البيانات المقدرة بطريقتي التقدير (KNNE و LLRE)

No.	KNNE	LLRE	No.	KNNE	LLRE	No.	KNNE	LLRE
1	31.67	34.49	51	35.67	39.15	101	44.00	45.66
2	38.67	38.13	52	26.00	26.03	102	44.33	44.40
3	29.33	28.69	53	33.67	32.40	103	46.67	46.21
4	32.33	33.09	54	23.00	24.71	104	41.33	45.49

¹. عبارة عن موقع يحتوي على عدد كبير من مجاميع البيانات ويمكن الوصول إليه من خلال الرابط الآتي:
<https://archive.ics.uci.edu/>

5	30.67	29.35	55	30.33	30.34	105	43.00	44.51
6	22.00	16.16	56	33.00	34.85	106	48.33	46.64
7	23.00	22.45	57	29.33	28.69	107	47.00	45.94
8	37.67	39.82	58	29.67	30.01	108	46.00	44.63
9	24.33	22.77	59	23.67	24.06	109	47.00	45.84
10	29.00	29.68	60	31.67	34.49	110	45.33	46.44
11	29.67	30.01	61	26.33	26.36	111	42.33	44.74
12	34.67	35.95	62	36.67	37.43	112	46.00	44.87
13	35.67	39.15	63	23.33	21.49	113	42.33	46.51
14	30.33	30.68	64	32.33	33.44	114	41.67	44.14
15	33.00	34.85	65	32.33	33.44	115	48.33	46.57
16	43.00	40.83	66	38.67	38.13	116	45.67	45.75
17	30.67	29.35	67	43.00	40.83	117	47.33	42.42
18	24.00	23.42	68	35.33	35.58	118	48.00	45.10
19	35.67	38.81	69	24.00	23.42	119	44.33	44.99
20	30.33	30.34	70	30.00	29.02	120	48.33	46.64
21	34.00	32.05	71	33.00	31.71	121	39.33	41.18
22	32.67	33.79	72	29.67	28.36	122	44.33	46.76
23	50.67	45.21	73	45.33	42.13	123	50.67	45.21
24	29.00	29.68	74	38.67	38.13	124	46.00	42.68
25	27.33	27.36	75	24.33	25.70	125	46.67	43.40
26	37.00	37.08	76	37.00	39.48	126	44.67	46.82

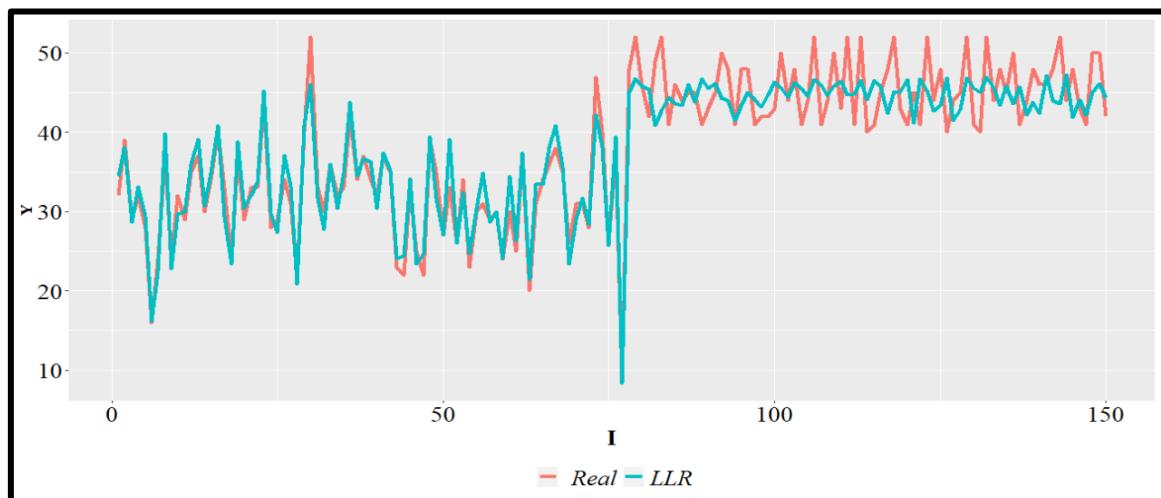
27	32.33	33.09	77	19.33	8.32	127	45.67	41.51
28	22.67	20.86	78	44.33	44.99	128	46.00	42.94
29	43.00	40.83	79	44.67	46.70	129	44.33	46.88
30	49.00	46.04	80	47.00	45.84	130	45.67	45.58
31	33.00	31.71	81	41.67	45.40	131	44.33	44.99
32	28.00	27.70	82	43.00	40.83	132	44.33	46.94
33	34.67	35.95	83	46.00	42.68	133	44.00	45.66
34	30.33	30.34	84	44.33	44.40	134	46.67	43.40
35	33.00	34.85	85	50.00	43.62	135	47.00	45.84
36	45.33	43.82	86	46.67	43.40	136	50.00	43.62
37	31.67	34.49	87	49.00	46.04	137	45.67	45.75
38	35.00	36.71	88	45.33	43.82	138	45.33	42.13
39	36.00	36.33	89	44.67	46.70	139	45.33	43.82
40	30.33	30.34	90	41.33	45.49	140	47.33	42.42
41	36.67	37.43	91	47.33	46.13	141	49.33	47.15
42	34.00	35.21	92	42.33	44.27	142	45.00	43.99
43	23.67	24.06	93	45.00	43.99	143	50.00	43.62
44	23.33	24.39	94	45.67	41.51	144	50.00	47.22
45	31.67	34.14	95	46.67	43.40	145	44.00	41.83
46	24.00	23.42	96	44.33	44.99	146	41.67	44.14
47	23.00	24.71	97	41.67	44.14	147	45.33	42.13
48	37.00	39.48	98	46.67	43.17	148	44.33	44.99

49	33.00	31.71	99	42.33	44.74	149	47.33	46.13
50	28.00	27.03	100	47.67	46.37	150	42.33	44.27

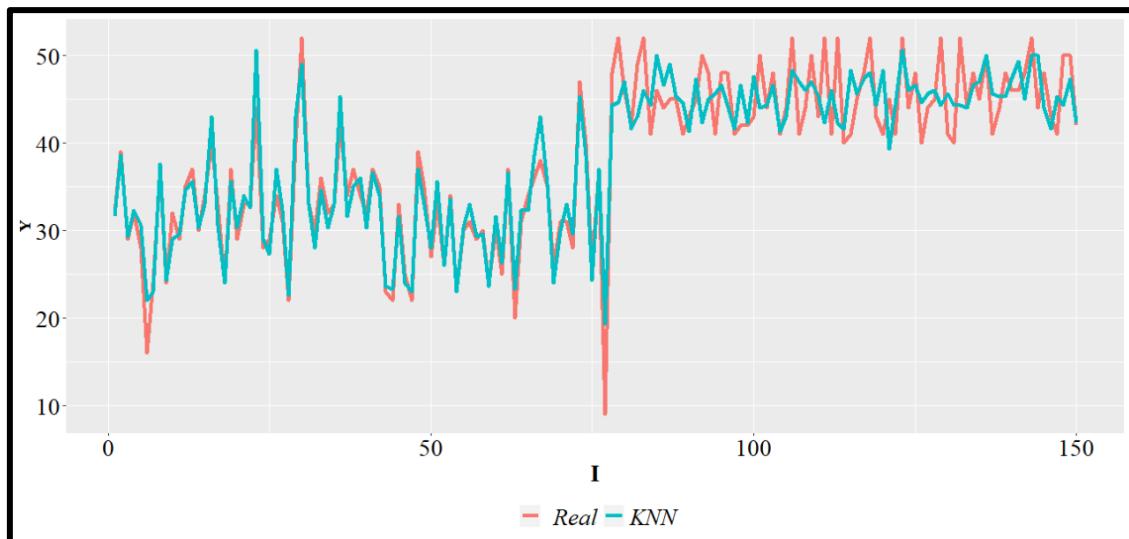
الجدول (8): يبين قيمة معيار المقارنة (RMSE) للبيانات الحقيقية

Methods	KNNE	LLRE
RMSE	3.280137	3.317077

تبين من الجدول (8) أن أفضل طريقة كانت هي طريقة مقدر الجوار الأقرب (KNNE) لامتلاكها أقل قيمة لمعيار جذر متوسط مربعات الخطأ (RMSE) والمساوية إلى (3.280137).



الشكل (3): حجم الخلايا الحمر المكذبة الحقيقة مع المقدرة بطريقة مقدر الانحدار الخطّي الموضعي يتبين من الشكل (3) تقارب سلوك البيانات المقدرة بطريقة الانحدار الخطّي الموضعي (LLRE) مع البيانات الحقيقة، والمتمثلة بحجم الخلايا الحمر المكذبة (PCV).



الشكل (4): حجم الخلايا الحمر المكذبة الحقيقة مع المقدّرة بطريقة مقدّر الجوار الأقرب

يتبيّن من الشكل (4) تقارب سلوك البيانات المقدّرة بطريقة الجوار الأقرب (KNNE) مع البيانات الحقيقة والممثّلة بحجم الخلايا الحمر المكذبة (PCV).

6- الاستنتاجات Conclusions

بناءً على ما تم التوصل إليه من خلال نتائج تجارب المحاكاة (الجائب التجاري) والجائب التطبيقي نستنتج ما يأتي:

Conclusions of the Experimental Side

1-6 استنتاجات الجائب التجاري

- بالنسبة للنموذج الأول كانت الأفضلية لطريقة مقدّر الجوار الأقرب (KNNE) عند حجوم العينات (50,100,150) وبمستوى تباين خطأ ($\sigma^2 = 0.3, 0.7$)، باشتثناء قيمة ($\sigma = 1$)، ول أحجام العينات (50,100,150) كانت الطريقة الأفضل هي مقدّر الانحدار الخطّي الموضعي (LLRE).
- بالنسبة للنموذج الثاني تفوق مقدّر الانحدار الخطّي الموضعي (LLRE) عند حجوم العينات (50,100,150) مستويات التباين المختلفة جميعها.

Conclusions of the Applied Side

6-2 استنتاجات الجائب التطبيقي

- من خلال النتائج للبيانات الحقيقة والممثّلة بالمصابين بأمراض الكلى المزمنة تم التوصل إلى أن أفضل طريقة كانت هي طريقة مقدّر الجوار الأقرب (KNNE).

7- التوصيات Recommendation

7- التوصيات

- اعتماد طريقة مقدّر الجوار الأقرب (KNNE) كطريقة لتقدير أنموذج الانحدار الامثلمي، كونها أثبتت جدارتها في نتائج المحاكاة والتطبيق.
- إجراء مقارنة بين هذه الطرائق المعتمدة بأنموذج شبّة معلمي.
- اعتماد طرائق أخرى في تقدير أنموذج الانحدار الامثلمي.

References

المصادر

أولاً: المصادر العربية.

1. الاشقر، السيد الشربيني، (2023)، "استعمال بعض الشرائح لتمهيد معدلات الوفاة الخام بجدول الاكتواري المصري "، المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط، 4 (1)، 3، 512-547.
2. بدر، دريد حسين، وعبد، هيفاء طه، (2019)، "مقارنة بعض طرائق تقدير أنموذج دالة الانحدار اللامعملي باستعمال المحاكاة "، مجلة الادارة والاقتصاد، العدد (121).
3. حسن، فارس طاهر، ومجيد، غيث حميد، (2016)، "تحديد أفضل أسلوب تمهيدي لتقدير أنموذج انحدار لامعملي مع تطبيق عملي". مجلة كلية التربية الأساسية ، 22 (93 / علمي)، 1-22.
4. الصفاوي، صفاء يونس، ومتى، نور صباح ، (2011). "تقدير دوال الانحدار اللامعملي باستعمال بعض أساليب التمهيد ". المجلة العراقية للعلوم الإحصائية ، العدد 20 (392 -373).

ثانياً: المصادر الإنكليزية.

5. Aydin, D., (2007), "A comparison of the nonparametric regression models using smoothing spline and kernel regression", World Academy of Science, Engineering and Technology, 36, 253-257
6. Burba, F., Ferraty, F., & Vieu, P. (2009). k-Nearest Neighbour method in functional nonparametric regression. *Journal of Nonparametric Statistics*, 21(4), 453-469.
7. Chai, T., & Draxler, R. R. (2014). "Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature". *Geoscientific model development*, 7(3), 1247-1250.
8. Cleveland, W. S. (1979). Robust locally weighted regression and smoothing scatterplots. *Journal of the American statistical association*, 74(368), 829-836.
9. Denis H. and Yan L. (2005), "Cross-Validation in Nonparametric Regression with Outliers", *The Annals of Statistics*, Vol. 33, No. 5, pp. 2291-2310.
10. Denison, D.G.T., Mallick, B.K. & Smith, A.F.M., (1998), "Automatic Bayesian Curve Fitting", *J.R. Statist. Soc. B*, Vol. 60, 333-350.
11. Eguasa, O., Edionwe, E., & Mbegbu, J. I. (2023). Local Linear Regression and the problem of dimensionality: a remedial strategy via a new locally adaptive bandwidths selector. *Journal of Applied Statistics*, 50(6), 1283-1309.
12. Fan, J. (1993). Local linear regression smoothers and their minimax efficiencies. *The annals of Statistics*, 196-216.

13. Ferraty, F., & Vieu, P. (2004)." Nonparametric models for functional data, with application in regression, time series prediction and curve discrimination". *Nonparametric Statistics*, 16(1-2), 111-125.
14. Fix, E. ; Hodges , J. (1989)." Discrimintory Analysis . Nonparametric Discrimintion :consistency properties ". *Inter.Stat. Re.*,57, 238 -247.
15. Györfi, L. Kohler, M. Krzyzak, A. and Walk, H. (2002). Distribution-Free Theory of Nonparametric Regression, New York: Springer.
16. Härdle, W., Müller, M., Sperlich, S., & Werwatz, A. (2004). Nonparametric and semiparametric models (Vol. 1). Berlin: Springer.
17. Hardle.W.(1990),"Applied nonparametric regression",Cambridge- MA: cambirg university press.
18. Linton,O. Xiao, Z.(2001)." A Nonparametric Regression Estimator That Adapts to Error Distribution of Unkown From" Working Paper . o.linton @ Ise.ac.uk.
19. Mundra, K. (2005). "Nonparametric slope estimation for fixed effects paneldata. Working Paper" , Department of Economics, San Diego State University.
20. Smith, M., Sheather, S. & Kohn, R., (1996), " Finite Sample Performance of Robust Bayesian Regression", *Computational Statistics*, Vol. 11, 269-301.
21. Theodoridis S. and Koutroumbas K.,(2003),"Pattern Recognition " 2nd ed. ,Elsevier(USA).