

أسلوب مقترن في تقدير القيم المفقودة في نموذج الانحدار المتعدد اللامعلمي

أ.م.د. قتيبة نبيل نايف القزاز، كلية الادارة والاقتصاد / جامعة بغداد

المستخلص

في هذا البحث سوف نقدم أسلوب مقترن في تقدير القيم المفقودة لمشاهدات المتغيرات التوضيحية لنموذج الانحدار المتعدد اللامعلمي ومقارنتها مع طريقة التعويض بالوسط الحسابي، أن أساس فكرة هذا الأسلوب استندت الى كيفية توظيف العلاقة السببية بين المتغيرات في ايجاد تقدير كفؤ للقيمة المفقودة، معتمدين في ذلك على استعمال تقدير Kernel والمتمثل بمقدار Nadary - Watson - Nadary و على طريقة المرربعات الصغرى للعبور الشرعي LSCV في تقدير المعلمة التمهيدية، ومستخدمين اسلوب المحاكاة في المقارنة بين الطريقتين.

المصطلحات الرئيسية للبحث / الانحدار المتعدد اللامعلمي- المشاهدات المفقودة- آلية فقدان- نمط فقدان- مقدر Nadary – Watson - المرربعات الصغرى للعبور الشرعي





المقدمة

من المشاكل التي تواجه البيانات ولاسيما بيانات نماذج الانحدار المتعدد اللامعجمي، وجود فقدان في مشاهدات المتغيرات التوضيحية (X^s) بشكل انماط مختلفة لفقدان ويسبب آليات مختلفة لفقدان أيضاً. لقد شهدت مشكلة فقدان اهتماماً واسعاً في بداية السبعينيات لما شهدته هذه الفترة من تطور ملحوظ في اجهزة الحاسوب وبرامجه، ولقد اسهم العديد من الباحثين من امثال Rubin , Demprster & Laird الذين يدعون من الرواد الأولئ، في تطوير وايجاد طائق كفوعة في تقدير القيم المفقودة في شتى بيانات البحث العلمي خلال الأربعين سنة المنصرمة. كما ان هناك العديد من طائق تقدير القيم المفقودة وكل طريق لها شروطها في الاستعمال وبحسب نمط فقدان وأليته، ومن الطائق المتدالوة في تقدير القيم المفقودة لمشاهدات المتغيرات التوضيحية X^s لنموذج الانحدار المتعدد اللامعجمي وعند آلية فقدان من نوع " فقدان البيانات تماماً بشكل عشوائي" Missing Complete At Random (MCAR)، هي طريقة التعويض بالوسط الحسابي اذ تُعد هذه الطريقة من طائق التعويض الاحادية Single Imputation ، ولم يُعاب على هذه الطريقة، ضعف كفالتها عند نسب فقدان عالية من جهة، ومن جهة اخرى ضعف العلاقة السببية بين المتغيرات التي تؤدي الى فشل هذه الطريقة في التقدير أيضاً.

وفي ضوء هذه المشكلتين التي تواجه طريقة التعويض بالوسط الحسابي، انبثقت فكرة هذا البحث بتوظيف اسلوب جديد ضمن هذه الطريقة لغرض زيادة كفالتها، والمتمثل باستعمال طريقة تقدير Kernel في تقدير القيم المفقودة في المتغيرات التوضيحية X^s .

سيتم في هذا البحث عرض طريقة المتوسط الشرطي في تقدير القيم المفقودة لمشاهدات المتغيرات التوضيحية X^s ومن ثم عرض مفصل لكيفية توظيف تقدير Kernel Nadary - Watson والمتمثل بمقدار Kernel في تقدير القيمة المفقودة لمشاهدات المتغيرات المستقلة، ومن ثم استعراض طريقة المربعات الصغرى للعبور الشرعي (LSCV) في تقدير المعلمة التمهيدية في مقدار Nadary – Watson ، ومن ثم تتم المقارنة بين الطريقتين باستعمال المحاكاة.

الجانب النظري : في بعض الظواهر التي يتم دراستها والتي يمكن تمثيلها بمنحنى الانحدار لوصف العلاقة بين المتغيرات التوضيحية X^s ومتغير الاستجابة Y والتي تتم الحصول عليها من عينة حجمها n، فإن هذه العلاقة (علاقة تأثير) بين هذه المتغيرات والتي يمكن وصفها بالنموذج الآتي:

$$Y_i = g(X_{1i}, X_{2i}, X_{3i}, \dots, X_{ki}) + \varepsilon_i ; \quad i = 1, 2, 3, \dots, n \quad (1)$$

وان الصيغة (1) تمثل نموذج الانحدار المتعدد اللامعجمي Nonparametric Multiple Regression وان K تمثل عدد المتغيرات المستقلة وأن $g(X_{1i}, X_{2i}, X_{3i}, \dots, X_{ki})$ تمثل دالة الانحدار المجهولة والتي يتم افتراضها دالة مستمرة، وأن ε_i يمثل الخطأ العشوائي بمتوسط مساواً للصفر وتباعي مقدار σ^2 .

أن مشكلة المشاهدات المفقودة في المتغيرات التوضيحية من المشاكل التي تواجه الباحثين في شتى المجالات، لذلك فان هذه المشكلة لها تأثير كبير في نتائج معادلة الانحدار التقديرية وعليه يجب تقدير هذه القيم قبل البدء في تقدير معادلة الانحدار، ولغرض دراسة اساليب تقدير المشاهدات المفقودة في اي متغير مستقل (أو متغيرات مستقلة) سنقوم اولاً باستعراض آليات وانماط فقدان ومن ثم نستعرض اسلوب الوسط الحسابي في تقدير القيم المفقودة وبعد ذلك س يتم توضيح آلية توظيف مقدر Kernel في التقدير مع توضيح طريقة المربعات الصغرى للعبور الشرعي LSCV في تقدير معلمة التمهيد.

القيم المفقودة : أن فقدان المشاهدات في أية ظاهرة معينة من الأمور المسلم بها ويعود ذلك لأسباب عديدة ومتعددة عديدة كانت أم غير عدية ولكن بصورة عامة هناك آليات وانماط لهذه المشكلة، ولغرض التطرق لهذه الآليات والأنماط نفترض لدينا المتغيرات المستقلة X^s مع المتغير المعتمد Y وكما يأتي:(القازار، صفحة ٨ - ١١)^[1]

$$Y \quad X_1, X_2, X_3, \dots, X_k$$



أن آلية فقدن تتمحور على ثلاثة أنواع هي:

١. **الآلية الأولى:** فقدان البيانات تماماً بشكل عشوائي Missing Complete at Random ويرمز لها MCAR، ويعني ان سبب فقدان أية مشاهدة لمتغير مستقل معين يكون مستقل عن القيمة المفقودة نفسها وكذلك عن قيم اي متغير مستقل اخر (او متغيرات مستقلة اخرى).

٢. **الآلية الثانية:** فقدان البيانات بشكل عشوائي Missing At Random ويرمز لها MAR، هنا سبب فقدان اي مشاهدة لمتغير مستقل معين يعتمد على مشاهدات المتغير المستقل الآخر (او المتغيرات المستقلة الأخرى) ولكن مستقل عن المشاهدة المفقودة نفسها.

٣. **الآلية الثالثة:** فقدان البيانات بشكل غير عشوائي Missing At Not Random ويرمز لها Not MAR، هذا يعني ان سبب فقدان اية مشاهدة لمتغير مستقل معين يعتمد على مشاهدات المتغير المستقل الآخر (او المتغيرات المستقلة الأخرى) وكذلك يعتمد على القيمة المفقودة نفسها.

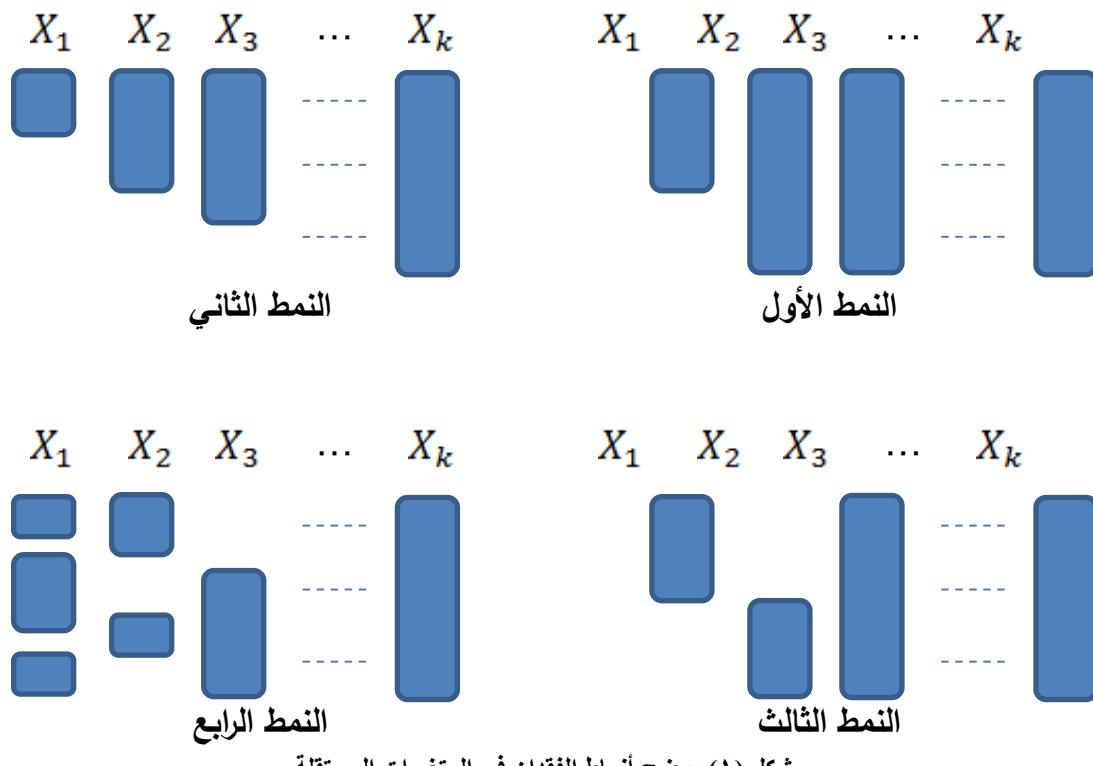
اما الأنماط الخاصة بالفقدان فهي أربعة انواع وكما يأتي:

النمط الأول: فقدان مشاهدات متغير مستقل واحد، في هذه الحالة يكون فقدان في مشاهدات أحد المتغيرات المستقلة وباقى المتغيرات تكون تامة المشاهدات.

النمط الثاني: فقدان المشاهدات بشكل مرتب لبعض المتغيرات المستقلة، في هذا النمط يكون ترتيب المشاهدات المفقودة لبعض المتغيرات المستقلة بشكل تصاعدي أو تنزالي.

النمط الثالث: فقدان المشاهدات بشكل عدم تطابقها لمتغيرين مستقلين، في هذا النمط يكون فقدان في متغيرين فقط اذ يكون هناك فقدان في مشاهدات المتغير الأول يقابلها مشاهدات تامة في المتغير الثاني، كذلك فان المشاهدات المفقودة في المتغير الثاني يقابلها مشاهدات تامة في المتغير الأول.

النمط الرابع: النمط العام، في هذا النمط لا يمكن وضع شكل معين للمشاهدات المفقودة بل تكون بشكل عشوائي ومبشرة.



شكل (١) يوضح أنماط فقدان في المتغيرات المستقلة



طرائق تدبير القيم المفقودة: سوف نستعرض طرفيتين في تدبير القيم المفقودة لمشاهدات المتغيرات التوضيحية X^s والمتمثلة بطريقة التعويض بالوسط الحسابي وطريقة التعويض بتدبير Kernel كأسلوب مقترن تحت آلية فقدان من نوع MCAR .

أولاً: التعويض بالوسط الحسابي: تعد هذه الطريقة من اقلم طرائق التعويض الأحادي Single Imputed وابسطها اذ يتم حساب متوسط مشاهدات المتغير الذي يعاني من فقدان في مشاهداته، ويتم تعويض هذا المتوسط بدلاً عن القيمة المفقودة، لو فرضنا أن المتغير المستقل X_j يعني فقدان في بعض مشاهدته فإنه يمكن حساب متوسط مشاهدات هذا المتغير بحسب الصيغة الآتية:

$$\bar{X}_j = \frac{\sum_{r=1}^m X_{jr}}{m_j} ; \quad r = 1, 2, 3, \dots, m_j ; \quad j = 1, 2, 3, \dots, k \quad \dots (2)$$

حيث أن m_j يمثل عدد المشاهدات في المتغير التوضيحي X_j بعد استبعاد عدد المشاهدات المفقودة، اي ان m_j هي مجموعة جزئية من المشاهدات الكلية n اي بصورة اخرى $m_j \subseteq n$ ان طريقة التعويض بالمتوسط تعد من اكفاء الطرائق في التقدير ولاسيما في حالة تجانس بيانات العينة وضعف العلاقة السببية بين المتغيرات التوضيحية في معادلة الانحدار، وكذلك تبرز كفانتها في حالة نسب الفقدان الصغيرة، ولكن تفشل هذه الطريقة في حالة نسب الفقدان الكبيرة وكذلك عند وجود علاقة سببية بين المتغيرات التوضيحية.

ثانياً: التعويض باستعمال تدبير Kernel: في عام عام ١٩٩٢ قدم الباحث Little^[5] بحثاً وضح فيه اسلوب تدبير المشاهدات المفقودة لأحد المتغيرات التوضيحية في نموذج الانحدار المتعدد المعلمي باستعمال اسلوب التعويض بالمتوسط الشرطي الذي يتم الحصول عليه من خلال بناء نموذج انحدار بين المتغير التوضيحي الذي تعاني مشاهداته من فقدان مع بقية المتغيرات التوضيحية وتوصيل الى كفاءة هذا المقدر تقل عند نسب الفقدان العالية وكذلك عند ضعف العلاقة السببية بين المتغيرات التوضيحية. كذلك في عام ٢٠٠٨ قدم الباحثان قتيبة ومناف^[2] بحثاً حول تدبير القيم المفقودة في مشاهدات متغير الاستجابة Y لنموذج الانحدار البسيط اللامعجمي وبالاعتماد على تعويض مقدر قاعدة Kernel الاحادي بدلاً عن القيمة المفقودة، اذا اظهر هذا الاسلوب كفاءة عالية في التقدير.

ومما سبق فإن فكرة الاسلوب المقترن في هذا البحث هو الحصول على مقدرات للقيم المفقودة تكون ذات كفاءة عالية في حالة نسب الفقدان الكبيرة وفي حالة النشت الكبیر في مشاهدات المتغيرات وكما يأتي: لو فرضنا انه لدينا متغيرين توضيحيين هما X_1, X_2 يؤثران في المتغير المعتمد Y فان نموذج الانحدار المتعدد اللامعجمي هو :

$$Y_i = g(X_{1i}, X_{2i}) + \varepsilon_i ; \quad i = 1, 2, 3, \dots, n \quad \dots (3)$$

ولو فرضنا ان المتغير X_2 يعني من فقدان في بعض مشاهداته، ولغرض تدبير هذه المشاهدات يتم بناء نموذج انحدار لامعجمي للمتغير X_2 مع المتغير X_1 وبحسب الصيغة الآتية:

$$X_{2i} = g(X_{1i}) + \varepsilon_i ; \quad i = 1, 2, 3, \dots, n \quad \dots (4)$$

حيث أن ε_i يمثل الخطأ العشوائي المجهول لاستجابة X_{2i} كذلك ان الصيغة (4) سوف تحتوي على حالة استجابة وعدم استجابة للمتغير X_2 والتي يرمز لها بالرمز γ بحيث ان :

$$\gamma_i = \begin{cases} 1 & \text{if } X_2 \text{ is response} \\ 0 & \text{if } X_2 \text{ is not response} \end{cases}$$

وعليه فان المعادلة التقديرية للصيغة (4) يمكن الحصول عليه كما يأتي :

$$\hat{X}_{2i} = \hat{g}(X_{1i}) + \hat{\varepsilon}_i ; \quad i = 1, 2, 3, \dots, n \quad \dots (5)$$



حيث أن $\hat{\varepsilon}_i$ هي الفرق بين $\hat{g}(X_{1i})$ و $g(X_{1i})$ أما $\hat{g}(X_{1i})$ تم الحصول عليها بحسب قاعدة Kernel (Nadary – Watson) ومقدار $\hat{g}(X_{1i})$:

$$\hat{g}(X_{1i}) = \frac{\sum_{i=1}^n \gamma_i X_{2i} k\left(\frac{X_1 - X_{1i}}{h}\right)}{\sum_{i=1}^n \gamma_i k\left(\frac{X_1 - X_{1i}}{h}\right) + n^{-2}} \quad \dots (6)$$

وعليه فان الصيغة (5) تحتوي على مشاهدات تامة للمتغير X_{2i} , بعد ذلك يتم استبدال قيمة \hat{X}_{2i} بدل القيمة المفقودة في المتغير X_{2i} فيصبح لدينا متغير جديد بمشاهدات تامة نرمز له \tilde{X}_{2i} ومن ثم يتم اعادة كتابة الصيغة (5) كما يلى:

$$\tilde{X}_{2i} = g(X_{1i}) + \hat{\varepsilon}_i ; \quad i = 1, 2, 3, \dots, n \quad \dots (7)$$

ان السبب في اعادة بناء الصيغة (7) هو لتمهيد البيانات التي تم تقديمها بدل القيم المفقودة في المتغير X_{2i} لغرض الحصول على مقدارات اكثر كفاءة بالاعتماد على العلاقة السببية بين المتغيرات، وباستعمال مقدر Nadary – Watson مرة ثانية وللمشاهدات التامة للمتغيرين X_{1i} و \tilde{X}_{2i} وبحسب الصيغة الآتية:

$$\hat{g}(X_{1i}) = \frac{\sum_{i=1}^n \tilde{X}_{2i} k\left(\frac{X_1 - X_{1i}}{h}\right)}{\sum_{i=1}^n k\left(\frac{X_1 - X_{1i}}{h}\right) + n^{-2}} \quad \dots (8)$$

نحصل على تقدير جديد للمتغير \tilde{X}_{2i} هو :

$$\hat{\tilde{X}}_{2i} = \hat{g}(X_{1i}) ; \quad i = 1, 2, 3, \dots, n \quad \dots (9)$$

ومن ثم نقوم باستبدال $\hat{\tilde{X}}_{2i}$ بدلأ عن القيمة المفقودة في X_{2i} ، تجدر الاشارة هنا أن $k(\cdot)$ في الصيغة (6) و (8) تمثل دالة لبيبة والتي يمكن الحصول عليها من دالة الكثافة الطبيعية القياسية او ما يطلق عليها باسم Gaussian Kernel وبحسب الصيغة الآتية:

$$k(z) = \sqrt{2\pi} \exp\left(-\frac{z^2}{2}\right) \quad \dots (10)$$

اما h في الصيغة (6) و (8) فتمثل المعلمة التمهيدية او معلمة عرض الحزمة (Bandwidth)، وهناك طرائق مختلفة في تقديره فقد استعمل قتبية ومناف^[2] صيغة المصدر الطبيعي وكما يلى :

$$h = 1.06 \sigma n^{-1/5} \quad \dots (11)$$

في بحثنا هذا سوف نستعمل طريقة تقدير اكثر كفاءة من صيغة المصدر الطبيعي وهي طريقة المربعات الصغرى للعبور الشرعي Least Squared Cross Validation (LSCV).

طريقة المربعات الصغرى للعبور الشرعي LSCV : ان أساس فكرة طريقة المربعات الصغرى تعتمد على تصغير تكامل مربعات الخطاء بين دالة القيم الحقيقة والتقديرية اي أن:

$$[\text{Horne \& Garton : p.641-642}] \int (\hat{f}(X_i) - f(X_i)) dx^2 = \int \hat{f}^2(X_i) dx - 2 \int \hat{f}(X_i) f(X_i) dx + \int f^2(X_i) dx$$

وفي عام ١٩٨٢ توصل الباحث Silverman الى صيغة تقريبية لصيغة السابقة وهي:

$$LSCV(h) = \int \hat{f}^2(X_i) dx - 2n^{-1} \sum \hat{f}_{-i}(X_i) \quad \dots (12)$$



اذ تمثل الصيغة (12) مجموعة قيم للمعلمة h بطريقة المربعات الصغرى للعبور الشرعي.
وأن \hat{f}_{-i} هي تقدير دالة الكثافة عند حذف المشاهدة i . في عام ١٩٩٢ توصل Worton الى قيم للمعلمة h في الصيغة (12) وكما يلى:^[4]

$$LSCV(h) = \frac{1}{\pi h^2 n} + \frac{1}{4\pi h^2 n^2} \times \sum_{i=1}^n \sum_{j=1}^n \left(\exp \left[\frac{-d_{ij}^2}{4h^2} \right] - 4 \exp \left[\frac{-d_{ij}^2}{2h^2} \right] \right) \dots (13)$$

حيث ان d_{ij}^2 تمثل المسافة بين الموقعين i^{th} و j^{th} للمشاهدات أما قيمة h فتحسب من الصيغة (11)، وللحصول على قيمة h المثلث من الصيغة (13) يكون بحسب الصيغة الآتية:

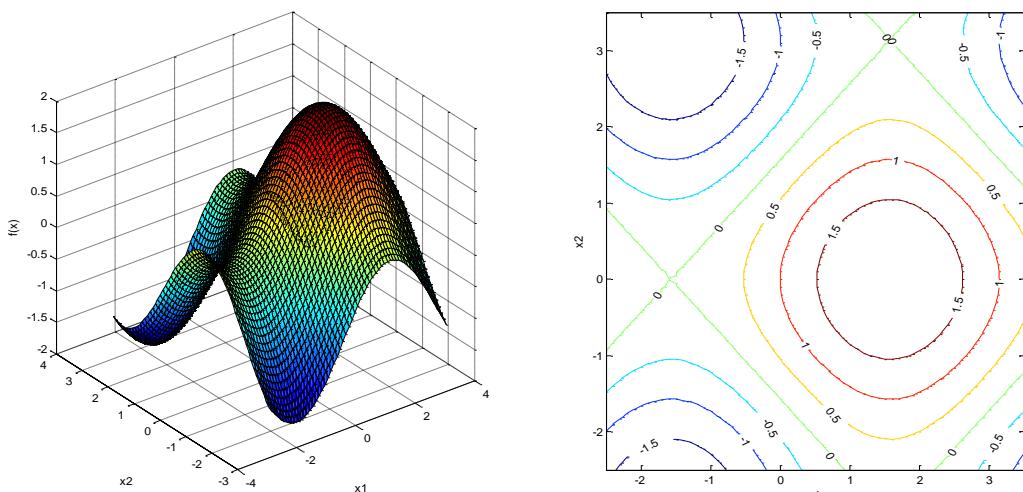
$$\hat{h}_{LSCV} = \operatorname{argmin}_h LSCV(h) \dots (14)$$

الجانب التجربى : لغرض معرفة كفاءة الأسلوب المقترن والمتمثل بتعويض مقدر Nadary - Watson عن القيم المفقودة بالنسبة لطريقة التعويض بالوسط الحسابي وبيان تأثير هذه الطرائق بنسب الفدانا وأختلف حجوم العينة وتغير قيم التباينات والأرتباط تم اللجوء الى اسلوب المحاكاة وكما يأتى:

أولاً: تم استعمال نموذج الانحدار المتعدد اللامعملي الآتى:

$$Y_i = \sin(X_{1i}) + \cos(X_{2i}) + \varepsilon_i \dots (15)$$

والشكل رقم (2) يمثل الرسم البياني لهذا النموذج.



شكل (٢) يوضح الشكل البياني لنموذج الانحدار المتعدد اللامعملي في الصيغة (15)

ثانياً: توليد توزيع طبيعي ثانى المتغيرات باستخدام دالة التوليد (mvnrnd) المتوفرة في البرنامج الجاهز Mat lab، وتم استخدام تباينات مختلفة للمتغيرات المستخدمة وهي على التوالي :
 $X \sim N \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} \right); X \sim N \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 2 & \rho\sqrt{6} \\ \rho\sqrt{6} & 3 \end{pmatrix} \right); X \sim N \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 3 & \rho\sqrt{15} \\ \rho\sqrt{15} & 5 \end{pmatrix} \right)$



وقد تم استعمال قيم مختلفة للارتباطات هي $\rho = 0.20, 0.50, 0.90$ كذلك تم استخدام حجم مختلف للعينات $n = 15, 40, 100$

ثالثاً: تم توليد مصفوفة فقدان تحت شرط الـ MCAR^[1] وللنطاق الأول وبنسبة فقدان (10%, 20%, 30%, 40%).

رابعاً: ولغرض المقارنة تم استعمال معيار متوسط مربعات الخطأ MSE.

والجدول الآتي يوضح نتائج المحاكاة على وفق المعطيات المذكورة آنفًا، كذلك تم عرض بعض الاشكال لعدد من الحالات المستخدمة.

جدول (١)

يبين قيمة متوسط مربعات الخطأ لتقدير دالة الانحدار المتعدد اللامعجمي في الصيغة (15) وبحسب النطاق الأول للقيم المفقودة وقيم التباينات وحجم العينات المستخدمة ونسبة فقدان (العدد الناتج مضروب في ١٠٠٠)

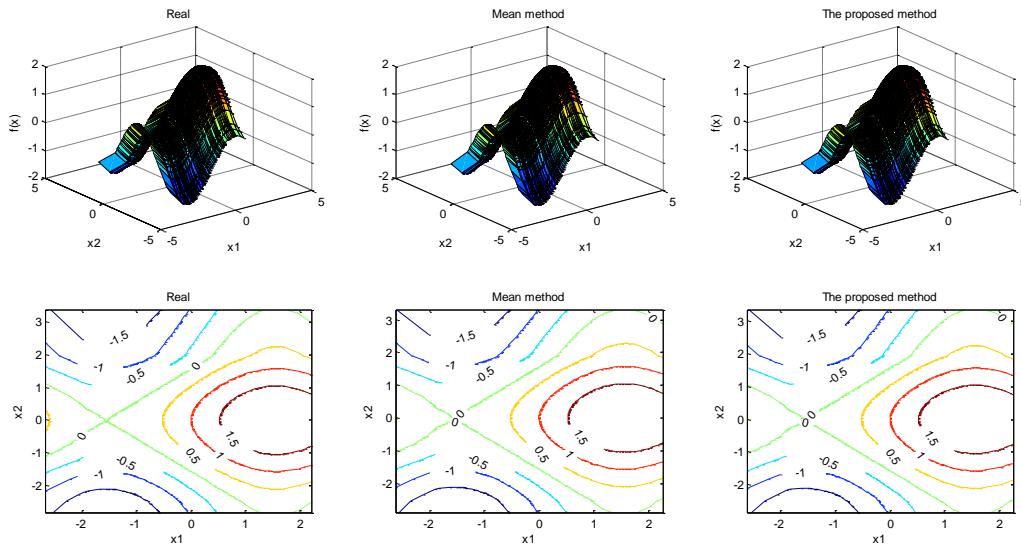
Missing		10%									20%								
n	ρ	0.2			0.5			0.9			0.2			0.5			0.9		
	σ_1^2	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3
	σ_2^2	1	3	5	1	3	5	1	3	5	1	3	5	1	3	5	1	3	5
15	Mean Method	453	1224	1521	442	1248	1502	421	1288	1493	645	1800	2190	644	1795	2129	689	1797	2188
	Proposed method	515	1136	1202	432	941	1126	105	360	564	770	1672	1922	595	1397	1727	168	510	879
40	Mean Method	365	986	1231	347	975	1228	350	995	1228	647	1973	2456	686	1982	2454	680	1946	2387
	Proposed method	402	846	974	298	685	875	84	258	394	763	1626	1897	600	1430	1767	163	522	816
100	Mean Method	359	1020	1296	357	1011	1296	343	1061	1299	686	2097	2590	689	2025	2594	686	2058	2579
	Proposed method	399	828	958	308	706	877	79	267	414	767	1641	1913	607	1425	1753	160	514	803
Missing		30%									40%								
n	ρ	0.2			0.5			0.9			0.2			0.5			0.9		
	σ_1^2	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3
	σ_2^2	1	3	5	1	3	5	1	3	5	1	3	5	1	3	5	1	3	5
15	Mean Method	1100	2954	3560	1066	2970	3441	1085	2959	3441	1279	3456	4240	1301	3407	4132	1276	3482	4228
	Proposed method	1293	2705	3269	989	2389	2900	264	2361	2765	1477	3325	3741	1214	2788	3426	330	1052	1626
40	Mean Method	1049	2950	3607	1016	2911	3596	1022	2895	3564	1357	3893	4734	1323	3879	4752	1371	3838	4739
	Proposed method	1159	2440	2840	917	2076	2625	240	756	1211	1531	3285	3812	1189	2820	3480	318	1036	1619
100	Mean Method	1045	3077	3848	1069	3088	3810	1052	3091	3836	1398	4050	5038	1380	4087	5073	1386	4033	5042
	Proposed method	1159	2485	2871	935	2120	2579	243	776	1221	1527	3295	3770	1239	2849	3521	328	1031	1601

شكل رقم (٣)

يشير إلى القيم الحقيقية والقيم التقديرية لقيم المفقودة لنموذج الانحدار المتعدد اللامعجمي وبحسب النطاق الأول عند حجم عينة $n = 100$ ونباعات $1 = \sigma_1^2 = 1, \sigma_2^2 = 1$ ودرجة ارتباط $\rho = 0.50$ ونسبة فقدان 10%

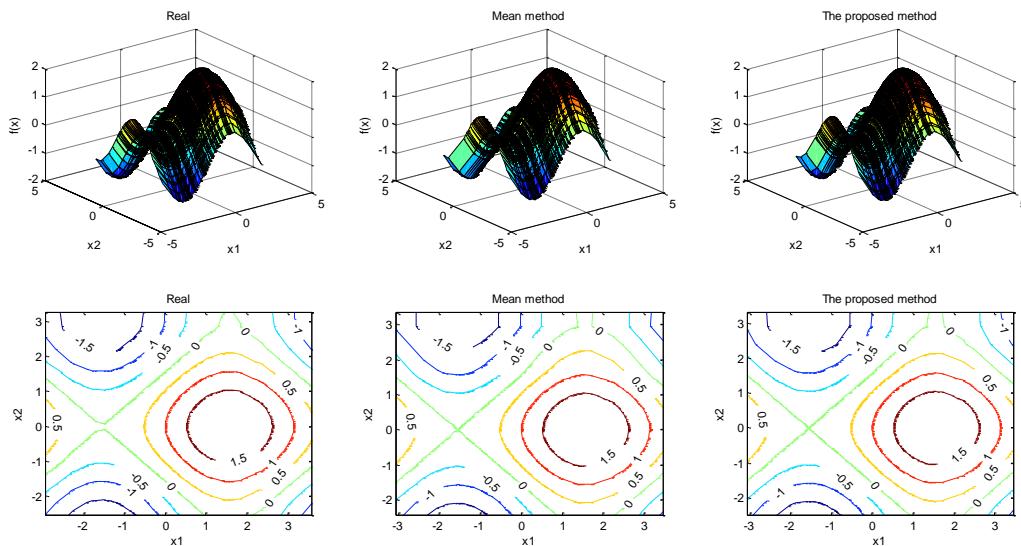


أسلوب مقترن في تقدير القيم المفقودة في نموذج الانحدار المتعدد اللامعلمي



شكل رقم (٤)

يشير الى القيم الحقيقة والقيم التقديرية للقيم المفقودة لنموذج الانحدار المتعدد اللامعلمي وبحسب النمط الأول عند حجم عينة $n = 100$ وبيانات $1 = \sigma_1^2 = \sigma_2^2$ ودرجة أرتباط $\rho = 0.50$ ونسبة فقدان 20%

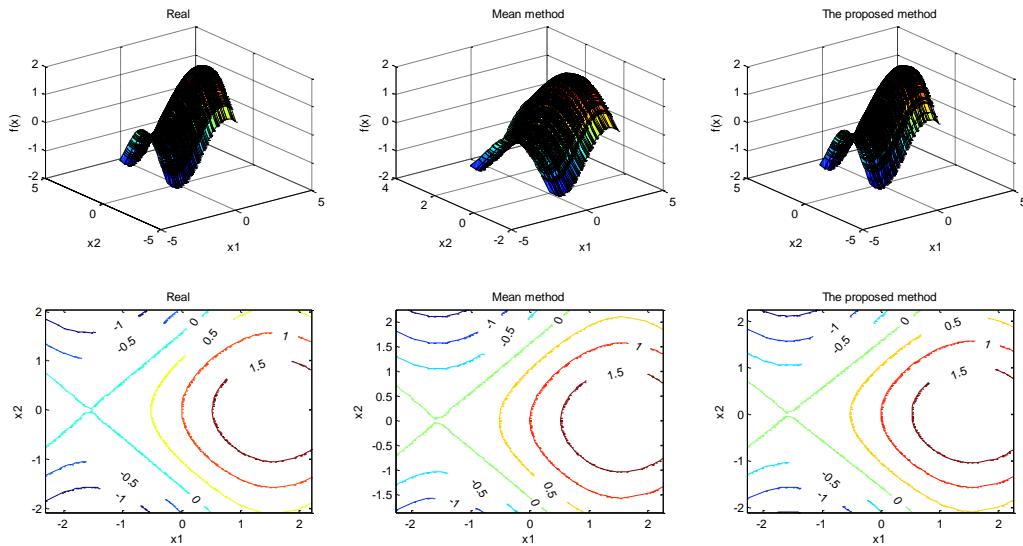


شكل رقم (٥)

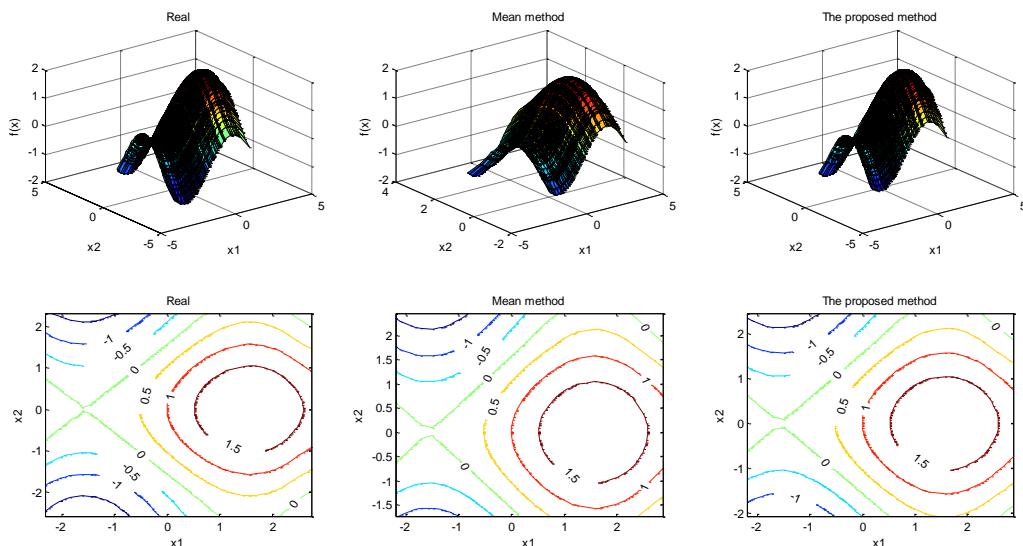
يشير الى القيم الحقيقة والقيم التقديرية للقيم المفقودة لنموذج الانحدار المتعدد اللامعلمي وبحسب النمط الأول عند حجم عينة $n = 100$ وبيانات $1 = \sigma_1^2 = \sigma_2^2$ ودرجة أرتباط $\rho = 0.50$ ونسبة فقدان 30%



أسلوب مقترن في تقدير القيم المفقودة في نموذج الانحدار المتعدد اللامعجمي



شكل رقم (6)
يشير الى القيم الحقيقة والقيم التقديرية للقيم المفقودة لنموذج الانحدار المتعدد اللامعجمي وبحسب النمط الأول عند حجم عينة $n = 100$ وتبانات $\sigma_1^2 = 1$ ، $\sigma_2^2 = 1$ ودرجة ارتباط $\rho = 0.50$ ونسبة فقدان 40%



تفسير النتائج:
من الجدول (١) نلاحظ النتائج الآتية:

- عند تبادن $\sigma_1^2 = 1$ ، $\sigma_2^2 = 1$ وارتباط $\rho = 0.20$ ولجميع نسب الفقدان ولجميع حجوم العينات أظهرت النتائج ان التعويض بالوسط الحسابي افضل من الاسلوب المقترن، ومن الناحية العلمية يكون هذا الواقع الصحيح، حيث ان حساب الوسط الحسابي لبيانات متباينة يكون ممثلاً لهذه البيانات بصورة دقيقة جداً ولاسيما في حالة ضعف العلاقة السببية بين هذه المتغيرات.



- لجميع نسب الفقدان ولجميع حجوم العينات وعند قيم ارتباط $\rho = 0.20$ وكذلك عند تباينات $\sigma_1^2 = 3, \sigma_2^2 = 2$ ، $\sigma_1^2 = 5, \sigma_2^2 = 3$ أظهرت النتائج ان الأسلوب المقترن في التعويض عن القيمة المفقودة أفضل من طريقة التعويض بالوسط الحسابي ولاسيما عند زيادة نسب الفقدان (30% ، 40%).
- نلاحظ عند زيادة قيم الارتباطات وقيم التباينات استقرار الأسلوب المقترن ولكن نلاحظ تأثير وبشكل كبير لطريقة التعويض بالوسط الحسابي وهذا ما يعبّر على هذه الطريقة لأنه عند زيادة قيم الارتباطات وقيم التباينات تقل كفاءتها [5].
- من الشكل ٣ و ٤ و ٥ و ٦ نلاحظ قلة التحيز للأسلوب المقترن في التعويض عن القيمة المفقودة، اي أن البيانات التي تم تقديرها تكون قريبة جداً من البيانات الحقيقة.

الأستنتاجات:

لقد تم التوصل في هذا البحث الى ان الأسلوب المقترن ذو كفاءة عالية في التقدير ويطابق الواقع العلمي ولاسيما فيما يخص حالة ارتفاع نسب الفقدان وكذلك في حالة زيادة تشتت البيانات، كذلك تم التوصل في هذا البحث الى امكانية اسلوب المقترن من استخلاص المعلومات المناسبة في تقدير القيمة المفقودة لاحد المتغيرات بالاعتماد على العلاقة السببية التي تربطه بمتغير اخر.

المصادر:

1. القراء، قتبة نبيل نايف، ٢٠٠٧، "مقارنة أساليب بيز الحصين مع طرائق أخرى لتقدير معلم أنموذج الانحدار الخطى المتعدد في حالة البيانات غير التامة"، اطروحة دكتوراه، قسم الإحصاء، كلية الإدارة والاقتصاد، جامعة بغداد.
2. القراء، قتبة نبيل نايف والساماني، مناف يوسف حمود، ٢٠٠٨، "مقارنة طرائق التعويض الأحادي عن القيمة المفقودة لأنموذج الانحدار اللامعجمي"، مجلة العلوم الإدارية والاقتصادية (كلية الإدارية والاقتصاد - جامعة بغداد)، المجلد ١٥، العدد ٥٣.
3. Hardle; Wolfgang; 1994; "Applied Nonparametric Regression" Humboldt – University; Berlin.
4. JON S. HORNE & EDWARD O. GARTON; 2010 "Likelihood Cross-Validation versus Least Squares Cross-Validation for Choosing the Smoothing Parameter in Kernel Home-Range Analysis" The Journal of Wildlife Management Volume 70, Issue 3, pages 641–648
5. Little; Roderick J. A.; 1992; "Regression with Missing X's: A Review"; JASA; Vol. 87; No. 420.



Proposed method to estimate missing values in Non - Parametric multiple regression model

Abstract:

In this paper, we will provide a proposed method to estimate missing values for the Explanatory variables for Non-Parametric Multiple Regression Model and compare it with the Imputation Arithmetic mean Method, The basis of the idea of this method was based on how to employ the causal relationship between the variables in finding an efficient estimate of the missing value, we rely on the use of the Kernel estimate by Nadaraya – Watson Estimator , and on Least Squared Cross Validation (LSCV) to estimate the Bandwidth, and we use the simulation study to compare between the two methods.

Keyword/ Non-Parametric Multiple Regression Model- missing observation, Missing Data Mechanisms- Patterns of Missing Data- Nadaraya – Watson Estimator- Least Squared Cross Validation