

التعدد الخطى في الأنحدار المتعدد اللامعلمى ، الكشف و المعالجة بأستعمال المحاكاة

أ.م.د. لقاء علي محمد / كلية الأدارة والأقتصاد / جامعة بغداد
الباحث/ صابرین حسين کاظم

تاريخ التقديم: 2017/3/6
تاريخ القبول: 2017/5/9

المستخلص

يعتبر تحليل الأنحدار هو الحجر الأساس لعلم الأحصاء ، و الذي يعتمد في الغالب على طريقة المربعات الصغرى الأعتيادية Ordinary Least Square Method ، لكن كما هو معروف ان الطريقة المذكورة انفـا لها عدة شروط كـي تعمل بدقة و بنتائج يمكن الاعتماد عليها ، اضافة الى إن عدم توفر بعض من شروطها يجعل من المستحيل اتمام العمل و تحليل النماذج و من ضمن تلك الشروط هي عدم وجود مشكلة التعدد الخطى (Multi-CoLinearity) و نحن في صدد الكشف عن وجود تلك المشكلة بين المتغيرات التوضيحية بأستعمال اختبار فيرار كلوير، بالإضافة الى شرط خطية البيانات و لعدم توفر الشرط الأخير تم اللجوء الى الأنحدار اللامعلمى (Nonparametric Regression) و معالجة المشكلة بأستعمال دالة انحدار الحرف الليبي Kernel Ridge Regression و التي تعتمد على تقدير عرض الحزمة (معلمة التمهيد) و لذلك تم اللجوء الى طريقتين مختلفتين لتقدير المعلمة التمهيدية و هما طريقة قاعدة الأبهام Rule of thumb (RULE) و الطريقة التمهيدية (BOOT) و المقارنة بين تلك الطرق بأستعمال أسلوب المحاكاة .

المصطلحات الرئيسية للبحث/ اختبار Fararr – Gluaber ، احصاءة مربع كاي ، تقدير عرض الحزمة h ، RULE ، BOOT ، انحدار الحرف الليبي KRR .





الجانب النظري :-

1- Introduction :

ان تحليل الأنحدار هو من اسasيات علم الأحصاء و هو من الأساليب المهمة لتحليل العلاقة بين متغيرين او اكثر [7] . و حتى يتم اجراء هذا التحليل و تفسير العلاقة بين المتغيرات يجب ان نختبر فيما اذا كانت هناك مشكلة عدم تجنس التباين او مشكلة الارتباط الذاتي او مشكلة التعدد الخطى ، كما و قد اعتبر الباحث Kmenta المشكلة الأخيرة مشكلة درجة وليس مشكلة نوع حيث اشار بأنها مشكلة وجود علاقة بين المتغيرات التوضيحية و بأختفاء تلك العلاقة يمكن استعمال p من النماذج الخطية البسيطة و بالتالي لا داعي لاستعمال نموذج خطى متعدد [2] ، ولذلك نحن في صدد اختبار مشكلة التعدد الخطى Multi-collinearity و التي يتم معالجتها عادة بأسعمال انحدار الحرف الأعيادي Ridge Regression لكن عند وجود بيانات لخطية تضطرنا الى اللجوء الى اسلوب النمذجة اللامعلمية (Nonparametric Modeling) ، حيث إن الحاجة الى المرونة في تحليل البيانات و ادراك الأحصائيين بعدم توافق التقدير المعلمى في تغير منحنى الأنحدار في حالة لخطية البيانات و كذلك التطور التكنولوجي ماديا و برمجيا، ادى كل ذلك الى تطور طرق التمهيد اللامعلمية خلال العقود الماضيين [4] .
و من اهم الطرق اللامعلمية لمعالجة تلك المشكلة هي انحدار الحرف الليبي Kernel Ridge Regression . (KRR)

Goal of the Search

هدف البحث

أن الهدف من البحث هو الكشف عن مشكلة التعدد الخطى Multi-Collinearity Problem بأسعمال اختبار فيرار كلوبر Farrar - Gluaber Test و معالجتها عندما تكون البيانات لخطية Nonlinear وذلك بأسعمال دالة انحدار الحرف الليبي Kernel Ridge Regression وذلك بأسعمال الطرائق البدية Kernel و تطبيق تلك الطرق بأسعمال اسلوب المحاكاة .

Multi – Co Linearity

مشكلة التعدد الخطى

يقصد بمشكلة التعدد الخطى هو وجود علاقة خطية بين المتغيرات التوضيحية اي حدوث ازدواجية بين تلك المتغيرات او البعض منها. و يظهر الازدواج الخطى بين المتغيرات التوضيحية عند تساوى قيمة احد المتغيرات التوضيحية (المستقلة) لكافة المشاهدات او عندما يرتبط متغيرين او اكثر بعلاقة خطية و يصعب فصلهما .

إن مشكلة التعدد الخطى نالت الاهتمام من قبل عدد كبير من الأحصائيين و التي ظهرت منذ عام 1934م من خلال البحث المقدم من قبل العالم (Frisch) ، و الذي أشار الى وجود علاقة خطية بين متغيرين او أكثر من المتغيرات التوضيحية [5] .

4- اختبار وجود مشكلة التعدد الخطى Test The Problem Of Multi – Linear [1]

قبل البدأ بتقدير دالة الأنحدار المجهولة في تحليل الأنحدار اللامعلمى يجب اختبار فيما اذا كانت لدينا مشكلة الأزدواجية (اي مشكلة التعدد الخطى) بين المتغيرات التوضيحية أم لا . و هناك عدة اختبارات للقيام بذلك ، و منها اختبار Farrar - Glauber .

Farrar - Glauer Test

[8][5] 4- اختبار فيرار كلوبر

هو اختبار احصائى لمشكلة التعدد الخطى تطور من قبل الباحثين Farrar و Glauber في عام 1967 و هو عبارة عن مجموعة من ثلاثة اختبارات الأول يستند الى أحصاءة مربع كاي χ^2 و ذلك لأختبار الفرضية التالية :

$H_0 : X_j$ is orthogonal

$H_1 : X_j$ is not orthogonal



التعدد الخططي في الانحدار المتعدد اللامعليمي، الكشف والمعالجة بأسعمال المحاكاة

و تكتب الصيغة العامة له بالشكل التالي [8] :-

$$\chi^2_0 = - \left[n - 1 - \frac{1}{6} (2 * p + 5) \right] \ln|R|$$

عندما n يمثل حجم العينة . Sample Size

p تمثل عدد المتغيرات التوضيحية Independent Variable بينما يشير الرمز R الى مصفوفة معاملات الارتباط التالية :-

$$R = \begin{pmatrix} 1 & r_{12} & \cdots & r_{1p} \\ \vdots & \ddots & \ddots & \vdots \\ r_{p1} & r_{p2} & \cdots & 1 \end{pmatrix}$$

كما يوصف معامل الارتباط بالصيغة الآتية :-

$$r_{12} = \frac{\sum_{i=1}^n x_{i1} x_{i2}}{\sqrt{\sum_{i=1}^n x_{i1}^2 x_{i2}^2}}$$

و تقارن قيمة χ^2 المحسوبة مع χ^2 الجدولية بمستوى دلالة معين و درجة حرية $(p(p-1)/2)$ [5].
اما ثانى اختبار فهو اختبار F والذى يحدد موقع المتغيرات التي تسبب مشكلة التعدد الخطى ، بينما الاختبار
الثالث فهو اختبار t و الذى يوضح نمط الأزدواجية الخطية [8].
وبعد التأكيد من ظهور مشكلة التعدد الخطى على الباحث معالجة تلك المشكلة بأحدى الطرق المناسبة أحصائيا
مثل انحدار الحرف اللي *Kernel Ridge Regression*.

5- انحدار الحرف اللي Kernel Ridge Regression

هو الشكل اللاخطى لأنحدار الحرف و يرمز له اختصارا بالرمز **KRR** و يمكن كتابة الصيغة العامة بالشكل
التالى [13] :

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

حيث ان λ هي معلمة التنظيم Regularization Parameter و التي سيتم التحدث عنها لاحقا.
و على فرض بأن x_n هي متوجهات عشوائية مستقلة تمتلك نفس التوزيع iid حيث ان
 x_i هو متوجه من المتغيرات التوضيحية X_j [6].
و يشير الرمز $\|f\|$ الى طول المتوجه f ، حيث ان الدالة f تستخرج بالشكل التالي :-

$$f^*(.) = \sum \alpha_i K(., X_i)$$

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

حيث إن α تمثل متوجهات معاملات انحدار الحرف Kernel Ridge Regression Vector و يمكن كتابة
الصيغة العامة لها بالشكل الآتى :

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

و يشير الرمز K الى مصفوفة Kernel و التي يمكن ان توصف بالشكل التالي [6] :-
 $K_{ij} = k(x_i, x_j)$



التعدد الخططي في الانحدار المتعدد الامثل، الكشف والمعالجة بأسعمال المعاكمة

و يتم تكوينها بأسعمال دوال كيرنال وقد تم استعمال دالة Biweight كما في الجدول التالي [12] :

Kernel	$K(u)$	Range
Biweight	$(3/4)(1 - u^2)^2$	$ u \leq 1$

حيث ان :

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

عندما h : عرض الحزمة .

BandWidth (Smoothing Parameter)

6- عرض الحزمة [7][1]

تعرف بمعلمة التمهيد او بعرض الحزمة و قد تسمى بمعلمة الانتشار و هي قد تقترب من الصفر لكن كلما اقتربت قيمتها من الصفر ازداد التباين و قل التحيز بينما بزيادتها يقل التباين و يزداد التحيز و لذلك يجب على الباحث تقديرها بطريقة توازن بين التباين و التحيز و قد تم اللجوء الى طريقتين لتقدير المعلمة المذكورة و هي طريقة قاعدة الأبهام (Rule Of Thumb (RULE) و الطريقة التمهيدية (Bootstrap (BOOT) و Rule Of Thumb Band width

كما يلي:-

Rule – Of –Thumb Band width

6- طريقة قاعدة الأبهام [9]

و تدعى بقاعدة التوزيع الطبيعي (Normal Distribution Rule) و المقترنة من قبل الباحث Silverman ، و تكتب الصيغة العامة لها بالشكل التالي :-

$$h = \hat{\sigma} CV(k) n^{-\frac{1}{2v+1}}$$

حيث تدل v على درجة kernel و التي تمثل اول عزم غير صافي و ذلك كون العزوم من الدرجة الفردية تساوي صفر لذلك تكون v دائماً عدداً زوجياً ، بينما يشير المقدار $\hat{\sigma}$ الى قيمة الاتحراف المعياري للعينة .

و تعتبر $CV(k)$ ثابتة و كما في الجدول التالي و المعتمدة على v (درجة Kernel) :-

درجة Kernel	V=2	V=4	V=6
Biweight	2.78	3.39	3.84

Bootstrab Smoothing

6- الطريقة التمهيدية

تعتمد هذه الطريقة على تقليل معيار (MISE) و الذي ينطوي على الدالة المجهولة $f_{\hat{x}}$ و بالتالي يصعب ايجاده و كما في الصيغة التالية [10] :

$$MISE(h) = E \int [\hat{f}_h(x; h) - f(x; h)]^2 dx$$

و لذلك نلجأ الى ما افترضه Peter Hall في عام 1990 بأن هناك عينات جديدة و لتكن x_i^* بحجم $n_i \leq n$ مسحوبة من العينة الأصلية x_i وبأيجاد الدالة اللبية و لتكن l بحيث ان $l \neq k$ لتلك العينات الجديدة و بقيمة افتراضية لعرض الحزمة و لتكن g بحيث ان $h \neq g$ نستطيع ايجاد $MISE^*(h)$ بدلاً من $MISE(h)$ وحسب الصيغة التالية:-

$$(h) = E^* \int [\hat{f}_h^*(x) - \hat{f}_g(x)]^2 dx MISE^*$$

حيث ان :

$$\hat{f}_h^*(x) = n^{-1} \sum_{i=1}^n k_h \left(\frac{x - X_i}{h} \right)$$

و أن [14] :

$$\hat{f}_g(x) = n^{-1} \sum_{i=1}^n l_g \left(\frac{x - X_i}{g} \right)$$



وتحسب قيمة معلمة التمهيد النهائية بتقليل $MISE^*(h)$ اي ان ^[10] :-

$$= \operatorname{argmin}_{h>0} MISE^*(h) \hat{h}^*$$

لكن عندما تستخدم تقديرات **bootstrap** فإن **MSE** و **MISE** يأخذ عرض الحزمة عادة بحجم $n^{-1/(2r+1)}$ وبالتالي فإن

$$= n^{-1/(2r+1)} \hat{h}^* \hat{h}_{boot}$$

عندما $r=2$ ^[11].

Regularization parameter

7- معلمة التنظيم

و تدعى بمعلمة الضبط **Tuning Parameter** او بمعلمة التنظيم **Regularization Parameter** هي التي تحكم بكمية التنظيم و يرمز لها بالرمز λ و الصيغة العامة لها بالشكل الآتي :-

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

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

عندما

و تعتمد بذلك معلمة التنظيم على قيمة الانحراف المعياري و عدد المتغيرات التوضيحية ^[15].

8- الجانب التجريبي:

عرض الجانب النظري و تطبيق الطرق التي طرقتنا اليها انفا و المقارنة بينها تم استعمال تجارب المحاكاة وتكرار التجربة و لتوضيح الجانب التجريبي قسم الى عدة مراحل و كما يلي :-

المرحلة الأولى:-

تحديد قيم افتراضية مختلفة والتي تعتمد عليها المراحل التالية و هي حجم العينات ($n=70,150$) و قيم مختلفة للانحراف المعياري ($sd=2.5,5$) بالإضافة الى ابعاد مختلفة للمتغيرات التوضيحية ($p=9,12$) و عرض حزمة افتراضي كقيمة اولية و هو ($h=0.1$) كما و تم احتساب المتغير المعتمد التموذج التالي :-

$$[3] a) Y_i = x_i + 2 \exp(-16 x_i^2) + e_i$$

المرحلة الثانية:-

تقدير المعلم المعلم اللازم و كما يلي :-

1- تقدير معلمة التمهيد (عرض الحزمة **Bandwidth parameter**) و قد استعملت طريقتين مختلفتين لتقدير المعلمة وهي (طريقة قاعدة الأبهام **RULE** ، طريقة التمهيدية **BOOT**).

2- تقدير معلمة التنظيم (معلمة الضبط) (**Regularzation parameter (Tunning Parameter)**). كما و تم رسم المتغير المعتمد Y_i مع دالة انحدارحرف اللبي التقديرية بأسعمال برنامج **Excel** لبعض الحالات المفترضة حيث لا مجال لعرض كل الحالات .



**التعدد الخططي في الأنحدار المتعدد اللامعلمي، الكشف
والمعالجة بأسعمال المحاكاة**

الجدول رقم (1) يوضح قيمة متوسط مربعات الخطأ في حالة كون عدد المتغيرات التوضيحية (p=9)

sample	standard deviation	Sd=2.5	Sd=5
	function method	Biw	Biw
n=70	RULE	0.013	0.4178
	BOOT	0.0128	0.4181
n=150	RULE	0.0463	0.3451
	BOOT	0.0463	0.3451

يتبيّن من الجدول رقم (1) ما يلي:-

- يتبيّن بأن طريقة **Bootstrap** بالنسبة لدالة **Biweight** تعطي أقل قيمة لمعيار الأختبار **Mean Square Error (MSE)** عندما تكون قيمة الانحراف المعياري $sd=2.5$ و حجم عينة $n=70$ و بالتالي فهي الطريقة الأفضل .
- بينما تكون طريقة **Rule Of Thumb** الطريقة الأفضل عندما تكون قيمة الانحراف المعياري $sd=5$ عند حجم عينة $n=70$.
- يلاحظ بأن قيم معيار الأختبار **MSE** تتعادل لطريقتي **Bootstrap** و **Rule Of Thumb** عند حجم عينة $n=150$ مما يعني الحصول على الاستقرارية لكلا الطريقتين من حيث الأفضلية .

الجدول رقم (2) يوضح قيمة متوسط مربعات الخطأ في حالة كون عدد المتغيرات التوضيحية (p=12)

sample	standard deviation	Sd=2.5	Sd=5
	Function Method	Biw	Biw
n=70	RULE	0.1946	0.5498
	BOOT	0.1947	0.5497
n=150	RULE	0.0586	0.1883
	BOOT	0.0586	0.1883

- يتضح من خلال نتائج المحاكاة و كما في الجدول رقم (2) بأن طريقة **Bootstrap** تعطي أقل قيمة لمعيار الأختبار **MSE** من طريقة **Rule of Thumb** وبالتالي فهي الطريقة الأفضل بالنسبة لدالة **Gaussian** عندما تكون قيمة الانحراف المعياري $sd=2.5$ و حجم عينة $n=70$ و بالتالي فهي الطريقة الأفضل .
- بينما تكون طريقة **Rule Of Thumb** الطريقة الأفضل عندما تكون قيمة الانحراف المعياري $sd=5$ عند حجم عينة $n=70$.
- يلاحظ بأن قيم معيار الأختبار **MSE** تتعادل لطريقتي **Bootstrap** و **Rule Of Thumb** عند حجم عينة $n=150$ مما يعني الحصول على الاستقرارية لكلا الطريقتين من حيث الأفضلية .



الانحدار المتعدد الالمعجمي، الكشف والمعالجة بأسعمال المحاكاة

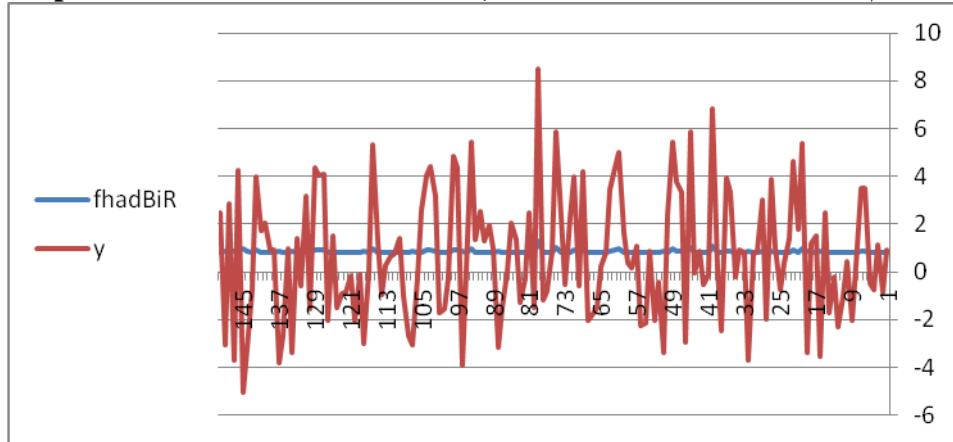
9- الاستنتاجات :-

- نستنتج بأن الأفضلية لطريقة Bootstrap و بذلك فقد اثبتت اهميتها عند استعمال قيمة الانحراف المعياري $sd=2.5$.
- نستنتج بأن طريقة Rule Of Thumb هي الأفضل عندما تكون قيمة الانحراف المعياري $sd=5$.
- نستنتج بأن قيمة الانحراف المعياري $sd=2.5$ هو من يعطي اقل قيمة لمعيار الاختبار MSE في جميع الحالات المفترضة و بالتالي فهو الأنسب اختياراً.
- نستنتج الحصول على الاستقرارية عند حجم العينة $n=150$ وفي جميع الحالات المفترضة بينما.

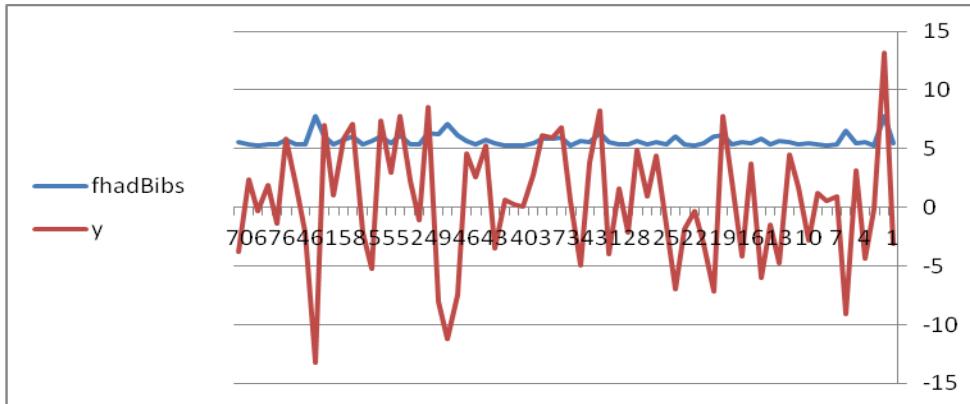
10- التوصيات :-

- نوصي بأسعمال طريقة Bootstrap لتقدير عرض الحزمة h عند استعمال دالة Biweight وذلك لأنها أثبتت افضليتها من حيث استقرارها و من حيث اعطائها اقل قيمة لمعيار الاختبار Mean Square Error (MSE).
- نوصي بأختيار قيمة انحراف معياري اقل و ليكن $sd=0.5,1$.
- نوصي بأختيار حجم عينة كبير للحصول على الأتزان من حيث الأفضلية .

الشكل رقم (1) يوضح المتغير المعتمد Y مع دالة انحدار الحرف الليبي التقديرية عند استعمال طريقة RULE لحجم عينة $n=150$ و قيمة انحراف معياري $sd=2.5$ و عدد متغيرات توضيحية $p=9$.



الشكل رقم (2) يوضح المتغير المعتمد Y مع دالة انحدار الحرف الليبي التقديرية عند استعمال طريقة BOOT لحجم عينة $n=70$ و قيمة انحراف معياري $sd=5$ و عدد متغيرات توضيحية $p=12$.





المصادر

المصادر العربية:-

- 1- البياتي ، صابرین حسین کاظم " استعمال دالة الأنحدار الحرف النبی فی معالجة مشکلة التعدد الخطی مع طبیق عملی " رساله ماجستیر قید المناقشة .
- 2- السعدون ، فوزیة غالب عمر و الشعبي ، ساهره حسین زین " تحلیل الأنحدار " لعام 2014 م الطبعة 932 ، طبع فی مديریة دار الكتب للطباعة و النشر دامعة البصرة .
- 3- حمود ، مناف یوسف " مقر نادرة - Watson اسلوب تمہیدی لتقدير دالة الأنحدار " مجلة العلوم الاقتصادیة العدد (65) 2001المجلد (18) ص [291-283].
- 4- الشاروط ، محمد حبيب " مقارنة بعض طرائق تمہید الأنحدار اللامعليمي بأسخدام المحاكاة " بحث مقدم الى كلية الادارة و الاقتصاد / جامعة القادسية .
- 5- کاظم ، اموري هادي و الدليمي ، محمد مناجد " مقدمة فی تحلیل الأنحدار الخطی" 1988 الطبعة 1001 ، طبع فی مديریة دار الكتب للطباعة و النشر /جامعة الموصـل .

المصادر الأجنبية:-

- 6- Rudelson , Mark (2015) "Spectral Norm of Random Kernal Matrices WithApplications To Privacy"
- 7- Rs – Ec2 – Lecture12 .
- 8- Olawuwo , Simeon ;Ogunleye , Timothy A. ; Ojo, Thompson O & Adejumo, Adebowale O.(2014)" Comparison of Classical Least Squares (CLS), Ridge and Principal Component Methods of Regression Analyses using Gynecological Data".
- 9- Hansen , Bruce .E.(2009) "Lecture Noteson Nonparametrics" University Of Wisconsin.
- 10- A. Delaigle And I. Gijbels (2004) " Bootstrap Bandwidth Selection In Kernel Density Estimation From A Contaminated Sample" .
- 11- Hall , Peter (1990) "Using The Bootstrap To Estimate Mean Square Erorr and Select Smoothing Parameter in Nonparametric Problems".
- 12- Berwin A.Turlach " Bandwidth Selection In Kernel Density Estimation : A Review" .
- 13- Yuchen Zhang , John Duchi , Martin Wainwright " Divide and Conquer Kernel Ridge Regression " *University of California* ,Year (2013) .
- 14- J. S. Marron (1990) " Bootstrap Bandwidth Selection " University of North Carolina
- 15- Ryota Tomioka "Introduction To The analysis of Learning algorithms : ridge regression and lasso " University of Tokyo .



Multi – Linear in Multiple Nonparametric Regression , Detection and Treatment Using Simulation

ABSTRACT:

It is the regression analysis is the foundation stone of knowledge of statistics , which mostly depends on the ordinary least square method , but as is well known that the way the above mentioned her several conditions to operate accurately and the results can be unreliable , add to that the lack of certain conditions make it impossible to complete the work and analysis method and among those conditions are the multi-co linearity problem , and we are in the process of detected that problem between the independent variables using farrar –glauber test , in addition to the requirement linearity data and the lack of the condition last has been resorting to the nonparametric regression and processor the problem using kernel ridge regression function and that depend on estimate band width (smoothing parameter) therefore has been resorting to two different ways to estimate the parameter and are Rule of thumb (RULE) and Bootstrap (BOOT) and comparison between those ways using the style of simulation .

Keyword: Ferarr – Glauber Test , Chi-square Statistic , bandwidth estimating h , RULE ,BOOT ,Kernel ridge regression KRR .