

تقدير دالة انحدار الحرف الليبي في الانحدار المتعدد اللامعملي باستعمال المحاكاة

أ.م.د. لقاء علي محمد / كلية الادارة والاقتصاد / جامعة بغداد
الباحث / صابرین حسين کاظم

تاريخ التقديم: 2017/3/6
تاريخ القبول: 2017/10/5

المستخلص

عادة ما يستعمل الباحثون بشكل عام والأحصائيون بشكل خاص الانحدار اللامعملي عندما تعجز الطرائق المعممية عن تحقيق غاياتهم في تحليل النماذج بدقة معينة ، و من ثم تكون هذه الطرائق غير مجذبة لذلك يتم اللجوء الى الطرائق اللامعممية لسهولة برمجتها حاسوبيا ، كما ويمكن أن تستعمل الطرائق اللامعممية لأفتراض النموذج المعممي للانحدار لاستعماله لاحقا ، ومن ضمن استعمالات الطرائق اللامعممية هي معالجة احدى مشاكل الانحدار ، الا وهي مشكلة التعدد الخطي Multi-Colinearity Problem بين المتغيرات التوضيحية عند اقترانها بمشكلة لاختطاف البيانات Nonlinear Data ، وذلك باستعمال دالة انحدار الحرف الليبي (KRR) ، والتي تعتمد على تقدير عرض الحزمة (او ما تسمى بمعلمة التمهيد Bandwidth) (smoothing parameter) و لذلك تم اللجوء الى طريقتين مختلفتين لتقدير المعلمة الأخيرة و هما طريقة الأمكان الأعظم للعبور الشرعي (MLCV) و طريقة معيار (AIC) و المقارنة بين هاتين الطريقتين باستعمال اسلوب المحاكاة وقد تم التوصل الى إن طريقة معيار (AIC) هي الأفضل بالنسبة لدالة Gaussian .

المصطلحات الرئيسية للبحث/انحدار الحرف الليبي (KRR ، AIC ، MLCV) ، معلمة التنظيم λ



مجلة العلوم
الاقتصادية والإدارية
العدد 103 المجلد 24
الصفحات 419-411

* بحث مستقل من رسالة ماجستير



1- Introduction :

تزداد الحاجة الى استعمال اساليب الاحصاء كونها ادوات ذات اهمية في التقدير و التنبؤ ، و يعد تحليل الانحدار احد اهم الادوات الرئيسية و الفاعلة في اساليب التحليل الاحصائي لكثير من الباحثين و لكن يصاحب هذا التحليل عدد من المشاكل و منها مشكلة التعدد الخطى ، ويقصد بمشكلة التعدد الخطى هو ارتباط المتغيرات التوضيحية مع بعضها بعضا (كل المتغيرات او البعض منها) بعلاقة خطية يصعب فصلها . و عادة ما يستعمل انحدار الحرف Ridge Regression لمعالجة هذه المشكلة وهو من الطائق المستعملة لمعالجة مشكلة التعدد الخطى (شبه التام) [1] ، و يشترط لمعالجة تلك المشكلة بطريقة انحدار الحرف الاعتيادية ، خطية البيانات و عند عدم توفر ذلك الشرط يلجأ الباحثون الى معالجتها باتباع احد اساليب الانحدار الامثل ، و هو اسلوب التقدير الليبي Kernel و الذي يعد اسلوبا لامعانيا تمهديا لتقدير دالة احصائية عندما تكون البيانات لخطية [2] .

2- هدف البحث :

أن الهدف من البحث هو تحليل و معالجة البيانات اللافخطية Nonlinear Data و لاسيما تلك التي تعاني مشكلة التعدد الخطى Multi-CoLinearity Problem باستعمال دالة انحدار الحرف الليبي Kernal Ridge Regression ، و التعرف على الطريقة الأفضل لتقدير المعلمة التمهيدية و التوصل الى الحل الأمثل من خلال المقارنة بين طريقي الأمكان الأعظم للعبور الشرعي Maximum Likelihood و معيار Akaike Inormation criterion Cross-Validation وذلك باستعمال اسلوب المحاكاة .

3- الجانب النظري :

إن الهدف الرئيسي هو تقدير دالة الانحدار المجهولة (m) و التي تعبر عن التوقع الشرطي لمتغير الاستجابة Y_i بالنسبة الى X_i التي تشير الى مشاهدات العينة المدروسة [2] .

$$m(x) = E(Y/X=x)$$

و من ضمن طرائق التمهيد المعروفة لتقدير دالة الانحدار هي :-

Local Linear Regression

يدعى احيانا بالانحدار متعدد الحدود الخطى الموضعي وقد اقترح من قبل الباحث Fan في عام 1993 و Fan and Gijbels [3] عامي 1992 و 1996 و يعد من افضل المقدرات في الانحدار الامثل و ذلك لانه يصحح بعض العيوب في مقدرات kernel [3] .

ويعتمد هذا المنهج على افتراض ان المشتقة الثانية لدالة الانحدار الامثل المجهولة $(m(x))$ موجودة و على اساس ذلك و لتقدير المعلم a , b يتم تصغير المقدار الآتي [2] :-

$$\sum (Y_i - a - b(x - X_i))^2 k\left(\frac{x - X_i}{h}\right)$$

و على فرض ان حل مسألة المربيعات الصغرى الموزونة (WLS) يتمثل بالمقدرات \hat{b} , \hat{a} و بأجراء بعض الحسابات البسيطة يكتب ممهد LLS بالشكل الآتي [2] :-

$$\hat{a} = \hat{m}(x) = \frac{\sum_{i=1}^n w_i Y_i}{\sum_{i=1}^n w_i}$$

اذ تشير w_i الى دالة الوزن و تحسب بالشكل الآتي [2] :-

$$w_i = k\left(\frac{x - X_i}{h}\right) (S_{n,2} - (x - X_i) S_{n,1})$$



مع الإشارة الى إن [2] :

$$S_{n,l} = \sum_{i=1}^n k\left(\frac{x-X_i}{h}\right)^l (x - X_i)^l \quad l = 1, 2.$$

: $k(u)$ تمثل دالة kernel.

h : تمثل معلمة التمهيد (عرض الحزمة) و التي يجب تقديرها بأحدى الطرق الأحصائية المناسبة .

4- تقدير عرض الحزمة :-

تدعى احيانا بالمعلمة التمهيدية او سعة القيد و يرمز لها بالرمز (h) ، ولها علاقة طردية مع مقدار التحيز و علاقة عكسية مع التباين (اي بزيادة عرض الحزمة يزداد التحيز ويقل التباين و العكس صحيح) . لذلك يتوجب على الباحث اختيار عرض الحزمة بطريقتين معينة للوصول الى مرحلة التوازن بين التحيز و التباين .

و من ضمن تلك الطرق لاختيار عرض الحزمة هي :

1-4 طريقة الإمكان الأعظم للعبور الشرعي Maximum Likelihood Of Cross -Validation

اقترحت هذه الطريقة لاختيار عرض الحزمة h من قبل van den Broek , Hermans و Habbema في عام 1974 و Duin في عام 1976 و تكتب صيغتها العامة كما يأتي [7][4] :-

$$MLCV(h) = \left(n^{-1} \sum_{i=1}^n \log \left[\sum_{j \neq i} K\left(\frac{x-X_j}{h}\right) \right] - \log[(n-1)h] \right)$$

ومن الطبيعي ان يتم اختيار عرض الحزمة الأعظم لل $MLCV(h)$ اي أن :-

$$h = \arg \max_{h>0} (MLCV(h))$$

و يلاحظ انه يعطي نتائج زانفة عند افتراض ان $h=0$ كقيمه اولية [7][4] .

2- معيار معلومات Akaike- Information criterion Akaike

ويرمز له بالرمز (AIC) اختصاراً و يعد تقدير غير متخيّز تقريري لمعلومات Kullback المتنوّعة [8] ، كما و تعتبر الأسلوب التقريري لمعيار LCV و تكتب الصيغة العامة لها بالشكل الآتي :-

$$AIC(h) = - \sum_{i=1}^n \log \hat{m}_h(x_i) - \sum_{i=1}^n infl k\left(\frac{x-X_i}{h}\right)$$

إذ ان :-

$$\hat{m}_h(x_i) = \frac{1}{nh} \sum_{i=1}^n k\left(\frac{x-X_i}{h}\right)$$

$$infl k\left(\frac{x-X_i}{h}\right) = k(0)/(nh\hat{m}_h(x_i))$$

إذ ان $infl k\left(\frac{x-X_i}{h}\right)$ يمثل مقياس الحساسية .

و بتقليل معيار AIC نجد ان [9] :-

$$h = (AIC \min_{h>0}(h))$$

و يلاحظ استحالة إيجاد $\hat{m}_h(x_i)$ إذا تم افتراض ان $h=0$ كقيمة أولية إذ لا يجوز أن يكون المقام مساوياً للصفر و في هذه الحالة فإن معيار Akaike يعطي قيمة زانفة .



Regularization parameter

5 - معلمة التنظيم

تدعى بـ **معلمة الضبط Tuning Parameter** وهي تتحكم بكمية التنظيم وبحجم المعاملات ويرمز لها بالرمز λ .

ومن الجدير بالذكر انه عندما تقترب قيمة هذه المعلمة من الصفر $\rightarrow 0$ يتم الحصول على حلول المربعات الصغرى و الخالية من التنظيم $[14]$ و تكتب الصيغة العامة لها بالشكل الآتي $[13]$:-

$$\lambda_n = 4\sigma R \sqrt{\frac{\log p}{n}}$$

عندما $[13]$:

$$R = \max_j \frac{\|x_j\|}{\sqrt{n}}$$

إذ إن p تمثل عدد المتغيرات التوضيحية X_j .

Kernel Ridge Regression

6 - انحدار الحرف الليبي

هو اسلوب فاعل لبناء نماذج الانحدار اللاخطي و الذي يعمل من خلال انحدار الحرف بطرائق Kernel و الذي يهدف الى تقدير الدالة غير المعلومة .

و يرمز له اختصارا بالرمز **KRR** و يمكن كتابة الصيغة العامة بالشكل الآتي $[10]$:

$$\hat{m}_{KRR} := \operatorname{argmin}_{f \in H} \left(\frac{1}{n} \sum_{i=1}^n (Y_i - f(x_i))^2 + \lambda \|f\|_H^2 \right)$$

حيث ان λ هي معلمة التنظيم .

و على فرض أن x_1, x_2, \dots, x_n هي متجهات عشوائية مستقلة تمتلك التوزيع (iid) نفسه حيث ان x_i هو متجه صفي من المتغيرات التوضيحية X_j $[6]$ اي ان :-

$$x_i = \begin{bmatrix} X_{11} & \cdots & X_{1p} \\ \vdots & \ddots & \vdots \\ X_{n1} & \cdots & X_{np} \end{bmatrix}$$

إذ ان :-

$i=1,2,\dots,n$

$j=1,2,\dots,p$

عندما p تمثل عدد المتغيرات التوضيحية .
حجم العينة .

و يشير الرمز $\|m\|$ الى طول المتجه m و الذي يحسب بالشكل الآتي على اساس الضرب الداخلي Inner product :- *Hilbert Space*

$$\|m^*\| = \sqrt{\langle m^*, m^* \rangle}$$

إذ ان $[12]$:

$$\langle m^*, m^* \rangle = m^* ' m^*$$

$[10]$: و من ثم فإن

$$\|m^*\|_H^2 = \langle m^*, m^* \rangle$$



تقدير دالة انحدار الحرف الليبي في الانحدار المتعدد الامثل

باستعمال المحاكاة

حيث ان الدالة m^* تستخرج بالشكل الآتي :-

$$(.) = \sum_{i=1}^n \sum \alpha_i K(., X_i) \quad m^*$$

$$\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$$

تمثل متجهات معاملات انحدار الحرف و يمكن كتابة الصيغة العامة لها بالشكل الآتي [6]:

$$= (K + \lambda I_n)^{-1} Y \alpha^*$$

و يشير الرمز K الى مصفوفة Kernel و التي يمكن ان توصف بالشكل الآتي [6] :-

$$K_{ij} = k(x_i, x_j)$$

و يتم تكوينها باستعمال دوال كيرنال و قد تم استعمال دالة Gaussian وكما في الجدول الآتي :

Kernel	K(u)	Range
Gaussian	$/2(2\pi)^{-1/2} \exp(-u^2)$	$I (u \leq \infty)$

حيث ان :

$$u = \left(\frac{x - X_i}{h} \right)$$

7- الجانب التجريبي :

تم استعمال اسلوب المحاكاة لعرض الجانب النظري و تطبيق الطرائق المعروضة فيه و المقارنة بينها باستعمال معيار الاختبار Mean Square Error (MSE) أستناداً الى حجم عينات مختلفة ($n=70, 150$) و قيم مختلفة للانحراف المعياري ($s.d = 0.5$) فضلاً عن ابعاد مختلفة للمتغيرات التوضيحية ($p=9, 12$) و عرض حزمة افتراضي قيمة أولية و هو ($h=0.1$) و كذلك عندما يكون عدد مرات تكرار التجربة هو ($r=1500$) كما و تم احتساب المتغير المعتمد من خلال النموذج الآتي [5] :-

$$Y_i = \exp((x_i x_i')/2m) + e_i$$

عندما :

$$m = \text{mean}(x_i x_i')$$

إذ إن

$$e_i \sim N(0, \sigma^2)$$

كما و تم رسم بعض الحالات المفترضة للمتغير المعتمد Y_i مع دالة انحدار الحرف الليبي التقديرية باستعمال برنامج Excel إذ لا مجال لعرض جميع الحالات و كما في الشكل (1)، (2) بينما كانت النتائج كما يأتي :-

جدول رقم (1) يوضح قيمة متوسط مربعات الخطأ MASE عندما تكون عدد المتغيرات التوضيحية ($p=9$) و لكافة الحالات المفترضة

sample	Standard deviation	Sd=0.5	Sd=1
	Function Method	Gauss	Gauss
n=70 P=9	MLCV	0.0064	0.0245
	AIC	0.0063	0.0238
n=150 P=9	MLCV	0.0042	0.0161
	AIC	0.0043	0.0165



تقدير دالة انحدار الحرف الليبي في الانحدار المتعدد الامثلجي باستعمال المحاكاة

الجدول رقم (2) يوضح قيمة متوسط مربعات الخطأ MSE عندما تكون عدد المتغيرات التوضيحية ($p=12$) وكافة الحالات المفترضة

sample	Standard deviation	Sd=0.5	sd=1
	Function Method	Gauss	Gauss
n=70	MLCV	0.0099	0.0374
p=12	AIC	0.0096	0.0363
n=150	MLCV	0.0059	0.0230
p=12	AIC	0.0060	0.0233

يتضح من الجدول رقم (1) و الجدول رقم (2) ما يأتي :-

- لوحظ أن طريقة (AIC) هي الأفضل عند حجم عينة $n=70$ وذلك عندما يكون عدد المتغيرات التوضيحية $p=9,12$ اثناء اختيار دالة Gaussian .
- بينما تتميز طريقة MLCV بالفضلية عند حجم عينة $n=150$ وذلك عندما يكون عدد المتغيرات التوضيحية $p=9,12$ اثناء اختيار دالة Gaussian .
- يتضح أن قيمة MASE يقل بزيادة حجم العينة بينما يزداد بزيادة الإنحراف المعياري و بحسب النظرية الإحصائية.

8- الاستنتاجات:-

- نستنتج من خلال نتائج المحاكاة بأن طريقة AIC هي الأفضل من طريقة MLCV عند حجم عينة $n=70$ بينما تكن طريقة MLCV الأفضل عند $n=150$ و للحالات المفترضة كافة.
- نستنتج بأن هناك علاقة عكسية بين معيار الإختبار (MASE) وحجم العينة (n) بينما تكن هناك علاقة طردية بينه وبين الإنحراف المعياري (sd).

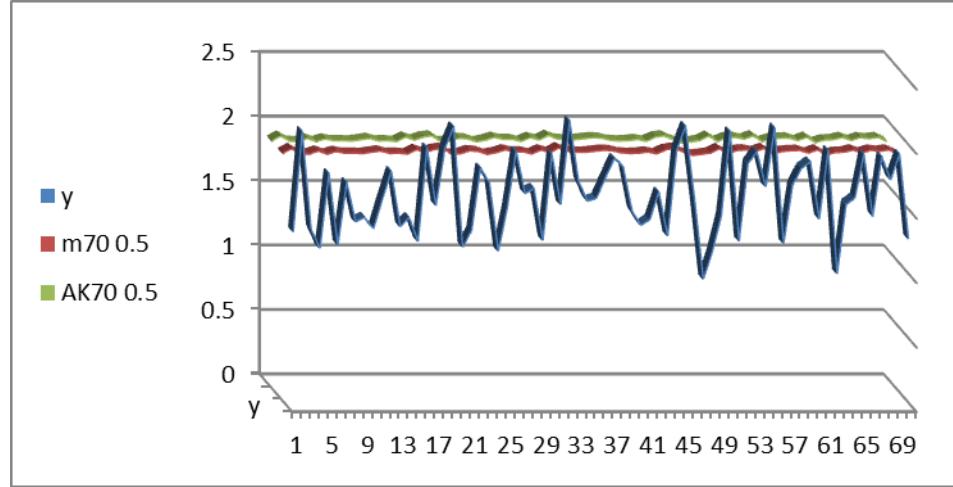
9- التوصيات:-

- نوصي باستعمال طريقة AIC عند استعمال دالة Gaussian بدلا من طريقة MLCV لحجم عينة أقل بينما نوصي بعكس ذلك لحجم عينة أعلى.
- نوصي بأختيار قيمة أقل للإنحراف المعياري كما نوصي بأختيار حجم عينة أكبر لتقليل قيمة معيار الإختبار MSE .
- نوصي باستخدام دوال أخرى مثل دالة Double Exponential .

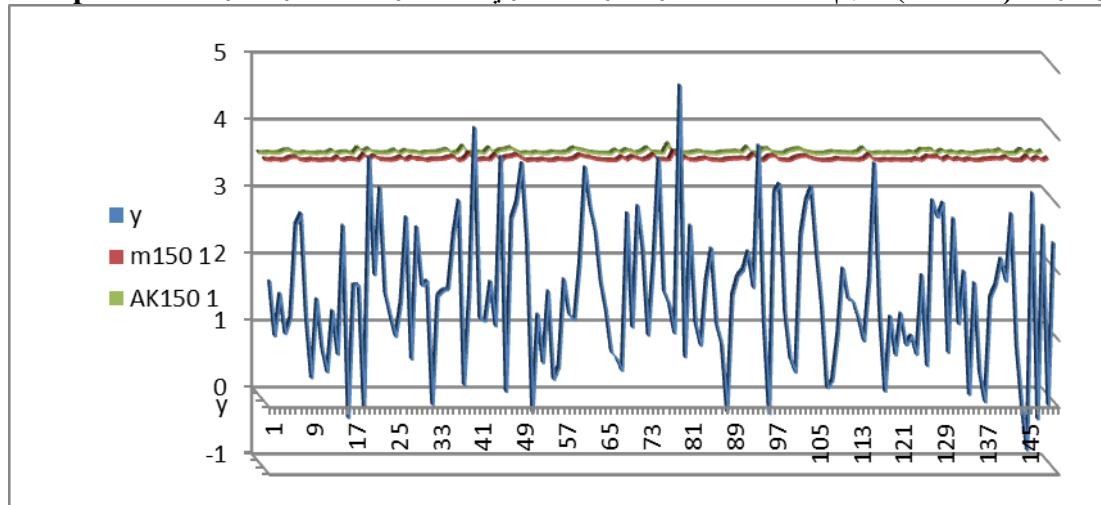


تقدير دالة انحدار الحرف الليبي في الانحدار المتعدد الامثلجي باستعمال المحاكاة

الشكل رقم (1) يوضح المتغير المعتمد y مع دالة انحدار الحرف الليبي التقديرية KRR عند استعمال طريقة $p=9$ لحجم عينة $n=70$ و انحراف معياري $sd=0.5$ و عدد متغيرات توضيحية (MLCV)



الشكل رقم (2) يوضح المتغير المعتمد Y مع دالة انحدار الحرف الليبي التقديرية عند استعمال طريقة (AIC) و طريقة (MLCV) لحجم عينة $n=150$ و انحراف معياري $sd=1$ و عدد متغيرات توضيحية $p=12$



المصادر:-

1- المصادر العربية:-

- 1- كاظم ، اموري هادي و الدليمي ، محمد مناجد "مقدمة في تحليل الانحدار الخطى" 1988 الطبعة 2001 ، طبع في مديرية دار الكتب للطباعة و النشر /جامعة الموصل .
- 2- حمود ، مناف يوسف "مقارنة مقدرات Kernel الامثلجية لتقدير دوال الانحدار " المجلة العراقية للعلوم الأحصائية كلية علوم الحاسوبات و الرياضيات جامعة الموصل العدد 2 لعام 2001 ص 44-26 .
- 3- حمود ، مناف يوسف و عاشور ، مروان عبد الحميد " مقارنة بضعة مقدرات لخطية لتقدير دالة الانحدار " مجلة العلوم الاقتصادية و الإدارية المجلد 18 العدد 68 ص 359 – 372 .
- 4- حمود ، مناف يوسف (2005) " مقارنة المقدرات الامثلجية لتقدير دوال الكثافة الاحتمالية " اطروحة دكتوراه مقدمة الى كلية الادارة و الاقتصاد / جامعة بغداد .



- المصادر الأجنبية :- 2

- 5- Rosipal, Roman and Trejo , Leonard J. (2001) " Kernel Partial Least Squares Regression in Reproducing Kernel Hilbert Space" Journal of Machine Learning Research 2 , pp [97-123] .
- 6- Kasiviswanathan , Shiva & Rudelson , Mark (2015) " spectral norm of random kernel matrices with application to privacy " Algorithms and Techniques - 18th International Workshop, APPROX 2015 , and 19th International Workshop , RANDOM 2015 , vol (40) , No (17) , pp[898-914] .
[rudelson@umich.edu.](mailto:rudelson@umich.edu)
- 7- Guidoum, A.(2015). " Kernel Estimator and Bandwidth Selection for Density and its Derivatives ". University of Science and Technology, The kedd Package, Version 1.0.3 .
- 8- Clifford M. Hurvich; Jeffrey S. Simonoff; Chih-Ling Tsai (1998) " Smoothing parameter selection in nonparametric regression using an improved Akaike information criterion " vol (60) No (2) pp [271-293] .
- 9- Clive R. Loader (1999) " Bandwidth Selection: Classical Or Plug-In " The Annals of statistics ,No 27, pp [415-438].
- 10- Zhang, Yuchen & Duchi, John and Wainwright, Martin (2013) "Divide and Conquer Kernel Ridge Regression" University of California , JMLR: Workshop and Conference Proceedings vol(30) pp[1-26] .
- 11- Arthur E.Horl and Robert W.Kennard (1970) " Ridge Regression : Biased Estimation For Non orthogonal Problems " University of Delaware and E.I.dupont de Nemours &Co. vol(12) , No(1) pp[55-67].
- 12- Bierens , H.J. (2007) " Lecture : Introduction to Hilbert Spaces [PDF] " Retrieved from Pennsylvania State University , Time series econometrics , Theory and applications Blackboard.
<http://personal.psu.edu/hxb11/HILBERT.PDF>.
- 13- Tomioka, R. (n.d) " Introduction To The analysis of Learning algorithms : ridge regression and lasso " University of Tokyo .
<http://tomioka.dk/teaching/dtuphd13/dtuphd13.pdf>
- 14- Quarter, Autumn (2006) " Lecture: Regularization: Ridge Regression and the Lasso [Pdf] " Lecture Note.
Blackboard:
<http://statweb.stanford.edu/~owen/courses/3051314/Rudyregularization.pdf>.



Estimate Kernel Ridge Regression Function in Multiple Regression

ABSTRACT :

In general, researchers and statisticians in particular have been usually used non-parametric regression models when the parametric methods failed to fulfillment their aim to analyze the models precisely. In this case the parametic methods are useless so they turn to non-parametric methods for its easiness in programming. Non-parametric methods can also used to assume the parametric regression model for subsequent use. Moreover, as an advantage of using non-parametric methods is to solve the problem of Multi-Colinearity between explanatory variables combined with nonlinear data. This problem can be solved by using kernel ridge regression which depend on what so-called bandwidth estimation (smoothing parameters). Therefore, for this purpose two different methods were used to estimate the smoothing parameter (Maximum Likelihood Cross-Validation (MLCV) and Akaike Information Criterion (AIC)). Furthermore, a comparision between the previous methods had been provided using simulation technique , and the method of Akaike Information Criterion (AIC) has been found to be the best for the Gaussian function .

Keyword :kernel ridge regression KRR , MLCV, AIC , Regularization parameter λ .