

تقدير المرحلتين الحصين وتقرير متعدد الحدود المحلي (kernel)

لأنموذج المعاملات المتغيرة زمنياً مع بيانات طولية متزنة¹

الباحث علي سيف الدين عبد الحافظ

أ. د. ظافر حسين رشيد
كلية الادارة والاقتصاد - جامعة بغداد
قسم الاحصاء

المستخلص

في هذا البحث تم استعراض تقنية لا معلمية لتقدير دوال المعاملات المتغيرة زمنياً للبيانات الطولية المتزنة والتي تتصف بكون المشاهدات يتم الحصول عليها من n من القطاعات المستقلة كل واحد منها يكرر قياسها خلال مجموعة نقاط زمن محددة m ، وعلى الرغم من أن القياسات هي مستقلة بين القطاعات المختلفة إلا أنها على الأغلب تكون مرتبطة داخل كل قطاع، والتقنية المستعملة هي تقنية متعدد الحدود الخطى المحلي LLPK ، ولتجاوز مشكلة تعدد الابعاد والحسابات الكثيفة، تم استعمال طريقة المرحلتين لتقدير دوال المعاملات بأستعمال التقنية السابقة، ولكون طريقة المرحلتين تعتمد بالتقدير على طريقة المرربعات الصغرى ols التقليدية، وهي حساسة لوجود الشوائب بالبيانات أو تلوث الخطأ، لذا تم اقتراح أستعمال اساليب حصينة مثل LAD و M لتحسين طريقة المرحلتين اتجاه الشوائب او تلوث الخطأ، وتمت صياغة تجارب محاكاة في هذا البحث والتحقق من أداء الطرائق التقليدية والحسينية لتقنية LLPK بأستعمال معيارين ولمختلف حجوم العينة ومستويات التباين.

المصطلحات الأساسية للبحث/

المعاملات المتغيرة زمنياً، تقدير المرحلتين، تقديرات M و LAD الحصينة، تمديد متعدد الحدود المحلي، البيانات الطولية.

بحث مستل من رسالة دكتوراه



مجلة العلوم

الاقتصادية والإدارية

المجلد 19

العدد 70

-297 الصفحات

324



1. المقدمة :

غالباً ما يتم الحصول على المشاهدات في الدراسات الطويلة من n من القطاعات المستقلة كل واحداً منها يكرر قياسها خلال مجموعة نقاط زمن محددة ، وغالباً ما يتركز اهتمام هذه الدراسات على تقييم آثار الزمن (t) وكذلك مجموعة المتغيرات المستقلة $\chi_r(t)$, $r = 1, 2, \dots, d$ على نتيجة المتغير المعتمد $y(t)$ ، نفرض أن t_j تمثل الزمن لقياسات القطاع i^{th} ، وأن y_{ij} و χ_{ij} تمثل مشاهدات القطاع i للمتغير المعتمد والمستقل عند الزمن j على التوالي، فأن مجموعة المشاهدات الطويلة تعطى كالتالي :-

$$\{(t_j, y_{ij}, \chi_{ij})\}$$

على الرغم من أن القياسات هي مستقلة بين القطاعات المختلفة إلا أنها على الأغلب تكون مرتبطة داخل كل قطاع.

البيانات الطويلة شائعة الاستعمال في الدراسات الطبية، الوبائية، الاقتصادية، المالية ، ... وغيرها ، والتحليل الأحصائي مع هكذا نوع من البيانات مهم بنمذجة منحنى المتوسط $y(t)$ والتاثيرات

للمتغيرات المستقلة في $y(t)$ ، وتطوير التقدير وأجراءات الاستدلال ، وتحت إطار النماذج المعلمية مثل النماذج الخطية ، وقد درست نظريات وطرق التقدير للمعاملات والاستدلالات بصورة موسعة ، ولكن المشكلة في النماذج الخطية أنها غير واقعية في الكثير من التطبيقات، عندها بدأ التفكير بتقنيات أخرى مثل التحليل اللامعملي.

إن النماذج اللامعلمية للبيانات الطويلة لا تقدم افتراضات بشأن تحديد الأنماذج ولكنها قد تتحقق في ما يسمى مشكلة البعدية (Curse of Dimensionality) مما يجعل الطرائق اللامعلمية القياسية عاجزة عملياً عندما تكون المتغيرات المستقلة ذات أبعاد عالية ، وتكون الصعوبة في حدود التفاعل (Interaction) بين الأبعاد المستعملة في الظاهرة، حيث لا يمكن تمثيلها بسهولة، وحل مشكلة البعدية ظهر نهج بديل يتمثل في تخفيض القيود المفروضة على النماذج المعلمية التقليدية واستكشاف الهيكل الخفي (Hidden Structure) ومنها نماذج المعاملات المتغيرة (Varying Coefficient Models)، وما يميزها فضلاً عن تمكناها من حل مشكلة تعدد الأبعاد هو إمكانية استعمالها لاستكشاف الملامح (الдинاميكية) في البيانات ذات الأبعاد العالية، وقد تم تطبيقها بنجاح في الانحدار اللامعملي متعدد الأبعاد، النماذج الخطية العامة، نماذج السلسل الزمنية غير الخطية، البيانات الطويلة، بيانات البقاء والبيانات الاقتصادية والمالية،... وغيرها.



وتعتبر نماذج المعاملات المتغيرة البديل الطبيعي للنماذج المضافة (Additive Models)، إذ إن النماذج المضافة تعتمد على حل مشكلة تعدد الأبعاد بتجاهل حدود التفاعل بين الفضاءات (المتغيرات) والتركيز على المتغيرات المعيبة عن التأثيرات الرئيسية (Main Effects) فقط واعتبارها دوال ممهدة، أما نماذج المعاملات المتغيرة فأنها ستعتمد على ايجاد نوع من أنواع التفاعل بين الفضاءات (المتغيرات)، إذ أنها تكون خطية في المتغيرات ولكن معاملات هذه المتغيرات يسمح لها بالتغيير تمهدياً وهو ما قد يسمى تعديلات التأثير (Effect Modifiers)، وأول من أستعمل المعاملات المتغيرة زمنياً كحل لمشكلة تعدد الأبعاد لأنموذج الالامعفي للبيانات الطولية وكذلك استكشاف الديناميكية لها هم (Hoover et al 1998)⁽⁵⁾ ، حيث اعتمدوا على أنموذج المعاملات المتغيرة زمنياً التالي :-

$$Y(t) = X'(t) \beta(t) + e(t) \quad \dots\dots\dots(1)$$

اذ ان $e(t)$ عملية عشوائية بمتوسط (0) ، ولجميع قيم t فإن $X(t)$ و $e(t)$ مستقلان، إن $X(t)$ الأنماذج المذكور آنفأً يبين أن الزمن (t) يغير المعاملات لـ $\beta(t)$ اذ ان $X(t) = (X_1(t), X_2(t), \dots, X_d(t))'$ هو متجة للدواال الممهدة خلال الزمن (t) ، واقتربوا أستعمال تقييدين لامعممية لتقدير $\beta(t)$ بما متعدد الحدود الخطى المحلي وشرائح التمهيد ، وأستعملوا خوارزمية (Backfitting) لأيجاد التقديرات، ولكن بأستعمال هذه الخوارزمية في البيانات الطولية ستظهر مشكلة من نوع اخر وهي كثافة العمليات الحسابية والجهد البرمجي ، للتغلب على هذه المشكلة يمكن اجراء تقدير المرحلتين المقترن من قبل (Fan & Zhang 2000)⁽³⁾ كبديل لأجل تقدير $\beta(t)$ في (1) ، أن تقدیرات دوال المعاملات $\beta(t)$ بأسلوب المرحلتين يتم الحصول عليه بأستعمال طريقة المربعات الصغرى ،وكما هو معلوم أن مقدرات المربعات الصغرى تمتلك بعض الخصائص الجيدة ، وخاصة عندما الخطأ العشوائي يتبع التوزيع الطبيعي ، ولكن المقدرات المعتمدة على المربعات الصغرى حساسة جداً الى الشوائب في البيانات أو عند تلوث (contamination) الخطأ، لذلك فإن طرائق التقدير الحصينة مطلوبة أكثر.



في هذا البحث سيتم الاعتماد على البيانات الطولية المتزنة (عندما تكون عدد القياسات للقطاعات متساوية) والمصاغة على وفق المعالم المختلفة زمنياً (TVC) لأيجاد تقديرات متعدد الحدود الخطى المحلى LLPK الحصين لدوال المعالم بطريقة المرحلتين، وبالاعتماد على أسلوب LAD و M الحصينين، ومقارنتها مع طرائق التقدير التقليدية عن طريق تجارب محاكاة بحسب تلوث مختلف وحجوم عينة مختلفة ومستويات تباين مختلفة، ولأغراض الملاعنة والتعميم، تم عرض كل الصيغ والمعادلات بدلاله d من المتغيرات التوضيحية، على الرغم من إستعمال دراسة المحاكاة لحالة ثاني المتغيرات (متغيرين فقط).

2. طريقة تقدير المرحلتين (Two-Step Estimation Method)^{(3) ، (4) ، (11)}

لنفترض $m, j = 1, 2, \dots, m$ ، هي نقاط زمن محددة، حيث تم جمع البيانات ، أذ ان m تمثل

عدد القياسات المكررة لكل قطاع، لأن هناك عدد من المشاهدات التي جمعت في الزمن j ، فمن الممكن لهذا الثابت t_j استعمال البيانات المجمعة هناك لمطابقة أنموذج (1) والحصول على المقدرات الخام (raw estimates)

$$b(t_j) = (b_1(t_j), \dots, b_d(t_j))'$$

$$\beta(t_j) = (\beta_1(t_j), \dots, \beta_d(t_j))'$$

هذه هي المرحلة الأولى، عادة المقدرات الخام هي غير ممهدة تحتاج الى تمهيد للحصول على المقدرات الممهدة لدوال المعاملات، لذلك في المرحلة الثانية لكل مرکبة معطاة $d, r = 1, 2, \dots, d$ نطبق تقنية

$$\{b_r(t_j), t_j, j = 1, 2, \dots, m\}$$

إن مرحلة تقديرات التمهيد (Smoothing estimates) هذه حاسمة لأنها تعطي مقدرات تمهيدية لدوال معاملات التمهيد الأساسية، وإضافة الى ذلك فان مرحلة التمهيد عادة ذات بعد واحد one-dimensional .



1.2 مرحلة التقديرات الخام (Raw Estimates Step)⁽¹⁰⁾

في هذه المرحلة سيتم الاعتماد على هيكلة خاصة لمجموعة البيانات الطولية حيث سنعيد هيكلة أنموذج كالاتي :

نفترض m, m, \dots, m هي نقاط زمن محددة لمجموعة البيانات الطولية لكل نقطة زمن

t_j ، لنفترض N_j هو مجموعة المراجع للقطاع الى جميع مشاهدات y_{ij} عند t_j .

نجمع كل χ_{ij} و y_{ij} التي تقابل المراجع للقطاعات في N_j ونشكل مصفوفة التصميم \tilde{X}_j ومتجه الاستجابة \tilde{Y}_j بالتتابع.

الجدير بالذكر ان البحث يعتمد على حالة البيانات المتزنة وبذلك فان N_j مجموعة المراجع للقطاع الى جميع مشاهدات y_{ij} عند t_j ستكون متساوية ولجميع القطاعات. عندئذ فان صيغة أنموذج (1) عندما البيانات تجمع عند الزمن t_j يتبع الأنموذج الخطى التالي :

$$\left. \begin{aligned} \tilde{Y}_i(t_j) &= \tilde{X}_i(t_j) \beta(t_j) + \tilde{e}_i(t_j) \\ &\quad , i=1,2,\dots,n \\ &\quad j=1,2,\dots,m \end{aligned} \right\} \dots\dots(2)$$

إذ إن :

$$\tilde{Y}_i(t_j) = [y_{11}, y_{12}, \dots, y_{1m}, y_{21}, \dots, y_{2m}, \dots, y_{n1}, \dots, y_{nm}]'$$



$$\tilde{X}_i(t_j) = \begin{bmatrix} X_{1,r} \\ X_{2,r} \\ \vdots \\ \vdots \\ X_{n,r} \end{bmatrix} = \begin{bmatrix} X_{1,1} & X_{1,2} & \cdots & \cdots & X_{1,d} \\ X_{2,1} & X_{2,2} & \cdots & \cdots & X_{2,d} \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ X_{n,1} & X_{n,2} & \cdots & \cdots & X_{n,d} \end{bmatrix}$$

$$X_{i,r} = \begin{bmatrix} X'_{i1,r} \\ X'_{i2,r} \\ \vdots \\ \vdots \\ X'_{im,r} \end{bmatrix}, \quad i=1,2,\dots,n, \quad r=1,2,\dots,d$$

(m*dm)

$$\beta(t_j) = [\beta_{1,1}, \beta_{1,2}, \dots, \beta_{1,m}, \dots, \beta_{d,1}, \dots, \beta_{d,2}, \dots, \beta_{d,m}]$$

$$\tilde{e}_i(t_j) = [e_{11}, e_{12}, \dots, e_{1m}, e_{21}, \dots, e_{2m}, \dots, e_{n1}, \dots, e_{nm}]'$$

وان

المتغيرات $\tilde{X}_i(t_j)$ مستقلة عن الأخطاء العشوائية $\tilde{e}_i(t_j)$ ، والأخطاء العشوائية $e_i(t_j)$ هي عبارة عن عمليات عشوائية مشتركة بمتوسط (0) ودالة تباين كالتالي :

$$1.1.2 \quad \sigma_{js} = \text{cov}\{\tilde{e}_i(j), \tilde{e}_i(s)\}$$

(6) **AR(1)**



(Feasible GLS Estimation With AR(1) Errors)

لتقدير معلم الأنماذج (2) تحت افتراض هيكل الارتباطات للأخطاء يتبع AR(1) كالتالي :

$$\tilde{e}_i(t_j) = \rho \tilde{e}_i(t_{j-1}) + u_{ij} \quad \dots \dots \dots \quad (3)$$

يمكننا تطبيق المربعات الصغرى العامة حيث مقدراتها ستكون كالتالي :

$$b_{GLS}(t_j) = \left(X_i'(t_j) \Omega^{-1} X_i(t_j) \right)^{-1} X_i'(t_j) \Omega^{-1} \tilde{Y}_i(t_j) \quad \dots \dots \dots \quad (4)$$

ان المشكلة في مقدرات GLS بأنها تفترض مصفوفة التباين المشترك Ω معلومة، بعبارة أخرى إن ρ معلوم وهذا نادراً ما هو معلوم من الناحية العملية .

ولتجنب افتراض GLS علينا ايجاد تقدير متسبق لـ $\hat{\Omega}$ اي $\hat{\rho}$ واستخدامه لايجاد تقدير لمعاملات الأنماذج (2). إن هذا المقدر يدعى مقدرات المربعات الصغرى العامة المقبولة (FGLS) والذي يمكن ايجاده حسب الخطوات التالية :

a. نجد اولاً مقدرات المربعات الصغرى الاعتيادية الى أنماذج (2) والذي سيكون كالتالي :

$$b_{OLS}(t_j) = \left(\tilde{X}_i'(t_j) \tilde{X}_i(t_j) \right)^{-1} \tilde{X}_i'(t_j) \tilde{Y}_i(t_j) \quad \dots \dots \dots \quad (5)$$

ثم نجد الاخطاء باستخدام مقدرات OLS إذ إن :

$$\tilde{e}_i(t_j) = \tilde{Y}_i(t_j) - \tilde{X}_i(t_j) b_{OLS}(t_j) \quad \dots \dots \dots \quad (6)$$

b. تحت افتراض الاخطاء هي عمليات عشوائية مشتركة فان مقدر ρ المشترك يمكن تقديره كالتالي :



$$\hat{\rho} = \frac{\sum_{i=1}^n \sum_{j=2}^m \tilde{e}_i(t_j) \tilde{e}_i(t_{j-1})}{\sum_{i=1}^n \sum_{j=1}^m \tilde{e}_i^2(t_j)} \quad \dots \dots \dots (7)$$

c. إجراء تحويل للبيانات باستخدام ((Prais – Winsten) transformation)

$$Y_i(t_j)^* = \begin{bmatrix} \sqrt{1 - \hat{\rho}^2} \tilde{y}_i(t_1) \\ \tilde{y}_i(t_2) - \hat{\rho} y_i(t_1) \\ \tilde{y}_i(t_3) - \hat{\rho} y_i(t_2) \\ \vdots \\ \tilde{y}_i(t_m) - \hat{\rho} \tilde{y}_i(t_{m-1}) \end{bmatrix}, i = 1, 2, \dots, m \quad \dots \dots \dots .8)$$

$$X_i(t_j)^* = \begin{bmatrix} \sqrt{1 - \hat{\rho}^2} \tilde{\chi}_i(t_1) \\ \tilde{\chi}_i(t_2) - \hat{\rho} \tilde{\chi}_i(t_1) \\ \tilde{\chi}_i(t_3) - \hat{\rho} \tilde{\chi}_i(t_2) \\ \vdots \\ \tilde{\chi}_i(t_m) - \hat{\rho} \tilde{\chi}_i(t_{m-1}) \end{bmatrix}, i = 1, 2, \dots, m \quad \dots \dots \dots .9)$$

d. وبتطبيق المربعات الصغرى الاعتيادية على البيانات المحولة فاننا نحصل على مقدرات FGLS كالتالي :

$$b_{FGLS}(t_j) = \left(X_i(t_j)^* X_i(t_j) \right)^{-1} X_i(t_j)^* Y_i(t_j) \quad \dots \dots \dots (10)$$



وان تقديرات كلاً من σ_u^2 و σ_e^2 سيكون كالتالي :

$$\hat{\sigma}^2 = \frac{e_i(t_j)e_i(t_j)}{nm} = \frac{\left(* Y_i(t_j) - X_i(t_j)b_{FGLS} \right)^* \left(* Y_i(t_j) - X_i(t_j)b_{FGLS} \right)}{nm} ..(1)$$

$$2.1.2 \quad \sigma_e^2 = \frac{\hat{\sigma}_u^2}{1 - \hat{\rho}^2} \quad(2)$$

(Robust Raw Estimate)

اقتراح أسلوب M الحصين اولاً من قبل (Huber)⁽⁷⁾، وتستند الفكرة ببساطة على تقليل بعض الدوال للأخطاء بدلاً عن مجموع المربعات لها، والمقدر الحصين يحدد بواسطة الاختيار لدالة وزن، وان اسلوب مقدرات M بحاجة الى بعض التوسيع لتطبيقها على البيانات الطولية المتزنة الموصوفة في أنموذج (2) والتي تحتوي على n من القطاعات و m من القياسات المكررة لكل قطاع.

إذ ان اهم ما يميز هذه البيانات هو ارتباطها ضمن القطاع، اي بمعنى ان الأخطاء مرتبطة، وهذا سينافي الافتراض لاسلوب مقدرات M وهو ان تكون الأخطاء غير مرتبطة، ولتلafi هذه المشكلة سيتم الاعتماد على البيانات المحولة في طريقة (Feasible GLS) .

لنفرض ان $X_{ij} = X_i(t_j)$ و $Y_{ij} = Y_i(t_j)$ و متوجه المعلم $\beta = \beta(t_j)$ ، ولتوسيع هذا الاسلوب، ان المربعات الصغرى الاعتيادية للبيانات المحولة تخضع مجموع مربعات الخطأ الى اقل ما يمكن كالتالي :

$$\min \sum_{i=1}^n \sum_{j=1}^m e_{ij}^2 = \min \sum_{i=1}^n \sum_{j=1}^m \left(* Y_{ij} - X_{ij} \beta \right)^2 \quad(3)$$

إذ إن :

$* Y_{ij}$: المشاهدة j للقطاع i للمتغير المعتمد.

$* X_{ij}$: مصفوفة التصميم .

وإن :

$$* X_{ijk} = \begin{bmatrix} * X_{ij1}, \dots, * X_{ijd} \end{bmatrix}, k = 1, 2, \dots, d$$



β : متوجه معلم ذو بعد dm .

*²

ان تقديرات M المطورة من قبل (Huber) تعتمد على فكرة ابدال مجموع مربعات الأخطاء e_{ij} بدالة اخرى للأخطاء الهدف منها تقليل المقدار الآتي :

$$\sum_{i=1}^n \sum_{j=1}^m P \left(\frac{Y_{ij}^* - X_{ij}^* \beta}{\sigma_e} \right)^2 \quad \dots\dots\dots (14)$$

حيث P هي دالة محدبة

متتماثلة (symmetric convex function) ولتقليل المقدار اعلاه تؤخذ المشتقة بالنسبة الى متوجه المعلم وجعلها مساوية الى الصفر كالتالي :

$$\sum_{i=1}^n \sum_{j=1}^m X_{ij}^* \Psi \left(\frac{Y_{ij}^* - X_{ij}^* \beta}{\sigma_e} \right) = 0 \quad \dots\dots\dots (15)$$

إذ إن :

Ψ : المشتقة الجزئية الى متوجه المعلم β للدالة P وبهذا يكون هناك (dm) من المعادلات غير الخطية والتي يمكن حلها بعده طرائق منها طريقة المربعات الصغرى الموزونة التكرارية (IWLS) او طريقة نيوتن رافسون (N-R Method) او طريقة (Huber) وغيرها، ولكي تكون لمقدرات M خاصية (Scale) يتم إعادة كتابة الصيغة (14) كما يأتي :

$$\sum_{i=1}^n \sum_{j=1}^m P \left(\frac{\left(Y_{ij}^* - X_{ij}^* \beta \right)^2}{\sigma_e^2} \right) \quad \dots\dots\dots (16)$$

والصيغة (15) ستكون كما يلي :



$$\sum_{i=1}^n \sum_{j=1}^m X_{ij}^* \Psi \left(\frac{\left(Y_{ij}^* - X_{ij}^* \beta \right)}{\sigma_e^2} \right) = 0 \quad \dots\dots\dots (17)$$

ولإيجاد مقدرات M بالاعتماد على طريقة IWLS يتطلب حساب دالة الوزن وفيها يتم اعادة كتابة الصيغة (17) كما يلي :

$$\sum_{i=1}^n \sum_{j=1}^m W_{ij} X_{ij}^* \Psi \left(\frac{\left(Y_{ij}^* - X_{ij}^* \beta \right)}{\sigma_e^2} \right) = 0 \quad \dots\dots\dots (18)$$

وبحل المعادلة اعلاه نحصل على تقديرات أسلوب M الحصين b_M باستعمال IWLS .
إذ إن :

$$b_M = \left(X^* W^* X \right)^{-1} X^* W^* Y \quad \dots\dots\dots (19)$$

إذ إن :
 (dm) : متجه ذو بعد b_M
 W : مصفوفة اوزان قطرية بعد $(nm * nm)$ تحسب عناصرها كما يأتي :



$$W_{ij} = \frac{\Psi \left(\frac{\left(\begin{array}{c} * \\ Y_{ij} - X_{ij} \beta \end{array} \right)}{\hat{\sigma}_e} \right)}{\Psi \left(\frac{\left(\begin{array}{c} * \\ Y_{ij} - X_{ij} \beta \end{array} \right)}{\hat{\sigma}_e} \right)} \quad \dots \dots \dots \quad (20)$$

إذ إن :

$$\hat{\sigma}_e = 1.483 \left[Median \left| e_{ij}^* - Median(e_{ij}^*) \right| \right]$$

وتم استعمال دالة P ومشتقها Ψ التالية :
 دالة (Andrews)

$$P\left(e_{ij}^*\right) = \begin{cases} A^2 \left[1 - \cos\left(e_{ij}^* / A\right) \right] & \left| e_{ij}^* \right| \leq A\pi \\ 2A^2 & \left| e_{ij}^* \right| > A\pi \end{cases}$$

$$\Psi\left(e_{ij}^*\right) = \begin{cases} A \sin\left(e_{ij}^* / A\right) & \left| e_{ij}^* \right| \leq A\pi \\ 0 & \left| e_{ij}^* \right| > A\pi \end{cases}$$

$$A = 1.339$$

أن أسلوب M الحصين هو ليس أفضل أسلوب حصانة ، وهذا يجعل مقدراتها ليست بالضرورة هي الأفضل، لذلك نلجم إلى أساليب حصينة أخرى اتجاه الشواد و من بين هذه الأساليب هو الانحرافات المطلقة الصغرى ((Least Absolute Deviations (LAD) المقرحةة من قبل (Schlossmacher)⁽⁹⁾، حيث سيتم توسيع هذا الأسلوب لتطبيقه في البيانات الطولية المتزنة المصاغة في نموذج (2) وبالاعتماد على البيانات المحولة في طريقة FGLS لتفادي مشكلة ارتباط الأخطاء كما مر سبقاً في أسلوب M . وللتوضيح فكرة هذا الأسلوب لنفترض أن القيم المطلقة للأخطاء يمكن وصفها كالتالي :

$$L = \sum_{i=1}^n \sum_{j=1}^m \left| e_{ij}^* \right| \quad \dots \dots \dots \text{1})$$

اُذ ان :

$$e_{ii} = Y_{ii} - X_{ii} \beta$$

* * كما تم تعریفها سابقاً. β , X , Y

ولايجاد مقدرات LAD بالاعتماد على دالة وزن وطريقة IWLs وبتقليل الصيغة التالية :

$$L = \sum_{i=1}^n \sum_{j=1}^m W_{ij} e^{ij} \quad \dots \dots \dots \text{Eq(2)}$$

فان تقدیرات LAD ستکون کالاتی :

$$b_{LAD} = \left(\begin{array}{cc} * & * \\ X'W X & \end{array} \right)^{-1} X'W Y \quad \dots \dots \quad (3)$$

أذ ان :

(dm) متجه ذو بعد : b_{LAD}

W : مصفوفة اوزان قطرية ببعد $(dm * dm)$ تحسب عناصرها كالتالي :

$$W_{ij} = \frac{1}{|e_{ij}|} \quad \dots\dots\text{Eq4)$$



2.2 مرحلة تحسين او تمهيد المقدرات الخام ⁽³⁾

(Refining Or Smoothing The Raw Estimates)

الطريق الطبيعي لتحسين المقدرات الخام هي تمهيدها من خلال الزمن، وببساطة نحن نمهد البيانات الكاذبة التالية $\{b_r(t_j), t_j\}_{r=1,2,\dots,d}, j=1,2,\dots,m$ للحصول على تمهيد دوال المعاملات $\beta_r(t)$ عن طريق احدى تقنيات التمهيد المعروفة، وقبل البدء بهذه المرحلة فان مركبات دوال المعالم المقدرة في المرحلة الاولى نحصل عليها كالتالي :

وـ $r=1,2,\dots,d$ نفرض أن :

$b_r(t_j)$ هي المركبة رقم r لتقديرات المرحلة الاولى $b(t)$ عندـ

$$b_r(t) = L'_r \begin{pmatrix} * & * \\ X & X \end{pmatrix}^{-1} \begin{pmatrix} * & * \\ X & Y \end{pmatrix} \quad \dots\dots\dots \text{Eq5}$$

إذ إن :

L_r : يعرف كمتجه وحدة ذو بعد (dm) المدخل رقم r هو (1) والباقي (0) .
ومن المعلوم ان

$$E[b_r(t)] = \beta_r(t) \quad \dots\dots\dots \text{Eq6}$$

وكذلك

$$\text{var-cov}[b_r(t)] = \sigma_e^2 L'_r \begin{pmatrix} * & * \\ X & X \end{pmatrix}^{-1} L_r \quad \dots\dots\dots \text{Eq7}$$

وبذلك سيصبح التمهيد عند كل مركبة (r) ، حيث سنستعمل تقنية تمهيد متعدد الحدود الخطى المحلى $LLPK$ ، ولكن للبيانات التالية :

$$(b_r(t_j), t_j), j=1,2,\dots,m$$



إذ إن :

 t_j : هي نقاط زمن التصميم.

($b_r(t_j)$: هي الاستجابة عند نقاط زمن التصميم، مع التأكيد بانها اي تقدير مستخرج من المرحلة الاولى).

ان أنموذج الانحدار الامامي البسيط للبيانات السابقة سيكون كالتالي :

$$b_r(t_j) = f(t_j) + \varepsilon_j \quad , \quad j = 1, 2, \dots, m \quad \dots\dots\dots \quad (28)$$

ونحن نريد تقدير الدالة الممهدة ($f(t_j)$).

إذ إن :

 ε_j : هي اخطاء القياسات التي لا يمكن شرحها بواسطة دالة الانحدار ($f(t_j)$).رياضياً ($f(t)$ هي التوقع الشرطي لـ $b_r(t_j) | t_j = t$ او

$$f(t) = E(b_r(t_j) | t_j = t)$$

1.2.2 ممهد Kernel متعدد الحدود الخطي الداخلي⁽²⁾

(Local Linear Polynomial Kernel Smoother (LLPK))

لابجاد ممهد (Kernel) متعدد الحدود الخطي المحلي لأنموذج (28) نفرض t_0 هي نقطة زمن ثابتة محددة ونريد تقدير ($f(t_j)$ ، ونفرض ان ($f(t)$ تمتلك ($P+1$) من المشتقات المستمرة لبعض القيم الصحيحة ($P > 0$) ، وهنا ($P=1$) وهي درجة متعدد الحدود الداخلي، وباستعمال متسلسلة تايلر، التقرير الخطي المحلي سيكون كالتالي :

$$f(t) \approx f(t_0) + (t - t_0) f'(t_0)$$

وان

$$\tilde{\beta}_V = \frac{f^{(V)}(t_0)}{V!} \quad , \quad V = 0, 1$$



نفرض ان $V = 0,1$ يقل صيغة المربعات الصغرى الموزونة WLS التالية :

$$\sum_{j=1}^m \left\{ b_r(t_j) - [\tilde{\beta}_0 + (t_j - t_0) \tilde{\beta}_1] \right\}^2 K_h(t_j - t_0) \quad \dots \dots \dots \text{29}$$

إذ إن :
 $K_h = \frac{K(\cdot/h)}{h}$
. ($h > 0$)

: تسمى معلمة التمهيد او عرض الحزمة.

ان عرض الحزمة h يستعمل أساساً لتحديد أقرب تجاور محلي إذ إن :

$$I_h(t_0) = [t_0 - h, t_0 + h] \dots \dots \dots \text{30}$$

و دالة (Kernel) تحديد كيف المشاهدات داخل $I_n(t_0)$ تشارك في المطابقة عند (t_0) ، واحدى اشهر دوال (Kernel) شيوعاً هي دالة الكثافة الاحتمالية الطبيعية المتماثلة الآتية:

$$K\left(\frac{t_i - t_0}{h}\right) = \exp\left\{-\frac{\left(\frac{t_i - t_0}{h}\right)^2}{2}\right\} \quad \sqrt{2\pi} \quad \dots \dots \dots \text{31}$$

وان

$$\hat{f}_h^{(V)}(t_0) = V! \hat{\beta}_V \quad , V = 0,1 \quad \dots \dots \dots \text{32}$$

و للتعبير عن $\hat{f}_h^{(V)}(t_0)$ من المفيد وضعها بصيغة المصفوفات كالتالي :

$$b_r = [b_{r,1}, b_{r,2}, \dots, b_{r,m}]$$

متوجه ذو بعد (m) .

$$X = \begin{bmatrix} 1 & (t_1 - t_0) \\ 1 & (t_2 - t_0) \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & (t_m - t_0) \end{bmatrix} \quad 33$$

صفوفة بعد $(m*2)$

$$\tilde{\beta} = [\tilde{\beta}_0, \tilde{\beta}_1]^\top \quad . \quad (2)$$

$$W = \text{diag}(K_h(t_1 - t_0), \dots, K_h(t_m - t_0))$$

. (m*m) مصفوفة أوزان قطرية بعد

ولايجاد مطابقة LLPK عند (t_0) وباستخدام WLS فان

$$(b_r - X \tilde{\beta})' W (b_r - X \tilde{\beta})$$

وإن قيمة المطابقة هي

$$\hat{f}_h^{(V)}(t_0) = V! \ e'_{V+1} \ S_m^{-1} \ T_m \ b_r \quad , \ V=0,1$$

e_{V+1} : يعرف كمتوجه وحدة ببعد $(m * m)$ ولد $(2 * 1)$ من المدخلات (1) والباقيه (0) .
وان

$$S_m = X'W X$$

$$T_m = X'W$$

و بذلك يصبح

$$\hat{f}_h(t_0) = e'_2 \ S_m^{-1} \ T_m \ b_r \quad \dots\dots\dots(34)$$



عندما $b_r^* = \hat{f}_h(t_j)$ هو قيمة المطابقة $f(t_j)$ بواسطة الصيغة (34) نحصل على

$$b_r^* = \hat{f}_h(t_j) = a'(t_j)b_r \quad \dots\dots\dots \text{35}$$

إذ إن :

$a(t_j)$ هي $e_2' S_m^{-1} T_m$ بعد ابدال (t_0) بـ (t_j) .

اففترض ان

$$b_{r,h}^* = \begin{bmatrix} * & * & * \\ b_{r,1}, b_{r,2}, \dots, b_{r,m} \end{bmatrix}'$$

ويعرف بأنه قيم المطابقة عند جميع نقاط الزمن المحددة عند

$$b_{r,h}^* = A_h b_r \quad \dots\dots\dots \text{36}$$

إذ إن :

A_h هي مصفوفة قطرية تعرف كالتالي :

$$A_h = \text{diag}(a(t_1), a(t_2), \dots, a(t_m))$$

2.2.2 المهد الخطى وأختيار معلمة التمهيد⁽¹⁾

(Linear Smoother and Smoothing Parameter Selection)

المهدات الخطية تعبر عن المطابقة لمتجه الاستجابة b_r^* عند نقاط الزمن المحددة كمطابقات خطية (Linear Combinations) إلى متجه الاستجابة b_r ، وبشكل أكثر تحديداً المهد

يسمى مهد خطى إذا أستطعنا أن نجعل المطابقة لمتجه الاستجابة b_r ان يكون مرتبطة بمتجه الاستجابة b_r^* عن طريق الصيغة البسيطة التالية :

$$b_r^* = A_P b_r \quad \dots\dots\dots \text{37}$$



إذ إن :

$$\overset{*}{b}_r = \left[\overset{*}{b}_{r,1}, \overset{*}{b}_{r,2}, \dots, \overset{*}{b}_{r,m} \right]'$$

مع

$$\overset{*}{b}_{r,j} = \hat{f}_P(t_j)$$

وإن :

A_P : هي مصفوفة التمهيد بدرجة ($m*m$)، وتحدد بواسطة الممهد مع معلمة تمهيد P .

إن مصفوفة التمهيد A_P غالباً تعتمد على نقاط زمن التصميم ولكن يجب أن تكون غير معتمدة على

متجه الاستجابة b_r ، وهذا يعني ان :

$$E\left(\overset{*}{b}_r | t_1, t_2, \dots, t_m\right) = A_P E(b_r | t_1, t_2, \dots, t_m) \quad \dots\dots \beta 8)$$

$$\text{cov}\left(\overset{*}{b}_r | t_1, t_2, \dots, t_m\right) = A_P \text{cov}(b_r | t_1, t_2, \dots, t_m) A'_P \quad \dots\dots \beta 9)$$

وباستعمال الممهدات الخطية تم تطوير العديد من طرائق اختيار معلمة التمهيد وبشكل موحدة الى الممهدات الخطية ($\hat{f}_P(t)$ المعرفة في (37)) الاختيار الجيد يحول عادةً لتحديد معلمة تمهيد جيدة (P).

إن أحد أفضل طرائق اختيار معلمة التمهيد وأكثرها انتشاراً هو (GCV – Generalized Cross Validation) ، ولا اختيار معلمة التمهيد (P) للممهد الخطى ($\hat{f}_P(t)$ في (37)) وللنموذج الامثل في الصيغة (28) ، عن طريق تصغير المعيار الآتي :



$$GCV(P) = \frac{m^{-1} \sum_{j=1}^m \left[b_{r,j} - \overset{*}{b}_{r,j} \right]^2}{\left\{ 1 - \frac{t_r(A_P)}{m} \right\}^2} = \frac{m^{-1} SSE_P}{\left(1 - \frac{df}{m} \right)^2} \quad 40)$$

ويتم اختيار معلمة التمهيد (P) التي تقابل اقل GCV.

3.2.2 مقترن التقديرات الممهدة الحصينة (8)

(Robust Smoothing Estimates)

ان طريقة تقدير الأنماذج الامعلمي في (28) وهي طريقة متعدد الحدود الخطى المحلى حساسة إتجاه وجود قيم شاذة وجعلها أكثر صرامة بوجود الشواذ يمكن اجراء الاساليب الحصينة في القسم (2.1.2)، إذ إن الاخطاء لأنماذج الامعلمي في (28) ستكون كالتالي :

$$e_j = b_r(t_j) - \overset{*}{b}_{r,j} \quad , \quad j = 1, 2, \dots, m$$

لذلك سيكون من الواجب تحصين معيار GCV(P) كالتالي :

$$GCV_{Rob}(P) = \frac{m^{-1} \sum W_j \left(b_{r,j} - \overset{*}{b}_{r,j} \right)^2}{\left\{ 1 - \frac{t_r(A_P)}{m} \right\}^2} \quad 41)$$

إذ إن :

W_j : هي دالة وزن تحتوي على (m) من العناصر ويمكن حسابها دون الحاجة الى التوسيع لاسلوب M او LAD في القسم (2.1.2) وفيما يلي وصف لدالة الوزان.
في اسلوب M الحصين فان دالة الوزن تكون كالتالي :



$$W_j = \frac{\Psi\left(\frac{b_{r,j} - b_{r,j}^*}{\hat{\sigma}}\right)}{\left(\frac{b_{r,j} - b_{r,j}^*}{\hat{\sigma}}\right)} = \frac{\Psi(e_j)}{e_j} \quad 42)$$

وبالاعتماد على دالة Andrews يمكننا ايجاد دالة الوزن W_j

وفي اسلوب LAD فان دالة الوزن W_j تكون كالتالي :

$$W_j = \frac{1}{|e_j|} = \frac{1}{\left|b_{r,j} - b_{r,j}^*\right|} \quad 43)$$

3. المحاكاة Simulation

تم تنفيذ تجارب المحاكاة باستعمال ($n=10$) ويمثل عدد القطاعات مع ($m=15, m=10, m=5$) وتمثل القياسات المتكررة لكل قطاع. وبذلك سيكون لدينا ثلاثة حجوم للعينات ($nm=150$) وأخيراً ($nm=100$) ، وللأنموذج التالي:

$$Y_{i,j} = X_{1,i}(t_j) \beta_1(t_j) + X_{2,i}(t_j) \beta_2(t_j) + e_i(t_j) \quad , i=1,2,\dots,n ; j=1,2,\dots,m$$

إذ إن :

$\beta_r(t_j)$: هي دوال معاملات ممهدة.



لمتغيران التوضيحيان $X_{2,i}$ و (t_j) يتبعان التوزيع الطبيعي بمتوسط μ وتباین σ^2 ويتم توليدهما باستعمال طريقة (Box – Muller) وبصورة مستقلة لكل واحداً منها، أما الأخطاء العشوائية فيتم توليدها كالتالي:

1. متوجه الأخطاء $e_i(t_j)$ يتبع التوزيع الطبيعي بمتوسط (0) وتباین σ^2 يتم عن طريق استعمال طريقة (Box – Muller)، وقد تم تناول ثلاثة مستويات للبيان:

* تباین عالٍ (High Noise)

$$\sigma = \left(\frac{1}{2}\right) * Function\ Range$$

* تباین متوسط (Medium Noise)

$$\sigma = \left(\frac{1}{4}\right) * Function\ Range$$

* تباین واطئ (Low Noise)

$$\sigma = \left(\frac{1}{8}\right) * Function\ Range$$

إذ إن :

σ : هو الانحراف المعياري للخطأ e .

2. أما التوزيع الآخر للخطأ العشوائي $e_i(t_j)$ فهو التوزيع الملوث ويستعمل في حالة تلوث البيانات بقيم شاذة وبنسبة 10% و 20% إذ تم توليد بيانات تتبع توزيع طبيعي بمتوسط (0) وتباین $(=36\sigma^2)$.

أما دوال المعاملات فهي كالتالي :

$$\beta_1(t) = \sin(4\pi t)$$

$$\beta_2(t) = \cos(0.5\pi t)$$

أما المتغير المعتمد فيتم توليداً مباشراً من خلال استعمال الأنماذج في دراسة المحاكاة.



ولتقييم إداء طرائق التقدير لمرحلة التقدير الخام ومرحلة التقدير الخام الحصينة وكذلك مرحلة التمهيد ومرحلة التمهيد الحصينة تم استعمال المعايير التالية:

1. متوسط الانحراف المطلقة للأخطاء (Mean Absolute Deviation Error):

$$MADE = (dm)^{-1} \sum_{j=1}^m \sum_{r=1}^2 \frac{|\beta_r(t_j) - \hat{\beta}_r(t_j)|}{range(\beta_r)}$$

2. متوسط مربعات الخطأ الموزون (Weighted Average Squared Error)

$$WASE = (dm)^{-1} \sum_{j=1}^m \sum_{r=1}^2 \frac{\{\beta_r(t_j) - \hat{\beta}_r(t_j)\}^2}{range^2(\beta_r)}$$

إذ إن :

$\cdot \beta_r(t_j)$ هو المدى إلى دالة $range(\beta_r)$

وتم تكرار جميع تجارب المحاكاة (Replicates = 200) مرة لكل تجربة وتم وضع جميع النتائج في الجداول من رقم (1) إلى (5).

جدول (1) معايير تقدير Two Step لحالة عدم استعمال أساليب الحصانة في المرحلة الاولى والثانية، ولجميع حجوم العينة ولجميع مستويات التباين

ϵ	method	n	m	WASE			MADE		
				$\sigma = \frac{1}{2}$	$\sigma = \frac{1}{4}$	$\sigma = \frac{1}{8}$	$\sigma = \frac{1}{2}$	$\sigma = \frac{1}{4}$	$\sigma = \frac{1}{8}$
10 %	LLPK	10	5	1612.4	1203.59	2833.78	35.37	30.04	35.02
		10	10	269.28	193.95	277.09	14.35	12.72	13.02
		10	15	77.34	50.76	44.02	13.73	11.30	10.35
20 %	LLPK	10	5	994.58	1165.55	1265.65	23.45	26.10	28.36
		10	10	212.81	168.28	195.33	13.34	10.54	12.04
		10	15	65.48	47.08	46.83	12.59	10.68	10.48



جدول (2) معايير تقدير Two Step لحالة استعمال أساليب الحصانة LAD و M في المرحلة الاولى فقط ، ولجميع حجم العينة ولجميع مستويات التباين

ϵ	method	n	m	Rob	WASE			MADE		
					$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$	$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$
10 %	LLPK	10	5	LAD	1609.46	1162.14	1472.46	34.82	28.79	27.50
				M	1495.20	1769.44	2100.70	34.49	32.91	32.78
		10	10	LAD	133.77	186.61	219.76	8.86	12.19	12.84
				M	169.76	226.50	208.90	11.74	12.90	11.77
		10	15	LAD	66.23	45.43	41.17	8.28	6.55	9.34
				M	63.41	49.54	40.17	6.75	7.83	8.43
20 %	LLPK	10	5	LAD	931.50	1174.78	1037.48	20.93	26.49	27.55
				M	2887.55	1660.75	1341.42	46.92	35.51	29.92
		10	10	LAD	208.46	105.07	145.33	12.34	9.02	10.57
				M	354.71	211.79	453.88	15.31	12.31	14.72
		10	15	LAD	47.23	37.52	39.89	6.19	5.74	7.91
				M	48.98	43.21	45.72	6.52	6.18	10.39

جدول (3) معايير تقدير Two Step لحالة استعمال أساليب الحصانة LAD و M في المرحلة الثانية فقط، ولجميع حجم العينة ولجميع مستويات التباين

ϵ	method	n	m	Rob	WASE			MADE		
					$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$	$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$
10 %	LLPK	10	5	LAD	421.74	1248.64	1842.85	13.95	30.80	32.14
				M	2285.43	1010.16	2839.37	39.34	27.98	38.94
		10	10	LAD	165.17	158.66	179.74	11.61	11.23	12.54
				M	206.04	217.72	72.06	13.02	13.17	7.36
		10	15	LAD	175.89	28.74	39.14	13.83	8.21	9.40
				M	42.27	220.07	83.48	10.44	13.20	11.51
20 %	LLPK	10	5	LAD	720.15	1227.45	1158.75	22.67	29.61	24.82
				M	816.09	1338.69	1358.42	23.03	31.87	30.16
		10	10	LAD	47.35	214.74	194.81	9.59	13.03	12.00
				M	179.20	127.70	187.64	11.68	9.64	11.80
		10	15	LAD	51.30	36.47	142.22	11.70	9.65	12.48
				M	50.93	32.13	56.98	10.36	8.49	11.58



جدول (4) معايير تقدير Two Step لحالة استعمال أسلوب LAD في المرحلة الاولى، واستعمال اسلوب M في المرحلة الثانية، ولجميع حجوم العينة ولجميع مستويات التباين

ϵ	method	n	m	Rob	WASE			MADE		
					$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$	$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$
10 %	LLPK	10	5	LAD	1278.31	1111.17	1704.12	35.09	27.80	33.92
				M	1855.61	1177.40	1834.85	38.71	28.31	33.50
		10	10	LAD	191.68	103.24	121.51	11.93	11.90	8.74
				M	72.20	97.82	178.08	6.78	8.03	11.47
		10	15	LAD	62.95	45.56	40.22	7.13	7.27	7.52
				M	72.24	47.44	39.85	7.07	7.38	6.81
20 %	LLPK	10	5	LAD	862.38	2875.13	1150.40	20.06	37.66	26.73
				M	927	2019.07	960.98	22.62	35.90	25.71
		10	10	LAD	178.91	166.86	242.98	11.34	10.39	13.28
				M	184.31	141.46	260.54	11.19	10.08	13.91
		10	15	LAD	62.53	43.92	44.85	7.34	7.68	8.45
				M	64.08	38.91	40.71	7.96	5.17	6.09

جدول (5) معايير تقدير Two Step لحالة استعمال أسلوب M في المرحلة الاولى، واستعمال اسلوب LAD في المرحلة الثانية ، ولجميع حجوم العينة ولجميع مستويات التباين

ϵ	method	n	m	Rob	WASE			MADE		
					$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$	$\sigma = 1/2$	$\sigma = 1/4$	$\sigma = 1/8$
10 %	LLPK	10	5	LAD	1053.92	585.94	1007.65	23.93	21.22	25.72
				M	1606.01	1324.61	2795.92	29.04	32.29	34.01
		10	10	LAD	186.16	111.64	328.08	11.94	9.57	15.95
				M	268.55	161.71	170.57	14.11	11.31	10.70
		10	15	LAD	67.55	44.29	32.03	10.93	9.33	8.24
				M	59.77	48.32	23.02	9.39	10.05	7.86
20 %	LLPK	10	5	LAD	865.17	1159.86	1177.07	22.74	25.93	24.48
				M	2200.42	1167.20	3537.22	38.69	27.12	44.86
		10	10	LAD	210.69	108.68	150.45	12.43	9.69	11.15
				M	208.44	120.33	40.50	12.12	10.38	6.91
		10	15	LAD	60.61	46.91	39.98	9.46	7.16	6.61
				M	58.16	46.54	42.91	8.93	7.05	7.49



4. تحليل النتائج

لحالة عدم استعمال أسلوب الحصانة في المرحلة الاولى والثانية، ومن نتائج جدول (1) ، قيم معياري (MADE , WASE) سجلاً انخفاضاً ترافق مع زيادة حجم العينة (الزمن) ولكن حالتي التلوث عدا حالة واحدة عند تلوث 20% وحجم عينة ($n=10, m=15$) ومستوى تباين ($\alpha=1/4$) .

وللحالة استعمال أساليب الحصانة LAD و M في المرحلة الاولى فقط، ومن نتائج جدول (2) ، قيم معياري (MADE , WASE) سجلاً انخفاضاً ترافق مع زيادة حجم العينة (الزمن) ولكن حالتي التلوث ، وبأخذ أفضل النتائجين ومقارنتها مع نتائج جدول (1) نلاحظ انخفاض قيم المعياريين بنسبة كبيرة عند تلوث 10% وبنسبة أقل عند تلوث 20% ما عدا اخفاق حالة واحدة عند تلوث 20% وحجم عينة ($n=10, m=5$) ومستوى تباين ($\alpha=1/4$) ، وأن أسلوب LAD تفوق قليلاً على أسلوب M عند تلوث 10% وتتفوق بشكل كلي عند تلوث 20%.

وللحالة استعمال أساليب الحصانة LAD و M في المرحلة الثانية فقط، ومن نتائج جدول (3) ، قيم معياري (MADE , WASE) سجلاً انخفاضاً ترافق مع زيادة حجم العينة (الزمن) ولكن حالتي التلوث الاربع حالات اثنان عند تلوث 10% واثنان عند تلوث 20% وجميعهم عند حجم عينة ($n=10, m=15$) ، وبأخذ أفضل النتائجين ومقارنتها مع نتائج جدول (1) نلاحظ انخفاض قيم المعياريين بنسبة كبيرة عند تلوث 10% وبنسبة أقل عند تلوث 20% ما عدا اخفاق حالة واحدة عند تلوث 20% وحجم عينة ($n=10, m=5$) ومستوى تباين ($\alpha=1/4$) ، وأن أسلوب LAD تفوق على أسلوب M عند تلوث 10% ، وأسلوب M تفوق قليلاً على أسلوب LAD عند تلوث 20% .

وللحالة استعمال أسلوب الحصانة LAD في المرحلة الاولى وأستعمال أساليب الحصانة LAD و M في المرحلة الثانية ، ومن نتائج جدول (4) ، قيم معياري (MADE , WASE) سجلاً انخفاضاً ترافق مع زيادة حجم العينة (الزمن) ولكن حالتي التلوث عدا حالة واحدة عند تلوث 10% وحجم عينة ($n=10, m=15$) ، وبأخذ أفضل النتائجين ومقارنتها مع نتائج جدول (1) نلاحظ انخفاض قيم المعياريين بنسبة كبيرة عند تلوث 10% و 20% ما عدا أخفاق حالتين عند تلوث 20% الاولى عند حجم عينة ($n=10, m=5$) ومستوى تباين ($\alpha=1/4$) والثانية عند حجم عينة ($n=10, m=10$) ومستوى تباين ($\alpha=1/8$) ، وأن أسلوب M تفوق قليلاً على أسلوب LAD عند تلوث 10% وبشكل اكبر عند تلوث 20% .

وللحالة استعمال أسلوب الحصانة M في المرحلة الاولى وأستعمال أساليب الحصانة LAD و M في المرحلة الثانية، ومن نتائج جدول (5) ، قيم معياري (MADE , WASE) سجلاً انخفاضاً ترافق مع زيادة حجم العينة (الزمن) ولكن حالتي التلوث عدا حالة واحدة عند تلوث 20% وحجم عينة ($n=10, m=15$) ومستوى تباين ($\alpha=1/8$) ، وبأخذ أفضل النتائجين ومقارنتها مع نتائج جدول (1) نلاحظ انخفاض قيم المعياريين بنسبة كبيرة عند تلوث 10% و 20% ، وأن أسلوب LAD تفوق على أسلوب M عند تلوث 10% وبشكل اقل عند تلوث 20% .



ومن خلال متابعة الجداول من (1) إلى (5) فإن أفضل النتائج لطريقة تقدير LLPK عند تلوث 10% هي استعمال أسلوب الحصانة LAD في المرحلة الأولى مع استعمال أسلوب الحصانة M في المرحلة الثانية، وعند تلوث 20% استعمال أسلوب الحصانة LAD في المرحلة الأولى فقط، ولوحظ انخفاض قيم المعياريين لحالات استعمال اساليب الحصانة LAD و M مقارنة مع الطريقة التقليدية ولكن التلوث ولمختلف حجوم العينة ومستويات التباين، وكذلك انخفاض قيم المعياريين على الأغلب لمستوى التباين المتوسط $\text{S} = (1/4)$ مقارنة مع مستوى التباين العالي $\text{S} = (1/2)$ والواطن $\text{S} = (1/8)$ ، كما أظهر المعياريين (WASE و MADE) تطابق في تفضيل ومقارنة طرائق التقدير.

المصادر

- 1- Buja, A., Hastie, T. and Tibshirani, R., (1989), "Linear Smoothers and Additive Models", Annals of statistics, vol. 17, pp. 453-510.
- 2- Fan, J. and Gijbels, I., (1996), "Local Polynomial Modelling and its Applications", Chapman and Hall, London.
- 3- Fan, J. and Zhang, J., (2000), "Two – Step Estimation of Functional Linear Models with Applications to Longitudinal Data", Journal of Royal statistical society, vol. 62, no. 2, pp. 303-322.
- 4- Fan, J. and Zhang, W., (2008), "Statistical Methods with Varying Coefficient Models" Statistics and Interface, vol. 1, pp. 179-195.
- 5- Hoover, D. R., Rice, J. A., Wu, C. O. and Yang, L., (1998), " Non Parametric Smoothing Estimates of time - Varying Coefficient Models with Longitudinal Data", Biometrika, vol. 85, no. 4, pp. 809-822.
- 6- Hsiao, C., (2003), "Analysis of Panel Data", second edition, Cambridge University Press.
- 7- Huber, P. J., (1981), "Robust Statistics", John Wiley & Sons, New York.
- 8- Kovac, A., (2002), "Robust Nonparametric Regression and Modality", <http://Maths.bris.ac.uk/~Maxak/>
- 9-Schlossmacher, E. J., (1973), "An Iterative Technique for Absolute deviations curve fitting", JASA, vol. 68, no. 344, pp.857-859.
- 10- Senturk, D. and Muller, H. G. (2008), "Generalized varying coefficient models for longitudinal data", Biometrika, vol. 95, Iss.3, pp.653-666.
- 11- Wu, C. O., Tian, X. and Yu, J., (2010), "Non parametric estimation for time-varying transformation models with longitudinal data", Journal of non parametric statistics, vol. 22, no. 2, pp. 133-147.



Robust Two-Step Estimation and Approximation Local Polynomial Kernel For Time-Varying Coefficient Model With Balance Longitudinal Data

Abstract

In this research, the nonparametric technique has been presented to estimate the time-varying coefficients functions for the longitudinal balanced data that characterized by observations obtained through (n) from the independent subjects, each one of them is measured repeatedly by group of specific time points (m). Although the measurements are independent among the different subjects; they are mostly connected within each subject and the applied techniques is the *Local Linear kernel LLPK* technique. To avoid the problems of dimensionality, and thick computation, the two-steps method has been used to estimate the coefficients functions by using the two former technique. Since, the two-steps method depends, in estimation, on (OLS) method, which is sensitive for the existence of abnormality in data or contamination of error; robust methods have been proposed such as LAD & M to strengthen the two-steps method towards the abnormality and contamination of error. In this research imitating experiments have been performed, with verifying the performance of the traditional and robust methods for *Local Linear kernel LLPK* technique by using two criteria, for different sample sizes and disparity levels.

Keywords: Time varying coefficient;Two step estimation;Robust M&LAD estimation;Local polynomial smoothing;Longitudinal data.