

استخدام مقدر (Nadaraya-Watson) كيرنل في تقدير دالة الانحدار الامثل

م.م محمد عبد الحسين محمد

هيئة التعليم التقني

المعهد التقني الديوانية

الملخص

تعد النماذج الامثل جزءاً مهماً من الاحصاء الامثل وهي تختلف عن النماذج المعلمية (*Parametric models*) في بناء هيكلية النموذج ، فهي لا تعتمد على محددات او فروض سابقة (*prior specified*) ولكنها تعتمد بشكل مباشر واساسي على البيانات (*Data*) ، كما ان مصطلح النماذج الامثل لا يعني أنها لا تتضمن على معلمات (*parameters*) ولكن طبيعة هذه المعلمات وعددتها يكون بشكل مرن (*flexible*) وغير ثابت (*not fixed*) ، لذلك يطلق على هذه النماذج بنماذج حررة التوزيع (*distribution free*). إن طرق الاستدلال الامثل هي عمليات رياضية لاختبار الفرضيات الاحصائية والتي لا تشترط وجود فرضيات حول التوزيعات التكرارية للمتغيرات ، لذلك فهي تكون أقل قوة من الاختبارات المعلمية ولكنها أكثر حصانة (*robust*) في حالة انتهاك الفروض الأساسية او عدم تتحققها . في هذا البحث تم تقدير دالة الانحدار الامثل بشكل مباشر دون الاعتماد على معلمات محددة باستخدام مجموعة من الطرائق الامثلية وهي طرائق ندارايا-واتسن وقد تم استخدام اسلوب المحاكاة في تطبيق طرائق التقدير وفي اجراء المقارنات .

[1],[2] المقدمة

ان نماذج الانحدار المعملي (*parametric regression*) تصف العلاقة بين متغير الاستجابة مع متغير واحد او مجموعة من المتغيرات التوضيحية وتستخدم هذه النماذج عندما توجد معلومات عن شكل هذه العلاقة وتحقق مجموعة من الافتراضات وتتم عملية تحليل هذه النماذج بتقدير معلمات النموذج باستخدام أي طريقة تقدير مناسبة مثل OLS او MLE ومن ثم تقدير دالة الانحدار وتكون نتائج التقدير هي منحنى يختار من مجموعة من المنحنيات ليطابق البيانات وان هذا الاختيار مقيد بشروط عديدة لمطابقة الاشكال المتوقعة ، أما الأسلوب الآخر في مطابقة المنحنيات للبيانات هو طرائق الانحدار الامثل (*nonparametric regression*) هذه الطرائق تسمح بمرونة عالية في الاشكال الممكنة لمنحنى الانحدار والافتراض على هذه الطرائق هو ان دالة العلاقة يجب ان تكون قابلة للاشتغال ، وان هذه الطرائق تعتمد بشكل رئيس على البيانات حيث ان نوع البيانات يفسر الشكل الفعلي لمنحنى الانحدار .

هدف البحث

ان هذا البحث يهدف الى تطبيق مجموعة من طرائق نداريا-واتنسن لتقدير دالة الانحدار الامثلية والتي لا تعتمد على معلمات محددة ومن ثم اجراء المقارنة بين الطرائق المستخدمة باستخدام اسلوب المحاكاة . (simulation)

[1],[2],[3]: Nonparametric Regression

ان نماذج الانحدار المعلمى التقليدى تكتب بالصيغة التالية

$$y_i = f(\beta_j x'_i) + \varepsilon_i$$

حیث ان :

y : المتغير التابع (متغير الاستجابة)

هو متوجه بمعلمات النموذج: $\beta_i = (\beta_1, \beta_2, \dots, \beta_k)$

(Observation) : هو متجه بمشاهدات المتغير التوضيحي $x'_i = (x_1, x_2, \dots, x_k)$

⁵ : الاخطاء العشوائية والتي يفترض ان تتوزع طبيعياً بمتوسط صفر وتبالن ثابت

اما نماذج الانحدار اللامعلمى، فهي تكتب بشكل عام بالشكل الآتى :

$$y_i = f(x'_i) + \varepsilon_i \quad \dots \quad 1$$

$$= f(x_{i1}, x_{i2}, \dots, x_{ik}) + \varepsilon_i$$

ان الانحدار الامثلمي هو احد اشكال تحليل الانحدار، لكنه لا يعتمد على نموذج ثابت ذي معلمات محددة وانما هو دالة تنشأ بموجب معلومات مستندة الى البيانات (*data*) وذلك لأنها الشيء الاساسي الذي يستند اليه في بناء النموذج ويستخدم الانحدار الامثلمي لتقدير دالة الانحدار (.)*f* بشكل مباشر وبدون وجود أي صيغة محددة لها وبعيداً عن تقدير معلمات النموذج كما هو الحال في الانحدار المعملي ، وان معظم طرائق الانحدار الامثلمي تفترض ان $(\epsilon_i)_{i=1}^n \sim NIID(0, \sigma^2)$ هي دالة مستمرة (*continuous function*) وممهدة (*smooth function*).

[1],[4],[6] (Kernel Regression) اندار کیرنل

ان انحدار كيرنل (*Kernel*) هو طريقة احصائية لامثلية لتقدير دالة التوقع الشرطي الهدف منه ايجاد علاقه لا خطية بين ازواج المتغيرات العشوائيه كما انه طريقة مبسطة لايجاد هيكلية او نمط البيانات بدون الحاجه الى انموذج معلمي عن طريق سلسله من الاوزان ، توصف دالة الوزن بواسطه دالة الكثافه مع معلمه قياس التي تعدل حجم وشكل الاوزان ، دالة الوزن هذه تسمى K (*kernel*) وهي دالة كثافه احتمالية حقيقية محددة مستمرة ومتقابلة حول الصفر تكاملها يساوي واحد فعلى فرض انه لدينا مجموعة من المشاهدات لمتغيرين عشوائين بشكل ازواج مرتبه وبالشكل الاتي :

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

فان دالة الانحدار کېرنل ھى:

حیث ان

Y: هو المتغير المعتمد (*depended variable*)

X: هو المتغير التوضيحي (*independend variable*)

وان سلسلة الوزن (w_i) لتقديرات كيرنل (kernel) كالاتي

$$w_i(x) = k_h(x - X_i) / \hat{f}_h(x)$$

حیث ان

h هو عدد موجب يمثل عرض الحزمة (*bandwidth*) .

تقدير دالة الكثافة $\hat{f}_h(x)$

تمثل دالة كيرنل K_h .

• مقدر کیرنل نداریا-واتسن [5],[6] (Nadaraya-Watson)

ان مقدر (Nadaraya-Watson) كيرنل للدالة f يمكن تعريفه بالصيغة الآتية :

حيث ان w_i تمثل اوزان تحسب من الصيغة الآتية :

تعريف : مقدر الدالة نوع *kernel* يعرف كما في الصيغة الآتية:

ان الحصول على مقدار k يعتمد على دالة كيرنل k (حيث ان هناك عدة دوال كيرنل يمكن اعتمادها) وعلى قيمة $bandwidth$ (حيث ان لكل دالة كيرنل هناك قيمة مثل L يمكن استخدامها) ، كما ان

$$\int_{\forall t} k(t)dt = 1 \quad 6$$

وذلك لأن مقدار *kernel* يمثل مقدار اصلي (*Bona fide*)

تعريف : ان مقدار الدالة الاحتمالية f والذى يكون غير سالب وتكامله واحد يدعى مقدار اصلي (Bona fide) وبعبارة اخرى :

$$\hat{f}(x) \geq 0 \quad , \quad x \in \chi$$

$$\int_{\mathbb{R}^d} \hat{f}(x) dx = 1$$

ولصعوبة الحصول على مقدر اصلي (*Bona fide*) غير متحيز يتم الاعتماد على ايجاد الاتي:

- مقدار $(Bona fide)$ يمتلك اقل mse .
 - متابعة $\{\hat{f}_n\}$ من المقدرات $(Bona fide)$ والتي تكون غير متحيزه بشكل محاذٍ $(asymptotically unbiased)$.

$$E|\hat{f}_n(x)| \rightarrow f(x), \quad x \in \chi \quad \text{as } n \rightarrow \infty$$

ولتحديد المقدار f . يمكن الاعتماد على أحد المعايير الآتية :

دورية فصلية علمية محكمة تصدر عن كلية الادارة والاقتصاد

- 1- متوسط مربعات الخطأ التجمعي (Mean Integrated Squared Error) (MISE)
 - 2- متوسط مربعات الخطأ التجمعي المحاذي (Asymptotic Mean Integrated (AMISE) Squared Error Integrated)

ان عرض الحزمة h (bandwidth) هو بمثابة ثابت التمهيد في المقدر \hat{f} فعندما تكون قيمة صغرى
فان منحني الدالة يكون خشن (غير ممهد) (rough currey) اما عندما تكون قيمة كبيرة نسبياً فسوف
يكون المنحني اكثراً تمهيداً (more smoother). ونظراً لأهمية ثابت التمهيد h في الحصول على مقدر
 \hat{f} لذلك يمكن تعريف متوسط مربعات الخطأ التجميعي المحاذى كدالة في h

$$\left\{ AMISE_{\hat{f}_n}(h) \right\}$$
 وحسب الصيغة التالية:

حیث ان

: تمثل دالة كيرنل بمتوسط $M_k = 0$ وتبين محدد هو K

$$\sigma_k^4 = \int x^2 k(x) dx \quad , \quad 0 < \sigma_k^2 < \infty \quad 8$$

و ان

$R(f)$: تمثل مقياس الخشونة للدالة f والذى يحسب من

$$R(f) = \int (f(x))^2 dx \quad 9$$

تمثيل تباین k اذ ان: $S(k)$

$$S(k) = \int k^2(x) dx \quad \dots \dots \dots \quad 10$$

ان القيمة المثلث لـ h (*Optimal bandwidth*) والتي تؤدي الى تصغير قيمة $\{AMISE_{\hat{f}_n}(h)\}$ يمكن الحصول عليها من الصيغة الآتية:

$$h^* = \left(\frac{S(k)}{n\sigma_k^4 R(f)} \right)^{\frac{1}{5}} \quad \dots \dots \dots \quad 11$$

حپث ان

. (Optimal bandwidth) هو h^*

ووفق ذلك فإن متوسط مربعات الخطأ التجميعي المحاذي والذي يمكن استخدامه في التطبيقات العملية يحسب بالشكل الآتي:

$$h^* = \left(\frac{3}{4n}\right)^{\frac{1}{5}} \sigma \quad \dots \dots \dots \quad 12$$

[3],[4],[5] (Nadaraya Watson) حدود الثقة لمقدر (ناداري- واتسن) باحتمال $(1 - \alpha)$ هي :
ان حدود الثقة لمقدر (ناداري- واتسن) باحتمال $(1 - \alpha)$ هي :

$$\left. \begin{array}{l} \ell_n = \hat{f}(x) - q\hat{s}e(x) \\ u_n(x) = \hat{f}(x) + q\hat{s}e(x) \end{array} \right\} \dots\dots\dots 13$$

حپٹ ان

$$\hat{Se}(x) = \hat{\sigma} \sqrt{\sum_{i=1}^n w_i^2(x)}$$

$w = 3h$, h is abandwidth

$$\hat{\sigma}^2 = \frac{1}{2(n-1)} \sum_{i=2}^{n-1} (y_{i+1} - y_i)^2$$

$$q = \phi^{-1}\left(\frac{1 + (1 - \alpha)^{1/n}}{2}\right)$$

بعض دوال ندارايا- واتسن (*Nadaraya Watson*) الشائعة: [5],[6]

سوف نتناول بعض دوال نداريا- واتسن الشائعة حيث تم اخذ القيم المثلثي h

دورة فصلية علمية محكمة تصدر عن كلية الادارة والاقتصاد

الدوال هي : *Optimal bandwidth*) المحسوب وفق المعادلة رقم (11) في حساب كل من هذه الدوال ،واهم هذه

- 1 دالة *Uniform* وصيغتها هي :

-2 دالة Triangle وصيغتها هي:

$$\hat{f}(x) = (1 - |u|) \quad |u| \leq 1$$

-3 دالة *Epanechnikov* وصيغتها هي :

$$\hat{f}(x) = \frac{3}{4}(1-u^2) \quad |u| \leq 1 \quad \dots \dots \dots \quad 16$$

-4 دالة *Quadratic* وصيغتها هي :

$$\hat{f}(x) = \frac{15}{16}(1-u^2)^2 \quad |u| \leq 1 \quad \dots \dots \dots \quad 17$$

-5 دالة *Triweight* وصيغتها هي:

$$\hat{f}(x) = \frac{35}{32} (1 - u^2)^3 \quad |u| \leq 1 \quad \dots \dots \dots \quad 18$$

-6 دالة Gaussian وصيغتها هي :

دالة Cosinus و صيغتها هي : -7

حيث ان : $(\frac{x - x_i}{h}) = u$ في جميع الصيغ اعلاه .

الجانب التجريبي:

تم استخدام المحاكاة (*Simulation*) في توليد المشاهدات الخاصة بالدراسة وحسب احجام العينات ($n=25,50,75,100,120$) ، وذلك بفرض ان الخطأ يتوزع حسب التوزيع الطبيعي، بمتوسط مساو الى

الصفر وتباين σ^2 ، وقد تم تطبيق طرائق نداريا-واتسن المذكورة في الجانب النظري ولكلية احجام العينات واعتمد معيار mse في المفاضلة بين طرائق التقدير، وحسب الخطوات الآتية:

-1 توليد مشاهدات الخطأ العشوائي حسب التوزيع الطبيعي وذلك على فرض ان:

$$\varepsilon \sim N(0, \sigma_\varepsilon^2)$$

-2 افتراض دالة معينة بالمتغير العشوائي X .

-3 حساب قيم للمتغير المعتمد Y حسب المعادلة رقم

(1)

-4 تطبيق طرائق نداريا-واتسن المذكورة في الجانب

النظري لتقدير الدالة $f(x)$ ، فمثلاً لتطبيق طريقة *Epanechnikov* الموصوفة في المعادلة رقم (16) يكون بالشكل الآتي:

$$\hat{f}(x) = \sum w_i(x) y_i$$

$$w_i(x) = \frac{k_e(u)}{\sum k_e(u)}$$

$$k_e(u) = k_e\left(\frac{x - x_i}{h_e}\right) = \begin{cases} \frac{3}{4}\left(1 - \left(\frac{x - x_i}{h_e}\right)^2\right) & \text{if } \left|\frac{x - x_i}{h_e}\right| \leq 1 \\ 0 & \text{otherwise} \end{cases}$$

حيث ان :

(2) $k_e(u)$: دالة (نداريا-واتسن كيرنل) *Epanechnikov*

h_e : ثابت التمهيد (*bandwidth*) للدالة *Epanechnikov*

-5 حساب معيار mse حسب الصيغة الآتية :

$$mse = \frac{\sum [f(x) - \hat{f}(x)]^2}{n-2}$$

(1) المقارنة بين طرائق التقدير نداريا-واتسن حسب معيار mse والنتائج موضحة في الجدول رقم

-6 تم اعادة تجربة المحاكاة لكل حالة 500 مرة لضمان العشوائية .

-7 جدول رقم (1)

يمثل قيم mse لدوال نداريا- واتسن عند احجام عينات مختلفة وقيمة مثلی L

<i>n</i>	<i>mse</i>						
	<i>Uniform</i>	<i>Triangle</i>	<i>Epanech.</i>	<i>Quartic</i>	<i>Triweight</i>	<i>Gaussian</i>	<i>Cosinus</i>
25	9.914	8.566	7.509	7.972	7.592	3.827	8.261
50	2.763	2.244	1.567	1.919	1.673	0.825	2.060
75	2.021	1.332	1.122	1.208	1.083	0.170	1.247
100	1.633	2.286	2.594	2.042	1.303	0.025	1.282
120	0.325	0.325	0.700	0.415	0.168	0.021	0.223

تحليل النتائج

من خلال الجدول رقم (1) نلاحظ الآتي:

- عند الحجم $n=25$ نجد ان قيم mse مرتفعة نسبياً لكافة طرق نداريا-واتسن مقارنة مع باقي احجام العينات ، كما نجد ان هناك افضلية واضحة لطريقة *Gaussian* في التقدير على حساب بقية الطرائق المستخدمة حيث كانت قيمة mse لهذه الطريقة 3.827 بينما كانت اقل قيمة لبقية الطرق الاخرى هي 7.509 لطريقة *Epanechenikov*.
- عند الاحجام $n=50,75,100$ وبالرغم من وجود تحسن كبير في اداء كافة الطرائق مع زيادة احجام العينات، الا اننا في نفس الوقت نجد ان هناك تذبذب في اداء هذه الطرائق وهذا واضح من خلال قيم mse ، فتارة نجدها تنخفض مع زيادة حجم العينة وتارة اخرى نجد ان قيمه ترتفع مع زيادة حجم العينة ، وعموماً تبقى طريقة *Gaussian* هي الافضل فعند الحجم $n=100$ كانت قيمة mse هي 0.025 بينما اقل قيمة لبقية الطرائق هي 1.303 لطريقة *Triweight*.
- عند الحجم $n=120$ نجد ان هناك تحسناً كبيراً في اداء كافة الطرائق وهذا واضح من انخفاض قيم mse وهذا يعني ان هذه الطرق كفؤة في العينات الكبيرة

الاستنتاجات

- ان لزيادة حجم العينة دور كبير في تحسن اداء طرق نداريا-واتسن وهذا ناتج من اعتماد هذه الطرائق على معلومات العينة فكلما زاد حجم العينة زادت دقة التقدير.
- ان طرائق نداريا-واتسن هي طرق كفؤة في التقديرات الامثلية في العينات الكبيرة وهذا واضح من خلال انخفاض قيم mse لكافة الطرائق مع زيادة عدد البيانات .
- بشكل عام نجد ان طريقة *Cosinus* هي افضل طرق نداريا-واتسن (التي تم دراستها) في التقدير.

النوصيات

١- التعرف على كفاءة طرق نداريا- واتسن وذلك بمقارنتها مع طرق لامعلمية اخرى مثل طريقة C.V او طريقة الانحدار الخطى الموضعى (L.L.R) (Cross Validation)

المصادر References

- ١- يوسف ، خلود يوسف خمو يوسف ،(٢٠٠٤) "مقارنة اساليب بييز مع طرائق اخرى لتقدير منحنى الانحدار الامعلمى" اطروحة دكتوراه في الاحصاء ، كلية الادارة والاقتصاد ، جامعة بغداد
- 2- John Fox.(2002), "Nonparametric Regression ",Appendix to an R and s-plus Companion to Applied Regression.
- 3- John Fox.(2004), "Nonparametric Regression", McMaster ,Hamilton,Canada. E-mail jfox@mcmaster.ca
- 4- Li,Qi;racine,Jeffrey s.(2007), "Nonparametric Econometrics:Theory and practice ",Princeton University.
- 5- M. Amalia and Ricardo Cao(2005), "Comparison of Nadaraya-Watson and local linear methods ",Uiniversiry de Vigo (Spain). E-mail : amaliajp@uvigo.es
- 6- Nageswara S.V.Rao.(1996) "Nadaraya-Watson Estimator for Sensor Fusion problem ",center for Engineering system advanced Research ,Oak Ridge National Laboratory.