

مقارنة طريقي تقدير الدالة الامثلية لبيانات عنقودية عن كريات الدم البيضاء لمرضى اللوكيميا

أ.م.د. سجي محمد حسين / كلية الادارة والاقتصاد / جامعة بغداد

م.م. حلا كاظم عبيد / كلية الادارة والاقتصاد / الجامعة العراقية

تاريخ التقديم : 2016/8/16

تاريخ القبول : 2016/11/9

المستخلص:

البيانات العنقودية تظهر في الكثير من العلوم الاجتماعية والصحية والسلوكية. ويتميز هذا النوع من البيانات بوجود الارتباط بين مشاهداتها . وتمكن التعبير عن العقدة من حيث العلاقة بين القياسات على الوحدات ضمن المجموعة نفسها . تم في هذا البحث تقدير الدالة الامثلية لبيانات العنقودية باستعمال طريقة المقدرات اللبية غير المرتبطة ظاهريا The Seemingly Unrelated Kernel Estimators The Generalized Least Squares وتم تطبيق الطريقتين المذكورتين على بيانات مرضى اللوكيميا وتمت المقارنة بين الطريقتين عن طريق معيار المقارنة MAE و MSE واوضحت النتائج التطبيقية كفاءة مقدر المربعات الصغرى المعتمدة لمقدرات الشريحة التمهيدية.

المصطلحات الرئيسية للبحث / البيانات العنقودية ، الطريقة المقدرات اللبية غير المرتبطة ظاهريا، وطريقة المربعات الصغرى المعتمدة لمقدرات الشريحة التمهيدية، MAE,MSE



مجلة العلوم
الاقتصادية والإدارية
العدد 97 المجلد 23
الصفحات 419-394

*البحث مستل من اطروحة دكتوراه



المقدمة:

يطلق على مجموعة من القياسات المشتركة من المعلومات او الاشياء ضمن عنقود واحد (cluster) التي تمت هيكلتها في عناقيد بالبيانات العنقودية. حيث ان مجموعة من الاشياء المشتركة تسمى عنقود والبيانات ضمن العنقود الواحد تكون متماثلة (مرتبطة) اكثر مع بعضها البعض من تلك الموجودة في العناقيد الاخرى^[3]. استعملت البيانات العنقودية في الكثير من مجالات الطب الحيوى وعلم الوبئة والظواهر الزراعية والاقتصادية وغيرها ، ومما تجدر الاشارة اليه ان البيانات العنقودية تشبه البيانات الطولية من حيث اعتمادية البيانات داخل العنقود الواحد (القطاع بالنسبة للبيانات الطولية) على بعضها بعضا^[5]. ومن هنا تأتي اهمية الارتباط الموجود داخل المشاهدات لتقدير الدوال حيث ان استخدام الاسلوب المعلمى لا يكون دائمًا مرغوب فيه لتقدير بعض الدوال بسبب ان شكل الدالة الملائمة للبيانات غير معروف مسبقا او نتيجة لوجود بعض المعوقات لذلك يتم استخدام الاسلوب الامعلمى لتقدير(تمهيد) الدالة الامثلية. لقد تطورت البحوث في الاونة الاخيرة حول استخدام الانحدار الامعلمى عندما تكون الافتراضات المعلمية غير متحققة، والانحدار الامعلمى يسمح بمروره اكبر للدواال المعتمدة على المتغيرات الناتجة من البيانات. لقد تطرقت البحوث السابقة الى حالة تقدير البيانات العنقودية بالطرائق الامعلمية والطرائق الشبه معلمية واعتمدت حالة اهمال الارتباط داخل بيانات العنقود الواحد الخاصة التي تميز البيانات العنقودية بشكل خاص . حيث ان المقدرات اللبية الموضعية حققت كفاءة اكثرا باهمال الارتباط داخل العناقيد (حتى وان كان الارتباط في مصلحة الدراسة).

حيث ان مصفوفة الارتباط داخل العنقود تلعب دورا مهما في كفاءة التقدير للدواال غير المعلومة (x) في نموذج الانحدار الامعلمى

$$(1) \quad y = \theta(x) + \epsilon$$

وتتشا البيانات العنقودية في كثير من المجالات ومنها المجالات الطبية ويعتبر سرطان الدم احدي المجالات التي يمكن ان تعد البيانات الماخوذة من المرضى المصابين به احدي انواع البيانات العنقودية. حيث يعتبر كل شخص (مريض) كعنقود وتؤخذ له قياسات دورية لنسبيه كرات الدم البيضاء ونسبة الهايموغلوبين وتعتبر القياسات المتكررة في حالات (اوقات) مختلفة وحدات المستوى الاول وتمثل وحدات المستوى الثاني بالاشخاص.

يتتميز سرطان الدم بوجود عدد كبير من الخلايا البيضاء الناضجة نسبيا ولكنها تمتلك شكل غير طبيعي فضلا عن ان خلايا الدم البيضاء في العادة تحتاج الى شهور لتتضخم ولكن في هذه الحالة خلايا الدم البيضاء تنتج بسرعة عالية مما يؤدي الى وجود عدد من الخلايا البيضاء غير الطبيعية غير المسيطر عليها التي من غير الممكن التكهن بسلوكها. لهذا النوع من البيانات يمكن تدريجها باستعمال النموذج (1).

هدف البحث:

يهدف البحث الى تقدير الدالة الامثلية لبيانات العنقودية باستخدام طريقة المقدرات اللبية غير المرتبطة ظاهريا (seemingly unrelated kernel regression) وطريقة المربعات الصغرى المعممة لمقدر الشريحة التمهيدية (generalized least squares smoothing spline estimator) مع الاخذ بنظر العناية الارتباط الموجود داخل العنقود الواحد حيث ان مصفوفة الارتباط داخل العنقود الواحد تلعب دورا مهما في تحليل البيانات العنقودية مع اخذ حالة الارتباط الموجود داخل العناقيد ومقارنتها مع حالة الاستقلالية لبيانات كريات الدم البيضاء لمرض اللوكيميا من خلال معيار المقارنة MSE و MAE .



الاستعراض المرجعي:

في عام 2000 درس كل من LIN,X.&CARROLL,R.J طريقة الانحدار النبي لمتعدد الحدود الموضعي مع متغير واحد لبيانات عنقدية باستخدام المعادلات التقديرية على افتراض ان كل عنقد يشمل عدة مشاهدات ولتكن m^{∞} حيث يتم قياس المؤشر في حالة غياب خط القياس للانحدار العشوائي بتجاهل هيكلية الارتباط داخل العنقد واثبت ان المقدر النبي الموضعي لمتعدد الحدود يكون اكثراً كفاءة في حالة تجاهل الارتباط الموجود داخل العنقد الواحد واستخدموا الطريقة المقترحة في تحليل بيانات نقص المناعة البشرية لخلايا الـ CD_4 . واكدا ان استعمال الطريقة النبيه المحددة لا تسفر بالضرورة عن مقدر جيد عند حساب الارتباط داخل العنقد.^[12]

وفي عام 2001 استخدم كل من الباحثين LIN, X. and CARROLL R.J النماذج شبه المعلمية الخطية العامة لبيانات العنقدية باستخدام المعادلات التقديرية المعممة GEE وطبقت النتائج في حالة كون عدد المشاهدات لكل عنقد محدودة وعدد العنقدات كبير ومتوسط النتيجة μ يمثل بالشكل

$$g(\mu) = X^T \beta + \theta(T)$$

حيث $(.)$ دالة ربط و X و T متغيرات و β متوجه المعلم غير المعلومة و $\theta(T)$ دالة ممهدة غير معلومة^[11]

وفي عام 2002 قام كل من الباحثين Welsh,A.H.,Lin,X.and Carroll,R.J. بدراسة مقدر الشريحة الذي يمتلك وزنا اكثراً وتبين اقل من الطريقة النبيه والتباعين المحاذي يكون اقل عند حساب الارتباط بشكل صحيح. حيث ان الطريقة النبيه تسلك سلوك مختلف عن طريقة الشرائح التمهيدية في حالة اخذ هيكلية الارتباط الموجود داخل العنقد في حين ان كلا الطريقتين الشرائحية والنبيه تكونان متكافتين في حالة اهمال الارتباط داخل العنقد.^[17]

وفي عام 2005 قام الباحث مناف يوسف حمود باستعراض بعض الطرائق اللامعليمية وشبه المعلمية مع بعض الطرائق المقترحة لتقدير دالة الكثافة الاحتمالية كذلك استعراض الطرائق الاهم والخاصة بتقدير المعلمة التمهيدية ومقارنة تلك الطرائق من خلال استخدام اسلوب المحاكاة باستعمال توزيعات وجسم عينات ومستويات تباين مختلفة للمتغير λ .^[1]

وفي عام 2007 قام الباحث عمر عبد المحسن بدراسة امكانية تقدير النموذج التجاري Generalized Additive Model (GAM) لتحليل النماذج الشبه معلمية فضلاً عن التحليل اللامعليمي واقتراح تقدير GAM الحصينة عبر دالة وزن معينة للتحليل المعلمي وشبه المعلماني في حالة وجود تلوث في البيانات واوضح استعمال الشرائح التمهيدية بشكل جزئي (partially) (شبه معلماني) افضل من استعمالها بشكل كامل completely (لامعلماني) عند تحليل GAM.^[2]

وفي عام 2008 قام كل من Wang, Y. G. & Zhao, Y. بتحليل البيانات العنقدية لنماذج الانحدار على اساس الرتبة واقتروا طريقة رتبة wilixon الموزونة لحساب الارتباط داخل العنقد والأحجام مختلفة من العنقدات. واجراء دراسة المحاكاة لمقارنة المقدرات المختلفة لعدد من الطرائق حول هيكلية الارتباط بوجود او عدم وجود القيم المتطرفة وان الطرائق المقترحة تظهر اداء جيد في حالة حساب الارتباط الموزون داخل العنقدات فضلاً عن الطرائق الحصينة المتضمنة عدم الحساسية للقيم الشاذة وهيكلية الارتباط.^[16]

وفي عام 2010 قام كل من Ibrahim, N.A.& Suliadi بتحليل البيانات العنقدية /الطولية باستخدام المعادلات التقديرية GEE مع ممهادات الشريحة الطبيعية التكعيبية باستخدام المحاكاة مع اخذ حالة الارتباط الموجود داخل العنقد بعين العناية حيث اظهر ان GEE-Smoothing spline لها خصائص افضل من GEE-Local Polynomial Kernel الذي تناولتها Lin &Carroll 2000 Ibrahim, N. A. & Suliadi كفاءة المقدرات الناتجة من حيث التحييز والكافأة والاتساق في حالة الارتباط الحقيقي للبيانات داخل العنقد.^[13]

وفي عام 2013 قام كل من Ma, S., Song, Q. & Wang, L., بتطوير منهجية عامة لاختيار المتغيرات انيا وتقدير العناصر المجهولة للنماذج التجريبية الخطية جزئياً additive partially linear models (APLMS) باختصار (APLMS) لبيانات العنقدية



وافترحوا في الخطوة الاولى المربعات الصغرى للحصول على التقدير المعلميم اما المركبات اللامعلميمية فيتم تقديرها على اساس متعدد الحدود للشراوح التمهيدية polynomial spline smoothing ويعتبر هذا الاسلوب من سهل التطبيق على ارض الواقع وركزوا على اخذ الجزء الخطى في النموذج وتحسين الكفاءة يجب على المرء ان يختار هيكلية الارتباط المناسبة لبيانات المدروسة.^[7]

الجانب النظري:

تم في هذا البحث عرض بعض طرائق تقدير الدالة اللامعلميمية لبيانات العنقدية وكما يأتي:

(1) طريقة مقدر النواة غير المتصل ظاهريا: The Seemingly Unrelated Kernel Estimator

نفرض n من العناقيد بـ m_i من المشاهدات داخل كل عنقود حيث $i = 1, 2, \dots, n$ وان j من المشاهدات $m_j = 1, 2, \dots, m_i$ في كل عنقود مؤلف من متغيرات الاستجابة Y_{ij} ومتغير مفرد X_{ij} التي تمثل القياسات المتكررة داخل كل عنقود عبر اوقات مختلفة . بالنسبة لبيانات الطولية حيث ان كل عنقود يمثل قطاع، اما بالنسبة لبيانات العائلية فان كل عائلة تمثل عنقود والمشاهدات داخل العنقود تمثل مختلف افراد الاسر من العائلة نفسها كما موضح في النموذج في المعادلة رقم 1 ،فان لأى مصفوفة تباين وتباین مشترك V فان معدل مقدر النواة غير المتصل ظاهريا ويرمز لها بالرمز $\hat{\theta}_k(x)$ ويساوي لأى نقطة وعندما تكون رتبة مقدر النواة غير المتصل ظاهريا p فان

$$\hat{\theta}_k(x) = k_{wh}^T(x) \{ I + (\tilde{V}^{-1} - \tilde{V}^d) k_w \}^{-1} \tilde{V}^{-1} Y \quad (2)$$

حيث ان: k_{wh} ويساوي: $nm \times 1$ متوجه من الرتبة

$$k_{wh}(x) = \left\{ \sum_{i=1}^n \sum_{j=1}^m k_h(X_{ij} - x) V^{jj} \right\}^{-1} \{ k_h(X_{11} - x), \dots, k_h(X_{nm} - x) \}^T$$

$$nm \times nm \quad \text{مصفوفة من الدرجة} \quad Y = [\underline{y}_1, \underline{y}_2, \dots, \underline{y}_n]^T \quad \text{وان} \quad \underline{y}$$

$$y_i = (y_{1i} \ y_{2i} \ \dots \ y_{im})^T \quad \text{متوجه من الرتبة} \quad nm \times 1$$

وان k_w عبارة عن مصفوفة $nm \times nm$

$$\tilde{V}^d = diag(V^d, V^d, \dots, V^d); V^d = diag(V^{-1}) = diag(V^{jj}) \quad \text{وان}$$

$$\tilde{V} = diag(V_1, \dots, V_n)$$

ولمتجه (X) من الرتبة $1 \times nm$ يحتوي كل المقدرات $(\hat{\theta}_k(x))$ لكل نقاط التصميم

$$\hat{\theta}_k(X) = \{ \hat{\theta}_k(X_{11}), \dots, \hat{\theta}_k(X_{nm}) \}^T \quad \text{حيث ان:} \\ \text{فان:}$$

$$\hat{\theta}_k(X) = \{ I + K_w(\tilde{V}^{-1} - \tilde{V}^d) \}^{-1} k_w \tilde{V}^{-1} Y \quad (3)$$



وحيث ان

$$k_{wh}(x) = \delta_1' \{ \tilde{X}(x)' k_{dh}(x) V^d \tilde{X}(x) \}^{-1} \tilde{X}(x)' k_{dh}(x)$$

$$\delta_1 = (1, 0, \dots, 0)'$$

وان $\tilde{X}(x)$ مصفوفة من الدرجة $nm \times p+1$ $\{(n-1)^{i+j}\}$ من الصفوف

$$\tilde{X}(x) = \begin{bmatrix} 1 & (X_{11} - x) & (X_{12} - x)^2 & \dots & (X_{1m} - x)^p \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & (X_{n1} - x) & \dots & (X_{n2} - x)^2 & \dots & (X_{nm} - x)^p \end{bmatrix}$$

$$k_{dh}(t) = diag\{(X_{11} - x)/h, \dots, (X_{nm} - x)/h\}$$

$$k_h(s) = h^{-1} k_h(s/h)$$

حيث: $k_h(s)$ تمثل دالة الكيرنل وباستخدام دالة ال Gaussian فان:

$$k(\cdot) = (2\pi)^{-0.5} \text{Exp}\left(-\frac{u^2}{2}\right) \quad (4)$$

و h يمثل عرض الحزمة (Bandwidth) التي سيتم حسابها لاحقاً و مصفوفة الـ V من الدرجة $nm \times nm$ تحسب كالتالي:

$$V = A^{1/2} R(\alpha) A^{1/2} \quad (5)$$

A تمثل مصفوفة الانحراف المعياري من الدرجة $nm \times nm$

$$A = \begin{bmatrix} a_{11}^{1/2} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & a_{im}^{1/2} \end{bmatrix}$$

$$a_{ii} = \sqrt{\text{var } y_{i1}} \quad \text{حيث ان :}$$

و ان $R(\alpha)$ تمثل مصفوفة الارتباطات من الدرجة $nm \times nm$

$$R(\alpha) = \begin{bmatrix} 1 & \rho_{i1} & \dots & \rho_{imi} \\ \vdots & \ddots & \ddots & \vdots \\ \rho_{imi} & \dots & 1 \end{bmatrix}$$



$$R(\alpha) = \text{corr}(y_{ij}, y_{ij+1}) \quad i = 1, \dots, n-1$$

$$\hat{\rho}_{ij} = \frac{y_{ij} - m(y_{ij})}{\sqrt{v(y_{ij})}}$$

(2) طريقة المربعات الصغرى المعممة لمقدر الشريحة التمهيدية: The Generalized Least Squares Smoothing Spline Estimator

يراد من دراسة الشرائح التمهيدية مطابقة البيانات بشكل جيد من جهة ويكون الممهد على قدر من التمهيد من جهة أخرى ولتقدير المعلمة الممهد في النموذج (1) باستخدام ممهدات الشريحة من الدرجة p ولأي مصفوفة تباين عاملة V والذي يقلل المعادلة

$$\frac{1}{n} \sum \{Y_i - \theta(X_i)\}' V^{-1} \{Y_i - \theta(X_i)\} + \lambda \int \{\theta^{(p)}(X)\}^2 dX \quad (6)$$

حيث ان $\theta^{(p)}(X)$ قابلة للاستدراك P من المرات لدالة الانحدار، وان الحد الثاني من المعادلة (6) يمثل مقدار عدم التمهيد فان مقدر الشريحة الممهد بالصيغة الآتية :

$$\hat{\theta}_s(X) = (\tilde{V}^{-1} + n\lambda\psi)^{-1} \tilde{V}^{-1} Y \quad (7)$$

λ : معلمة تمهد التي تتغير بتغير الدوال وليس بتغير العقد وتكون $0 < \lambda^{[9]}$ وان الد

$$nm \times nm \quad Y = [\underline{y}_1, \underline{y}_2, \dots, \underline{y}_n]'$$

$$nm \times 1 \quad y_i = (y_{1i} \ y_{2i} \ \dots \ y_{im})'$$

$$[15],[8],[10] \quad nm \times p+1 \quad \tilde{X}(x)$$

ومصفوفة ال $\tilde{X}(x)$ من الدرجة $p+1$

ولتقليل المعادلة (6) وباستخدام معلمة تمهد ثابتة λ لجميع الدوال المستمرة والمختلفة تقود الى استخدام الشرائح التكعيبية مع عقد عند نقاط البيانات (اي تستخدم البيانات كعقد عند نقاط التصميم) حيث ان قيمة الـ $p=2$ في المعادلة (6)^[4] وإيجاد مصفوفة ال C فان:

$$\psi = C Q^{-1} C' \quad (7)$$

حيث ان C مصفوفة من الدرجة $n \times n-2$

$$C_{n \times n-2} = [C_{ij}] \quad i = 1, \dots, n; j = 2, \dots, n-2$$

$$L_i = x_{(i+1)} - x_i \quad i = 1, \dots, n-1$$

$$C_{ij} = 0 \quad \text{if } |i-j| \geq 2$$

$$C_{j-1,j} = L_{j-1}^{-1}$$



$$C_{jj} = -L_{j-1}^{-1} - L_j^{-1}$$

وتصفوفة الـ Q من الدرجة $n-2 \times n-2$

$$Q = [q_{ij}] \quad i, j = 2, \dots, N-1 \quad (8)$$

حيث ان :

$$q_{ij} = 0 \quad \text{if } |i-j| \geq 2$$

$$q_{i,i+1} = q_{i+1,i} = L_i / 6 \quad i = 2, \dots, N-2$$

$$q_{ii} = (L_{i-1} + L_i) / 3 \quad i = 2, \dots, N-1$$

$$\tilde{V} = \text{diag}(V, V, \dots, V) \quad ; V = D^{1/2} R(\alpha) D^{1/2} \quad (9)$$

$$D = \text{diag} [\sqrt{\text{var}(y)}]$$

ولنفرض ان نقاط التصميم x_1, x_2, \dots, x_m المرتبة تصاعديا تمثل جميع نقاط المشاهدات في العناقيد $x_{ij}, i = 1, 2, \dots, n, j = 1, 2, \dots, m$ حيث تستخدم عقدة كعده حيث ان $a < x_1 < x_2 < \dots < x_m < b$ حيث ان a, b تحدد مدى فترة الزمن . تستعمل جميع نقاط التصميم ويجب ان تكون العقد اصغر من حجم العينة^[14]

معيار العبور الشرعي العام (General Cross Validation):

يتم استخدام معيار العبور الشرعي العام لاختيار معلمة التمهيد من خلال ابدال القيمة الموضحة في المعادلة (6) والتي

$$\sum_{i=1}^n (I - A_{ii})^{-1} (I - A_{ii})^{-1} \quad \text{تساوي} \quad \frac{1}{(nm)^{-1} \text{trace}(A)} \quad \text{والتي تكون صيغته كالتالي}$$

$$GCV(\eta) = \frac{\sum_{i=1}^n \sum_{j=1}^m \{Y_{ij} - \hat{\theta}(X_{ij})\}^2}{\{1 - (nm)^{-1} \text{trace}(A)\}^2} \quad (11)$$

ويتم اختيار معلمة التمهيد ال η التي تقابل اصغر قيمة لـ $GCV(\lambda)$

معيار المقارنة:

يستخدم معيار المقارنة للتعرف على افضل طريقة للتقدير ، من خلال المقارنة باقل متوسط مربعات الخطأ او اقل متوسط القيمة المطلقة للأخطاء وللذان تكون صيغة كل منها بالشكل الاتي:

$$MSE[\hat{\theta}(X)] = \text{mean}[\theta(X) - \hat{\theta}(X)]^2 \quad (12)$$

$$MAE[\hat{\theta}(X)] = \text{mean}|\theta(X) - \hat{\theta}(X)| \quad (13)$$



الجانب التطبيقي:

يعرف سرطان الدم (اللوكيميا) بأنه عبارة عن تكاثر غير محكم لخلايا الدم وعادة ما يكون هذا التكاثر لخلايا الدم البيضاء، حيث أن عددها في الدم يزيد عن الحد الطبيعي وهو من 5 الاف إلى 10 الاف خلية لكل ملم. ففي سرطان الدم يكون عدد الخلايا من (15-30) ألف خلية لكل ملم . وقد يصل هذا التكاثر إلى أكثر من 100 ألف خلية لكل ملم أو حتى يكون أقل من 5 الاف خلية لكل ملم (أي أقل من العدد الطبيعي). ويعد اختلاف هذا العدد إلى مرحلة سرطان الدم ومدى تقدمه في الجسم ، فخلايا كرات الدم البيضاء غير طبيعية تنتج في نخاع العظم وهو مصنوع ومصدر خلايا كرات الدم جميعها في الجسم فيؤدي تكاثرها في نخاع العظم إلى خروجها من الدم . ففي تكاثرها في المراحل الأولى يؤدي ذلك إلى تقليل عدد خلايا كرات الدم المصنعة وقبل ان تخرج خلايا كرات الدم البيضاء إلى خارج الدم مما يؤدي إلى وجود نقص مرحي في كرات الدم البيضاء في الدم في بداية المرض، ولكن سرعان ما يصدر نخاع العظم هذه الخلايا السرطانية إلى الدم ليزيد بذلك عدد كرات الدم البيضاء في الدم. وهذه الزيادة عادة ما تكون مضطربة. ومن اثار هذه الزيادة يصاب المريض بنقص الهيموغلوبين ومن ثم بفقر في الدم فيبدأ يعاني من تعب من اي مجهود يقوم به ودوران وكثرة حب النوم وكسل شديد. ومع استمرار المرض يعاني المريض من نقص في الصفائح الدموية فيصبح دمه يتاخر في التجلط وتكون عدة كدمات على جلدته نتيجة عدم قدرة الجسم على وقف التجلطات [6]

تم جمع بيانات عن مرض اللوكيميا لـ 100 شخص واخذت ثلاثة قياسات لكل شخص لثلاث اوقات مختلفة من مستشفى بغداد التعليمي /مدينة الطب، واخذت نسبة التغيرات لعدد كريات الدم البيض كمتغيرات توضيحية ومن ثم اخذت نسبة الهيموغلوبين في الدم كمتغيرات استجابة، ترتبط هذه القياسات فيما بينها مكونة مصفوفة الارتباط التي تلعب دوراً مهماً في تقدير دالة الانحدار الامعلمية لبيانات كريات الدم البيضاء حيث تكون مصفوفة الارتباط في حالة الاستقلالية لثلاث اوقات لمتغير الاستجابة بالشكل الآتي:

$$R(\alpha) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

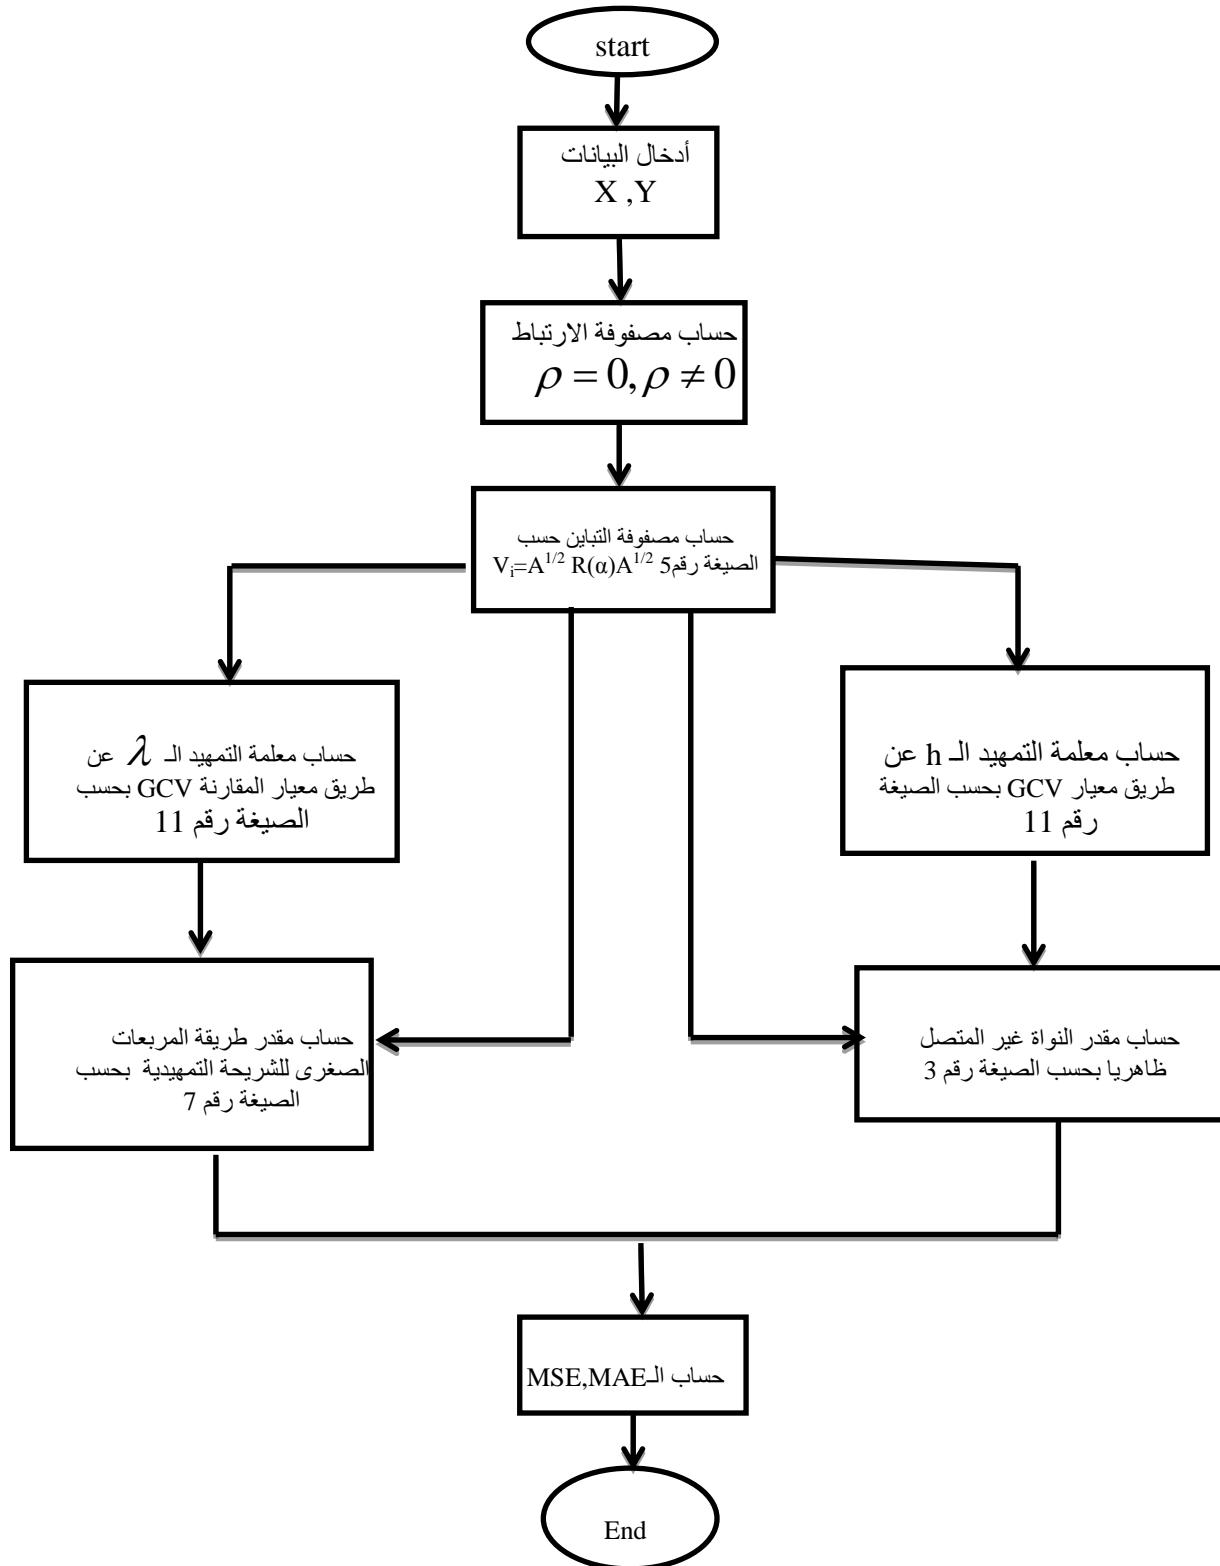
وفي حالة الارتباط الحقيقي بين العناصر فان:

$$R(\alpha) = \begin{bmatrix} 1 & 0.57 & 0.415 \\ 0.57 & 1 & 0.584 \\ 0.415 & 0.584 & 1 \end{bmatrix}$$



مقارنة طريقي تقدير الدالة الامثلية لبيانات متقدمة عن كريات الدم البيضاء لمرضى اللوكيميا

مخطط انسيابي يوضح العمل الرياضي





مقارنة طريقي تقدير الدالة الامثلية لبيانات عنقودية عن كريات الدم البيضاء لمرضى اللوكيميا

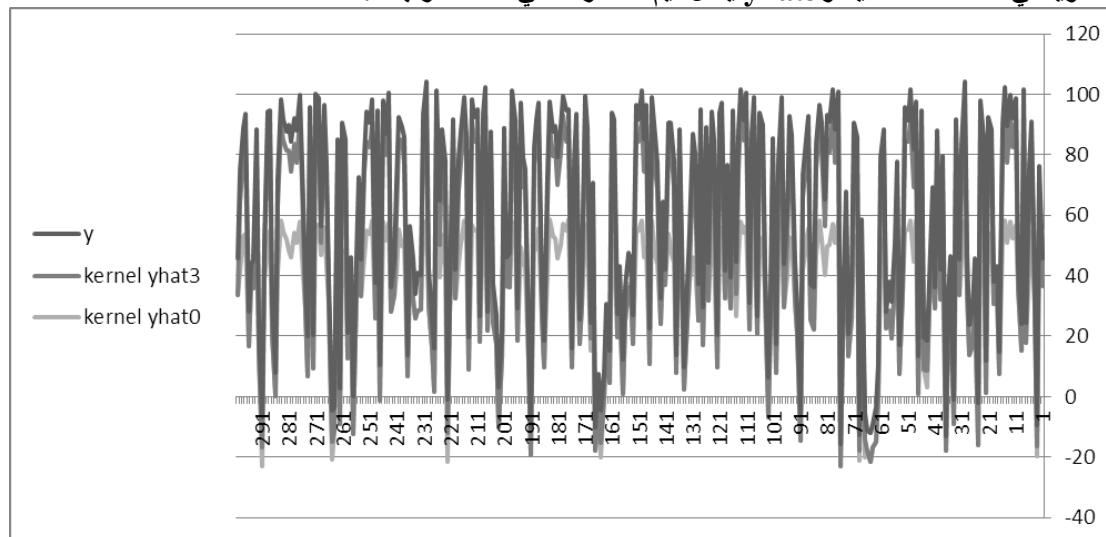
تحليل النتائج

تم تطبيق الطرائق المذكورة في الجانب النظري لبيان افضل طريقة لتقدير الدالة الامثلية التي تحقق اقل متوسط مربعات الخطأ واقل قيمة لمتوسط الاخطاء المطلقة باستخدام برنامج برماج بلغة الماتلاب (MATLAB) كما موضح في الملحق رقم (2) والجدول رقم (1) يمثل قيم MAE , MSE لطريقة المقدرات الليبية غير المرتبطة ظاهريا، وطريقة المربعات الصغرى المعممة لمقدرات الشريحة التمهيدية في حالة الارتباط والاستقلالية ونلاحظ من الجدول ان اقل متوسط مربعات الخطأ واقل قيمة لمتوسط الاخطاء المطلقة كانت لطريقة المربعات الصغرى للشريحة التمهيدية في حالة وجود الارتباط.

جدول رقم (1) يبين قيم MSE , MAE لحالتي الاستقلالية والارتباط لكل من طريقتي(المقدرات الليبية غير المرتبطة ظاهريا، وطريقة المربعات الصغرى المعممة لمقدرات الشريحة التمهيدية)

Methods	حالة الاستقلالية	حالة الارتباط
Kernel	$Mse=(30.60145)$ $Mae=(1156.274)$	$Mse=(15.21513)$ $Mae=(283.6377)$
Spline	$Mse=(1.685315)$ $Mae=(4.290639)$	$Mse=(1.681781)$ $Mae=(4.284745)$

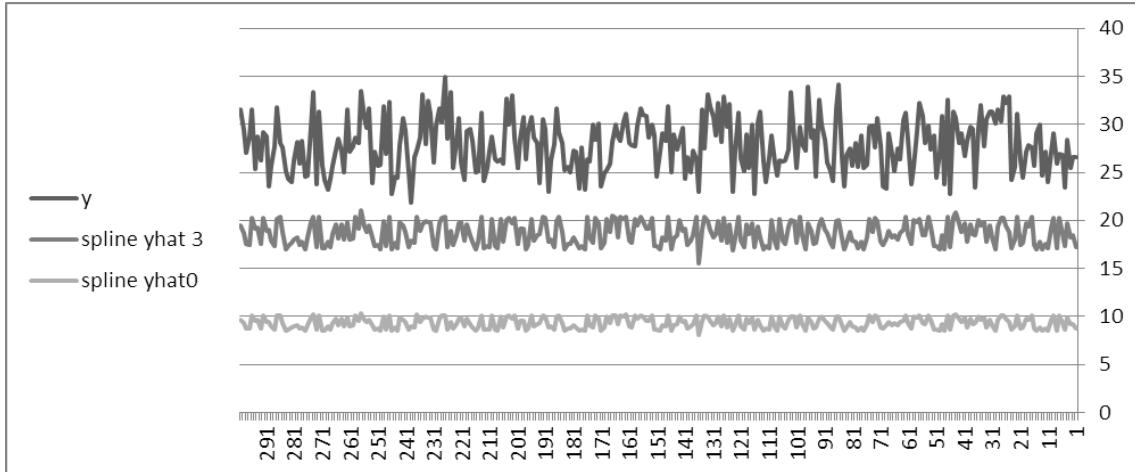
شكل رقم (1): يمثل قيم y الحقيقة و $yhat0$ يمثل تقدير النموذج باستخدام المقدرات الليبية غير المرتبطة ظاهريا في حالة الاستقلالية و $yhat3$ يمثل قيم المقدرات في حالة الارتباط .



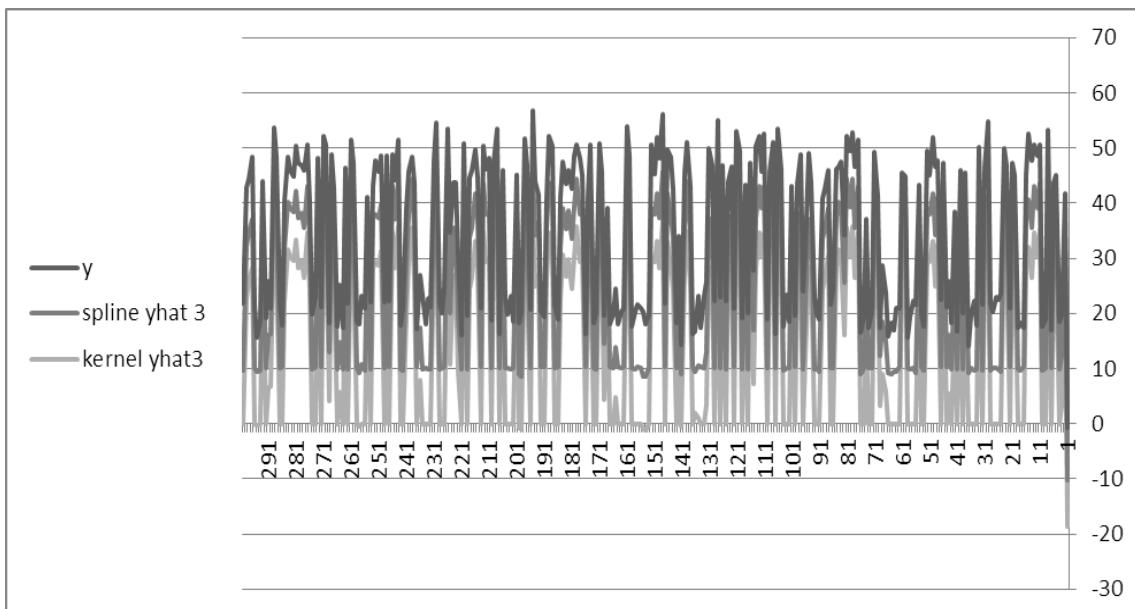


مقارنة طريقة تقدير الدالة اللامعالمية لبيانات عشوائية عن كريات الدم البيضاء لمرضى اللوكيميا

شكل رقم (2): يمثل قيم y الحقيقية يمثل قيم y الحقيقة و $yhat0$ يمثل تقدير النموذج باستخدام مقدرات المربعات الصغرى المعممة لممهد الشريحة في حالة الاستقلالية و $yhat3$ يمثل قيم المقدرات في حالة الارتباط



شكل رقم (3): y يمثل القيم الحقيقة للمتغير المعتمد و $yhat0$ يمثل تقدير النموذج باستخدام مقدرات المربعات الصغرى المعممة لممهد الشريحة في حالة الارتباط و $yhat3$ يمثل تقدير النموذج باستخدام قيم المقدرات الليبية غير المرتبطة ظاهريا في حالة الارتباط.



من ملاحظة الاشكال الثلاثة فنرى من الشكل (1) مقدرات طريقة مقدر النواة غير المتصل ظاهريا مقارنة مع قيم y الحقيقة حيث تقترب قيم $yhat3$ في حالة الارتباط من القيم الحقيقة اكثر من قيم المقدر $yhat0$ في حالة الاستقلالية .



اما في الشكل (2) فنلاحظ بان مقدرات طريقة المربيعات الصغرى المعممة لمقدر الشريحة التمهيدية Generalized least squares smoothing spline) مقارنة مع قيم بالحقيقة حيث تقترب قيم y_{hat} في حالة الارتباط من القيم الحقيقة اكثرا من قيم المقدر \hat{y}_{00} في حالة الاستقلالية. اما في الشكل (3) فيوضح مقدرات مقدر النواة غير المتصل ظاهريا Seemingly Unrelated Kernel و مقدرات طريقة المربيعات الصغرى المعممة لمقدر الشريحة التمهيدية generalized least squares smoothing spline في حالة ارتباط البيانات مقارنة مع قيم y الاصلية حيث ان مقدرات مقدرات طريقة المربيعات الصغرى المعممة لمقدر الشريحة التمهيدية Generalized least squares smoothing spline تقترب اكثرا من القيم الحقيقة مقارنة مع قيم مقدرات النواة غير المتصل ظاهريا spline في حالة الارتباط لكلا المقدرين Unrelated Kernel .

الاستنتاجات :

- ان كل من الطريقتين (طريقة النواة غير المتصل ظاهريا) و(طريقة المربيعات الصغرى لممهد الشريحة التمهيدية) حققت اقل MSE واقل MAE عند حساب مصفوفة الارتباط داخل العناصر بعين العناية بالمقارنة مع حالة استقلال البيانات .
- حققت طريقة المربيعات الصغرى لممهد الشريحة التمهيدية اقل MSE واقل MAE مقارنة مع طريقة ممهد النواة غير المتصل ظاهريا في الحالتين (حالة الارتباط الحقيقي للبيانات) و(حالة الاستقلالية) .

التصويبات :

- 1- يمكن استخدام الطرائق المذكورة في البحث في حالة الامراض غير المسيطر عليها (النادرة) التي يكون تطورها غير معروف .
- 2- يمكن اخذ حالة البيانات العتفودية غير المتنزنة وتطبيق الطرائق المذكورة انفا .

المصادر:

المصادر العربية:

- 1- حمود د مناف يوسف (2005) ((مقارنة المقدرات اللامعلمية لتقدير دالة الكثافة الاحتمالية)) اطروحة دكتوراه في الاحصاء كلية الادارة والاقتصاد/جامعة بغداد.
- 2- علي د.عمر عبد المحسن (2007) ((مقارنة مقدرات النماذج التجميعية المعممة باستخدام الشرائح التمهيدية عند تحليل الانحدار اللامعلمي وشبكة المعلمي)) اطروحة دكتوراه في الاحصاء كلية الادارة والاقتصاد/جامعة بغداد.

المصادر الأجنبية:

- 3-Galbraith, S. Daniel, J. A .& Vissel ,B.(2010)((A Study of Clustered Data and Approaches to Its Analysis)),The Journal of Neuroscience ,30(32) : 10601-10608.
- 4-Garrett_Fitzmaurice,_Marie_Davidian,_Geert_Verbeke & Geert_Molenberghs .(2009) ((Longitudinal Data Analysis)) Chapman& Hall/ CRC.
- 5-[Http://www.jormedic.com/component/mailto/?tmpl=com](http://www.jormedic.com/component/mailto/?tmpl=com)
- 6-[Https://en.wikipedia.org/wiki/Cluster_analysis](https://en.wikipedia.org/wiki/Cluster_analysis)
- 7- Ibrahim, N, A.& Suliadi,2010a ((Analyzing Longitudinal Data Using Gee-Smoothing Spline)) . WSEAS Transactions on Systems and Control
- 8-Liang ,K.-Y. and Zeger, S.L. (1986) ((Longitudinal data analysis using generalized linear models)).Biometrika,73,13-22.



- 9- Lin, D. & Ying, Z. (2001) ((semiparametric and nonparametric regression analysis of longitudinal data)). J.Amer. Statist. Assoc . ,96,103-126.
- 10- Lin, X. Carroll, R. J.(2001) ((Semiparametric Regression For Cluster data) ,Biometrika,88,No.4;1179-1185.
- 11-Lin,X.&Carroll,R. J.(2000) (Nonparametric function estimation for clustered data when the predictor is measured without/with error) J.Amer. Statist. Assoc.,95,520-534al Data)).
- 12- Linton, O.B., Mammen, E., Lin, X. and Carroll, R.J.(2003) ((Accounting for correlation in marginal longitudinal nonparametric regression)) 2nd Seattle Symp. Biostatistics.
- 13-Ma, S., Song., Q. and Wang,L.,2013,((Simultaneous variable selection and estimation in semi parametric modeling of longitudinal/clustered data))Bernoulli 19,252-274
- 14-Ruckstuhl,A.,Welsh,A.H.&Carroll,R.J.(2000).((Nonparametric function estimation of the relationship between two repeatedly measured variables)).Statist. Sinica, 10,51-71.
- 15- Wang, N.(2003)((Marginal nonparametric Kernel regression accounting for within-subject correlation)),Biometrika,90,43-52.
- 16- Wang, Y. G.& Zhao, Y.(2008)((Weighted rank regression for clustered data analysis)). [Biometrics](#). 64,:39-45.
- 17- Welsh, A. H., Lin, X.& Carroll, R. J.(2002).((Marginal longitudinal non parametric regression Locality and efficiency of spline and kernel methods)).

ملحق رقم (1)

القيم التالية تمثل قيم المتغيرات التوضيحية x المتمثلة بعدد كريات الدم البيض(wbc) لكل مريض خلال 3 زيارات متتابعة ، اما فيما يخص بيانات متغير الاستجابة y المتمثل بهيموغلوبين الدم (hb)

النسل	قيمة المتغير التوضيحي x	قيمة متغير الاستجابة y	الزيارة الاولى	الزيارة الثانية	الزيارة الثالثة	الزيارة الاولى	الزيارة الثانية	الزيارة الثالثة
العنقود الاول	7.90	7.80	9.38	1.15	1.4	63.7		
العنقود الثاني	8.26	8.6	8.1	10.1	6.9	2.9		
العنقود الثالث	13.3	13.3	7.27	18.2	16.8	24.3		
العنقود الرابع	17.3	7.98	8.69	8.9	4.75	5.97		
العنقود الخامس	12.7	8.71	6.1	7.15	1.16	0.8		
العنقود السادس	8.18	8.25	8.15	1.57	1.82	3.16		
العنقود السابع	6.3	6.1	6.76	7.8	8.08	8.84		
العنقود الثامن	9.06	7.5	8.8	0.277	0.4	0.320		
العنقود التاسع	9.07	8.26	8.82	0.754	1.56	9.50		
العنقود العاشر	8.49	8.8	7.9	8.68	7.7	4.6		
العنقود الحادي عشر	9.99	9.42	6.86	0.644	0.430	0.393		
العنقود الثاني عشر	8.2	6.65	9.6	0.7	0.859	1.24		
العنقود الثالث عشر	7	9.1	7.6	0.41	0.20	0.2		
العنقود الرابع عشر	10.8	13.1	12.2	11.3	2.4	1.5		
العنقود الخامس عشر	7.3	10.8	12.1	1.56	56.9	0.114		



مقارنة طريقي تقدير الدالة الامثلية لبيانات عتقة عن
كريات الدم البيضاء لمرضى اللوكيميا

8	5.6	8.3	0.15	0.5	0.94	العنقود السادس عشر
10.6	10.2	7.2	1.5	6.0	11.7	العنقود السابع عشر
11.0	6.9	8.5	2.9	3.1	4.8	العنقود الثامن عشر
9.8	9.4	7.5	5.3	5.3	5.7	العنقود التاسع عشر
6.4	7.9	6.8	1.7	0.5	1.3	العنقود العشرون
6.2	8.6	8.9	6.2	1.7	0.9	العنقود الواحد والعشرون
11.0	10.8	10.7	35.7	11.1	13.7	العنقود الثاني والعشرون
9.8	9.10	7.5	2.93	2.15	2.1	العنقود الثالث والعشرون
8.00	6.1	7.1	0.981	0.027	0.44	العنقود الرابع والعشرون
14.4	12.5	18.1	3.74	5.47	21.5	العنقود الخامس والعشرون
11.3	12.0	12.7	0.478	1.43	5.15	العنقود السادس والعشرون
14.5	12.7	12.7	13.6	9.04	9.04	العنقود السابع والعشرون
9.9	10.2	10.0	9.3	1.85	9.9	العنقود الثامن والعشرون
12.0	12.2	12.2	5.82	7.01	4.70	العنقود التاسع والعشرون
12.9	10.3	13.1	0.147	3.05	0.148	العنقود الثلاثون
8.69	12.5	13.1	0.818	2.40	2.5	العنقود الواحد والثلاثون
11.3	12.9	11.9	6.08	4.00	5.02	العنقود الاثنان والثلاثون
12.7	13.2	12.8	6.21	7.01	1.56	العنقود الثلاث وثلاثون
8.0	7.11	7.9	6.80	13.3	17.69	العنقود الاربع وثلاثون
13.6	12.5	12.6	5.38	4.07	4.96	العنقود الخامس وثلاثون
9.63	7.4	9.6	3.85	68.6	7.38	العنقود الستة وثلاثون
6.85	6.0	4.9	11.9	11.6	22.83	العنقود السبعة وثلاثون
8.9	8.89	11.0	1.46	2.77	2.96	العنقود الثمانية وثلاثون
4.0	7.1	10.2	1.7	1.9	5.39	العنقود التسعة وثلاثون
7.7	9.2	10.6	0.653	0.96	1.50	العنقود الاربعون
10.6	5.19	6.89	3.54	4.19	6.01	العنقود الواحد والاربعون
11.2	10.8	10.2	5.00	3.65	3.55	العنقود الاثنان والاربعون
7.96	8.25	8.3	6.24	7.21	5.81	العنقود الثلاث والاربعون
7.4	8.9	9.8	0.26	2.85	49.7	العنقود الاربع واربعون
6.90	10.8	10.9	1.34	2.29	11.3	العنقود الخامس والاربعون
5.7	8.0	5.6	0.2	0.15	0.5	العنقود الستة والاربعون
12	11.5	18.2	14.65	10.7	13.8	العنقود السبعة واربعون
9.6	10.4	6.75	0.81	1.80	0.129	العنقود الثمانية والاربعون
12.0	10.8	12.5	6.83	2.40	2.74	العنقود التسعة والاربعون
8.8	10.2	10.2	0.09	0.150	0.151	العنقود الواحد والخمسون
8.3	7.25	7.17	0.93	0.708	0.693	العنقود الاثنين والخمسون
9.8	11.5	11.6	0.71	0.8	0.7	العنقود الثالث والخمسون
5.68	9.7	7.98	2.40	8.9	4.75	العنقود الرابع والخمسون
12.2	9.5	9.5	5.1	4.32	11.7	العنقود الخامس والخمسون
10.8	11.7	9.6	3.49	4.27	2.9	العنقود السادس والخمسون
11.3	11.0	12.4	4.71	7.0	59.8	العنقود السابعة والخمسون
12.5	11.3	12.1	42.9	13.82	8.4	العنقود الثامن والخمسون
9	10.4	9.5	4.18	5.2	6.2	العنقود التاسع والخمسون
8.3	7.6	5.5	10.2	8.3	7.6	العنقود العاشر والخمسون
9.5	10.2	6.2	2.3	1.3	1.2	العنقود الستون
9.1	10.1	9.9	2.0	1.9	3.0	العنقود الواحد والستون
11.8	10.7	10.8	17.8	12.6	14.1	العنقود الاثنين والستون
7	10.2	11.4	2.1	8.1	20.8	العنقود الثالث والستون
7.6	7.9	7.7	18.7	14.3	21.9	العنقود الرابع والستون



**مقارنة طريقي تقدير الدالة الامثلية لبيانات عنقودية عن
كريات الدم البيضاء لمرضى اللوكيميا**

10.4	10.5	9.4	25.2	24.4	26.1	العنقود الخامس والستون
7.7	9.7	6.6	5.6	15	22.8	العنقود الستة والستون
7.1	7.6	8.7	3.0	39.4	24.5	العنقود السبعة والستون
7.2	7.2	10.1	0.5	3.4	3.8	العنقود الثمانية والستون
5.4	5.1	5.2	61.9	53.6	25.9	العنقود التسعة والستون
7.1	7.3	6.1	0.4	1.3	1.0	العنقود السبعون
8.5	6.5	10	0.4	0.3	1.6	العنقود الواحد والسبعين
11	10.4	10.7	11.2	5.8	6.8	العنقود الاثنان والسبعين
6.6	8.2	7.3	0.5	8.9	10.0	العنقود الثلاثة والسبعين
13.0	12.3	11.0	11.9	1.3	3.59	العنقود الاربع والسبعين
9.9	7.9	9.6	6.2	2.5	8.4	العنقود الخامس والسبعين
6.4	6	7.5	2.5	11	29.3	العنقود الستة والسبعين
7.5	6.2	8.4	0.2	0.06	0.2	العنقود السبعة والسبعين
10.5	10.3	11.1	1.5	0.7	1.5	العنقود الثمانية والسبعين
8.5	6.2	8.5	0.9	0.3	0.3	العنقود التسعة والسبعين
9.9	9.4	10.3	2.4	1.6	1.6	العنقود الثمانون
8.2	9	7.8	2	2.5	1.7	العنقود الواحد والثمانون
6.4	7.4	8.7	1.3	1.2	3.6	العنقود الاثنان والثمانون
7	8.1	9.2	0.8	1.1	1.3	العنقود الثلاثة والثمانون
8.2	8.3	6.6	0.1	0.07	0.1	العنقود الاربع والثمانون
8.8	9.3	8.3	3.41	3.4	2.3	العنقود الخمسة والثمانون
7.7	8.8	14.1	14.1	11	7.7	العنقود الستة والثمانون
11.6	11.7	11.7	8.2	6.9	6.9	العنقود السبعة والثمانون
10.4	10.7	6.9	0.7	0.58	0.6	العنقود الثمانية والثمانون
7.81	8.3	7.4	1.77	1.91	1.4	العنقود التسعة والثمانون
4.6	5.2	7.3	3.9	1.5	3.3	العنقود الواحد والتسعون
9.8	9.2	9.34	32.7	38.3	20.6	العنقود الاثنان والتسعون
8.9	10.2	9.8	9.6	10.7	8.1	العنقود الثلاثة والتسعون
8.7	5.3	13	1.1	3.1	5.5	العنقود الاربعة والتسعون
9.5	9.7	6.9	4.52	2.75	1.35	العنقود الخامس والتسعون
6.2	10.8	11.9	4.16	1.75	1.15	العنقود السادس والتسعون
18.1	10.6	9.7	9.1	8.6	3.7	العنقود السابعة والتسعون
11.3	11.8	18.1	0.94	1.0	5.92	العنقود الثمانية والتسعون
9.5	9.4	10.3	1.08	0.17	0.05	العنقود التسعة والتسعون
10.7	11.6	9.5	3.38	4.26	2.8	العنقود المئة
12.1	9.4	9.4	5.0	4.21	11.6	

**ملحق رقم (2)
لحساب طريقة الـ kernel للبيانات الحقيقية**

```

clc
clear
data=xlsread('Rdata.xlsx','data');
n=size(data,1);
subj=data(:,1);x=data(:,2);y=data(:,3);
corry0=[1 0 0;0 1 0;0 0 1];
corry1=[1 0.5700 0.415;0.5700 1 0.584;0.415 0.5841 1];
yy1=[y(1:n/3)];

```



```
yy3=[y(((n/3)+1):2*(n/3))];  
yy5=[y((2*(n/3)+1):n)];  
usubj=unique(subj);  
nsubj=length(usubj);  
xmin=min(x);  
xmax=max(x);  
xfit=linspace(xmin*1.05,xmax*.95,101');  
[ux,flag1,flag2]=unique(x);  
nux=length(ux);  
dpoly=2;  
dy1=std(yy1);  
dy2=std(yy3);  
dy3=std(yy5);  
dy=[dy1 dy2 dy3];  
sdy=diag(dy);  
dsd01=repmat(dy1,n/3);  
dsd1=diag((dsd01));  
dsd02=repmat(dy2,n/3);  
dsd2=diag((dsd02));  
dsd03=repmat(dy3,n/3);  
dsd3=diag((dsd03));  
dsdy=[dsd1' dsd2' dsd3'];  
dsdy=diag(dsdy);  
eyey=eye(n/3);  
output=['h' 'gcv' 'df'];  
output1=['vh' 'vgcv' 'vdf'];  
cdsdy0=kron(eyey,corry0);  
V0=dsdy*cdsdy0*dsdy;  
Vd10=inv(diag(diag(V0)));  
Vd20=diag(diag(inv(V0)));  
[yhat00,hgcv00,vhgcv00,B00,gcf01,gcf02]=glpfit(data,V0,Vd10,Vd20,[0,dpoly,1]);  
mse00=mean((y-yhat00).^2);  
mae00=mean(abs(y-yhat00));  
m00=[mse00 mae00];  
xlswrite('D:\KHala.xlsx',m00,'m00','A1:B1');  
xlswrite('D:\KHala.xlsx',yhat00,'yhat0');  
xlswrite('D:\KHala.xlsx',output,'gcv0','A1:C1');  
xlswrite('D:\KHala.xlsx',hgcv00,'hgcv0','A2:C2');  
xlswrite('D:\KHala.xlsx',output1,'vgcv0','A1:C1');  
xlswrite('D:\KHala.xlsx',vhgcv00,'vhgcv0','A2:C10');  
saveas(gcf01,'figure1','png')  
saveas(gcf02,'figure2','png')
```



```
cdsdy1=kron(eyey,corry1);
V1=dsdy*cdsdy1*dsdy;
Vd11=pinv(diag(diag(V1)));
Vd21=diag(diag(pinv(V1)));
[yhat01,hgcv01,vhgcv01,B01,gcf03,gcf04]=glpfit(data,V1,Vd11,Vd21,[0,dpoly,1]);
mse01=mean((y-yhat01).^2);
mae01=mean(abs(y-yhat01));
m01=[mse01 mae01];
xlswrite('D:\KHala.xlsx',m01,'m01','A1:B1');
xlswrite('D:\KHala.xlsx',yhat01,'yhat1');
xlswrite('D:\KHala.xlsx',output,'hgcv1','A1:C1');
xlswrite('D:\KHala.xlsx',hgcv01,'hgcv1','A2:C2');
xlswrite('D:\KHala.xlsx',output1,'vhgcv1','A1:C1');
xlswrite('D:\KHala.xlsx',vhgcv01,'vhgcv1','A2:C10');
saveas(gcf03,'figure3','png')
saveas(gcf04,'figure4','png')
```

لحساب دالة `kernel` للبيانات الحقيقية وفق البرنامج الاتي

```
function [yhat,hgcv,vhgcv,B,gcf1,gcf2]=glpfit(data,V,Vd1,Vd2,params,xfit,kstr)
n=size(data,1);
subj=data(:,1);
usubj=unique(subj);
nsubj=length(usubj);
x=data(:,2);
y=data(:,3);
[ux,~,flag2]=unique(x);
nux=length(ux);
xrange=max(ux)-min(ux);
if nargin<2||isempty(V),
    V=dsdy*cdsdy*dsdy;
end
V=V(flag2,flag2);
if nargin<3||isempty(Vd1),
    V=sdy*cdsdy*sdy;
    Vd1=inv(diag(diag(V)));
end
V=V(flag2,flag2);
Vd1=Vd1(flag2,flag2);
if nargin<4||isempty(Vd2),
    V=sdy*cdsdy*sdy;
    Vd2=diag(diag(inv(V)));
end
```



```
V=V(flag2,flag2);
Vd2=Vd2(flag2,flag2);
if nargin<5||isempty(params),
    h=0;
    dpoly=1;
    indfig=0;
elseif length(params)==1,
    h=params;
    dpoly=1;
    indfig=0;
elseif length(params)==2,
    h=params(1);
    dpoly=params(2);
    indfig=0;
elseif length(params)==3,
    h=params(1);
    dpoly=params(2);
    indfig=params(3);
end
if nargin<7||isempty(kstr),
    kstr='(1/sqrt(2*pi))*exp(-.5*t.^2)';
end
if h~=0,
    nh=1;
else
    nh=10;
    hmin=.5*(dpoly+1)*xrange/nux;
    hmax=xrange/8;
    vh = logspace(log10(hmin),log10(hmax),nh);
end
if nh>1,
    for ii=1:nh,
        h=vh(ii);
        for jj=1:nux,
            temp=x-ux(jj);
            t=(temp/h)*h^(-1);
            W=diag(eval(kstr));
            X=ones(n,1);
            for r=1:dpoly,
                X=[X,temp.^r];
            end
            AA=0;
            BB=[];

```



```
for kk=1:nsubj,
    flagi=(subj==usubj(kk));
    Wi=W(flagi,flagi);
    Xi=X(flagi,:);
    yi=y(flagi);
    ni=length(yi);
    Vi=V(flagi,flagi);
    Vd1i=Vd1(flagi,flagi);
    temp=Wi.*diag(diag(pinv(Vi));
    AA=AA+Xi'*temp*Xi;
    BB=[BB,Xi'*Wi];
end
temp=pinv(AA)'*BB;
iii=eye(size(temp));
temp1=pinv(iii+temp*(Vd1-Vd2))*temp*Vd1;
A(jj,:)=temp1(1,:);
end
B=A(flag2,:);
yhat=B*y;
df(ii)=trace(B);
gcv(ii)=mean((y-yhat).^2)/(1-df(ii)/n)^2;
end
vhgcv=[vh(:,gcv(:,df(:));
[gcv,temp]=min(gcv);
h=vh(temp);
hgcv=vhgcv(temp,:);
end
for jj=1:nux,
    temp=x-ux(jj);
    t=(temp/h)*h^(-1);
    W=diag(eval(kstr));
    X=ones(n,1);
    for r=1:dpoly,
        X=[X,temp.^r];
    end
    AA=0;
    BB=[];
    for kk=1:nsubj,
        flagi=(subj==usubj(kk));
        Wi=W(flagi,flagi);
        Xi=X(flagi,:);
        yi=y(flagi);
        ni=length(yi);
```



```
Vi=V(flagi,flagi);
Vd1i=Vd1(flagi,flagi);
temp=Wi.*pinv(Vi);
AA=AA+Xi'*temp*Xi;
BB=[BB,Xi'*Wi];
end
temp=pinv(AA)*BB;
iii=eye(size(temp));
temp1=pinv(iii+temp*(Vd1-Vd2))*temp*Vd1;
A(jj,:)=temp1(1,:);
end
efit=A*y;
B=A(flag2,:);
yhat=B*y;
df=trace(B);
dfa=xrange/h/sqrt(2*pi);
resid=y-yhat;
gcv=mean(resid.^2)/(1-df/n)^2;
hsig2=sum(resid.^2)/(n-df);
hgcv=[h,gcv,df];
uyfit=efit;
uysig=sqrt(hsig2*diag(A*A'));
if nh==1,
vhgcv=hgcv(1:3);
end
if nargin<6||isempty(xfit),
xfit=ux;
yfit=uyfit;
ysig=uysig;
else
yfit=spline(ux,uyfit,xfit);
ysig=spline(ux,uysig,xfit);
end
fits=[xfit,yfit,ysig];
if indfig==1,
figure(1);
clf;
subplot(2,2,1);
plot(x,y,'o',fits(:,1),fits(:,2),'r-',...
    fits(:,1),[fits(:,2)+1.96*fits(:,3),fits(:,2)-1.96*fits(:,3)],'g-.');
xlabel('x');
ylabel('y');
```



```
title(['(a)',num2str(dpoly),'-th order GLP fit']);
subplot(2,2,2);
plot(x,resid/sqrt(hsig2),'o');
xlabel('x');
ylabel('standardized residual');
title('(b) Standardized residuals vs x');
subplot(2,2,3);
plot(yhat,resid/sqrt(hsig2),'o');
xlabel('yhat');
ylabel('standardized residual');
title('(c) Standardized residuals vs fits');
subplot(2,2,4);
plot(y,resid/sqrt(hsig2),'o');
xlabel('y');
ylabel('standardized residual');
title('(d) Standardized residuals vs responses');
gcf1=gcf;
if nh>1,
figure(2);
clf;
subplot(2,2,1);
plot(log10(vhgcv(:,1)),vhgcv(:,2),'-o');
xlabel('log_{10}(h)');
ylabel('GCV');
title('(a) GCV vs log_{10}(h)');
subplot(2,2,2);
plot(log10(vhgcv(:,1)),vhgcv(:,3),'-o');
xlabel('log_{10}(h)');
ylabel('df');
title('(b) df vs log_{10}(h)');
end
gcf2=gcf;
end
clearvars -except yhat hgcv vhgcv B gcf1 gcf2
end
clc
clear
data=xlsread('Rdata.xlsx','data');
n=size(data,1);
subj=data(:,1);x=data(:,2);y=data(:,3);
corry0=[1 0 0;0 1 0;0 0 1];
corry3=[1 0.5700 0.415;0.5700 1 0.584;0.415 0.5841 1];
```

لحساب طريقة spline



```
yy1=[y(1:n/3)];
yy3=[y((n/3)+1:2*(n/3))];
yy5=[y(2*(n/3)+1:n)];
usubj=unique(subj);
nsubj=length(usubj);
xmin=min(x);
xmax=max(x);
xfit=linspace(xmin*1.05,xmax*.95,101)';
[ux,flag1,flag2]=unique(x);
nux=length(ux);
dy1=std(yy1);
dy2=std(yy3);
dy3=std(yy5);
dy=[dy1 dy2 dy3];
sdy=diag(dy);
dsd01=repmat(dy1,100);
dsd1=diag((dsd01));
dsd02=repmat(dy2,100);
dsd2=diag((dsd02));
dsd03=repmat(dy3,100);
dsd3=diag((dsd03));
dsdy=[dsd1' dsd2' dsd3'];
dsdy=diag(dsdy);
eyey=eye(n/3);
output=['spar' 'gcv'];
output1=['vspar' 'vgcv'];
cdsdy0=kron(eyey,corry0);
V0=dsdy*cdsdy0*dsdy;
Vd10=diag(diag(inv(V0)));
[yhat00,spargcv00,vspargcv00,A00,gcf01,gcf02]=ssfit(data,[],1,xfit,Vd10);
mse00=mean((y-yhat00).^2);
mae00=mean(abs(y-yhat00));
m00=[mse00 mae00];
xlswrite('D:\SHala.xlsx',m00,'m00','A1:B1');
xlswrite('D:\SHala.xlsx',yhat00,'yhat0');
xlswrite('D:\SHala.xlsx',output,'spargcv0','A1:B1');
xlswrite('D:\SHala.xlsx',spargcv00,'spargcv0','A2:B2');
xlswrite('D:\SHala.xlsx',output1,'vspargcv0','A1:B1');
xlswrite('D:\SHala.xlsx',vspargcv00,'vspargcv0','A2:B10');
saveas(gcf01,'figure1','png')
saveas(gcf02,'figure2','png')
cdsdy1=kron(eyey,corry1);
V1=dsdy*cdsdy1*dsdy;
```



```
Vd11=diag(diag(inv(V1)));
[yhat01,spargcv01,vspargcv01,A01,gcf03,gcf04]=ssfit(data,[],1,x,Vd11);
mse01=mean((y-yhat01).^2);
mae01=mean(abs(y-yhat01));
m01=[mse01 mae01];
xlswrite('D:\SHala.xlsx',m01,'m01','A1:B1');
xlswrite('D:\SHala.xlsx',yhat01,'yhat1');
xlswrite('D:\SHala.xlsx',output,'spargcv1','A1:B1');
xlswrite('D:\SHala.xlsx',spargcv01,'spargcv1','A2:B2');
xlswrite('D:\SHala.xlsx',output1,'vspargcv1','A1:B1');
xlswrite('D:\SHala.xlsx',vspargcv01,'vspargcv1','A2:B10');
saveas(gcf03,'figure3','png')
saveas(gcf04,'figure4','png')
```

لحساب دالة السبللين للبيانات الحقيقية

```
function [yhat,spargcv,vspargcv,A,gcf1,gcf2]=ssfit (data, spar, indfig, xfit, V)
subj=data(:,1);
usubj=unique(subj);
nsubj=length(usubj);
x=data(:,2);
y=data(:,3);
n=length(x);
[knots,~,flag2]=unique(x);
nknot=length(knots);
E=zeros(n,nknot);
if nargin<3||isempty(indfig),
    indfig=0;
end
if nargin<5||isempty(V),
    V=eye(n);
end
for i=1:n,
    E(i,flag2(i))=1;
end
S=E'*E;
S=diag(diag(S).^( -1/2));
Gmat=splmat(knots);
[~,D]=eig(S*Gmat*S);
d=diag(real(D));
if nargin<2||isempty(spar),
    nspar=15;
```



```
d0=sort(d);
dmin=d0(3);
dmax=max(d);
sparmax=((nknot-2)/(nknot-4)-1)/dmin;
sparmin=((nknot-2)/(4-2)-1)/dmax;
vspar = logspace(log10 (sparmin),log10 (sparmax), nspar)';
else
    vspar=spar;
    nspar=1;
end
for k=1:nspar,
    A=E*pinv(E'*V*E+(n)*vspar(k)*Gmat)*E'*V;
    yhat=A*y;
    gcv(k)=mean((y-yhat).^2)/(1-trace(A)/n)^2;
end
vspargcv=[vspar(:,gcv(:));
[gcv,temp]=min(gcv);
spar=vspar(temp(1));
spargcv=[spar,gcv];
A=E*pinv(E'*V*E+(n)*spar*Gmat)*E'*V;
yhat=A*y;
resid=y-yhat;
SSE=sum((y-yhat).^2);
hsig2=SSE/(n-trace(A));
ysig=sqrt(hsig2*diag(A*A'));
if nargin<4||isempty(xfit),
    fits=[x,yhat,ysig];
else
    [xx,xflag]=unique(x);
    yyhat=yhat(xflag);
    yysig=ysig(xflag);
    yfit=spline(xx,yyhat,xfit);
    ysig=spline(xx,yysig,xfit);
    fits=[xfit,yfit,ysig];
end
if indfig==1,
    figure(1);
    clf;
    [~,temp2]=sort(fits(:,1));
    ffits=fits(temp2,:);
    plot(x,y,'o',ffits(:,1),ffits(:,2),'r',...
        ffits(:,1),[ffits(:,2)-1.96*ffits(:,3),ffits(:,2)+1.96*ffits(:,3)],'g-.')
    gcf1(gcf);
    if nspar>1,
```



```
figure(2);
clf;
yyhat=y-resid;
resid=resid/std(resid);
subplot(2,2,1)
plot(log10(vspargcv(:,1)),vspargcv(:,2),'-o')
xlabel('log_{10}(\lambda)')
ylabel('GCV score')
title('(b) GCV curve')
subplot(2,2,2)
plot(yyhat,resid,'o')
xlabel('SS fit')
ylabel('Standardized residual')
title('(a)')
subplot(2,2,3)
plot(y,resid,'o')
xlabel('Response')
ylabel('Standardized residual')
title('(c)')
subplot(2,2,4)
hist(resid)
xlabel('Standardized residual')
ylabel('Frequency')
title('(d)')
end
gcf2=gcf;
end
clearvars -except yhat spargcv vspargcv A gcf1 gcf2
end
برنامج لحساب مصفوفة الـ بساي في دالة السبللين
function [K,Q,R,h]=splmat(t)
[n,m]=size(t);
if n==1,n=m;
t=t';
end
h=t(2:n)-t(1:n-1);
hinv=h.^(-1);
Q=diag([hinv(1:n-2);0],-1)-diag([0;hinv(1:n-2)+hinv(2:n-1);0],0);
Q=Q+diag([0;hinv(2:n-1)],1);
Q=Q(2:n-1,:)';
R=diag(h(2:n-2),-1)/6+diag(h(1:n-2)+h(2:n-1))/3+diag(h(2:n-2),1)/6;
K=Q*inv(R)*Q';
clearvars -except K Q R h
end
```



Compared of estimating two methods for nonparametric function to cluster data for the white blood cells to leukemia patients

Abstract:

We can notice cluster data in social, health and behavioral sciences, so this type of data have a link between its observations and we can express these clusters through the relationship between measurements on units within the same group.

In this research, I estimate the reliability function of cluster function by using the seemingly unrelated Kernel Estimators method and the Generalized Least Squares Smoothing Spline Estimators method, and I applied these two methods on Leukemia patients and made a comparison between the two methods by using MSE and MAE comparison standard, the empirical results showed the efficiency of the Generalized Least Squares Smoothing Spline Estimators method.

Keywords: cluster data, the seemingly unrelated Kernel Estimators method, and the Generalized Least Squares Smoothing Spline Estimators method, MSE, MAE.