

استعمال انحدار الاسقاطات المتلاحقة والشبكات العصبية في تجاوز مشكلة البعدية

أ.م.د. عمر عبد المحسن علي / كلية الادارة والاقتصاد / جامعة بغداد
الباحث / زينة ابراهيم حسن

تاريخ التقديم: 2017/6/2
تاريخ القبول: 2017/10/25

المستخلص

يهدف هذا البحث الى تجاوز مشكلة البعدية من خلال طرائق الانحدار الامعملي والتي تعمل على تقليل جذر متوسط الخطأ التربيعي (RMSE) ، اذ تم استعمال طريقة انحدار الاسقاطات المتلاحقة (PPR) ، والتي تعتبر احدي طرائق اختزال الابعاد التي تعمل على تجاوز مشكلة البعدية (curse of dimensionality) ، وان طريقة (PPR) من التقنيات الاحصائية التي تهتم بایجاد الاسقاطات الاكثر أهمية في البيانات المتعددة الابعاد ، ومع ایجاد كل اسقاط تتخلص البيانات بواسطة المركبات الخطية على طول الاسقاط ويتم تكرار العملية لایجاد اسقاطات جيدة لحين الحصول على افضل الاسقاطات والفكرة الاساسية لانحدار الاسقاطات المتلاحقة (PPR) هو نزجة الانحدار المتعدد كمجموع للدوال غير الخطية للتراكيب الخطية للمتغيرات .

ومن اجل التخلص من مشكلة البعدية تم استعمال اسلوبين الاول طريقة انحدار الاسقاطات المتلاحقة (PPR) المقترنة والاسلوب الثاني طريقة الشبكات العصبية (NN) المتمثلة (بالاتجاه الخلفي للخطأ) وهي من الطرائق المستخدمة في اختزال الابعاد ، وقد تم اجراء دراسة محاكاة للمقارنة بين الطرائق المستخدمة وتم التوصل من خلال تجارب المحاكاة الى استنتاجات بينت ان الطريقة (NN) في هذا البحث اعطت نتائج افضل مقارنة بطريقة (PPR) اعتنادا على معيار جذر متوسط مربعات الخطأ (RMSE).

المصطلحات الرئيسية للبحث / مشكلة البعدية ، انحدار الاسقاطات المتلاحقة ، الشبكات العصبية .



مجلة العلوم
الاقتصادية والإدارية
العدد 104 المجلد 24
الصفحات 353-344

* البحث مستل من أطروحة دكتوراه .



استعمال انحدار الاسقاطات المتلاحقة و الشبكات العصبية في تجاوز مشكلة البعدية

1. المقدمة :

نظراً للتطور الحاصل في العلوم التكنولوجيا والمعلوماتية في عصرنا الحديث الذي كان له الأثر الكبير في تطور باقية العلوم الطبية والطبيعية والانسانية ، ولقد انعكس هذا التطور التكنولوجي المعلوماتي بشكل واضح على علم الاحصاء وذلك لارتباطه الوثيق به ، فعندما يراد دراسة وتحليل بيانات الظواهر الاقتصادية و الطبيعية و الزراعية و المالية وغيرها ، يجب ان تتتوفر المعرفة المسبقة لهذه الظواهر ، بمعنى اخر ، معرفة نوع بياناتها والتي غالباً ما تكون كمية ، ويطلب ذلك بناء الأنماذج رياضي مناسب يمثل العلاقات السببية (دالة سببية او سلوكيّة) بين عواملها افضل تمثيل وهي ماتدعى مرحلة الوصف (description) ، لأعتماد التحليل المناسب والذي يمكننا بعد ذلك من اتخاذ العديد من القرارات بشأن أهم الدلالات والخصائص المتعلقة بتلك الظواهر، وتدعى تلك الدلالات المذكورة سابقاً بالمعلمات (characteristics) . (parameters)

فعد ثبات الظروف الاخرى المحيطة بالظاهرة و بمعرفة العلاقة السببية التي تربط المتغيرات العشوائية فإن التحليل الاحصائي المناسب لها يدعى بالتحليل المعملي ، حيث توفر المعلمات ملخص وجيز تنبؤ عن المشاهدات لتسهل الاستدلال الاحصائي ، اما في حالة عدم ثبات تلك الظروف أو عدم معرفة العلاقة التي تربط بين المتغيرات العشوائية من حيث كونها علاقة سببية او سلوكيّة فان التحليل المناسب يدعى بالتحليل اللامعملي ، حيث لا تتوفر معلومات عن خصائص (أو دلالات) الظاهرة.

ومن أهم نماذج التحليل الاحصائي ما يدعى بتحليل نماذج الانحدار و يوجد منهجين مختلفين لتناول هذه النماذج ، وكل منهج أو أسلوب توجد شروط أو قيود .

فالاسلوب الاول هو: اسلوب الانحدار المعملي الذي يفترض ان تكون العينة متأتية من مجتمع محدد لكن قد يؤدي الافتراض الخاطئ للتوزيع المعملي الى استنتاجات خاطئة وتقديرات غير متسقة و كذلك لأنها لاتناسب البيانات المعقّدة .

ولهذه الاسباب يلجأ الباحثون الى الاسلوب الثاني وهو اسلوب اللامعملي أو الشبه المعملي لتحليل البيانات وكذلك للبيانات المعقّدة ولتقييم شرعية الأنماذج المعملي المفترض وبالعكس ، وقد تم تطوير هذه الاساليب الأخيرة لتناسب دراسة الانحدار المتعدد والتي سيفرز عنها مشكلة جديدة تدعى بمشكلة البعدية او الأبعاد (curse of dimensionality) بسبب تزاحم البيانات في الفضاءات الممتّلة لها مع محدودية المتغيرات التي تمثلها ، عندها ستفشل الطرائق التقليدية في ايجاد تقدير جيد للمعلمات، لذلك يتوجب التعامل مع هذه المشكلة بشكل مباشر وغالباً ما يتم استعمال الاساليب التي تعمل على دمج (أو ضغط) المتغيرات دون خسارة ايّة معلومات من البيانات وهذا ما يدعى باختزال الابعاد (Dimensionality Reduction: (RD).

ان الهدف المشترك لجميع هذه الاساليب المستعملة هو اختزال ابعاد البيانات (أو ضغطها)، في حين تتم المحافظة على محتوى المعلومات الكامنة فيها مهما كانت طرائق تحليلها واستخلاص النتائج منها.

2. هدف البحث :

يهدف البحث الى استعمال انحدار خوارزمية الاسقاطات المتلاحقة (projection pursuit regression) للتخلص من مشكله البعدية اذ تعلم على تحليل البيانات بعد ان يتم تقسيمها الى مجامي او عناقيد او سطوح ويكون تحليلها بشكل منفصل وكل على حده ، وان احدي اهم مميزات (PP) انه يلائم مجموعات البيانات المنتشرة في فضاء عالي الابعد والتخلص من مشاكل الانحدار المختلفة ومقارنتها مع طريقة الشبكات العصبية (Neural Networks) (وهي تحد من الطرائق العددية في التقدير) في تجاوز مشكلة البعدية باستعمال المحاكاة بالاعتماد على معيار جذر متوسط مربعات الخطأ للحصول على افضل النتائج.



3. الجانب النظري :

1-3) **أنموذج الانحدار اللامعلمي** [1] (NPRM) Nonparametric Regression Model ()
ان أنموذج (NPRM) يتمتع هذا الأنموذج بمرنة عالية، اذ لا يتطلب توفير الشروط كما في أنموذج الانحدار
اللامعلمي مما جعل أنموذج الانحدار اللامعلمي مرغوبا لدى الباحثين وذلك لأن البيانات الحقيقة لا تكون ذات
مواصفات مثالية بشكل دائم ، حيث تم تمثيل الأنموذج بالصيغة الآتية :

$$y_i = m(\chi_i) + \epsilon_i \quad \dots \quad (2 - 2)$$

حيث ان :

y_i : يمثل متغير الاستجابة.

$m(\chi_i)$: تمثل دالة تمهيد مناسبة، وهي لا تحتوي على معلمات ويتم تقديرها باحدى الطرق الاملميمية.

ϵ_i : يمثل الخطاء العشوائي ، بمتوسط $E(\epsilon) = 0$ ، وتبين $var(\epsilon) = \sigma^2$

2-3) **مشكلة التعدد الخطى** [1] (Multicollinearity):

تظهر مشكلة الارتباط الخطى المتعدد في حالة وجود ارتباط خطى قوى بين متغيرين أو أكثر من المتغيرات التوضيحية (Explanatory Variable) المفسرة (X's) لغير المتغير التابع (Y) Explanatory Variable (dependent Variable) ، بمعنى اخر: عدم وجود استقلالية بين المتغيرات التوضيحية (Variable) ، مما يؤدي لصعوبة عزل تأثير كل منها عن المتغير التابع (dependent Variable) ، وذلك يفقد معنوية معاملات الانحدار المحسبة بأسلوب المربعات الصغرى ، وغالباً ما تظهر في تحليل السلاسل الزمنية نتيجة لتغير المتغيرات الاقتصادية معاً وتتأثرها بعوامل اقتصادية متعددة خلال الفترة الزمنية المعنية.
كما تظهر هذه المشكلة في بعض الاحيان عندما يصغر حجم العينة بحيث يكون مقارباً لعدد المتغيرات المستقلة (n=K) ، وللكشف عن وجود هذه المشكلة تستخدم عدة طرائق واختبارات.

3-3) **مشكلة الابعاد (البعدية)** [8,4] (Curse of Dimensionality) :

ان مشكلة البعدية (curse of dimensionality) ليست مشكلة بيانات ذات الابعاد العالية وإنما هي مشكلة مشتركة بين البيانات ذات الابعاد العالية والخوارزمية الواجب تطبيقها اذا يصعب تطبيق الخوارزمية لمثل هذه البيانات لذلك عندما نواجه هذه المشكلة يجب علينا ان نجد حلآاما عن طريق معالجة البيانات الاصلية او عن طريق تطوير الخوارزمية.

وتنشأ مشكلة البعدية (curse of dimensionality) في حالة وجود ارتباطات خطية بين البيانات ذات الابعاد العالية، فعندما يراد تقدير كثافة البيانات فان تكامل مربع الخطأ يكون كبيراً جداً حتى اذا كان حجم العينة كبير جدا.

4-3) **طريق انحدار الاسقاطات المتلاجحة** [5,7] (Projection Pursuit Regression) :

اذ تعد طريقة (PPR) من التقنيات الاحصائية التي تهتم بایجاد الاسقاطات الاكثر اهمية في البيانات المتعددة الابعاد ، ومع ايجاد كل اسقاط تتقاض البيانات بواسطة المركبة على طول الاسقاط ويتم تكرار العملية لاجداد اسقاطات جيدة لحين الحصول على افضل الاسقاطات، واهم ميزة لها انها من الاساليب القليلة التي تستطيع تجاوز مشكلة البعدية (curse of dimensionality) الناجمة عن فضاء الابعاد العالية .
، وان الفكرة الاساسية لانحدار الاسقاطات المتلاجحة هو لنمدجة سطح الانحدار كمجموع للدوال غير الخطية للتراكيب الخطية للمتغيرات والتي يعبر عنها بالدالة الآتية :

$$Y = \sum_{j=1}^M \theta_j (\beta_j X) \quad \dots \quad (2 - 3)$$

حيث ان :

Y : يمثل متغير الاستجابة .

β_j : تمثل المعلمات الاولية .



استعمال انحدار الاسقاطات المتلاحقة والشبكات العصبية في تجاوز مشكلة البعدية

M : عدد الاسقاطات في النموذج.

$r_j^{[0]}$: تمثل دالة تمهيد محددة .

X : تمثل مصفوفة المتغيرات التوضيحية بدرجة (n^*p) .

اذ ان :

P : تمثل عدد المتغيرات التوضيحية .

n : تمثل حجم العينة .

ان العديد من طائق التحليل الاعتيادية (الكلاسيكية) لمتعدد المتغيرات تكون حالات خاصة من طريقة الاسقاطات المتلاحقة و من الامثلة عليها تحليل المركبات الرئيسية (PC) والتحليل المميز (Discriminant Analysis).

The PPR Algorithm ١-٤-٣(خوارزمية انحدار الاسقاطات المتلاحقة)

ولغرض تقدير دالة الاستجابة (x) للبيانات $\{f(x_1, \dots, x_n, y_1), \dots, f(x_{n,1}, \dots, x_{n,M}, y_n)\}$ وكما يأتي:

١. تحديد $r_i^{[0]} = y_i$.

٢. لكل $j=1, \dots, M$ maximize

حيث ان :

j : تمثل عدد الاسقاطات .

$$R_{[j]}^2 = 1 - \frac{\sum_{i=1}^n \left(r_i^{[j-1]} - \hat{g}_j(\hat{\beta}_{[j]}^T x_i) \right)^2}{\sum_{i=1}^n (r_i^{[j-1]})^2} \quad \dots \quad (2-4)$$

حيث ان :

$r_i^{[j-1]}$: يمثل الباقي .

ومن خلال اجراء تغيير على المعلمات $\hat{\beta}_{[j]}$ varying over the parameters $R_{[j]}^2$.
ودالة الانحدار أحادية المتغير \hat{g}_j .

٣. جعل $r_i^{[j]} = r_i^{[j-1]} - \hat{g}_j(\hat{\beta}_{[j]}^T x_i)$ ثم نستمر بإعادة الخطوة الثانية حتى يتم تقليل قيمة $R_{[j]}^2$. وأن قيمة $R_{[i]}^2$ الصغيرة تعني أن $\hat{g}_i(\hat{\beta}_{[i]}^T x_i)$ هي تقريباً الدالة الصفرية وبذلك لا نستطيع الحصول على اتجاه آخر يكون مفيدة.

هذه الخوارزمية تؤدي إلى تقدير دالة الاستجابة عن طريق:

$$\hat{f}_M(x) = \sum_{j=1}^M \hat{g}_j(\hat{\beta}_{[j]}^T x) \quad \dots \quad (2-5)$$



(3-5) الإنشار الخلفي للخطأ في الشبكات العصبية Back in neural network)

[2,9] Propagation of error

بعد عملية التقدير الاولية في الشبكة العصبية وحساب الخطأ الاولى ، يتم إجراء مقارنة بين القيم المحسوبة والقيم المرغوبة (حساب الخطأ) من خلال الفرق بين قيم تلك المخرجات وذلك من خلال معادلة الخطأ الآتية:

$$E = (d_i - Y_i) \dots \quad (2-6)$$

اذن ان :

d_i : تمثل الارجاع المرغوب فيه اي متغير الاستجابة .

Y_i : تمثل قيمة المخرج من الشبكة اي متغير الاستجابة المقدر .

E : يمثل الخطأ الاولى المحسوب .

وبعد ذلك يتم تصحيح الوزن وتعديله من خلال عملية التعلم التي تتم على الشبكة من خلال طريقة الانبعاث الخلفي ، وتتلخص هذه الطريقة بالخطوات الآتية :

الخطوة (1) : البدء بالأوزان و Offsets ، اعطاء الأوزان وعقدة Offsets قيم عشوائية قليلة.

الخطوة (2) : تهيئة الإدخال ووصف الإخراجات المرغوب فيها ، تحضير القيم المستمرة لمتجه الإدخال

$\cdot d_0, d_1, d_2, \dots, d_{m-1}$

الخطوة (3) : حساب الإخراجات الحقيقية ، تم استعمال الدالة اللاخطية السبيبية (Sigmoid Function)

لحساب الإخراجات

$\cdot Y_0, Y_1, Y_2, \dots, Y_{M-1}$

الخطوة (4) : تعديل الأوزان.

تبدأ الخوارزمية بتوليف عقدة الإخراج (أي إيجاد أفضل قيمة لوزن المحسوب) وتعمل بصورة خلفية الى طبقة مخفية وتعديل الأوزان بواسطة :

$$W_{ij}(t+1) = W_{ij}(t) + \eta \delta_i \bar{X}_i \quad (2-7)$$

حيث ان :

$W_{ij}(t)$: الوزن في العقدة المخفية i أو من الإدخال الى العقدة j في الزمن t .

δ_i : مصطلح الخطأ للعقدة j .

η : تمثل معلمة التعلم وتكون محصوره بين (0 ، 1) .

فإذا كانت j تمثل عقدة إخراج فأن :

$$\delta_i = Y_i(1-Y_i)(d_i - Y_i) \quad (2-8)$$

حيث ان :

d_i : تمثل الإخراج المرغوب فيها لعقدة j ، وتمثل Y_i الإخراج الحقيقى.

أما إذا كانت j تمثل عقدة مخفية داخلية فأن :

$$\delta_i = \bar{X}_i(1-\bar{X}_i) \sum_k \delta_k W_{ik} \quad (2-9)$$

حيث ان:

k : تمثل كل العقد في الطبقات الموجودة فوق العقدة j .



تُعد قيمة العبة للعقد الداخلية بطريقة متشابهة بواسطة الافتراض بأنها عبارة عن أوزان متراقبة حيث ترتبط من الإدخالات ذات القيم الثابتة ولكي يكون التقارب (Convergence) سريعاً يضاف مصطلح معامل التعجيل (Momentum) ويرمز له بالرمز (α) علمًا أنه يساعد في تغيير الأوزان بصورة منتظمة كالتالي :

$$W_{ij}(t+1) = W_{ij}(t) + \eta \delta_i \bar{X}_i + \alpha(W_{ij}(t) - W_{ij}(t-1)) \quad (2-10)$$

حيث أن :

$$0 < \alpha < 1$$

بشكل عام لا يوجد معيار عام لكيفية اختيار معامل التعلم ومعامل التعجيل وتعتمد القيم المثالية على المشكلة التي يتم معالجتها وتقليلها.

٤- الجانب التجريبى :

تم استعمال المحاكاة في هذا البحث لتوليد البيانات ومن ثم تطبيق طائق الاختزال عليها و اختيار افضل طريقة من خلال معيار (RMSE) ، إذ تعد المحاكاة (Simulation) تقليد للبيانات الاصلية تحت البحث اذ تقوم بتوظيف او تكوين نماذج تظهر فيها عدد كبير من الحالات الافتراضية لتكون نتائج التحليل أكثر شمولية وتعيضاً.

1-4) خطوات اجراء المحاكاة :

٤-١-١) توليد المتغيرات التوضيحية :

تم توليد خمسة من المتغيرات التوضيحية لكي تلام واقع المشكلة تحت الدراسة حيث ان مشكلة البعدية تحدث في حالة وجود خمسة متغيرات توضيحية او اكثر وقد تم استعمال ثلاث احجام من العينات وهي $n = 100$, 200 , 400 بواقع تكرار (1000) حيث توزعت احجام المتغيرات التوضيحية على هذه الطرائق ، اذ تم الاستعانة ببرنامج (MATLAB R2012A)* في توليد البيانات حيث يعتبر من البرامج ذا قدرة الكبيرة في المجال البرمجي والرياضي ، اذ تم توليد المتغيرات التي تعاني من مشكلة البعدية عن طريق توليد مصفوفة ارتباط اولية تحكم بمقدار الارتباط بين هذه المتغيرات ، اذ تم تحديد قيمة الارتباط $P=0.5$ والتي تكون هي المسيبة لمكشلة التعدد الخطى في البيانات ومن ثم تعانى مشكلة البعدية وتتلخص خطوات المحاكاة كمايأتى :

تم التولد الاولم للمتغيرات التوضيحية تولدا طبعا كما يلي

$$x \sim N(0, 0.5) \dots \dots \dots \quad (2-10)$$

ثانيا :- توليد المتغيرات المتعددة التوضيحية

تم توليد المتغيرات المتعددة بمتجه الوسط الحسابي \bar{M} و بمصفوفة تباين $SIGMA$ بالاعتماد على التوليد الاولى لمتغيرات في (أولاً) اذ يتم حساب متوسط كل متغير والذى سيمثل متجه الوسط الحسابي \bar{M} وحساب مصفوفة التباين والتبالين المشترك للتوليد الاولى والذى سيمثل مصفوفة $SIGMA$ أي :

$$X \sim \text{MN}(\underline{\mu}, \Sigma) \quad \dots \quad (2-11)$$

وبذلك يتم توليد متغيرات متعددة تعاني مشكلة التعدد الخطى .

ثالثاً :- الكشف عن مشكلة التعدد الخطى [٣] :

تم الكشف عن مشكلة التعدد الخطى من خلال هذه المتغيرات عن طريق معامل تضخم التباين اذ يتم اختبار جميع المتغيرات التوضيحية فيما اذا كان معامل التضخم لديها عالى والذى يسمى **V.I.F variance** () inflation factor (لمعرفة فيما اذا كانت هنالك مشكلة تعدد خطى في هذه المتغيرات بأرتباطات عالية وبقيمة معامل تضخم **VIF>4**) ل بهذه المتغيرات ، دل ذلك على وجود تعدد خطى بين المتغيرات .



استعمال انحدار الاسقاطات المتلاحدة و الشકان العصبية في تجاوز مشكلة البعدية

٤-١-٤) توليد المتغير المعتمد [٤]:

ما نقدم في الفقرة (٤-١-١) نلاحظ ان المتغيرات التي تم توليدها هي متغيرات ذات ارتباط عالي فيما بينها وبغية توليد المتغير المعتمد (Y) تم استعمال الأنماذج التالي وبالاعتماد على المتغيرات التوضيحية المولدة في الفقرة (٤-١-١) اذ تم اختيار اول متغيرين من المتغيرات التوضيحية والتي تكون مترابطة مع بقية المتغيرات التوضيحية وذلك لأنها تعانى من مشكلة التعدد الخطى مع اضافة تبادل المعلومات (٥) مع تشويش (٦) وهذا هو الاسلوب المتبعة في عملية توليد المتغير المعتمد بشكل عام ، اذ كان النموذج كما يلى :

$$y = \frac{x_1}{0.5 + (x_2 + 1.5)^2} + (1 + x_2)^2 + \sigma * \delta \quad \dots \quad (2-12)$$

يمثل تبادل البيانات المولدة (٥) :

(٦) : تمثل تشويش يتبع التوزيع الطبيعي القياسي للمتغير المعتمد (او متغير الاستجابة) (Y). ويقصد بالتشويش هنا على انه قيم تضاف الى النموذج بغية تشتت المتغير المعتمد واعطائه العشوائية التامة .

٤-١-٤) توليد الاخطاء العشوائية :

يتم توليد الاخطاء العشوائية على وفق التوزيع الطبيعي القياسي وعلى وفق الصيغة الآتية : $\delta_i \sim N(0,1) \dots (2-13)$

٤-٢) تطبيق طرائق :

تم تطبيق طرفيتين في اختزال الابعاد وهي (PPR) المقترنة و طريقة (NN) اذ تم تقسيم عدد العقد في طبقة الشبكة العصبية الى (H) وهي على التوالي الى (5 ، 7 ، 10) عدة بغية الحصول على افضل النتائج اذ تعدد (H) بمثابة معلمة ضبط (tuning parameter) .

جدول رقم (1)

يبين مقارنة طرائق الاختزال حسب توليد عدد المشاهدات وبيانات مختلفة

RMSE																
methods	n	$\sigma^2 = 0.1$			$\sigma^2 = 0.5$			$\sigma^2 = 1$			H=5	H=7	w=10			
		H=5	H=7	H=10	H=5	H=7	H=10	H=5	H=7	w=10						
1	ppr	100	1.0115			2.0666			4.2423							
		200	1.0501			1.8791			3.8064							
		400	1.0652			2.0099			3.7477							
2	NN	100	0.3438	0.2603	0.4523	1.6109	1.8925	1.5208	2.9540	3.1632	2.9544					
		200	0.2826	0.4130	0.3791	1.5287	1.7164	1.9154	3.1334	2.9223	3.1082					
		400	0.3009	0.3039	0.3031	1.4062	1.5848	1.4337	2.9489	2.8656	3.0582					

نلاحظ من خلال نتائج جدول رقم (1) ان طريقة (PPR) تمتلك اقل (RMSE) عند حجم مشاهدات (100) عند الارتباط ($\sigma^2 = 0.1$) و كذلك تمتلك اقل (RMSE) عند حجم مشاهدات (200) عند الارتباط ($\sigma^2 = 0.1$) و ايضا تمتلك اقل (RMSE) عند حجم مشاهدات (400) عند الارتباط ($\sigma^2 = 0.1$).



استعمال انحدار الاسقاطات المتلاحدة والشبكات العصبية في تجاوز مشكلة البعدية

ذلك نلاحظ من خلال نتائج جدول رقم (1) الى ان طريقة (NN) تمتلك اقل (RMSE) عند الارتباط ($\sigma^2 = 0.1$) عند حجم المشاهدات (100) عندما (H=7) وكذلك عند حجم المشاهدات (200) عند (H=10) وعند حجم المشاهدات (400) عند (H=5) ، وفي حالة الارتباط ($\sigma^2 = 0.5$) عند (H=10) عند حجم مشاهدات (100) عند (H=10) وكذلك تمتلك اقل (RMSE) عند حجم المشاهدات (200) عند (H=5) وايضا عند حجم المشاهدات (400) تمتلك اقل (RMSE) عند (H=5) ، وفي حالة الارتباط ($\sigma^2 = 1$) تمتلك اقل (RMSE) عند حجم المشاهدات (100) عند (H=5) و كذلك عند حجم المشاهدات (200) فانها تمتلك اقل (RMSE) ايضا عند (H=7) و كذلك عند حجم المشاهدات (400) اياها عند (H=7).

جدول رقم (2)

جدول يبين افضلية المقدرات بحسب معيار جذر متوسط مربعات الخطأ

		RMSE								
method		$\sigma^2 = 0.1$			$\sigma^2 = 0.5$			$\sigma^2 = 1$		
		100	200	400	100	200	400	100	200	400
1	ppr	1.0115 ثانيا	1.0501 ثانيا	1.0652 ثانيا	2.0666 ثانيا	1.8791 ثانيا	2.0099 ثانيا	4.2423 ثانيا	3.8064 ثانيا	3.7477 ثانيا
2	NN	0.2603 اولا	0.2826 اولا	0.3009 اولا	1.5208 اولا	1.5287 اولا	1.4062 اولا	2.9540 اولا	2.9223 اولا	2.8656 اولا

تشير نتائج جدول رقم (2) الى افضلية طريقة (NN) عند التباينات (0.1 و 0.5 و 1) ولجميع احجام العينات (100 ، 200 ، 400) وذلك لأنها تمتلك اقل (RMSE) .

5- الاستنتاجات والتوصيات :

1-5) الاستنتاجات :

في ضوء تحليل تجارب المحاكاة ، تم التوصل للاستنتاجات الآتية:

1. أن طريقة (NN) هي الافضل من خلال نتائج معيار المقارنة إذا أعطت اقل (RMSE) بعد تطبيقها على جميع التباينات واحجام العينات .

2. لقيمة معلمة الضبط (H) أهمية قصوى في التحكم بدقة المقدرات، وتحقق الأمثلية في حالة اختيارها مساوية لعدد المتغيرات التوضيحية (P) (H=).

3. أن نتائج طريقة (PPR) كانت قريبة جدا من نتائج طريقة (NN) مما يعطي قوة لهذه الطريقة كون طريقة (NN) من الطرائق العددية وهذا ما بدا واضحًا في تحليل النتائج .

2-5) التوصيات :

بناءً على ما تم التوصل إليه من استنتاجات، فيما يأتي بعض التوصيات :

1. نوصي باستعمال طريقة (NN) وطريقة (PPR) في تقدير النماذج عندما يكون فيها عدد المتغيرات التوضيحية كبيراً وذلك لأن زيادة عدد المتغيرات التوضيحية يؤدي غالبا إلى حدوث مشكلة البعدية (Curse of Dimensionality) ومن ثم حدوث بقية المشاكل كعدم التجانس والتعدد الخطأ والارتباط الذاتي .

2. نوصي باستعمال طريقة (PPR) عندما يكون حجم العينة صغير وبوجود مشكلة البعدية (curse of dimensionality).



3. نوصي بمحاولة تقدير قيمة ضبط المعلمة (H) (tuning parameter) وذلك لأنّ أهميتها في حساب (NN).
4. نوصي باستعمال خوارزميات عدديّة حديثة وذلك لأنّ أهميتها في إيجاد الاسقاطات في عملية تجاوز مشكلة البعدية في طريقة (PPR) .

6- المصادر :

المصادر العربية :

1. الحسناوي ، اموري هادي - القيسى ، باسم شلبيه "القياسي الاقتصادي المتقدم - النظرية والتطبيق" المكتبة الوطنية ، دار الكتب والوثائق ببغداد 552، (2002).
2. رضا ، صباح منفي "تحديد هوية المتكلم باستعمال الشبكات العصبية" اطروحة دكتوراه ، جامعة بغداد ، (2004).
3. يوسف ، حنين مراد " مقارنة بين طرائق تقدير انحدار الحرف العامة في معالجة مشكلة التعدد الخطى شبة التام مع تطبيق عملي " ، رسالة ماجستير ، جامعة بغداد ، (2014) .

المصادر الأجنبية :

- 4.Francis Bach ;(2017) "Breaking the Curse of Dimensionality with convex Neural Networks" JMLR ,PP.(1-53).
- 5.Jerome H. Friedman , Werne Stuetzie ; (1981) " Projection Pursuit Regression " ,JASA,Vol.76 , No.376 , PP. (817-823) .
- 6.Kenji Fukumizu ,Francis R.Bach and Michael I.Jordan; (2009) "Kernel Dimension Reduction in Regression" Annals of statistics ,Vol.(37) ,No.(4) , PP.(1871-1905).
- 7.Nathan Intrator ; (1993) " Combining Exploratory Projection Pursuit Regression with application to Neural Networks" , MIT , Vol.5 , No.3 , PP.(443-455).
- 8.Swati kaur, S. M. Ghosh ; (2016) "A survey on dimension reduction techniques for classification of multidimensional data", IJSTE ,Vol.2 , Issue.12 , PP.(31-37).
- 9.Wei Wang , Yan Huang , Yizhou Wang and Liang Wang ; (2014) " Generalized Autoencoder A.Neural Network Framework for Dimensionality Reduction " CVPR , PP.(490-497).



Use projection pursuit regression and neural network to overcome curse of dimensionality

Abstract

This research aim to overcome the problem of dimensionality by using the methods of non-linear regression, which reduces the root of the average square error (RMSE), and is called the method of projection pursuit regression (PPR), which is one of the methods for reducing dimensions that work to overcome the problem of dimensionality (curse of dimensionality). The (PPR) method is a statistical technique that deals with finding the most important projections in multi-dimensional data , and With each finding projection , the data is reduced by linear compounds overall the projection. The process repeated to produce good projections until the best projections are obtained. The main idea of the PPR is to model the multiple regression as a sum of the nonlinear functions of the linear structures of the variables.

Two approaches were used to solve the problem curse of dimensionality : the first approach is proposed projection pursuit regression method (PPR) and The second approach is the method of neural networks (NN) representing by (Back Propagation of error) which is one of the methods used in reducing dimensions . A simulated study was conducted to compare the methods used. The simulations were based on findings that showed that the method (NN) in this study gave better results than the (PPR) based on RMSE.

Key words:- curse of dimensionality ; projection pursuit regression ; neural networks.