

تحليل الارتباط القويم اللاخطي باستخدام بعض دوال كيرنل

علي جواد كاظم*

الخلاصة :

يعد تحليل الارتباط القويم من تحليلات متعددة المتغيرات التقليدية حيث يعمل على ايجاد تحويل خطي لزوج من المتغيرات المتعددة بحيث يحقق هذا التحويل تعظيم معامل الارتباط ويجعله اعظم ما يمكن ومن وجهة النظر النظرية فان هذا التحويل يعمل على تعظيم المعلومات المستخلصة عن المعالم .

اذا كانت العلاقة بين المتغيرات غير خطية فان تحليل الارتباط القويم لا يستطيع استخلاص معلومات مفيدة عن تلك المعالم . في هذا البحث تم استخدام ما يدعى بخدعة كيرنل (Kernel trick) والتي تعمل على جعل البيانات ملائمة للتحليل وتم استخدام دوال مختلفة من نوع كيرنل منها دالة (Gaussian Kernel) ودالة (Uniform Kernel) ودالة (Triangle Kernel) .

المقدمة :

يفترض هذا التحليل وجود زوج من المتغيرات المتعددة $X \in R^{n_x}, Y \in R^{n_y}$ ويعمل على ايجاد زوج من التحويلات الخطية التي تجعل معامل الارتباط بين المعالم المستخلصة اعظم ما يمكن وبافتراض ان X, Y لكل منهما متوسط مقداره صفر وتباين مقداره واحد فان التحويلات تكون كما يأتي⁽³⁾:

$$U = \langle a, x \rangle, V = \langle b, y \rangle$$

حيث ان :

$\langle a, x \rangle, \langle b, y \rangle$ تمثل حاصل الضرب الداخلي (inner product) بين a, x و b, y على التوالي.

والهدف هنا هو ايجاد التحويل المناسب الى a, b والذي يجعل معامل الارتباط اعظم ما يمكن. وبمعنى اخر اذا كان لدينا متغير عشوائي يتكون من p من الأبعاد هو X ومتغير يتكون من q من الأبعاد هو Y ، هدفنا هو الحصول على تركيبات خطية $a^T X$ ، $b^T Y$ من المتغيرات الأصلية تمتلك اعظم ارتباط ، ويمكن التعبير عن ذلك بصيغة رياضية بالشكل التالي⁽⁸⁾ :

* مدرس مساعد قسم الاحصاء/جامعة القادسية

$$\rho = MAX |corr(a^T X, b^T Y)| \dots (1)$$

ان المتغيرات الناتجة $U=a^T X$ ، $V=b^T Y$ تدعى المتغيرات القوية وان الارتباط القويم الأول ρ يعرف كقيمه مطلقه للارتباط بين مجموعتين من المتغيرات القوية وكما في العلاقة رقم (1) ، ان المتغير القويم ذو الرتبة k ، $1 < k < \min(p,q)$ سيكون غير مرتبط مع كل المتغيرات القوية ذات الرتب الدنيا .

ويمكن ايجاد a^T, b^T كمتجه مميز مرافق لقيم مميزه عظمى (3) .

افرض ان Σ تمثل مصفوفة التباين المشترك للمجتمع للمتغير العشوائي Z حيث ان $Z = (X^T, Y^T)^T$ ويمكن وضع Σ بالشكل التالي :

$$\Sigma = \begin{bmatrix} \Sigma_{XX} & \Sigma_{XY} \\ \Sigma_{YX} & \Sigma_{YY} \end{bmatrix}$$

وقد نستخدم مصفوفة الارتباطات R

$$R = \begin{bmatrix} R_{XX} & R_{XY} \\ R_{YX} & R_{YY} \end{bmatrix}$$

حيث يتم حساب المتجه المميز b^T من العلاقة التاليه (7) :

$$(M - \lambda I)b = 0 \dots (2)$$

بفرض ان

$$M = \Sigma_{YY}^{-1} \Sigma_{YX} \Sigma_{XX}^{-1} \Sigma_{XY}$$

عند استخدام مصفوفة التباين المشترك .
او

$$M = R_{YY}^{-1} R_{YX} R_{XX}^{-1} R_{XY}$$

عند استخدام مصفوفة الارتباطات .

ان قيم المتجه المميز b^T والذي يرتبط بكل قيمه من القيم المميزه (λ) الناتجه من المعادله (2) تمثل اوزانا للمجموعه Y من المتغيرات .

وبعد حساب b^T يمكن ان نحدد المتجه a^T المقابل للمجموعه X من المتغيرات من خلال العلاقة التاليه (7):

$$a^T = \frac{1}{\sqrt{\lambda}} R_{XX}^{-1} R_{XY} b^T$$

يستخدم تحليل الارتباط القويم عندما تكون X, Y متغيرات تتبع التوزيع الطبيعي المشترك وحتى عندما يكون هذا الافتراض غير متحقق يمكن استخدامه في بعض الحالات وعندما يكون هدفنا هو الحصول على انحدار تلك المتغيرات فاننا نرغب في الحصول على قيم كبيره لمعاملات الارتباط . ولكن احيانا قد نحصل على قيم صغيره لتلك المعاملات وقد يكون ذلك عائدا الى احد السببين التاليين⁽³⁾ :

1- عدم وجود أي علاقه بين X, Y .

2- هنالك علاقه غير خطيه قويه بين X, Y .

في الحاله الاولى لا يمكن الحصول على افضل مما تم الحصول عليه ولا يمكن اجراء أي تحسينات تذكر . اما في الحاله الثانيه فيمكن الحصول على العلاقه باستخدام بعض الطرق منها طريقة كيرنل (Kernel Method) في تحليل الارتباط القويم .

طريقة كيرنل في تحليل الارتباط القويم Kernel CCA⁽³⁾

في هذه الطريقه يتم تحويل X, Y في فضاء هيلبرت* (Hilbert Space) حيث :

$$\phi_x(x) \in H_x, \phi_y(y) \in H_y$$

وبأخذ حاصل الضرب الداخلي (inner product) للمعالم في فضاء هيلبرت

$$a \in H_x, b \in H_y$$

نحصل على ما يأتي :

$$U = \langle a, \phi(x) \rangle, V = \langle b, \phi(y) \rangle$$

وبفرض وجود عينات $\{(x_i, y_i)\}_{i=1}^N$ يمكن ايجاد a, b وذلك عن طريق حل علاقة لاكرانج التاليه :

$$L_0 = E[(U - E[U])(V - E[V])] - \frac{\lambda_1}{2} E[(U - E[U])^2] - \frac{\lambda_2}{2} E[(V - E[V])^2]$$

ان علاقة لاكرانج لا تعمل بشكل جيد عندما تكون ابعاد فضاء هيلبرت كبيره ولهذا يجب اضافه حد انتظام تربيعي (Quadratic Regularization Term) وذلك من اجل تحسين عمل علاقة لاكرانج وكما يأتي :

$$L = L_0 + \frac{\eta}{2} (\|a\|^2 + \|b\|^2)$$

حيث ان η تمثل ثابت انتظام (Regularization Constant).

ان معدل L يمكن حسابه من الصيغه التاليه :

$$E[U] = \frac{1}{N} \sum_i \langle a, \phi_x(x_i) \rangle$$

- ان فضاء هلبرت الابتدائي الكامل يدعى فضاء هلبرت. بعبارة اخرى اذا كان X فضاء متجهات على الحقل F مع الضرب الداخلي $\langle, \rangle$ فان X يكون فضاء هلبرت اذا كان الفضاء المتري المتولد بواسطة المعيار $\|x\|^2 = \langle x, x \rangle$ فضاء كاملاً⁽¹⁾. ويمكن توضيح فضاء هلبرت الابتدائي او ما يسمى احيانا بفضاء الضرب الداخلي من خلال التعريف التالي:

تعريف: ليكن X فضاء متجهات على الحقل F . الدالة $\langle, \rangle : X \times X \rightarrow F$ تسمى بدالة الضرب الداخلي على X ، اذا تحققت البديهيات التالية⁽¹⁾:

$$-1 \quad \langle x, x \rangle \geq 0 \quad \text{لكل } x \in X.$$

$$-2 \quad \langle x, x \rangle = 0 \quad \text{اذا وفقط اذا كان } x = 0.$$

$$-3 \quad \overline{\langle x, y \rangle} = \langle y, x \rangle \quad \text{حيث } \overline{\langle x, y \rangle} \text{ تعني العدد المرافق للعدد } \langle x, y \rangle.$$

$$-4 \quad \langle \alpha x + \beta y, z \rangle = \alpha \langle x, z \rangle + \beta \langle y, z \rangle \quad \text{لكل } x, y, z \in X \text{ ولكل } \alpha, \beta \in F.$$

فضاء هلبرت الابتدائي (pre-Hilbert Space) او فضاء الضرب الداخلي هو الثنائي $(X, \langle, \rangle)$ حيث X فضاء متجهات على الحقل F ، $\langle, \rangle$ ضرب داخلي على X .

وكذلك معدل UV يمكن حسابه بالشكل التالي:

$$E[UV] = \frac{1}{N} \sum_{i,j} \langle a, \phi_x(x_i) \rangle \langle b, \phi_y(y_j) \rangle$$

وباشتقاق L بالنسبة الى a ومساواة المشتقة الى الصفر نحصل على ما ياتي:

$$a = \sum_i \alpha_i \phi_x(x_i)$$

حيث ان α_i تمثل ثابت (Scalar). ونتيجته للخطوة السابقة فان:

$$U = \sum_i \alpha_i \langle \phi_x(x_i), \phi_x(x) \rangle$$

والتي يمكن حسابها عن طريق حاصل الضرب الداخلي. ان ما يسمى بخدعة كيرنل (Kernel Trick) يتلخص باستخدام دالة كيرنل $K_x(X_1, X_2)$ بدلا من حاصل الضرب الداخلي بين $\phi_x(X_1), \phi_x(X_2)$ وبذلك لسنا بحاجة الى صيغة $\phi_x(X)$ نحتاج فقط الى تحديد K_x والتي تكون معرفه موجبه متماثله⁽²⁾. ويمكن اعادة كتابة L من حسب وجهة نظر طريقة كيرنل كما ياتي :
افرض ان

$$\beta = (\beta_1, \beta_2, \dots, \beta_N)^T, \quad \alpha = (\alpha_1, \alpha_2, \dots, \alpha_N)^T$$

$$(K_x)_{ij} = K_x(x_i, x_j), \quad (K_y)_{ij} = K_y(y_i, y_j)$$

فان :

$$L = \alpha^T M \beta - \frac{\lambda_1}{2} \alpha^T L \alpha - \frac{\lambda_2}{2} \beta^T N \beta$$

حيث ان :

$$M = \frac{1}{N} K_x^T J K_y$$

$$L = \frac{1}{N} K_x^T J K_x + \eta_1 K_x$$

$$N = \frac{1}{N} K_y^T J K_y + \eta_2 K_y$$

$$J = I - \frac{1}{N} 11^T$$

$$1 = (1, 1, \dots, 1)^T$$

$$\eta_1 = \frac{\eta}{\lambda_1}, \eta_2 = \frac{\eta}{\lambda_2}$$

واذا كانت $\eta > 0$ فان كل من N, L سيكون مصفوفة معرفة موجبه (Positive definite matrix) ويمكن اثبات ان $\lambda_1 = \lambda_2 = \lambda$ ونتيجة لذلك يكون لدينا ما يدعى بمشكلة قيمة مميزه عامه (Generalized eigenvalue problem) α, β و كما يأتي:

$$M\beta = \lambda L\alpha$$

$$M^T \alpha = \lambda N\beta$$

والتي يمكن حلها كمشكلة قيمة مميزه عامه (2).

المحاكاة:

لقد تم استخدام المحاكاة لغرض إجراء المقارنة بين مقدرات الارتباط القوي المحسوبة وفق الطريقة التقليدية ومقدرات الارتباط القوي المحسوبة وفق طريقة كيرنل باستخدام ثلاث دوال من نوع كيرنل هي دالة (Gaussian Kernal) ودالة (Uniform Kernel) ودالة (Triangle Kernel) وذلك بهدف معرفة أفضل المقدرات وذلك بالاعتماد على كون الارتباط القوي يمثل اكبر الارتباطات للحكم على المقدر الأفضل وتم كتابة برنامج باستخدام لغة (V.B) خاص بالتجربة لتحقيق هذا الهدف حيث تم تكرارها (1000) مرة لغرض الوصول إلى نتائج مقنعة ويمكن أدراج خطوات إجراء المحاكاة وكالتالي :

1- نولد قيم للمتغيرات (x_1, x_2) لتكوين تركيبة خطية هي UC_i والتي يتم استخدامها في حساب الارتباط القوي وفق الطريقة التقليدية وتركيبه خطيه أخرى هي UK_i والتي يتم استخدامها في حساب الارتباط القوي وفق طريقة كيرنل وبأحجام عينات $(n=10, 20, 30, 40, 50, 60, 70, 80, 90)$ أي لكل متغير من متغيرات x نولد n من المشاهدات المذكورة حيث إن :

$$UC_i = a_1 x_1 + a_2 x_2$$

$$UK_i = a_1 K(x_1) + a_2 K(x_2)$$

وان صيغ دوال كيرنل المستخدمة هي الصيغ التالية :

$$a) K(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$$

وهذه الدالة تدعى دالة (Gaussian Kernal).

$$b) K(x) = 1/2, |x| \leq 1$$

وهذه الدالة تدعى دالة (Uniform Kernel).

$$c) K(x) = (1 - |x|), |x| \leq 1$$

وهذه الدالة تدعى دالة (Triangle Kernel).
وان :

$$X = (\theta) \sin 3\theta + \varepsilon_1$$

حيث يتم توليد قيم θ على اساس انها تتبع التوزيع المنتظم المستمر على الفترة $[-\pi, \pi]$.
 ε_1 : يمثل حد الخطا العشوائي ويتم توليده على اساس انه يتبع التوزيع الطبيعي القياسي في الحالة الاولى ويتبع التوزيع الاسي بالمعلمة $\lambda=1/3$ في الحالة الثانية أما في الحالة الثالثة فيتم توليده على اساس انه يتبع توزيع مربع كاي بالمعلمة n .

2- يتم توليد متغيرات (y_1, y_2) لتكوين تركيبة خطية هي VC_i والتي يتم استخدامها في حساب الارتباط القويم وفق الطريقة التقليدية وتركيبه خطيه أخرى هي VK_i والتي يتم استخدامها في حساب الارتباط القويم وفق طريقة كيرنل وبأحجام عينات $(n=10, 20, 30, 40, 50, 60, 70, 80, 90)$ أي لكل متغير من متغيرات y نولد n من المشاهدات المذكورة حيث إن :

$$VC_i = b_1 y_1 + b_2 y_2$$

$$VK_i = b_1 K(y_1) + b_2 K(y_2)$$

وان $K(y)$ تأخذ نفس الصيغ السابقة وان الصيغة التي يتم الحصول على قيم y منها هي الصيغة التالية:

$$Y = e^{\theta/4} (\cos 2\theta)(\sin 2\theta) + \varepsilon_2$$

حيث يتم توليد قيم θ على اساس انها تتبع التوزيع المنتظم المستمر على الفترة $[-\pi, \pi]$.

ونولد قيم للمتغير ε_2 مرة بالتوزيع الطبيعي القياسي ومرة أخرى بالتوزيع الاسي بالمعلمة $\lambda=1/3$ ومره ثالثه بتوزيع مربع كاي بدرجة حرية (n) .

- 3- يتم حساب معاملات الارتباط بين UC_i و VC_i حيث ان اكبرها يمثل معامل الارتباط القويم المحسوب وفق الطريقة التقليديه ويتم حساب معاملات الارتباط بين UK_i و VK_i حيث ان اكبرها يمثل معامل الارتباط القويم المحسوب وفق طريقة كيرنل حسب الداله المستخدمه أي يتم حساب معامل الارتباط القويم نوع كيرنل لدوال كيرنل الثلاث .
- 4- يتم المقارنه بين معاملات الارتباط القويم المحسوبه وفق طريقه كيرنل وبالدوال الثلاث ومعامل الارتباط القويم المحسوب وفق الطريقه التقليديه .

تحليل النتائج :

بعد إجراء تجربة المحاكاة تم الحصول على النتائج التالية:

1- من الجدول رقم (1) والذي يمثل قيم معاملات الارتباط القويم المحسوبه باستخدام طريقة كيرنل وبالدوال الثلاث وكذلك معاملات الارتباط القويم المحسوبه وفق الطريقه التقليديه عندما يكون $\varepsilon_1, \varepsilon_2$ يتبع كل منهما التوزيع الطبيعي القياسي نلاحظ ان معاملات الارتباط القويم المحسوبه وفق طريقه كيرنل كانت اكبر من تلك المحسوبه وفق الطريقه التقليديه ولجميع حجوم العينات وكانت اكبر تلك الارتباطات باستخدام دالة (Gaussian Kernal) ومن ثم باستخدام دالة (Uniform Kernel) وبعد ذلك باستخدام دالة (Triangle Kernel) .

ونلاحظ بشكل عام ان الارتباطات المحسوبه وفق الطريقه التقليديه كانت صغيره جدا .

2- نلاحظ من الجدول رقم (2) والذي يمثل قيم معاملات الارتباط القويم المحسوبه باستخدام طريقة كيرنل وبالدوال الثلاث وكذلك معاملات الارتباط القويم المحسوبه وفق الطريقه التقليديه عندما يكون $\varepsilon_1, \varepsilon_2$ يتبع كل منهما التوزيع الاسي بالمعلمه $\lambda=1/3$ ان معاملات الارتباط القويم المحسوبه وفق طريقه كيرنل كانت اكبر من تلك المحسوبه وفق الطريقه التقليديه عند استخدام دالة (Gaussian Kernel) وكذلك عند استخدام داله (Uniform Kernel) ولجميع حجوم العينات بينما كانت تلك الارتباطات اقل مما كانت عليه ارتباطات الطريقه التقليديه عند استخدام داله (Triangle Kernel) .

ونلاحظ بشكل عام ان الارتباطات المحسوبه وفق الطريقه التقليديه كانت اكبر مما كانت عليه في الجدول رقم (1).

3- من الجدول رقم (3) والذي يمثل قيم معاملات الارتباط القويم المحسوبة باستخدام طريقة كيرنل وبالدوال الثلاث وكذلك معاملات الارتباط القويم المحسوبة وفق الطريقة التقليدية عندما يكون $\varepsilon_1, \varepsilon_2$ يتبع كل منهما توزيع مربع كاي بالمعلمه n نلاحظ ان معاملات الارتباط القويم المحسوبة وفق طريقة كيرنل كانت اكبر من تلك المحسوبة وفق الطريقة التقليدية ولجميع حجوم العينات وكانت اكبر تلك الارتباطات باستخدام دالة (Gaussian Kernal) ومن ثم باستخدام دالة (Uniform Kernel) وبعد ذلك باستخدام دالة (Triangle Kernel) . ونلاحظ بشكل عام ان الارتباطات المحسوبة وفق الطريقة التقليدية كانت اكبر مما كانت عليه في الجدول رقم (1) ، ولكنها كانت اقل مما كانت عليه في الجدول رقم (2) عند حجوم العينات المتشابهه.

الاستنتاجات:

- 1- عندما يكون $\varepsilon_1, \varepsilon_2$ يتبع كل منهما التوزيع الطبيعي القياسي او التوزيع الاسي بالمعلمه $\lambda=1/3$ او توزيع مربع كاي بالمعلمه n نلاحظ ان معاملات الارتباط القويم المحسوبة وفق طريقه كيرنل كانت اكبر من تلك المحسوبة وفق الطريقة التقليدية ولجميع حجوم العينات فيما عدا في حالة التوزيع الاسي حيث كانت الارتباطات القويمه المحسوبة باستخدام طريقه كيرنل اقل من الطريقة التقليدية عند استخدام دالة (Triangle Kernel) .
- 2- كانت الارتباطات القويمه المحسوبة وفق طريقة كيرنل باستخدام دالة (Gaussian Kernal) تمثل اكبر الارتباطات في جميع الحالات وعند جميع حجوم العينات.

المصادر:

- 1- المياحي ، نوري فرحان وعلي حسين بتور (2005). "مقدمه في التحليل الدالي". مؤسسة النبراس للطباعة والنشر والتوزيع ، النجف الاشرف، العراق.
- 2- Anderson, T.W (1984). "An Introduction to Multivariate statistical analysis". Jonwiley and sons.
- 3- Akaho, S. (2001) "A kernel method for canonical correlation analysis". International meeting of psychometric society, Osaka.
- 4- Donald F. Morrison (1988). "Multivariate statistical methods". Second edition, McGraw. Hill series in probability and statistics.
- 5- Florian, M. (2003) "Canonical Correlation Analysis With Kernels". Computational Diagnostics Group Seminar .Berlin.
- 6- Lai, p.l and C.fyfe (2000). "Kernel and nonlinear canonical correlation analysis". International Journal Of Neural Systems 10(5) , 365-377.

- 7- Lindeman, R, H (1980). "Introduction to bivariate and multivariate analysis". Scott-Foresman company, Illinois, U.S.A.
- 8- Romanazzi, m. (1992) "Influence in canonical correlation analysis", Psychometrika, 57, 237-259.

الملحق

جدول رقم (1)

يمثل الارتباطات القويمة المحسوبة وفق الطريقتين وبالدوال المختلفة عندما تتبع

الخطأ ϵ_1, ϵ_2

التوزيع الطبيعي القياسي

الطريقة	الدالة المستخدمة	n=10	n=20	n=30	n=40	n=50	n=60	n=70	n=80	n=90
Kernel CCA	Gaussian	0.82	0.80	0.79	0.78	0.78	0.77	0.77	0.77	0.77
	Uniform	0.63	0.62	0.61	0.59	0.58	0.57	0.57	0.57	0.58
	Triangle	0.55	0.52	0.50	0.47	0.46	0.45	0.45	0.46	0.46
CCA	Classical	0.10	0.03	0.02	0.002	0.02	0.04	0.04	0.04	0.03

جدول رقم (2)

يمثل الارتباطات القويمة المحسوبة وفق الطريقتين وبالدوال المختلفة عندما تتبع

الخطأ ϵ_1, ϵ_2

التوزيع الاسي بالمعلمه $\lambda=1/3$

الطريقة	الدالة المستخدمة	n=10	n=20	n=30	n=40	n=50	n=60	n=70	n=80	n=90
Kernel CCA	Gaussian	0.73	0.72	0.71	0.71	0.71	0.71	0.72	0.72	0.72
	Uniform	0.56	0.54	0.54	0.53	0.52	0.52	0.53	0.54	0.54
	Triangle	0.47	0.44	0.43	0.42	0.41	0.42	0.42	0.42	0.42
CCA	Classical	0.50	0.47	0.45	0.44	0.44	0.44	0.44	0.44	0.44

جدول رقم (3)

يمثل الارتباطات القويمة المحسوبة وفق الطريقتين وبالذوال المختلفة عندما تتبع

الاطفاء $\varepsilon_1, \varepsilon_2$

توزيع مربع كاي بالمعلمه n

الطريقة	الداله المستخدمه	n=10	n=20	n=30	n=40	n=50	n=60	n=70	n=80	n=90
Kernel	Gaussian	0.75	0.74	0.72	0.72	0.71	0.70	0.71	0.71	0.71
CCA	Uniform	0.62	0.59	0.57	0.56	0.55	0.54	0.55	0.55	0.55
	Triangle	0.52	0.51	0.48	0.46	0.45	0.44	0.45	0.45	0.45
CCA	Classical	0.43	0.40	0.39	0.36	0.35	0.34	0.34	0.34	0.34