

# مقارنة بعض المقدرات شبه المعلمية لتقدير دالة الانحدار

الباحثة أسيل مسلم عيسى

أ.م. د مناف يوسف حمود  
كلية الإدارة والاقتصاد- جامعة بغداد  
قسم الاحصاء

## المستخلص

ان هدف هذا البحث يتمثل بيان أهمية تقدير دالة الانحدار شبه المعلمية. إذ تم استعراض بعض الطرائق شبه المعلمية مع بعض الطرائق المقترحة لتقدير دالة الانحدار ، ومن ثم مقارنة هذه الطرائق من خلال أسلوب المحاكاة باستعمال توزيعات، إجمام عينات ومستويات تباين مختلفة للمتغير  $X$  ، إذ تم اقتراح مقدر مدمج شبه معلمي لتقدير دالة الانحدار وقد اثبتت النتائج افضلية هذا المقدر المقترح في حالة الأنموذجين الأول والثاني، إما للأنموذج الثالث فقد أظهرت النتائج أفضلية مقدر Burman and Chaudhuri (B&C).

## A comparison Of Some Semiparametric Estimators For consumption function Regression

### Abstract:

This article aims to explore the importance of estimating the a semiparametric regression function ,where we suggest a new estimator beside the other combined estimators and then we make a comparison among them by using simulation technique . Through the simulation results we find that the suggest estimator is the best with the first and second models ,wherealse for the third model we find Burman and Chaudhuri (B&C) is best.



مجلة العلوم

الاقتصادية والإدارية

المجلد 18

العدد 67

الصفحات 273 - 288



## 1-1 المقدمة

يعد الانحدار التقليدي من أكثر الأساليب الإحصائية وأوسعها استخداما في بيان العلاقة بين المتغير التابع والمتغيرات التوضيحية، إذ إن هذا الأسلوب يكون ذا فائدة عندما يكون متوسط الاستجابة خطيا أي إن:

$$E(Y/X) = \beta'X$$

لكن هذا الافتراض قد لا يتحقق في أغلب التجارب العلمية، إذ أنه لا يأخذ بنظر الاعتبار التأثير اللاخطي<sup>[8]</sup> للمتغيرات التوضيحية. لذلك جاء أسلوب آخر يأخذ بنظر الاعتبار التأثير اللاخطي، وهذا الأسلوب هو الأسلوب اللامعلمي الذي تم اقتراحه من قبل الباحث Jacob Wolfowitz عام (1942)<sup>[16]</sup> إذ يكون متوسط الاستجابة بالشكل الآتي:

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

أذ يشير  $m(\cdot)$  إلى دالة الانحدار اللامعلمي ذات البعد  $P$  (P-dimensional).

وقد لاحظ أغلب الباحثين إن هذا الأسلوب يعاني أيضا من مشكلة الإبعاد (The Curse of Dimensionality) التي تحصل عند زيادة عدد المتغيرات. لذلك قدم أسلوب أفضل من الأسلوبين المذكورين إنفا وهو أسلوب الانحدار شبه معلم (Regression Semiparametric) والذي تم اقتراحه من قبل الباحث Robinson<sup>[17]</sup> عام (1988) و Speckman عام (1988)<sup>[15]</sup> الذي يعد في الوقت الحاضر من أكثر الأساليب الإحصائية استعمالا. إذ فاق هذا الأسلوب كل من الانحدار المعلمي واللامعلمي من خلال دراسة المتغيرات التوضيحية سواء أكانت متقطعة أم مستمرة في نموذج واحد بالإضافة إلى تجاوز المشاكل التي تعيق كل من الأسلوبين المشار إليها. إن الانحدار شبه معلم له عدة تسميات منها الانحدار الخطي الجزئي "Partial linear Regression" والذي يرمز له بالرمز (PL) كما يطلق عليه في بعض المصادر الانحدار شبه المعلمي "Semiparametric regression"<sup>[12]</sup> أو الانحدار شبه الخطي "Semi linear regression".

## 1-2 هدف البحث

يهدف البحث إلى عرض بعض الطرائق الأهم والأكثر انتشارا لتقدير دالة الانحدار مستخدمين بذلك مقدرات شبه معلمية، فضلا عن محاولتنا إيجاد مقدر جديد مقترح لها أداء أفضل من أداء المقدرات المتاحة.

## 2- الجانب النظري

تعتمد مقدرات المدمجة شبه المعلمية على توافق المقدرات المعلمية والمقدرات اللامعلمية بوجود معلمة دمج والتي تعطي وزنا للمقدر وبفرض كون  $\{T_i, Y_i\}_i^n$  متغيرات عشوائية مستقلة ومتماثلة التوزيع<sup>[3]</sup>.

## (1-2) آلية تقدير دالة الانحدار المدمج

سوف نتطرق إلى آلية عمل مقدرات الانحدار المدمج بعدها نذكر أهم الطرائق المستعملة لتقدير هذه الدوال كما يأتي:

1- باختيار حجم عينة معين وبفرض إن  $f(\beta, T)$  تشير إلى إحدى الصيغ المعلمية المعروفة والمعتمدة على المعلمة المجهولة  $\beta$ . إن دالة الانحدار المعلمي قد يكون خطيا بسيطا أو متعددًا، وقد يكون لا خطيا أي قد يكون تربيعا أم تكعيبيا أم لوغاريتميا... الخ. لذلك نحن بحاجة لتقدير تلك المعالم المجهولة، وهناك عدة طرائق لتقدير المعلمة المجهولة منها طريقة المربعات الصغرى وطريقة الإمكان الأعظم... الخ. وهنا سيتم تقدير  $\beta$  بطريقة المربعات الصغرى، وصيغتها:

$$\hat{\beta}' = (T'T)^{-1}T'Y$$



## مقارنة بعض المقدرات شبه المعلمية لتقدير دالة الانحدار

2 - إما دالة الانحدار اللامعلمي فقد يتم تقديرها باستعمال عدة مميزات، منها مميزات اللب، مميزات متعدد الحدود الموضوعي، مميزات الشريحة... الخ. وهنا سيتم تقدير الدالة اللامعلمية باستخدام مميزات انحدار متعدد الحدود الموضوعي (local polynomial regression smoother)، أولاً لنفرض متسلسلة تايلور (Taylor expansion) دالة التوقع الشرطي المجهول  $m(\cdot)$  إذ أن:

$$m(T) = m(t) + m'(t)(T_i - t) + \frac{m''(t)}{2}(T_i - t)^2 + \dots + \frac{m^{(p)}(t)}{p}(T_i - t)^p \quad \dots(1)$$

إذ إن  $t$  يكون جوار النقطة  $T$  لنفرض ان :

$$\begin{aligned} m(t) &= \beta_0 \\ m'(t) &= \beta_1 \\ \frac{m''(t)}{2} &= \beta_2 \\ &\vdots \\ \frac{m^{(p)}(t)}{p} &= \beta_p \end{aligned}$$

بعد التعويض تصبح  $m(T)$  بالشكل الآتي:

$$m(T) = \beta_0 + \beta_1(T_i - t) + \beta_2(T_i - t)^2 + \dots + \beta_p(T_i - t)^p \quad \dots(2)$$

بما إن دالة الانحدار اللامعلمي تعطى بالشكل الآتي :

$$Y = m(T) + \varepsilon \quad \dots(3)$$

ألآن نقوم بتعويض  $m(T)$  بدالة الانحدار فتصبح :

$$Y_i = \beta_0 + \beta_1(T_i - t) + \beta_2(T_i - t)^2 + \dots + \beta_p(T_i - t)^p + \varepsilon_i \quad \dots(4)$$

ولكي يتم تقدير المعالم المجهولة نستخدم طريقة المربعات الصغرى الموزونة وكالاتي :

$$\sum_{i=1}^n \varepsilon_i^2 * K_h(T_i - t) = \sum_{i=1}^n (Y_i - (\beta_0 + \beta_1(T_i - t) + \beta_2(T_i - t)^2 + \dots + \beta_p(T_i - t)^p))^2 * K_h(T_i - t)$$

وبتحويل المعادلة أنفا إلى صيغة مصفوفات فتكون :

$\beta = [\beta_0, \beta_1, \dots, \beta_p]$  : موجة المعالم المجهولة من الدرجة  $p$  والمراد تقديرها .

$$Y = \begin{bmatrix} Y_1 \\ \vdots \\ Y_n \end{bmatrix}, T = \begin{bmatrix} 1(T_1 - t) & \dots & (T_1 - t)^p \\ \vdots & \ddots & \vdots \\ 1(T_n - t) & \dots & (T_n - t)^p \end{bmatrix}, W = \begin{bmatrix} K_h(t - T_1) & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & K_h(t - T_n) \end{bmatrix} = \text{diag} K_h(t - T_i)$$

فيصبح تقدير  $\beta$  بالشكل الآتي :

$$\hat{\beta}(t) = (T'WT)^{-1}T'WY$$

إن الصيغة أنفا هي الصيغة العامة لانحدار متعدد الحدود الموضوعي ، من المهم ملاحظة أنه  $\hat{\beta}(t)$  هي عبارة

عن  $\hat{\beta}_0(t)$  و  $\hat{\beta}_1(t)$  و ... و  $\hat{\beta}_p(t)$ ، لذلك فإن مقدر متعدد الحدود الموضوعي لدالة الانحدار هو

$$\hat{m}_{p,h}(t) = \hat{\beta}_0(t)$$



نلاحظ حقيقة إن  $\hat{m}_{p,h}(t) = \hat{\beta}_0(t)$  ففي حالة  $p=0$  فإن هذا يعني ان المقدر هو مقدر Nadaraya-Watson

$$\hat{m}_{0,h}(t) = \hat{m}_h(t) = \frac{\sum_{i=1}^n K_h(t-T_i)y_i}{\sum_{i=1}^n K_h(t-T_i)}, i=1,2,\dots,n \quad \dots(5)$$

$$K_h(\cdot) = \frac{1}{h} K\left(\frac{\cdot}{h}\right)$$

أذن:

إما في حالة  $p=1$  فإن المقدر سيكون ممهد الانحدار الخطي الموضعي (Local linear regression LLS) [1][2][4][7]، إذ يتم إيجاده بالطريقة الآتية :

$$m(x) \cong m(t) + m'(t)(x-t) \cong \beta_0 + \beta_1(x-t)$$

لذلك فإن :

$$\sum_{i=1}^n \varepsilon_i^2 K_h^*(t-x) = \sum_{i=1}^n (Y_i - (\beta_0 + \beta_1(x-t)))^2 * K_h(t-x)$$

ولهذا فإن مساواة تقدير دالة الانحدار  $m(t)$  تكون مساوية إلى مسألة الانحدار الخطي الموضعي والتي تتمثل بتقدير الحد الثابت  $\beta_0$

بفرض إن  $\hat{\beta}_0$  و  $\hat{\beta}_1$  يمثلان حل لمسألة المربعات الصغرى الموزونة المذكور أنفا و بحساب بسيط ينتج إن :

$$\hat{\beta}_0 = \frac{\sum_{i=1}^n W_i Y_i}{\sum_{i=1}^n W_i + n^{-1}}$$

إذ إن

$$W_i = K_h(T_i - t)[S_{n,2} - (T_i - t)S_{n,1}]$$

$$S_{n,l} = \sum_{i=1}^n K_h(T_i - t)(T_i - t)^l, l=1,2$$

3- دمج المقدر المعلمي مع المقدر اللامعلمي والذي يستند على وجود معلمة دمج مرافقة ( combining parameter ) ولها تسميات عدة منها معلمة شبه المعلمية (semiparametric parameter) وثابت المدمجة (combining constant) ومعامل الدمج (combining coefficient) ، وان هذه المعلمة تقدر بعدة طرائق منها طريقة المربعات الصغرى الاعتيادية وطريقة الإمكان الأعظم... الخ .



## مقارنة بعض المقدرات شبه المعلمية لتقدير دالة الانحدار

- طرائق تقدير دالة الانحدار المدمج :

من المعروف إن هذه الدالة تتكون من دمج دالتين هما دالة انحدار معلمية تحتاج إلى تقدير معالمها وكذلك تقدير دالة انحدار لا معلمية، و معلمة الدمج هي التي تقدير أيضا حسب صيغة الأنموذج . لذلك هنالك عدة طرائق لتقدير هذه الدوال وتقدير معلمة الدمج. إن أهم الطرائق المستعملة لتقدير دالة الانحدار المدمج هي :

- ❖ مقدر (B&C) Burman and Chaudhuri.
- ❖ مقدر (Woo) Wooldridge.
- ❖ مقدر (F&U) Fan & Ullah.
- ❖ المقدر المقترح من قبل الباحث (Suggest) وفيما يأتي عرضا لكل مقدر :

### (1-2-2) مقدر Burman and Chaudhuri (B&C)<sup>[14]</sup>

درس الكثير من الباحثين هذا المقدر منهم الباحثان Olkin و Spiegelman عام (1987)<sup>[11]</sup> والباحثة Julian Faraway عام (1990)<sup>[6]</sup> والباحثان Ullah و Rahma D.V Gokhale عام (1997)<sup>[10]</sup> والباحث حمود (2005)<sup>[3]</sup> في تقدير دالة الكثافة الاحتمالية. إما الباحثان Ullah و Vinod عام (1993)<sup>[5]</sup> والباحثان Burman and Chaudhuri عام (1994)<sup>[14]</sup> والباحثان Fan و Ullah عام (1999)<sup>[14]</sup> فأنهم درسوها في دالة الانحدار. إن هذا المقدر يدمج دالة معلمية للأنموذج المعلمي ومقدرا لا معلمياً للأنموذج اللامعلمي وفق مقدر لمعلمة المدمجة إذ إن صيغة هذا المقدر هي :

$$\hat{\theta}_1(T_i) = \hat{\lambda}f(\hat{\beta}, T_i) + (1 - \hat{\lambda})\hat{m}(T_i)$$

علما أن الصيغة المذكورة أنفا تعد مقدرًا لدالة الانحدار:

$$Y_i = \theta_1(T_i) + \varepsilon_i \quad \dots(7)$$

إذ أن

$$\theta_1(T_i) = \lambda_1 f(\beta, T_i) + (1 - \lambda_1)m(T_i) \quad \dots(8)$$

أي تصبح دالة الانحدار بعد تعويض المعادلة (8) عوضا عن (7) بالآتي :

$$Y_i = \lambda_1 f(\beta, T_i) + (1 - \lambda_1)m(T_i) + \varepsilon_i \quad \dots(9)$$

وان  $\lambda_1$  تشير إلى معلمة المدمجة (combining parameter) ، وهي تقع بين  $0 \leq \lambda_1 \leq 1$  فإذا كانت  $\lambda_1 = 0$  فإن الأنموذج سيكون لا معلمياً وصيغته :

$$Y_i = m(T_i) + \varepsilon_i$$

وإذا كانت  $\lambda_1 = 1$  فإن الأنموذج سيكون معلمياً وكما يأتي :

$$Y_i = f(\beta, T_i) + \varepsilon_i$$

سيتم تقدير هذه المعلمة بطريقة المربعات الصغرى وعلى النحو التالي : يتم إضافة وطرح الدالة المعلمية  $f(\beta, T_i)$  إلى معادلة (9) فنحصل على

$$Y_i = \lambda_1 f(\beta, T_i) + (1 - \lambda_1)m(T_i) - f(\beta, T_i) + f(\beta, T_i) + \varepsilon_i$$

بعد ذلك تصبح المعادلة كالتالي:

$$Y_i - f(\beta, T_i) = \lambda_1 f(\beta, T_i) + (1 - \lambda_1)m(T_i) - f(\beta, T_i) + \varepsilon_i$$

$$Y_i - f(\beta, T_i) = \lambda_1 f(\beta, T_i) + (\lambda_1 - 1)[f(\beta, T_i) - m(T_i)] + \varepsilon_i$$



## مقارنة بعض المقدرات شبه المعلمية لتقدير دالة الانحدار

وبعد تقدير الجزء المعلمي مع الجزء اللامعلمي نعمل على استبدال كل من ب  $f(\beta, T_i)$  ب  $f(\hat{\beta}, T_i)$  و  $m(T_i)$  ب  $\hat{m}(T_i)$  لذلك يصبح النموذج كما يأتي:

$$Y_i - f(\hat{\beta}, T_i) = \lambda_1 f(\hat{\beta}, T_i) + (\lambda_1 - 1)[f(\hat{\beta}, T_i) - \hat{m}(T_i)] + \varepsilon_i$$

لإيجاد  $\lambda_1$  نتبع الآتي

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - (\lambda_1 - 1)[f(\hat{\beta}, T_i) - \hat{m}(T_i)])^2$$

وبالاشتقاق بالنسبة إلى  $\lambda_1$

$$\frac{\partial \sum_{i=1}^n \varepsilon_i^2}{\partial \lambda_1} = -2 \left[ \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - (\lambda_1 - 1)[f(\hat{\beta}, T_i) - \hat{m}(T_i)]) [f(\hat{\beta}, T_i) - \hat{m}(T_i)] \right]$$

ومساواة المعادلة أعلاه بالصفر

$$-2 \left[ \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - (\lambda_1 - 1)[f(\hat{\beta}, T_i) - \hat{m}(T_i)]) [f(\hat{\beta}, T_i) - \hat{m}(T_i)] \right] = 0$$

يكون مقدر  $\lambda_1$  بالشكل الآتي :

$$\hat{\lambda}_1 = \frac{n^{-1} \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - [f(\hat{\beta}, T_i) - \hat{m}(T_i)])}{n^{-1} \sum_{i=1}^n [f(\hat{\beta}, T_i) - \hat{m}(T_i)]^2} + 1 \quad \dots(10)$$

مع ملاحظة إن  $f(\hat{\beta}, T_i) \neq \hat{m}(T_i)$

**2-2-2) مقدر Wooldridge (Woo)** [9]

اقترح هذا المقدر من قبل الباحث Wooldridge عام (1992) [9] ويعمل هذا المقدر على دمج مقدر معلم  $f(\beta, T_i)$  ، و مقدر لا معلم وكما يأتي :

$$\hat{\theta}_2(T_i) = f(\hat{\beta}, T_i) + \hat{\lambda}_2 \hat{m}(T_i) \quad \dots(11)$$

اذ تشير  $\lambda_2$  الى معلمة المدمجة (combining parameter) ، يلاحظ إن معلمة المدمجة محتواة فقط بالجزء اللا معلم وهي تقع بين  $0 \leq \lambda_2 \leq 1$  فإذا كانت  $\lambda_2 = 1$  فان النموذج سيكون أنموذج خطي جزئي والذي يدمج الانحدار المعلمي مع الانحدار اللامعلمي وصيغته كما يأتي :

$$Y_i = m(T_i) + f(\beta, T_i) + \varepsilon_i$$

وإذا كانت  $\lambda_2 = 0$  فان النموذج سيكون معلم وصيغته كما يأتي :

$$Y_i = f(\beta, T_i) + \varepsilon_i$$

و بعد تقدير الجزء المعلمي مع الجزء اللامعلمي نعمل على استبدال كل من ب  $f(\beta, T_i)$  ب  $f(\hat{\beta}, T_i)$  و  $m(T_i)$  ب  $\hat{m}(T_i)$  لذلك يصبح النموذج كما يأتي:

$$Y_i - f(\hat{\beta}, T_i) = \lambda_2 m(T_i) + \varepsilon_i$$

لإيجاد  $\lambda_2$  نعمل على اشتقاق المعادلة بالنسبة إلى  $\lambda_2$  وكالاتي:

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - f(\hat{\beta}, T_i) - \lambda_2 \hat{m}(T_i))^2$$



وبالاشتقاق بالنسبة إلى  $\lambda_2$

ومساواة المعادلة أعلاه بالصفر

$$\frac{\partial \sum_{i=1}^n \varepsilon_i^2}{\partial \lambda_2} = -2 \left[ \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - \lambda_2 \hat{m}(T_i)) \right] \hat{m}(T_i) \left[ \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - \lambda_2 \hat{m}(T_i)) \right] \hat{m}(T_i) = 0$$

يكون مقدر  $\lambda_1$  بالشكل الآتي :

$$\hat{\lambda}_1 = \frac{n^{-1} \sum_{i=1}^n [Y_i - f(\hat{\beta}, T_i)] \hat{m}(T_i)}{n^{-1} \sum_{i=1}^n \hat{m}(T_i)^2} \quad \dots(12)$$

مع ملاحظة إن  $\sum_{i=1}^n \hat{m}(T_i)^2 \neq 0$

### [14] مقدر (3-2-2) Fan & Ullah (F&U)

اقترح هذا المقدر من قبل الباحثين Fan & Ullah عام (1999) ، ان فكرة هذا المقدر تطابق مقدر Burman and Chaudhuri ، يعمل هذا المقدر على دمج كلا من المقدر المعلمي مع المقدر الانحدار المدمج المقترح من قبل Burman and Chaudhuri  $\theta_1(T_i) = \lambda_1 f(\beta, T_i) + (1 - \lambda_1) m(T_i)$  بالاعتماد على معلمة دمج تقع بين الصفر والواحد . نلاحظ إن هذا المقدر يحتوي على معلمتي دمج الواحدة داخل الأخرى ، الأولى معلمة المدمجة الخاصة بالمقدر الانحدار المدمج والتي يتم تقديرها، إما الثانية فهي خاصة بهذا المقدر . ان صيغة هذا المقدر هي :

$$\hat{\theta}_3(T_i) = \lambda_3 f(\hat{\beta}, T_i) + (1 - \lambda_3) \hat{\theta}_1(T_i)$$

علما ان الصيغة المذكورة انفا تعد لمقدر دالة الانحدار:

$$Y_i = \theta_3(T_i) + \varepsilon_i \quad \dots(13)$$

اذ ان

$$\theta_3(T_i) = \lambda_3 f(\beta, T_i) + (1 - \lambda_3) \theta_1(T_i) \quad \dots(14)$$

اي تصبح دالة الانحدار بعد تعويض المعادلة (14) في (13) بالآتي :

$$Y_i = \lambda_3 f(\beta, T_i) + (1 - \lambda_3) \theta_1(T_i) + \varepsilon_i$$

اذ إن  $\lambda_3$  تشير الى معلمة المدمجة (combining parameter) وهي تقع بين  $0 \leq \lambda_3 \leq 1$  فإذا كانت  $\lambda_3 = 1$  فان النموذج سيكون معلمي وفي هذه الحالة يكون محدد بشكل صحيح . **correctly specified**. وصيغته كما يأتي:

$$Y_i = f(\beta, T_i) + \varepsilon_i$$

وإذا كانت  $\lambda_3 = 0$  فان النموذج سيكون انحدار مدمج وفي هذه الحالة يكون محدد بشكل خاطئ **incorrectly specified** وصيغته كما يأتي :

$$Y_i = \theta_1(T_i) + \varepsilon_i$$



## مقارنة بعض المقدرات شبه المعلمية لتقدير دالة الانحدار

وفي حالة  $\lambda_3$  تكون قيمتها قريبة من الصفر فانه يكون ذات مواصفات قريبة من الصحة *approximately correct*. يتم تقدير معلمة المدمجة بطريقة المربعات الصغرى بعد تقدير الجزء المعلمي وتقدير مقدر الانحدار المدمج، وان طريقة تقديرها تكون مشابهة إلى تقدير  $\lambda_1$ ، لذلك

$$\hat{\lambda}_3 = \frac{n^{-1} \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - [f(\hat{\beta}, T_i) - \hat{\theta}_1(T_i)])}{n^{-1} \sum_{i=1}^n [f(\hat{\beta}, T_i) - \hat{\theta}_1(T_i)]^2} + 1 \quad \dots(15)$$

مع ملاحظة إن  $f(\hat{\beta}, T_i) \neq \hat{\theta}_1(T_i)$

(2-2-4) مقدر الانحدار المدمج المقترح

تستند هذه الطريقة على اقتراح نموذج انحدار شبه معلمي مدمج وذلك من خلال النموذج الآتي

$$Y_i = f(\beta, T_i) + \lambda_4 \theta_1(T_i) + \varepsilon_i \quad \dots(16)$$

اذ ان

$$\theta_1(T_i) = \lambda_1 f(\beta, T_i) + (1 - \lambda_1) m(T_i)$$

ويلاحظ من النموذج المقترح انه عبارة عن مزيج بين طريقتين **Fan & Ullah** من ناحية الفكرة ومقدر **Wooldridge** من ناحية هيكلية المقدر لكن الفرق يكون بتعويض  $\theta_1(T_i)$  عوضا عن  $m(T_i)$ . لتقدير هذا النموذج نقوم اولا بتقدير كل من  $f(\beta, T_i)$  وبعدها ايجاد تقدير  $\theta_1(T_i)$  وفقا للأساليب المذكورة أنفا مستخدمين بذلك طريقة **B&C** ومعيار **OLS** لتقدير معلمة المدمجة  $\lambda_1$ . بعد عمل الخطوات جميعا يتم ايجاد تقدير  $\lambda_4$  أيضا بطريقة المربعات الصغرى، و أيضا تقع بين  $(0 \leq \lambda_4 \leq 1)$  فإذا كانت  $\lambda_4 = 1$  فان المقدر سيكون بالشكل الآتي:

$$\theta_4(T_i) = (\lambda_4 + 1) f(\beta, T_i) + (1 - \lambda_4) m(T_i)$$

وإذا كانت  $\lambda_4 = 0$  فان المقدر سيكون معلمي وبالشكل التالي :

$$\theta_4(T_i) = f(\beta, T_i)$$

و بعد تقدير الجزء المعلمي مع الجزء اللامعلمي نعمل على استبدال كل من  $f(\beta, T_i)$  ب  $f(\hat{\beta}, T_i)$  و  $\theta_1(T_i)$  ب  $\hat{\theta}_1(T_i)$  لذلك يصبح النموذج كما يأتي:

$$Y_i - f(\hat{\beta}, T_i) = \lambda_4 \hat{\theta}_1(T_i) + \varepsilon_i$$

لإيجاد  $\lambda_4$  نعمل على اشتقاق المعادلة بالنسبة إلى  $\lambda_4$  وكالاتي:

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - f(\hat{\beta}, T_i) - \lambda_4 \hat{\theta}_1(T_i))^2$$

$$\frac{\partial \sum_{i=1}^n \varepsilon_i^2}{\partial \lambda_4} = -2 \left[ \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - \lambda_4 \hat{\theta}_1(T_i)) \right] \hat{\theta}_1(T_i)$$

وبالاشتقاق بالنسبة إلى  $\lambda_4$  ومساواة المعادلة أعلاه بالصفر

$$-2 \left[ \sum_{i=1}^n ([Y_i - f(\hat{\beta}, T_i)] - \lambda_4 \hat{\theta}_1(T_i)) \right] \hat{\theta}_1(T_i) = 0$$





## مقارنة بعض المقدرات شبه المعلمية لتقدير دالة الانحدار

يكون مقدر  $\lambda_4$  بالشكل الآتي :

$$\hat{\lambda}_1 = \frac{n^{-1} \sum_{i=1}^n [Y_i - f(\hat{\beta}, T_i)] \hat{\theta}_1(T_i)}{n^{-1} \sum_{i=1}^n \hat{\theta}_1(T_i)^2} \quad \dots(17)$$

مع ملاحظة إن  $\sum_{i=1}^n \hat{\theta}_1(T_i)^2 \neq 0$

## 3- الجانب التجريبي:

تم تنفيذ عددا من تجارب المحاكاة لمعايير اختيار أفضل المقدرات ، إذ سوف يتم تطبيق ما تم عرضه في الجانب النظري في المبحث السابق ، وفي هذه التجارب تم استخدام ثلاث دوال للانحدار هي :

$$\sim N(0,1) 1 - m_1(X) = X^3 \quad X$$

$$\sim N(0,1) 2 - m_2(X) = \sin(2X) + 2 \exp(-16X^2) \quad X$$

$$\sim N(0,1) 3 - m_3(X) = 1 - X + \exp(-200(X - \frac{1}{2})^2) \quad X$$

وبافتراض ان  $Y$  يمثل متغير عشوائي و ان المتغير  $X$  تم توليده وفق التوزيع الطبيعي القياسي لذلك تم استعمال الانموذج اللامعلمي لغرض مقارنة المقدرات

$$Y_i = m(X) + \varepsilon_i$$

وقد تم افتراض 3 قيم للخطأ هي (1, 0.5, 0.25) وان الخطأ يتوزع طبيعيا  $\varepsilon_i \sim N(0, \sigma^2)$  ، وان تجارب المحاكاة المنفذة تمت باستخدام ثلاث إجمام للعينات هي (50, 100, 150) وبتكرارات (Replicates = 500) لكل تجربة محاكاة .. علما ان تفسير الرموز في جدول (1) كالآتي :

Local linear smoother	مقدر	LLS
Multiple regression	مقدر	OLS
Burman and Chaudhuri	مقدر	B&C
Wooldridge	مقدر	Woo
Fan & Ullah	مقدر	F&U
المقترح	المقدر	Suggest



## مقارنة بعض المقدرات شبه ألعلميه لتقدير دالة الانحدار

## جدول رقم (1)

يبين معدل متوسط مربعات الخطأ للمقدرات المذكورة انفا مع كون قيم التباين المفروضة للمتغير x تكون (1, 0.5, 0.25) وباحجام عينات (150, 100, 50)

Model	n	$\sigma^2$	LLS	OLS	B&C	Woo	F&U	Suggest
1	50	0.25	0.0077	0.0049	0.0039	0.0032	0.0036	0.0031
	100		0.0058	0.0026	0.0019	0.0016	0.0017	0.0016
	150		0.0044	0.0017	0.0011	0.0010	0.0010	0.0010
	50	0.5	0.0217	0.0201	0.0147	0.0131	0.0141	0.0120
	100		0.0149	0.0099	0.0072	0.0062	0.0068	0.0058
	150		0.0097	0.0067	0.0048	0.0041	0.0044	0.0040
	50	1	0.0853	0.0814	0.0643	0.0672	0.0623	0.0567
	100		0.0685	0.0413	0.0305	0.0295	0.0295	0.0258
	150		0.0274	0.0269	0.0191	0.0180	0.0185	0.0163
2	50	0.25	0.0324	0.0077	0.0065	0.0054	0.0052	0.0054
	100		0.0171	0.0054	0.0038	0.0036	0.0033	0.0037
	150		0.0161	0.0045	0.0029	0.0029	0.0026	0.0030
	50	0.5	0.0869	0.0216	0.0192	0.0147	0.0154	0.0143
	100		0.0425	0.0130	0.0106	0.0088	0.0087	0.0087
	150		0.0319	0.0093	0.0078	0.0063	0.0063	0.0064
	50	1	0.1666	0.0793	0.0681	0.0523	0.0599	0.0494
	100		0.0872	0.0432	0.0368	0.0296	0.0319	0.0286
	150		0.0632	0.0298	0.0246	0.0198	0.0210	0.0197
3	50	0.25	0.0340	0.0567	0.0228	0.0453	0.0236	0.0523
	100		0.0195	0.0552	0.0190	0.0442	0.0201	0.0519
	150		0.0145	0.0549	0.0160	0.0435	0.0167	0.0518
	50	0.5	0.0494	0.0711	0.0437	0.0580	0.0448	0.0611
	100		0.0326	0.0629	0.0341	0.0513	0.0355	0.0565
	150		0.0257	0.0603	0.0283	0.0487	0.0299	0.0553
	50	1	0.1066	0.1319	0.0962	0.1125	0.0966	0.1040
	100		0.0688	0.0922	0.0655	0.0760	0.0664	0.0761
	150		0.0528	0.0800	0.0542	0.0659	0.0557	0.0673



## مقارنة بعض المقدرات شبه ألعلميه لتقدير دالة الانحدار

تفسير نتائج الجانب التجريبي:

### الأنموذج الأول:

- أظهرت النتائج إن المقدر المقترح هو أفضل مقدر ولجميع قيم تباين البواقي و أحجام العينات المستخدمة ، يليه مقدر Wooldridge فيما عدا حالة التباين واحد وحجم العينة 100,50 فإن المقدر F&U هو أفضل من مقدر Wooldridge ، كما يلاحظ انه في حال التباين 0.25 وحجم عينة 100 و150 فإن قيم MASE تكون متساوية تقريبا وهذا ما أوضحه الشكل (1).
- يلاحظ انه في حالة تباين البواقي صغير وحجم العينة كبير فإن مقدر F&U Wooldridge ، والمقدر المقترح تكون MASE متساوية .
- يلاحظ إن أسوأ مقدر هو مقدر الانحدار الخطي الموضوعي وذلك لان MASE كان كبير مقارنة مع بقية المقدرات .
- تناقص قيم MASE مع تزايد حجم العينة ولجميع المقدرات.
- تزايد MASE مع تزايد قيم تباين البواقي.

### الأنموذج الثاني:

- أظهرت النتائج إن مقدر F&U هو أفضل مقدر في حالة تباين الخطأ 0.25 لجميع أحجام العينات ، يليه مقدر Wooldridge . إما في حالة تباين الأخطاء 0.5 و واحد فإن المقدر المقترح هو الأفضل ، يليه مقدر Wooldridge وهذا ما بينه الشكل (2) . عدا حالة التباين 0.5 وحجم عينة 100 فإن قيم MASE للمقدر Wooldridge والمقدر F&U والمقدر المقترح تكون متقاربة .
- أظهرت النتائج إن أسوأ مقدر كان الانحدار الخطي الموضوعي وذلك لان MASE كبير مقارنة مع بقية المقدرات .
- تناقص قيم MASE مع تزايد حجم العينة ولجميع المقدرات.
- تزايد MASE مع تزايد قيم تباين البواقي.

### الأنموذج الثالث:

- أظهرت النتائج وكحالة عامة إن مقدر B&C هو أفضل مقدر لبعض قيم تباين البواقي و أحجام العينات المستخدمة ، يليه المقدر F&U في حالة MASE والشكل (3) يبين ذلك.
- في حالة تباين الخطأ 0.25 و 0.5 وبحجم عينة 150 يلاحظ إن مقدر LLS هو الأفضل .
- أظهرت النتائج إن أسوأ مقدر كان مقدر الانحدار المتعدد وذلك لان MASE كبير مقارنة مع بقية المقدرات .
- تناقص قيم MASE مع تزايد حجم العينة ولجميع المقدرات.
- تزايد MASE مع تزايد قيم تباين البواقي.



## شكل (1)

يشير إلى المقدرات المعملية اللاعلمية وشبه المعلمية عند استعمال الأتموزج الأول ولحجم عينة 100

Figure 1.1 : Local Linear Smoother

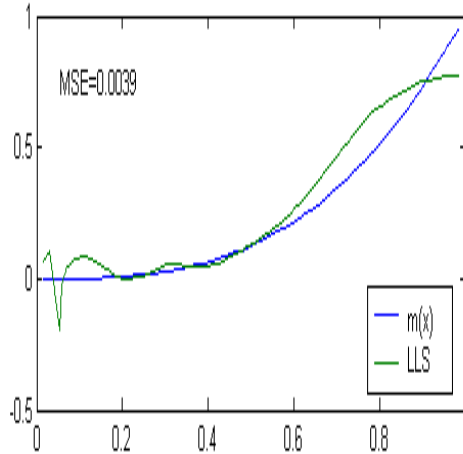


Figure 1.2 : Polynoial Regression




Figure 1.3 : Semipara. B&amp;C method




Figure 1.4 : Semipara. F&amp;U method

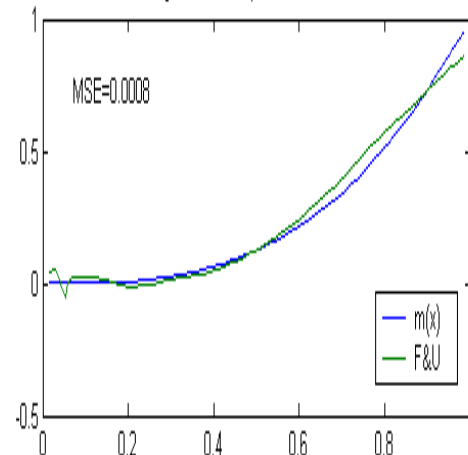


Figure 1.5 : Semipara. Wooldrige method


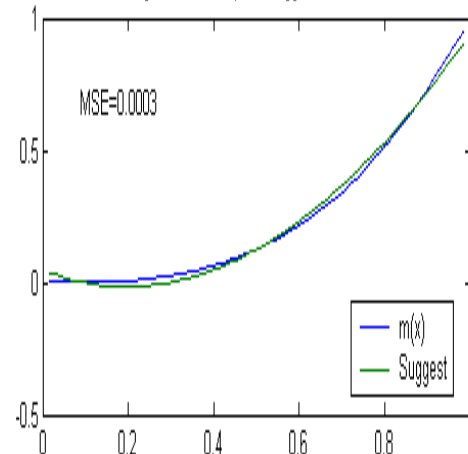


Figure 1.6 : Semipara. Suggested method





(0.25) وتباين خطأ

شكل (2)

يشير إلى المقدرات المعلمية واللامعلمية وشبه المعلمية عند استعمال النموذج الثاني ولحجم عينة 50

وتباين خطأ (1)

Figure 1.1 : Local Linear Smoother




Figure 1.2 : Polynomial Regression




Figure 1.3 : Semipara. B&amp;C method




Figure 1.4 : Semipara. F&amp;U method




Figure 1.5 : Semipara. Wooldrige method

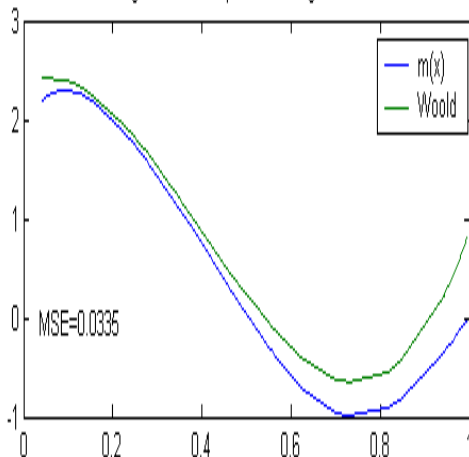
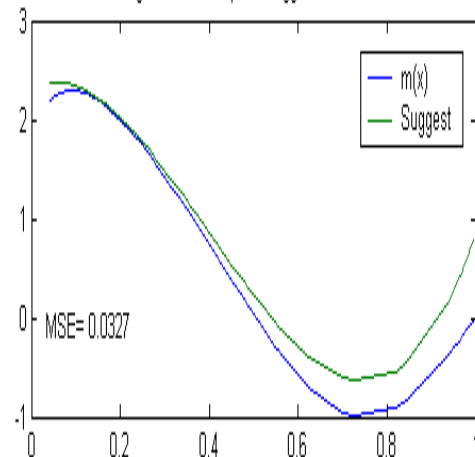


Figure 1.6 : Semipara. Suggested method





## مقارنة بعض المقدرات وشبه المعلمية لتقدير دالة الانحدار

## شكل (3)

يشير إلى المقدرات المعلمية واللامعلمية وشبه المعلمية عند استعمال الأتموزج الثالث ولحجم عينة 150 وتباين خطأ (0.5)

Figure 1.1 : Local Linear Smoother




Figure 1.2 : Polynomial Regression




Figure 1.3 : Semipara. B&amp;C method

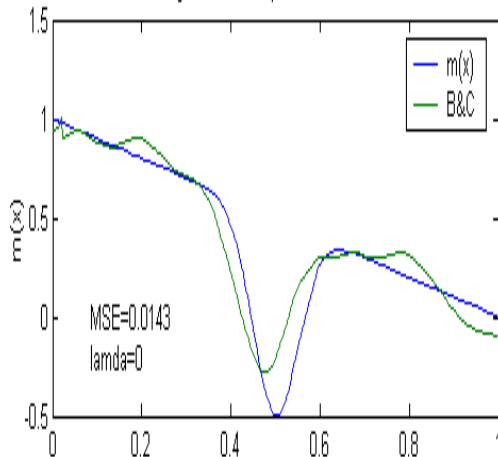


Figure 1.4 : Semipara. F&amp;U method




Figure 1.5 : Semipara. Wooldrige method





Figure 1.6 : Semipara. Suggested method





#### 4- الاستنتاجات:

- بناءً على ما تم تحليله من نتائج المحاكاة وفقاً لكل أنموذج من نماذج الانحدار اللامعلمي ولجميع الحالات الأخرى تم التوصل إلى الاستنتاجات الآتية :
- لأنموذج الانحدار اللامعلمي ولجميع الحالات وكحالة عامة تم التوصل إلى الاستنتاجات الآتية:
1. إن قيم MASE تتناسب تناسباً عكسياً مع إحصاء العينات وجميع قيم التباين، أي أنها تتناقص عند زيادة إحصاء العينات .
  2. إن قيم MASE تتناسب تناسباً طردياً مع قيم التباين ، أي أنها تزداد بزيادة قيم التباين .
  3. توسع حجم العينة يجعل من منحنيات المقدرات المستعملة أكثر قرباً للمنحنى الحقيقي وذلك لكون المقدرات تتأثر بقلّة البيانات وتشتتها .
- لأن الاستنتاجات لكل أنموذج من نماذج الانحدار اللامعلمي الخاصة بالأنموذج الأول:

#### الأنموذج الأول

4. كحالة عامة تبين إن المقدر المقترح هو أفضل مقدر لجميع قيم تباين البواقي و أحجام العينات المستخدمة .
- #### الأنموذج الثاني
5. وكحالة عامة إن المقدر المقترح هو الأفضل في حال قيم التباين متوسطة وكبيرة، إما في حال قيم التباين صغيرة فإن مقدر F&U هو الأفضل .
- #### الأنموذج الثالث
6. كحالة عامة تبين إن مقدر B&C هو أفضل مقدر لجميع قيم تباين البواقي و أحجام العينات المستخدمة .

#### 5- التوصيات :

- يمكن إجمال التوصيات الآتية على ضوء الاستنتاجات التي توصلنا إليها من خلال هذه الدراسة
- 1- استعمال المقدر المقترح في الأنموذج الأول عند تطبيق دالة الانحدار اللامعلمية، لأنه يعطي أفضل (MASE) .
  - 2- استعمال المقدر المقترح في الأنموذج الثاني عند تطبيق دالة الانحدار اللامعلمية ، لأنه يعطي أفضل (MASE) .
  - 3- استعمال مقدر (B&C) Burman and Chaudhuri في الأنموذج الثالث عند تطبيق دوال الانحدار اللامعلمية ، لأنه يعطي أفضل (MASE) .
  - 4- استعمال صيغ من الدوال Kernel غير المذكورة في البحث في المقدرات شبه المعلمية وغيرها من الدوال لمعرفة كفاءة المقدرات في أنموذج انحدار.
  - 5- استعمال صيغ من دوال الانحدار اللامعلمية في المقدرات شبه المعلمية مثل Spline و Piecewise لمعرفة كفاءة المقدرات في أنموذج انحدار .



## المصادر:

## المصادر العربية

1. حمزة ، سعد كاظم ، (2009) ، "مقارنة بعض الطرائق اللبية في تقدير نماذج الانحدار اللامعلمية بوجود بيانات تامة وغير تامة " ، رسالة ماجستير في الإحصاء ، كلية الإدارة والاقتصاد ، جامعة بغداد .
2. حمود، مناف يوسف، (2000)، "مقارنة مقدرات kernel اللامعلمية لتقدير دوال الانحدار" ، رسالة ماجستير في الإحصاء ، كلية الإدارة والاقتصاد ، جامعة بغداد .
3. حمود، مناف يوسف، (2005)، "مقارنة المقدرات اللامعلمية لتقدير دوال الكثافة الاحتمالية" ، أطروحة دكتوراه في الإحصاء، كلية الإدارة والاقتصاد ، جامعة بغداد .
4. حمود، مناف يوسف ، "مقارنة المقدرات معلمية تمهيدية متغيرة باستخدام مقدرات انحدار خطي موضعي مع تطبيق عملي " .

## المصادر الأجنبية :

5. A. Ullah and H. D. Vinod,( 1993), General nonparametric regression estimation and testing in econometrics, in ``Handbook of Statistics'' (G. S. Maddala, C. R. Rao, and H. D. Vinod, Eds.), Vol. 11, pp. 85\_117.
6. Julian Faraway,(1990), " Implementing Semiparametric Density Estimation " , Statistics & Probability Letters 10- 141-143.
7. Fan. J and Gijbels .I,(1992)," Variable Bandwidth and Local Linear Regression Smoothers" Ann.stst.No-4.pp 2002-2036 .
8. Marlene Muller,(2000)," Semiparametric Extensions to Generalized Linear Models"
9. Mezbahur Rahman, Gokhale, D.V and Ullah, (1997),"A note on combining parametric and non-parametric regression" , Communications in Statistics - Simulation and Computation , 26:2, 519 -529 .
10. Mezbahur Rahman ; D. V. Gokhale ; Aman Ullah ,(1997)," On testimation of a probability density: the normal case" , Communications in Statistics - Theory and Methods,26:2,263 — 278 .
11. Olkin and C. H. Spiegelman, (1987), "A semiparametric approach to density estimation" , J. Amer. Statist. Assoc. 82 \_858\_865.
12. W.Hardle, and Muller, M. (2000)." Multivariate and Semiparametric kernel Regression", in M. G. Schimek (ed.), Smoothing and Regression. Approaches, Computation and Application, Wiley.
13. W. Härdle and Oliver Linton ,(1994)," Applied Nonparametric Methods " , Cowles Foundation For Research In Economics At Yale University .
14. Y. Fan and A. Ullah,(1999), "Asymptotic Normality of a Combined Regression Estimator", Technical Report, University of Windsor.
15. Paul Speckman , (1988) ," Kernel Smoothing in Partial Linear Models " , Journal of the Royal Statistical Society. Series B (Methodological), Vol. 50, No. 3 , pp. 413-436 .
16. Paul H. Kvam and Brani Vidakovic, (2007)," Nonparametric Statistics with Applications to Science and Engineering", A John Wiley & Sons, Inc., Publication.
17. P. M. Robinson, (1988)," Root-N consistent semiparametric regression", Econometrical 56, No. 4, 931\_954.