

منهجية دمج طريقتي الاتحاد وتحليل المركبات الأساسية في اختيار
طاقم المتغيرات المستقلة

**A Methodology of Emerging Regression
And Principal Component Analyses Methods
For Selecting Set of Variables**

د. عبد الحميد عبد المجيد البلداوي
استاذ مساعد
كلية المنصور الجامعة
بغداد - العراق

تمهيد :

تتوفر عدة طرق ومنهجيات احصائية لغرض اختيار مجموعة
المتغيرات (التفسيرية) التي يمكن تضمينها في النموذج الذي يتم بناءه ،
ويأتي هذا الاختيار لاجل تحقيق هدفين حاسمين وهما :

- تحاشي مشكلة العلاقات الخطية المتداخلة بين المتغيرات التي يتم ترشيحها واخضاعها للتحليل وهي ما يطلق عليها بمسألة " Multicolinearity " .

- والاخر هو لتقليص عدد المتغيرات التي يضمها النموذج بغية تقليل الكلفة من جهة وتسهيل عملية احتسابه واستخدامه من جهة اخرى .

ومن اهم هذه الطرق (التي سيرد التطرق اليها لاحقا) هي التي تعتمد الانحدار المتعدد Multiple Regression ; (Draper and) (smith 1990) ، وتحليل المركبات الاساسية Principal Component Analysis (Hocking 1976 Jeffers 1978,) (Kendall 1980, Al- Beldawi 1978)

الا ان الطريقة المقترحة تطبيقها موضوع هذا البحث هي حصيله
دمج بين كلا الطريقتين اعلاه (Daling and Tamura, 1970)
والتي يمكن اعتبارها الحالة العملية لطريقة (Kendall, Principal Component Regression 1959) . والتي من ميزاتهما هو توفير مرونة عالية للباحث في اختيار المتغير الاكثر اهمية لتضمينه في النموذج ، بالاضافة الى النتائج المعنوية التي يمكن ان تتمخض عنها عملية التحليل باستخدام المنهجية المقترحة وكما افصحت عن ذلك نتائج هذا البحث .

وللوقوف على مدى اهمية المنهجية مقارنة بالطرق التقليدية الاخرى سيتم اخضاع المتغيرات المرشحة لعملية التحليل باستخدام الطرق الثلاث : الانحدار المتعدد ، وتحليل المركبات الاساسية ، والطريقة المقترحة وهي الدمج بين هاتين الطريقتين ، ومن ثم توظيف معايير تقييم المعنوية لنتائج كل منها .

1. مفهوم اختبار افضل طاقم من المتغيرات المستقلة

عند صياغة النموذج الخطي العام ، يفترض وجود علاقة خطية بين المتغير المعتمد Y و $(K-1)$ من المتغيرات المستقلة (التفسيرية) $(X_1, X_2, \dots, X_{K-1})$ والمتغير العشوائي μ وان هذه العلاقة في حالة اخذ عينة من المشاهدات Y_i ($i = 1, 2, 3, \dots, n$) فان الصيغة العامة للنموذج يكون :

$$Y_i = B_0 + B_1 X_1 + B_2 X_2 + \dots + B_{K-1} X_{K-1} + \mu$$

وان هذا النموذج يجب ان يحقق بالاضافة للفرضيات المتعلقة بالمتغير العشوائي فرضية عدم وجود علاقة خطية م. بين المتغيرات المستقلة (التفسيرية) ، اى ان هذه المتغيرات تكون مستقلة عن بعضها كما وان عدد المشاهدات التي هي n يجب ان لا تزيد على عدد المعلمات المجهولة في النموذج اى :

$$K \leq n$$

وفي حالة عدم تحقق هذه الافتراضات فإن النتائج التي يتم التوصل اليها لا تكون صحيحة ، لذلك ينبغي عدم استخدام النموذج الخطي العام الا بعد التأكد اولا من مدى انطباق الافتراضات التي على اساسها تم بناء النموذج على واقع المشاهدات . ومن بين اهم هذه الفرضيات هي المتعلقة بمشكلة العلاقات الخطية ، والتي تبرز عندما تكون هناك علاقات تامة او شبه تامة بين المتغيرات المستقلة ، لان قيمة محدد المصفوفة $|x'x|$ تساوي عنئذ صفر مما يتعذر معه ايجاد $(x'x)^{-1}$ وبالتالي يتعذر تقدير قيم المعلمات المجهولة .

2. نموذج تحليل المركبات الاساسية Principal Component Analysis

وهي طريقة احصائية وصفية تستخدم مع البيانات ذات المتغيرات المتعددة . وتقوم بتجميع كل مجموعة من البيانات المترابطة خطيا في احد المركبات الاساسية . وتعتمد في ذلك على مصفوفة الارتباط للمتغيرات التي تعتبر المرحلة الاساس في عملية تحليل المركبات . والمركبات الاساسية $Cp' S$ هي متغيرات عشوائية غير مترابطة ، وكل منها تضم مجموعة متغيرات عشوائية $(X_1, X_2, \dots, X_p)$ مترابطة وتشترك باتجاه خطي ، بحيث تأخذ الصيغة التالية :

$$C_j = \sum_{i=1}^p a_{ij} , j = 1, 2, \dots, p$$

وان a_{ij} هي عبارة عن معاملات عناصر (elements)
 مصفوفة الموجهات الذاتية الطبيعية (Normalised eigen vectors)
 لمصفوفة الارتباط للمتغيرات X_i 's
 وبواسطة مصفوفة قيم الموجهات الذاتية (eigen values)
 نحصل على الحجم النسبي للتغير أو التباين المفسر للبيانات الاحصائية
 بواسطة كل من المركبات الاساسية التي يتم احتسابها من المتغيرات
 X_i 's باستخدام التحويل المتعامد (orthogonal transformation)
 ويطلق على المعاملات a_{ij} عادة بتحميلات المركبة (component
 loadings) وهذه التحميلات تشير الى وزن العلاقة بين المتغيرات
 X_i 's والمركبات الاساسية C_p 's بشرط اخذ الجذر التربيعي لمصفوفة
 ارتباط تباينات الشيوخ لقيم التباين الذاتي (Morrison, 1967) .
 ويطلق على قيم الجذر التربيعي لتباينات الشيوخ (Communality)
 ويمكن الرمز له بـ :

$$h_j = a_{j1}^2 + a_{j2}^2 + \dots + a_{jp}^2$$

3. نموذج الانحدار المتعدد Multiple Regression

ان جوهر الافكار التي تعتمد عليها جميع طرق الاختيار التي سيلي ذكرها
 هي تضمين المتغير الذي يضيف اكبر زيادة ممكنة الى قوة التفسير
 للنموذج ، واذا كان على المتغير ان يحذف فيجب ان يكون تأثير حذفه
 اقل ما يمكن على قدرة النموذج التفسيرية .

اما اهم طرق نموذج الانحدار المتعدد المستخدمة لاختيار افضل طاقم متغيرات مستقلة فهي :

(1) طريقة شمول كافة المتغيرات (All Possible Regression) :-

وتستخدم اذا كان عدد المتغيرات ليس كبيرا ، وبرز عيوبها حاجتها لعمليات حسابية ووقت كبيرين .

(2) طريقة الاضافة المتتالية (Forward Selection Regression) :-

وفيها اذا كانت قيمة F الجدولة هي اقل من المحتسبة عندها يتوقف البحث عن متغير ، وبعبسه يتم ادخال متغير جديد الى المعادلة واعادة

$$\text{الاحتساب} \quad H_0 : \beta_i = 0 \quad \text{أي} \quad \text{vs} \quad H_1 : \beta_i \neq 0$$

طريقة الحذف التنازلي (Backward Elimination Selection

Regression) :- وهذا اذا كانت قيمة F المحتسبة لكافة المتغيرات

اكبر من قيمة F الجدولية ، عندها يحذف متغير من المعادلة والرجوع لمعرفة قيمة F المحتسبة من جديد وهكذا لغاية تفوق قيمة F الجدولية .

(3) طريقة الخطوات المتتالية (Stepwise Selection Regression) :-

تجمع بين طريقتي الاضافة المتتالية (FS) والحذف التنازلي (BE)، وفي كل خطوة يتم اختيار متغير ابتداء من الاكثر اهمية ولغاية عدم هبوط قيمة F المحتسبة عن قيمة F الجدولية بكلمة اخرى اجراء اختبار معاملات المتغيرات لمعرفة معنويتها من عدمها .

وتعتبر طريقة الخطوات Stepwise Regression هي اكثر الطرق استخداما وانتشارا من الناحية العملية لقلة الوقت الذي تحتاجه في عملية الاحتساب بالاضافة الى انها تعرض النتائج في كل خطوة بصورة واضحة ومرضية ومبكرة من دون الحاجة لاجراء الخطوات غير المعنوية .

4. منهجية الدمج بين طريقتي المركبات الاساسية والانحدار :

Principal Component Regression Analysis

وهي الطريقة المقترحة من قبل Kendall, 1957 ، وتمتاز بتوفيرها لمرونة كافية لاختيار المتغير الاكثر اهمية وذلك بالاعتماد على خبرة الباحث العملية ومثل هذه المرونة لا توفرها الطرق التقليدية التي تعتمد حصرا على الاساليب الميكانيكية بغض النظر عن مدى اهمية المتغير .

والفكرة التي تقوم عليها الطريقة هي : عند افتراض ان R هي مصفوفة الارتباط لـ P من المتغيرات التوضيحية او التفسيرية X_i وكما في السابق حيث ان $(P=1, 2, \dots, P)$ وافترضنا بأن C التي هي مصفوفة المركبات الاساسية المتعامدة orthogonal matrix و D هي المصفوفة القطرية Diagonal Matrix لقيم التباين الذاتي λ_i بحيث :

$$D = C^T R C$$

فإن المركبات الأساسية هي عناصر للموجه (Vector)

$$g_i = C^T X$$

وبذلك فإن انحدار المتغير التابع (الاستجابة) Y على المركبات g_i تعطي انحدار تعامدي

ويمكن تلخيص اهم الخطوات العملية للطريقة بما يلي :

(1) اختيار عدد المركبات الأساسية التي تفسر اعلى نسبة من التباين ولنقل ما يزيد على 90% مثلاً .

(2) تحليل انحدار المتغير التابع (الاستجابة) Y مع كل مركبة يتم اختيارها في الخطوة 1 اعلاه واحتساب قيمة R^2 مع التحقق من صحة اشارة المعاملات .

(3) اختيار المركبات التي تحقق اعلى R^2 .

(4) اختيار متغير مستقل من كل مركبة تم اختيارها في الخطوة 3 اعلاه على الاسس التالية:

— الاهمية العملية للمتغير بالنسبة للمتغير التابع (الاستجابة)

— سهولة قياسه (كلفته) .

— درجة ارتباطه مع المتغير التابع (الاستجابة) .

(5) اجراء عملية تحليل الانحدار للمتغير المعتمد مع كل من المتغيرات المستقلة التي يتم اختيارها في الخطوة 4 اعلاه .

5. البيانات الاحصائية :

لاجل اختبار مستوى اداء المنهجية المقترحة ومقارنتها بمستوى اداء الطرق التقليدية فقد تم ترشيح ثلاثة عشر متغيرا توضيحيا تم الحصول عليها من مسح احصائي لعينة شملت 842 مسافرا من مسافري النقل بين مراكز البلديات في العراق والتي تم توفيرها لغرض بناء نموذج احصائي لتفسير الطلب على النقل بين المدن . وسيكون المطلوب في هذا البحث هو استخدام كل من النماذج الثلاث لاختيار افضل مجموعة متغيرات معنوية من بين هذه لـ 13 متغيرا . والمتغيرات المرشحة هي :

- (1) مسافة الطريق (بالكم) X_1 قيمة مطلقة
- (2) يوم السفر X_2 متغير هيكلي (Dumy Variable) (1, 2, ----, 7)
- (3) نوع واسطة النقل (باص متوسط الحجم ، باص كبير الحجم) X_3 متغير هيكلي 1,2
- (4) وقت السفر (قبل الظهر ، بعد الظهر) X_4 متغير هيكلي 2,1
- (5) الغرض من السفر (رحلة عمل ، رحلة غير عمل) X_5 متغير هيكلي 2,1
- (6) عمر المسافر X_6 قيمة مطلقة (عدد السنين)
- (7) جنس المسافر X_7 متغير هيكلي 2,1
- (8) مهنة المسافر X_8 متغير هيكلي 1,2,3,--,5
- (9) معدل دخل اسرة المسافر الشهري X_9 قيمة مطلقة (بالدينار)
- (10) طول زمن الرحلة X_{10} قيمة مطلقة (بالدقائق)
- (11) معدل وقت انتظار المسافر في المحطة X_{11} قيمة مطلقة (بالدقائق)

(12) اجور السفر X12 قيمة مطلقة (بالدينار)

(13) معدل عدد رحلات واسطة النقل الواحدة يوميا X13 قيمة مطلقة (عدد)

1. نتائج التحليل :

1-6 نموذج الدمج بين طريقتي المركبات الاساسية والانحدار

طبقا لمتطلبات التحليل التي تطرقنا اليها في (الفقرة 4) اعلاه ، ففي الخطوة الاولى وكما مبين في الجدول رقم (1) حصلنا على 19 مركبات اساسية معنوية استطاعت هذه المركبات ان تقوم بتفسير اكثر من 99% من التباين .

وعند اجراء عملية تحليل الانحدار للخطوة التالية مع كل من المركبات العشرة التي حصلنا عليها ، واحتساب قيمة R^2 لكل منها ، نستدل على معنوية 7 مركبات وهي ، 1،4،5،6،7،9،10 وكما مبين في الجدول رقم (1) .

وباعتماد الاسس المشار اليها في الخطوة الرابعة لاجل تحديد متغير واحد من كل مركبة ، نجد ان مجموعة المتغيرات المختارة تشمل على التوالي كل من :

X2 , X5 , X7 , X9 , X12 , X11 , X4 ,

وعند بناء النموذج الذي سيضم هذه المجموعة من المتغيرات ، سيحقق

المعايير الاحصائية التالية :

$$R^2 = 0.84$$

$$S.E = 232$$

$$F\text{-ratio} = 609$$

$$\text{Sig at } 0.000$$

عدد المتغيرات = 7

2-6 نموذج الاحدار بطريقة كافة المتغيرات (All. Possible

Regression) وبأفترض ان البيانات خالية من مسألة العلاقات

المتداخلة (Multicollinearity) وتضمن المتغيرات المستقلة البالغ

عددها 13 متغيرا في النموذج ، فإن النموذج سيؤول الى ما يلي :

$$R^2 = 0.84$$

$$S.E. = 231$$

$$F = 329$$

$$\text{Sig at } 0.000$$

عدد المتغيرات = 13

Table (1)

Results of Variables Selection Using The Principal Component Regression .

Component	R ² *	Variable Selected
1	.05	X11
2	.02	---
3	.00	----
4	.05	X9
5	.06	X7
6	.04	X4
7	.04	X2
8	.00	----
9	.05	X5
10	.05	X12

* مع حجم عينة $n = 842$ فإن قيم R^2 في الجدول اعلاه هي عالية المعنوية أي $\alpha = 0.01$

3-6 نموذج تحليل المركبات الاساسية

وباستخدام طريقة تحليل المركبات الاساسية ، نستدل وكما موضح في الجدول (2) بأن هناك 10 مركبات (عوامل) معنوية ، استطاعت تفسير 99.4%

من مجموع التباين . وباعتماد حجم التحميل (size of loading) واهمية المتغيرات بالنسبة للمتغير المعتمد فإن هذه المركبات العشرة يمكن تسميتها كما يلي :

1. طول زمن الرحلة . وان اعلى معامل تحميل في هذه المركبة يعود لمتغيري مسافة الطريق (0.98) وطول زمن الرحلة (0.97) وان نسبة التباين التي قامت مجموعة متغيرات هذه المركبة بتفسيرها هي 33.9% .
2. واسطة النقل . وقد بلغ معامل التحميل لهذا المتغير 99% وساهمت المركبة الثانية بتفسير 13.7% من مجموع التباين .
3. عمر المسافرين . بمعامل تحميل مقداره 97% وتفسير 8.8% من مجموع التباين .
4. معدل دخل الاسرة الشهري . بمعامل تحميل مقداره 98% وساهمت هذه المركبة بتفسير 7.9% من مجموع التباين .
5. جنس المسافرين . بمعامل التحميل مقداره 99% وبتفسير 7.4% من مجموع التباين .
6. الغرض من السفر . بمعامل تحميل مقداره 99% وبتفسير 6.6% من مجموع التباين .
7. يوم السفر . بمعامل تحميل مقداره 99% وبتفسير 6.5% من مجموع التباين .
8. مهنة المسافرين . بمعامل تحميل مقداره 95% وبتفسير 5.6% من مجموع التباين .

10. وقت السفر . بمعامل تحميل مقداره 95% وبتفسير 5.1% من مجموع التباين .

11. معدل وقت الانتظار في المحطة . بمعامل مقداره 93% وبتفسير 3.9% من مجموع التباين .

Table (2)
Principal Component Loading for 13 Situational
Independent Variables

Variable	Components									
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
X1	.98									
X2							.99			
X3		.99								
X4	.31									
X5						.99			.95	
X6			.97							
X7					.99					
X8								.95		
X9				.98						
X10	.97									
X11	.35									
X12	.94									
X13	.95									
Eigenvalue	4.4	1.76	1.15	1.03	.97	.86	.84	.72	.66	.51
%	33.9	13.7	8.8	7.9	7.4	6.6	6.5	5.6	5.1	3.9
Variation										
Cum.%	33.9	47.9	56.4	64.3	71.7	87.3	84.8	90.4	95.5	99.4
Variation										

وان معايير تقييم نتائج عملية بناء النموذج الذي يتضمن مجموعة لـ 10 متغيرات المختارة في اعلاه ذات اعلى تحميل Loading في كل مركبة هي :

$$R^2 = 0.84$$

$$S.E = 231$$

$$F = 0.609$$

$$\text{Sig. at } 0.000$$

عدد المتغيرات = 10

4-6 المقارنة بين النتائج

لاجل اعطاء صورة واضحة من خلال المقارنة فأن الجدول التالي يعطي حصيلة كل طريقة ومستوى معنوية كل نموذج .

المعايير الاحصائية	النموذج النهائي لكافة المتغيرات بطريقة الانحدار	النموذج النهائي بالاعتماد على طريقة تحليل المركبات	النموذج النهائي بالاعتماد على طريقة الدمج بين تحليل المركبات والانحدار
عدد المتغيرات	13	10	7
R^2	0.84	0.84	0.84
S.E	231	233	232
F-ratio	329	609	856
At	0.000	0.000	0.000

ومنه نلاحظ بأنه رغم ما حققته المنهجية المقترحة وهي دمج بين تحليل المركبات والانحدار في اعداد المتغيرات التي يتضمنها النموذج الا ان درجة المعنوية قد ارتفعت بالنسبة لمعيار F-ratio مع عدم حصول اى انخفاض في درجة معنوية باقي المعايير الاحصائية

2. الاستنتاجات والتوصيات:

1-7 الاستنتاجات :

1. ان النتائج التي تمخضت عن عملية التحليل وفقا للمعايير الاحصائية والاقتصادية تشير الى ان طريقة نموذج الدمج بين طريقتي تحليل المركبات وتحليل الانحدار ، تمتاز بتقليص عدد المتغيرات المستقلة الى 7 متغيرات فقط مقابل عدم الانخفاض في قدرة النموذج التفسيرية للتباين .
2. ان منهجية الدمج ساعدت في تحديد اهم المتغيرات وفقا لاسباب المنطقية التي لها علاقة في تفسير الطلب مع شفافية الكشف عن المتغيرات المهمة التي لم يتضمنها النموذج ولكنها ممثلة Proxy بواسطة المتغيرات الداخلة الداخلة في النموذج من خلال النظر على تحميلات المتغيرات المسطرة في مركبة عند تحليل المركبات الاساسية ، استنادا الى العلاقة الخطية التي تربط هذه المتغيرات للمركبة الواحدة .
3. ان المنهجية تزداد فائدتها ومردوداتها الاقتصادية عندما تكون امام عدد كبير من المتغيرات وذلك لما تيسره في الكشف عن تلك الاكثر اهمية من خلال التأمل بحجم معاملات التحميل لكل متغير .

4. وفقا للأسس النظرية لتحليل المركبات الاساسية القائلة بوجود علاقات خطية مترابطة بين متغيرات كل مركبة وعدم وجود العلاقة بين المركبات . فأن عملية التخلص من العلاقات المتداخلة بين المتغيرات هي اكثر وضوحا وفعالية وتيسرا من خلال اختيار الممثل الانسب في كل مركبة .

2-7 التوصيات

1. بالرجوع عما تحقق من توظيف المنهجية المقترحة من نتائج مهمة ، فقد يكون من المفيد استخدام هذه المنهجية في عملية بناء النماذج الاقتصادية والاجتماعية . وعلى الاخص عند مجهولية المتغيرات التي لها تأثير فعلي على الظاهرة المدروسة بسبب عدم وجود دراسات سابقة عنها او بسبب مستجدات قد طرأت على الظاهرة مما يستدعي ترشيح اعداد كبيرة من المتغيرات لتحديد المجموعة التي لها تأثير فعلي وهام على الظاهرة الاقتصادية والاجتماعية . فاستخدام هذه المنهجية من شأنه تيسير عملية التحليل وللاخراج بشفافية اكبر في اتخاذ قرار اختبار المتغيرات .

2. ان اللجوء الى المنهجية موضوعة البحث من شأنها التخلص من دوامة اختيار الطريقة الانسب في عملية اختبار افضل طاقم متغيرات مستقلة ، والذي من شأنه محاولة اللجوء الى اغلب الطرق لاختبار الافضل وهو ما يتطلب كلفة اضافية في الوقت والاموال .

3. من المفيد ، اجراء دراسات لاحقة بأجراء تجربة محاكاة (Simulation) للوقوف على نتائج وتوصيات متقدمة ايضا بهذا الصدد.

المصادر

1. A.H.Al-Beldawi, Methods of Scientific Research using SPSS, Dar Al-Shrouk, Aman, 2004 .
2. A.H. Al-Beldawi, Statistics for Business and Applied Sciences, Dar Al-Shrouk, Aman, 1997 .
3. Daling , J.R. and Tomura, Use of Orthogonal Factors for selection of Variables in a Regression Equation .
An illustration , Applied Statistics, PP 260-68, 19,1970 .
4. Draper & Smith, Applied Regression Analysis, John Witley and son Inc. , London 1990 .
5. Hocking, R.R. , The Analysis and Selection of Variables in Linear Regression Biometrics, 32, PP.1-49, 1976 .
6. Jeffers, J.P. An Introduction to system Analysis : with ecological applications, William Clowes and sons LTD, London , 1978 .
7. Kendall , M. Multivariate Analysis, Second edition, Charts Griffin and LTD. , London, 1980.
8. Kendall , M. (1957) , A course in Mutivariat Analysis, Hafner New York , 1957 .

9. Morrison, D.F. , Multivariate Statistical Methods,
Mc. Graw-Hill, New York, 1967 .
10. Morrison, D.F., Multivariate Statistical Methods,
Mc. Graw-Hill, New York, 1967 .
11. W.J. Krzanowski, Principles of Multivariate
Analysis, Oxford University Press, 1988 .