

معايير إختيار معلمة التمهيد لمقدر الشريحة الجزائية: دراسة مقارنة باستخدام المحاكاة

حافظ محمد مطير
قسم الرياضيات
محمد حبيب الشاروط
قسم الإحصاء والمعلوماتية
كلية علوم الحاسوب والرياضيات
جامعة القادسية

الخلاصة

إن إنحدار الشرائح الجزائية (Penalized Regression Spline) أو اختصاراً (P-Spline) هو أحد الأساليب المهمة المستخدمة في تقدير منحنى الإنحدار اللامعلمي ، ومن أهم العناصر المستخدمة لتطبيق هذا الأسلوب هو إختيار معلمة التمهيد (Smoothing Parameter) والتي تلعب دوراً في الموازنة بين التحيز والتباين للمقدر الناتج أو ما يطلق عليه (bias – variance trad – off) ، يهدف هذا البحث إلى تسليط الضوء على بعض طرائق إختيار معلمة التمهيد لمقدر الشريحة الجزائية كما تضمن عمل دراسة مقارنة بين ثلاثة معايير لإختيار معلمة التمهيد وهي : معيار GCV ، ومعيار AIC ، ومعيار AIC_{corr} ، والمفاضلة بين المعايير الثلاث باستخدام معيارين من معايير الأخطاء للنماذج المستخدمة هما $MAAE$ ، $MRASE$ ، وقد توصلنا من خلال نتائج تجارب المحاكاة المطبقة من التوصل إلى أن معيار AIC_{corr} أفضل من بقية المعايير في تقدير معلمة التمهيد لمقدر الشريحة الجزائية.

١ - المقدمة

إذا افترضنا أنموذج الإنحدار الآتي :

$$y_i = g(x_i) + \varepsilon_i, \quad i = 1, \dots, n \quad (1)$$

حيث ε_i هي الأخطاء العشوائية وتتوزع توزيعاً طبيعياً توقعه صفر وتباينه ثابت ويساوي (σ^2) فإن إحدى الدوال المهمة والمستخدمه في الحصول على تقريب لمنحنى الانحدار هي دالة الشريحة Function Spline ، حيث يقسم مجال X إلى فترات جزئية صغيرة نسبياً بواسطة نقاط ربط تسمى عقد Knots ويتم تقدير متعددات حدود موضعية من نفس الدرجة في الفترات الجزئية ، ولضمان منحنى مستمر يفرض قيد الإستمرارية عند العقد وللحصول على منحنى ممهد Smooth Curve تفرض قيود الإستمرارية للمشتقات من رتب معينة عند العقد إن الدالة g تسمى دالة الانحدار Regression Function وهي دالة غير معلومة وتهدف طرائق تمهيد الانحدار اللامعلمية الى تقديرها دون فرض أي صيغة مسبقة محددة لشكل المنحنى المقدر ، وإن إحدى أهم الطرق لتقدير الدالة g هي انحدار الشرائح الجزائية، Penalized Regression Splines [3],[4],[7],[8],[9],[10],[11],[12] . قدمت الصيغة الأولى من قبل كل من Eilers و Marx في عام 1996 [4] وأطلقوا عليه إختصاراً P-Spline ، وافترض الباحثان أن $E(y) = g(x) = Ba$ حيث g هي دالة الانحدار و B هي مصفوفة من الدرجة $n \times m$ وأن $B = (b_{i,j})_{n \times m}$ حيث $b_{ij} = b_j(x_i; q)$ ، $i = 1, \dots, n$ ، $j = 1, \dots, m$ ، وأن b_j هي قيمة الشريحة j من الدرجة q عند

النقطة x_i ، وأن قيمة m تعتمد على درجة الشريحة وعدد العقد في الأنموذج حيث استخدم الباحثان عقد بمسافات متساوية. أما a فهو متجه معاملات الشرائح-B حيث $a = (a_1, \dots, a_m)^T$ ، أما الصيغة الأخرى فقدمها كل من Ruppert و Carroll في عام 1997 [٩] واستخدما فيه الشرائح مع قواعد أخرى تسمى قواعد Truncated TPF (Equally Spaced Sample Polynomial Function) واستخدما عقد عند نقاط تمثل مجزئات للبيانات (Quantile).

٢- هدف البحث

يهدف البحث إلى إجراء دراسة مقارنة بين ثلاثة معايير مختلفة لإختيار معلمة التمهيد لمقدر الشريحة الجزئية P-Spline وهي معيار GCV ، ومعيار AIC ، ومعيار AIC_{corr} ، وتم استخدام أسلوب المحاكاة Simulation لتوليد البيانات باستخدام الحاسوب الإلكتروني لتوليد عدد كبير من العينات (500 عينة) التي تتبع التوزيع الطبيعي بمتوسط صفر وتباين ثابت وتم استخدام قيم متدرجة للانحراف المعياري وأحجام مختلفة للعينات هي (300,150,50,20) ، ولغرض اجراء المقارنة بين المعايير الثلاث والمفاضلة فيما بينها تم استخدام معايير الأخطاء التالية $RASE$ ، $MAAE$ ، AAE ، $MRASE$ لكل أنموذج تم تقديره والتي سوف يتم التطرق لها في الجانب النظري.

٣ - الشريحة الجزئية P-Spline

لإيجاد تقدير لدالة الإنحدار g افترض الباحثان Marx و Eilers أن $g = Ba$ حيث B مصفوفة التصميم (design matrix) من الدرجة $n \times m$ حيث قيمة m تعتمد على درجة الشريحة وعدد العقد (knots) في الأنموذج وأن a متجه معاملات الشرائح من الدرجة $1 \times m$ واستخدم الباحثان معيار المربعات الصغرى التالي لإيجاد تقدير للمتجه a والذي أطلقا عليه معيار المربعات الصغرى الجزئية :

$$S = \sum_{i=1}^n \{y_i - \sum_{j=1}^m a_j B_j(x_i)\}^2 + \lambda \sum_{j=k+1}^m (\Delta^k a_j)^2 \quad \dots \dots \dots (2)$$

حيث $\Delta^k a_j$ تمثل الفروقات من الرتبة k لمعاملات الشرائح المتجاورة ، ونلاحظ من خلال الصيغة (2) أن المعيار يتكون من جزئين الأول يمثل مجموع مربعات البواقي RSS أما الجزء الثاني فأطلق عليه الباحثان الجزاء غير الممهدهد Roughness Penalty وتتحكم به معلمة التمهيد λ حيث عندما $\lambda = 0$ أي لا يوجد حد الجزاء فان تصغير مجموع مربعات البواقي يؤدي إلى منحنى متذبذب غير مقبول، وبزيادة قيمة λ تزداد كمية التمهيد في المنحنى ولكن الزيادة الكبيرة جداً ($\lambda \rightarrow \infty$) فإن المقدر الناتج يكون على شكل خط مستقيم ($k = 2$) ، ومنحنى تربيعي ($k = 3$). وبكتابة المعيار (2) بصيغة المصفوفات فانه يصبح كالآتي:

$$S = (Y - Ba)^T (Y - Ba) + \lambda D_k^T D_k a \quad \dots \dots \dots (3)$$

حيث $Y = (y_1, \dots, y_n)^T$ ، D_k مصفوفة الفروقات من الرتبة k

وللحصول على متجه المعاملات المقدره نقوم بتصغير المعيار في (3) بإيجاد التفاضل الجزئي بالنسبة الى a ثم مساواة الناتج للصفر فينتج نظام المعادلات الطبيعية التالي:

$$(B^T B + \lambda D_k^T D_k) \hat{a} = B^T Y \quad \dots \dots \dots (4)$$

$$\hat{a} = (B^T B + \lambda D_k^T D_k)^{-1} B^T Y \quad \text{إذن}$$

$$\begin{aligned}\hat{g} &= B\hat{a} \\ &= B(B^T B + \lambda D_k^T D_k)^{-1} B^T Y \\ &= H_\lambda Y\end{aligned}$$

إذن

المصفوفة H_λ تسمى مصفوفة التمهيد Hat Matrix أو Smoother Matrix ويعرف أثر المصفوفة H_λ بأنه مجموع عناصر القطر الرئيسي لها ويرمز له بالرمز $tr(H_\lambda)$ ويكتب كما يأتي:

$$tr(H_\lambda) = \sum_{i=1}^n h_{ii}$$

حيث h_{ii} هي عناصر القطر الرئيسي للمصفوفة H_λ

ويطلق على $tr(H_\lambda)$ أيضا درجات الحرية الفعالة Effective Dgree of Freedom

٤- معايير اختيار معلمة التمهيد Smoothing Parameter Selection Criterion

ليكن $Y = (y_1, \dots, y_n)^T$ ، $g = (g(x_1), \dots, g(x_n))^T$ ، $\hat{g} = (\hat{g}(x_1), \dots, \hat{g}(x_n))^T$ ، وأن $\hat{g} = H_\lambda Y$ فإن معايير اختيار معلمة التمهيد تكون كما يأتي:

(i) معيار العبور الشرعي المعمم (GCV) [10][4][11] Generalized Cross Validation

وضع من قبل كل من Wahba و Graven عام 1979 [11] ضمن سياق اختيار معلمة التمهيد لمقدر الشريحة الممهدة Smoothing Spline ، ويعتبر معيار GCV تقريبا لمعيار العبور الشرعي CV (Cross Validation) ، والفكرة تتمثل في تصغير أحد معايير الأخطاء ASE لأيجاد القيمة المثلى للمعلمة التمهيدية ولأن المعيار ASE يحوي على كمية غير معلومة يتم تقديره وتكون صيغة المقدر كما يلي : $RSS = (1/n) \sum_{i=1}^n (y_i - \hat{y}_i)^2$ ، ولكن تصغير هذه الصيغة يؤدي الى منحى متذبذب غير مقبول من قبل الإحصائيين لأن قيم y_i تستخدم مرتين في آن واحد لأنها تستخدم أصلا عند ايجاد \hat{y}_i ولذلك يتم حذف المشاهدة y_i عند ايجاد التقدير لكل نقطة من نقاط البيانات ولذلك يطلق عليه Leave – One – Out وتكون عندها صيغة معيار CV كما يلي :

$$CV = \sum_{i=1}^n (y_i - \hat{g}^{-i}(x_i; \lambda))^2$$

حيث $\hat{g}^{-i}(x_i)$ تعني تقدير الدالة g بعد حذف المشاهدة y_i ، وهناك صيغة تقريبية لمعيار CV تكتب كالآتي:

$$CV = \sum_{i=1}^n \frac{(y_i - \hat{g}(x_i, I))^2}{1 - h_{\lambda, ii}}$$

حيث $h_{\lambda, ii}$ هي عناصر القطر الرئيسي لمصفوفة التمهيد H_λ .

وباستبدال القيم $h_{\lambda, ii}$ بمتوسطها $\frac{\sum_{i=1}^n h_{\lambda, ii}}{n} = \frac{tr(H_{\lambda, ii})}{n}$ نحصل على تقريب لمعيار CV وهو معيار GCV وصيغته كالآتي:

$$GCV = \frac{n^{-1} \sum_{i=1}^n (y_i - g(x_i; \lambda))^2}{\left(1 - \frac{tr(H_\lambda)}{n}\right)^2} \dots\dots\dots (5)$$

وفيه يتم اختيار قيمة معلمة التمهيد λ التي تجعل قيمة المعيار GCV أصغر ما يمكن.

(ii) معيار Akaike Information Criterion AIC [10],[4],[2],[1]

وضع من قبل Akaike في عام 1973 ، والصيغة العامة للمعيار تكون كالآتي :

$$AIC = -2\log(L(\hat{b})) + 2 \times K$$

حيث K عدد المعالم في النموذج ، L دالة الترجيح الأعظم للمقدر ، \hat{b} متجه المعالم المقدرة، وهذه الصيغة التي وضعها العالم Akaike تمثل تقديراً لمعيار Kullback-Leibler information والذي وضع من قبل كل من Kullback و Leibler في عام 1951 وتكون صيغته كالآتي:

$$I(f, g) = E_x [\log f(X | \theta^*) - \log g(x | \theta)]$$

حيث $f(X | \theta^*)$ الأنموذج المقدر ، $g(x | \theta)$ الأنموذج الحقيقي ، ويمثل المعيار $I(f, g)$ الفرق (Separation) بين الأنموذجين. أن معيار AIC يكتب في سياق الإنحدار اللامعلمي كالآتي:

$$AIC = \log(RSS) + 2df / n \dots\dots\dots (6)$$

$$df = tr(H_\lambda) \quad , \quad RSS = \sum_{i=1}^n (y_i - g(x_i; \lambda))^2 \quad \text{حيث}$$

ويتم اختيار قيمة معلمة التمهيد λ التي تجعل المعيار AIC أصغر ما يمكن.

ويمثل معيار AIC تقديراً غير متحيز بالمحاذي Asymptotically Unbiased Estimates لمعيار Kullback-Leibler information حيث $E(AIC) = I(\theta; \theta^*) + o(1)$ وأن $o(1) \rightarrow 0$ عندما $n \rightarrow \infty$. إلا أن هذا المعيار يعاني من بعض العيوب نذكر منها [7]:

1- أن معيار AIC لا يمتلك خاصية الأمثلية Optimal Property ، بمعنى أنه لا يخفض قيمة المعدل لأية دالة معيار.

2- أن قاعدة AIC غير متنسقة بمعنى أن احتمال أن تذهب قاعدة القرار لاختيار أنموذج خاطيء ، لا يذهب هذا الاحتمال إلى الصفر حتى عندما يقترب عدد المشاهدات إلى ما لا نهاية .

(iii) معيار AIC المعدل (AIC_{corr})

وضع من قبل كل من Hurvich ، و Simonoff ، و Tsai [5] في عام 1998 كنسخة معدلة من معيار AIC حيث تم إضافة تعديل للتحيز Biase adjustment وتكون صيغته كالآتي:

$$AIC_{corr} = \log(RSS) + \frac{2(df + 1)}{n - df - 2} \quad \dots \quad (7)$$

، df كما سبق. أن معيار AIC_{corr} يمثل تقديراً غير متحيز فعلياً وليس محاذاً لمعيار Kullback-Leibler information.

٥- معايير الأخطاء

تم في البحث استخدام معايير الأخطاء الآتية:

(i) الجذر التربيعي لمتوسط مربعات الخطأ Root Average Squared Error وصيغته:

$$RASE = \sqrt{\frac{\sum_{i=1}^n (g(x_i) - \hat{g}(x_i))^2}{n}} \quad \dots \quad (8)$$

(ii) معدل الجذر التربيعي لمتوسط مربعات الخطأ Mean Root Average Squared Error وصيغته:

$$MRASE = \frac{\sum_{j=1}^N RASE(j)}{N} \quad \dots \quad (9)$$

حيث N عدد التكرارات.

(iii) متوسط الخطأ المطلق Average Absolute Error وصيغته:

$$AAE = \frac{\sum_{i=1}^n |g(x_i) - \hat{g}(x_i)|}{n} \quad \dots \quad (10)$$

(iiii) معدل متوسط الخطأ المطلق Mean Average Absolute Error وصيغته:

$$MAAE = \frac{\sum_{j=1}^N AAE(j)}{N} \quad \text{حيث } N \text{ عدد التكرارات.}$$

٦- الجانب التجريبي

لغرض تطبيق معايير اختيار معلمة التمهيد عند إيجاد مقدر الشريحة الجزئية P-Spline والواردة في الجانب النظري ، لابد من وضع بعض الافتراضات المهمة للحصول على تحليل أكثر شمولية من خلال استخدام عدد كبير من العينات وبأحجام مختلفة أو اختيار قيم مختلفة لتباين الأخطاء ونظراً لصعوبة تطبيق هذه الافتراضات والحصول على هذه العينات في الواقع العملي يتم استخدام الأسلوب التجريبي من خلال تطبيق أسلوب المحاكاة (Simulation) .

المحاكاة Simulation

تعرف المحاكاة بأنها تقليد للواقع العملي بحيث تقوم بتوظيف نماذج تظهر فيها عدد كبير من الحالات الافتراضية لتكون نتائج التحليل أكثر شمولية ، وقد ظهرت الاستعانة بالمحاكاة أساسا كإحدى افرازات التقدم الحاصل في مجال الحاسبات الالكترونية من جانب ، ومن جانب آخر بسبب التطور الحاصل في مجال التحليل العددي. أما مسوغات العمل بالمحاكاة تكون في الغالب للتأكد من تحقق جانب تطبيقي موجود أصلا أو لصعوبة الحصول على بيانات توفر معلومات دقيقة عن ظاهرة معينة أو عندما يصعب إثبات البرهان الرياضي بشكله النظري لبيان أفضلية طرائق تقدير معينة على حساب أخرى. تم توليد المتغيرات التوضيحية X_i والتي تتبع التوزيع المنتظم القياسي باستخدام برنامج R وبطريقة (Mersenne – Twister) ، وباستخدام طريقة (Box – Muller) يتم تحويل هذه المتغيرات الى متغيرات تتبع التوزيع الطبيعي القياسي ومن ثم باستخدام التحويل $\varepsilon = \sigma Z$ - حيث Z متغير يتبع التوزيع الطبيعي القياسي- يمكن الحصول على متغيرات عشوائية تتبع التوزيع الطبيعي الذي توقعه صفر وتباينه ثابت ويساوي σ^2 ، ولغرض استخدام أسلوب المحاكاة في بحثنا هذا تم استخدام ثلاث مستويات للانحراف المعياري (σ) هي كالآتي:

$$\sigma = 0.3 \quad (1) \quad \sigma = 0.5 \quad (2) \quad \sigma = 1 \quad (3)$$

أما قيم المتغير المعتمد فيتم توليدها باستخدام المعادلة التالية : $y_i = g(x_i) + \varepsilon_i$, $i = 1, \dots, n$ حيث x_i هي المتغيرات التوضيحية التي تم توليدها كما سبق ، و $g(x_i)$ قيمة دالة الإختبار عند النقطة x_i ، ε_i هي الأخطاء العشوائية التي تم توليدها كما سبق.

وقد تم استخدام أربع قيم لحجوم العينات هي : $n = 20, 50, 150, 300$

بالنسبة لدرجة الشريحة فتم استخدام أساس الشريحة التكعيبية Cubic Spline وأما بالنسبة لعدد العقد المستخدم في النموذج فتم الإعتماد على الخوارزمية التالية [9]:

خوارزمية اختيار عدد العقد

تعتمد هذه الخوارزمية على أحد المعايير مثل GCV ، AIC_{corr} ، AIC لاختيار عدد العقد وقيمة المعلمة الممهدة في أن واحد وكما يأتي :

١. يتم تعريف متجه عدد العقد $K = (5, 10, 20, 40, 80, 120)$ على أن لا يتجاوز عدد العقد في المتجه القيمة $n - P - 1$ حيث n عدد البيانات الغير مكررة و p درجة الشريحة .
٢. يتم إيجاد التقدير عند كل قيمة في المتجه K (عدد العقد) وتحسب قيمة λ المقابلة لأصغر قيمة للمعيار GCV أو AIC_{corr} أو AIC .
٣. يتم اختيار المتجه K المقابل لأصغر قيمة للمعيار GCV أو AIC_{corr} أو AIC وقيمة λ المقابلة .

دوال الإختبار المستخدمة في تجارب المحاكاة

تم اختيار خمسة دوال مختلفة للإختبار في تجارب المحاكاة يمكن توضيحها كالآتي:

١- دالة الانحدار اللاخطية وصيغتها:

$$g(x) = \sin(2(4x - 2)) + 2\exp(-(16(x - 0.5))^2)$$

٢- دالة الانحدار غير المتجانسة مكانيا **Spatially Heterogeneous Function** وصيغتها :

$$g(x) = \sqrt{x(1-x)} \sin\left\{\frac{2\pi(1+2^{(9-4j)/5})}{x+2^{(9-4j)/5}}\right\}, j = 6$$

٣- دالة الانحدار اللاخطية **Three - Bump** وصيغتها :

$$g(x) = \exp\{-400(x-0.6)^2\} + \frac{5}{3}\exp\{-500(x-0.75)^2\} + 2\exp\{-500(x-0.9)^2\}$$

٤- دالة الانحدار اللاخطية **Bump Function** وصيغتها :

$$g(x) = x + 2\exp[-\{16(x-0.5)\}^2]$$

٥- دالة الانحدار اللاخطية **Logistic Functin** وصيغتها :

$$g(x) = \frac{1}{1 + \exp(-20(x-0.5))}$$

تجارب المحاكاة

بعد توليد المتغيرات العشوائية تم تنفيذ تجارب المحاكاة بواقع (500) تكرار لكل تجربة وكانت النتائج كالاتي:

نتائج تجارب المحاكاة لدالة الإختبار الأولى

$$g(x) = \sin(2(4x-2)) + 2\exp(-(16(x-0.5))^2)$$

أظهرت النتائج باستخدام دالة الإختبار الأولى والمبينة في الجدول (1) ما يلي:

(1) عندما ($\sigma = 0.3, \sigma = 0.5$) وبناء على قيم المعيارين **MRASE**، و **MAAE** وعند حجوم العينات ($n = 50, n = 150, n = 300$) تفوق معيار اختيار معلمة التمهيد **AIC_{corr}** وكان الترتيب كالاتي: **AIC_{corr}** ثم **GCV** ثم **AIC**، في حين تفوق معيار **AIC** عند حجم العينة ($n = 20$).

(2) وعندما ($\sigma = 1$) وعند جميع حجوم العينات ($n = 20, n = 50, n = 150, n = 300$) وبناء على قيم المعيارين **MRASE**، و **MAAE** تفوق معيار **AIC_{corr}** وكان الترتيب كالاتي: **AIC_{corr}** ثم **GCV** ثم **AIC**.

(3) كانت النتائج للمعايير الثلاث لإختيار معلمة التمهيد متقاربة جدا عند حجم العينة (300).


(4) النتائج لكل من المعيارين **MRASE** و **MAAE** ولكل معيار من معايير اختيار معلمة التمهيد كانت

تتقارب كلما زاد حجم العينة عند ثبوت الإنحراف المعياري، وكلما قلت قيمة الإنحراف المعياري عند


ثبوت حجم العينة.

جدول (1) نتائج تجارب المحاكاة لدالة الاختبار الأولى

التسلسل	الأنموذج	حجم العينة	$\sigma = 0.3$		$\sigma = 0.5$		$\sigma = 1$	
			MRASE	MAAE	MRASE	MAAE	MRASE	MAAE
1	P-SPLINE GCV	20	0.243345	0.1889211	0.3652866	0.2905084	0.5963176	0.4838494
		50	0.1771237	0.1335809	0.2501669	0.1954053	0.4529894	0.3583659
		150	0.1617727	0.1117769	0.1929029	0.1440078	0.3074983	0.2432281
		300	0.1457595	0.0974267	0.1743363	0.1244588	0.2406186	0.1862853
2	P-SPLINE AIC	20	0.2423486	0.1885617	0.3634983	0.2897624	0.600413	0.4868099
		50	0.1794342	0.1354449	0.2552371	0.1993374	0.468431	0.3703915
		150	0.1621789	0.1120996	0.1941074	0.1449919	0.3110884	0.2459679
		300	0.145944	0.09756803	0.1746673	0.1247332	0.2415254	0.1870081
3	P-SPLINE AIC _{corr}	20	0.2597316	0.1978863	0.3752821	0.2963616	0.5891705	0.4782588
		50	0.1754659	0.1320879	0.2476987	0.1929891	0.4454057	0.3525148
		150	0.1615316	0.1115407	0.1921906	0.1434978	0.3062699	0.2420907
		300	0.1455945	0.0973053	0.1740704	0.1242379	0.2403106	0.1860291



شكل (2) منحنى مقدر الشريحة الجزئية معلمة التمهيد لدالة الاختبار الأولى.



شكل (1) المنحنى الحقيقي لدالة الاختبار الأولى باستخدام معيار AIC_{corr} الاختيار

نتائج تجارب المحاكاة لدالة الاختبار الثانية

$$g(x) = \sqrt{x(1-x)} \sin\left\{\frac{2\pi(1+2^{(9-4j)/5})}{x+2^{(9-4j)/5}}\right\}, j = 6$$

أظهرت النتائج باستخدام دالة الاختبار الثانية والمبينة في الجدول (2) ما يلي:

(1) عندما ($\sigma = 0.3$) وبناء على قيم المعيارين، $MAAE$ و $MRASE$ عند حجومات العينات

التسلسل	حجم الأنموذج العينة	$\sigma = 0.3$		$\sigma = 0.5$		$\sigma = 1$	
		MRASE	MAAE	MRASE	MAAE	MRASE	MAAE

(2) $n = 50, n = 150, n = 300$ تفوق معيار اختيار معلمة التمهيد AIC_{corr} وكان الترتيب كالاتي: AIC_{corr} ثم GCV ثم AIC ، في حين تفوق معيار AIC عند حجم العينة ($n = 20$).

(2) أما عندما ($\sigma = 1, \sigma = 0.5$) وعند جميع حجومات العينات ($n = 20, n = 50, n = 150, n = 300$) وبناء على قيم المعيارين، $MAAE$ و $MRASE$ تفوق معيار AIC_{corr} وكان الترتيب كالاتي: AIC_{corr} ثم GCV ثم AIC .


(3) كانت النتائج للمعايير الثلاث لإختيار معلمة التمهيد متقاربة جدا عند حجم العينة ($n = 300$)

(4) النتائج لكل من المعيارين $MAAE$ و $MRASE$ ولكل معيار من معايير اختيار معلمة التمهيد كانت


تتقارب كلما زاد حجم العينة عند ثبوت الإنحراف المعياري، وكلما قلت قيمة الإنحراف المعياري عند ثبوت حجم العينة.

جدول (2) نتائج تجارب المحاكاة لدالة الإختبار الثانية

1	P-SPLINE GCV	20	0.224573 4	0.1809882	0.301512 3	0.242957 1	0.485374 1	0.396568 5
		50	0.181564 1	0.1413051	0.252959 3	0.201302 8	0.429465 1	0.346449 4
		150	0.139043 1	0.1056154	0.191905 6	0.150934 0	0.321532 0	0.258678 4
		300	0.115577 3	0.0864661 7	0.157316 6	0.121494 1	0.252149 1	0.200430 6
2	P-SPLINE AIC	20	0.223131 7	0.1796258	0.302831	0.243907 6	0.493811	0.402753 5
		50	0.183795 8	0.1431776	0.259393 6	0.206122 0	0.444733 9	0.358060 3
		150	0.140579 5	0.1069414	0.196631 5	0.154494 3	0.327880 1	0.263523 8
		300	0.115725 1	0.0867360 9	0.158018 2	0.122097 7	0.253356 4	0.201337 3
3	P-SPLINE AIC _{corr}	20	0.230046 2	0.1856055	0.296254 2	0.239519 5	0.468407 7	0.382970 5
		50	0.180418 7	0.1402153	0.250279 3	0.199334 8	0.422230 8	0.340811 5
		150	0.138772 4	0.1051332	0.190724 6	0.14991	0.319943 7	0.257465 3
		300	0.115489 2	0.0861546 3	0.156885 1	0.121075 0	0.251773 8	0.200180 7



شكل (4) منحنى مقدر الشريحة الجزائية
معلمة التمهد لدالة الإختبار الثانية.



شكل (3) المنحنى الحقيقي لدالة الإختبار الثانية.
باستخدام معيار AIC_{corr} لإختبار

نتائج تجارب المحاكاة لدالة الإختبار الثالثة

$$g(x) = \exp\{-400(x - 0.6)^2\} + \frac{5}{3}\exp\{-500(x - 0.75)^2\} + 2\exp\{-500(x - 0.9)^2\}$$

أظهرت النتائج باستخدام دالة الإختبار الثالثة والمبينة في الجدول (3) ما يلي:

(1) عندما $(\sigma = 0.3)$ وبناء على قيم المعيارين، $MAAE$ و $MRASE$ فإن أداء معيار اختيار معلمة التمهيد AIC_{corr} أفضل من أداء المعيارين الآخرين خصوصاً عند حجوم العينات $(n = 150, n = 300)$ ، وكان ترتيب المعايير عند هذين الحجمين هو: AIC_{corr} ثم GCV ثم AIC ، في حين تفوق المعيار AIC عند الحجوم $(n = 20, n = 50)$.

(2) عندما $(\sigma = 0.5)$ وبناء على قيم المعيارين $MAAE$ و $MRASE$ تفوق معيار اختيار معلمة التمهيد AIC_{corr} عند حجوم العينات $(n = 150, n = 300)$ وكان ترتيب المعايير عند هذين الحجمين هو: AIC_{corr} ثم GCV ثم AIC في حين تفوق معيار AIC عندما $(n = 20)$ و $MRASE$ ومعيار GCV ل $MAAE$ ، وتفوق معيار GCV عندما $(n = 50)$.

(3) أما عندما $(\sigma = 1)$ وعند جميع حجوم العينات $(n = 20, n = 50, n = 150, n = 300)$ وبناء على قيم

المعيارين $MAAE$ و $MRASE$ تفوق معيار AIC_{corr} وكان الترتيب كالاتي: AIC_{corr} ثم

GCV ثم AIC .

(4) كانت النتائج للمعايير الثلاث لإختيار معلمة التمهيد متقاربة جداً عند حجم العينة $(n = 300)$


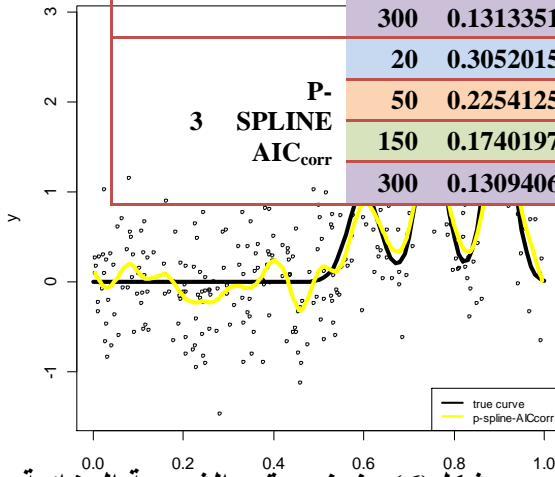
(5) النتائج لكل من المعيارين $MAAE$ و $MRASE$ ولكل معيار من معايير اختيار معلمة التمهيد كانت

تتقارب كلما زاد حجم العينة عند ثبوت الإنحراف المعياري، وكلما قلت قيمة الإنحراف المعياري عند

ثبوت حجم العينة.

جدول (3) نتائج تجارب المحاكاة لدالة الإختبار الثالثة

التسلسل	الأنموذج	حجم العينة	$\sigma = 0.3$		$\sigma = 0.5$		$\sigma = 1$	
			MRASE	MAAE	MRASE	MAAE	MRASE	MAAE
1	P-SPLINE GCV	20	0.2919296	0.2214334	0.3666626	0.2846156	0.5327417	0.4266905
		50	0.2236143	0.1681082	0.3052597	0.2336578	0.4738421	0.3760044
		150	0.1742942	0.1275391	0.2357195	0.1772353	0.3598004	0.2788376
		300	0.1310648	0.09612687	0.1933675	0.1435926	0.2977212	0.2275235
2	P-SPLINE AIC	20	0.2898255	0.2206015	0.3664167	0.2853265	0.5394976	0.4319782
		50	0.2234386	0.1680454	0.3064368	0.2351426	0.484833	0.3841152
		150	0.1750635	0.1281666	0.2377774	0.1788550	0.3630265	0.2813826
		300	0.1313351	0.09633456	0.1936901	0.1438194	0.2983989	0.2280401
3	P-SPLINE AIC _{corr}	20	0.3052015	0.2290701	0.3688299	0.2848836	0.5195889	0.4164398
		50	0.2254125	0.1689146	0.3077777	0.2345420	0.4678338	0.3705733
		150	0.1740197	0.1272828	0.234774	0.1764384	0.3583534	0.2773443
		300	0.1309406	0.0960147	0.1929458	0.1432547	0.2975246	0.2273732



شكل (6) منحنى مقدر الشريحة الجزئية

شكل (5) المنحنى الحقيقي لدالة الاختيار الثالثة.

معلمة التمهد لدالة الاختيار الثالثة.

باستخدام معيار AIC_{corr} لاختيار

نتائج تجارب المحاكاة لدالة الاختيار الرابعة.

$$g(x) = x + 2 \exp[-\{16(x - 0.5)\}^2]$$

أظهرت النتائج باستخدام دالة الاختيار الرابعة والمبينة في الجدول (4) ما يلي:

(1) عندما ($\sigma = 0.5$, $\sigma = 0.3$) وبناء على قيم المعيارين $MRASE$ و $MAAE$ وعند حجومات العينات ($n = 50, n = 150, n = 300$) تفوق معيار اختيار معلمة التمهد AIC_{corr} وكان الترتيب كالاتي: AIC_{corr} ثم GCV ثم AIC ، في حين تفوق معيار AIC عند حجم العينة ($n = 20$).

(2) وعندما ($\sigma = 1$) وعند جميع حجومات العينات ($n = 20, n = 50, n = 150, n = 300$) وبناء على قيم المعيارين $MRASE$ و $MAAE$ تفوق معيار AIC_{corr} وكان الترتيب كالاتي: AIC_{corr} ثم GCV ثم AIC .



(3) كانت النتائج للمعايير الثلاث لإختبار معلمة التمهيدي متقاربة جدا عند حجم العينة ($n = 300$).

(4) النتائج لكل من المعيارين $MAAE$ و $MRASE$ ولكل معيار من معايير اختيار معلمة التمهيدي

كانت تتقارب كلما زاد حجم العينة عند ثبوت الإنحراف المعياري، وكلما قلت قيمة الإنحراف المعياري عند ثبوت حجم العينة.

جدول (4) نتائج تجارب المحاكاة لدالة الإختبار الرابعة

التسلسل	الانموذج	حجم العينة	$\sigma = 0.3$		$\sigma = 0.5$		$\sigma = 1$	
			MRASE	MAAE	MRASE	MAAE	MRASE	MAAE
1	P-SPLINE GCV	20	0.2330881	0.1781946	0.3350887	0.2578642	0.5399063	0.4293125
		50	0.1769065	0.1334417	0.2499578	0.1954713	0.4514662	0.3583073
		150	0.1617204	0.1116438	0.1924706	0.1435296	0.3086679	0.2445869
		300	0.1458055	0.09717957	0.1740802	0.1241545	0.2399383	0.1857045
2	P-SPLINE AIC	20	0.2317695	0.1777089	0.3337696	0.2570414	0.54596	0.4342213
		50	0.1791599	0.1353116	0.2554956	0.1996873	0.4681223	0.3713525
		150	0.1621263	0.1119669	0.1936803	0.1444984	0.3120862	0.2472225
		300	0.1459946	0.09732652	0.1744107	0.1244296	0.2408808	0.1864488
3	P-SPLINE AIC _{corr}	20	0.2500742	0.1871741	0.3443846	0.2627588	0.5311377	0.4224709
		50	0.1751888	0.1319322	0.2474149	0.1929811	0.443989	0.3524316
		150	0.1614931	0.1114190	0.1918099	0.1430260	0.3072352	0.2433053
		300	0.1456377	0.09706124	0.1737513	0.1238788	0.2397641	0.1855129



$$\sigma = 0.3$$

$$\sigma = 0.5$$

$$\sigma = 1$$

شكل (8) منحنى مقدر الشريحة الجزائية باستخدام معلمة التمهيد لدالة الإختبار الرابعة.

شكل (7) المنحنى الحقيقي لدالة الإختبار الرابعة. معيار AIC_{corr} لإختبار

نتائج تجارب المحاكاة لدالة الإختبار الخامسة.


$$g(x) = \frac{1}{1 + \exp(-20(x - 0.5))}$$

أظهرت النتائج باستخدام دالة الإختبار الخامسة والمبينة في الجدول (5) ما يلي:


- (1) عندما ($\sigma = 0.3, \sigma = 0.5, \sigma = 1$) وعند جميع حجوم العينات ($n = 20, n = 50, n = 150, n = 300$) وبناء على قيم المعيارين، و تفوق معيار AIC_{corr} وكان الترتيب كالاتي: AIC_{corr} ثم GCV ثم AIC .
- (2) كانت النتائج للمعايير الثلاث لإختبار معلمة التمهيد متقاربة جدا عند حجم العينة ($n = 300$).
- (3) النتائج لكل من المعيارين $MAAE$ و $MRASE$ ولكل معيار من معايير اختيار معلمة التمهيد كانت تتقارب كلما زاد حجم العينة عند ثبوت الإنحراف المعياري، وكلما قلت قيمة الإنحراف المعياري عند ثبوت حجم العينة.

جدول (5) نتائج تجارب المحاكاة لدالة الإختبار الخامسة.

التسلسل	الأنموذج	حجم العينة	MRASE	MAAE	MRASE	MAAE	MRASE	MAAE
1	P-SPLINE GCV	20	0.1512608	0.1237027	0.2342071	0.1899261	0.4376186	0.3566224
		50	0.1157831	0.09314796	0.1916624	0.1537910	0.3833273	0.3098367
		150	0.07197386	0.05793716	0.1155194	0.09377281	0.2469128	0.1993353
		300	0.05564373	0.04518935	0.08932096	0.07204973	0.1765126	0.1422414
2	P-SPLINE AIC	20	0.15439	0.1261353	0.2394550	0.1939084	0.4477999	0.364432
		50	0.1188360	0.09543395	0.1979383	0.1586157	0.3969235	0.3203926
		150	0.07232149	0.05818825	0.1160435	0.09409664	0.2501138	0.2017712
		300	0.0557504	0.04525239	0.08950016	0.07219673	0.1774984	0.1430061
3	P-SPLINE AIC _{corr}	20	0.1456935	0.1193868	0.2237788	0.1824610	0.4203055	0.3442840
		50	0.1133978	0.09139237	0.1877814	0.1508021	0.3769753	0.3047724
		150	0.07170547	0.05768855	0.1152848	0.09367495	0.2459476	0.1986249
		300	0.05553896	0.045108	0.08906145	0.07185116	0.1761813	0.1419941



شكل (10) منحنى مقدر الشريحة الجزئية معلمة التمهيدي لدالة الإختبار الخامسة.



شكل (9) المنحنى الحقيقي لدالة الإختبار الخامسة باستخدام معيار AIC_{corr} لإختبار

مما تقدم يمكن استنتاج الآتي:

- (1) أن معيار AIC_{corr} كان الأفضل من بين المعايير GCV و AIC في اختيار معلمة التمهيد لمقدر الشريحة الجزائية (P-Spline) وخصوصا عند حجوم العينات الكبيرة ($n \geq 50$)، يليه معيار GCV ثم AIC
- (2) أن معيار اختيار معلمة التمهيد AIC حقق نتائج جيدة عند حجم العينة الصغيرة ($n = 20$).
- (3) كانت النتائج للمعايير الثلاث لإختيار معلمة التمهيد متقاربة جدا عند حجم العينة ($n = 300$).
- (4) النتائج لكل من المعيارين $MRASE$ و $MAAE$ ولكل معيار من معايير اختيار معلمة التمهيد كانت تتقارب كلما زاد حجم العينة عند ثبوت الإنحراف المعياري، وكلما قلت قيمة الإنحراف المعياري عند ثبوت حجم العينة.

٨- التوصيات

- (1) يوصي الباحث باستخدام معيار AIC_{corr} لإختيار معلمة التمهيد كونه أثبت تفوقا في هذه الدراسة.
- (2) كما يوصي الباحث باستخدام معلمة تمهيدية تتغير عبر العقد لأن المقدرات في هذه الحالة تكون أكثر تكيفا مع عدم التجانس في دالة الإنحدار حيث لوحظ بالنسبة للمعايير المستخدمة في البحث أن المقدرات تعاني من التذبذب.

٩- المصادر

- [1] Akaike, H. (1981) "Likelihood A Model And Information Criterion" Journal of Econometrics 16 (1981) 3-14.
- [2] Bozdogan, H. (2000) "Akaike s Information Criterion And Recent Developments in Information Complexity" Journal of Mathematical Psychology 44, 62_91 .
- [3] Claeskens, G, Krivobokova, T and Opsomer, J. (2007). "Asymptotic properties of penalized spline estimators". Katholieke Universiteit Leuven, AMS2000 subject classification. 62G08, 62G20.
- [4] Eilers, P.H.C. and Marx, B.D. (1996). "Flexible smoothing using B-splines and penalized likelihood (with Comments and Rejoinder)". Statistical Science 11(2): 89-121
- [5] Hurvich, C.M and Simonoff, J.S and Tsai, C.L. (1998) "Smoothing Parameter Selection in Nonparametric Regression using an Improved Akaike Information Criterion" J. R. Statist. Soc. B (1998) 60, Part 2, p p.2 71-293.
- [6] Kumar, D.N and Mujumdar, P.P (1990): "Stochastic Models of Steram Flow . Some Case Studies ". Hydrological Sciences , Vol 35 , No 4 , PP 395-410.
- [7] Li, Y. and Ruppert, D. (2008). "On the asymptotics of penalized splines". Biometrika, 95, 415-436.

- [8] Ruppert, D (2002) "Selecting the number of knots for Penalized Splines", Journal of Computational and Graphical Statistics 11, 735-757.
- [9] Ruppert, D and Carroll, R. J (1997) "Penalized Regression Splines" , <http://www.citeulike.org/user/hyndman/article/2577705>
- [10] Ruppert, D., Wand, M.P., and Carroll, R.J. (2003). "Semiparametric Regression". Cambridge University Press, New York.
- [11] Wahba, G. (1975) "Smoothing Noisy Data With Spline Functions" Numer. Math. 24, 383-393, by Springer – Verlag (1975).
- [12] Wand, M. P (1999) " On the optimal amount of smoothing in penalized spline regression " Biometrika , 86 , 4 , pp.936-940.

Smoothing Parameter selection Criteria for Penalized Spline Estimator: A Comparison Study Using Simulation.

Abstract

Penalized Regression Spline or P-Spline is one of the important approaches that are used to estimate the regression curve non parametrically , and one of the most important elements that contribute to the application of the method is a Smoothing Parameter, which plays a role in balancing between the bias and the variance of the estimator or the so-called Bias - Variance Trade - off, The research comes to shed light to some of the methods of selection of smoothing parameter for penalized spline estimator and included a comparative study between the three criteria for the selection of smoothing parameter: the *GCV* criterion, and the *AIC* criterion, and the corrected *AIC* criterion AIC_{corr} , A Comparison between these three criteria using two of the error criteria to models used are *MRASE* , *MAAE* , according to the results of simulation experiments we were able to reach that AIC_{corr} better than the rest of the criteria in estimating smoothing parameter for penalized spline estimator.