

الفصل الثاني: التحليل العاملي العام Analyse Factorielle Générale (AFG)

تمهيد

تعتبر طريقة التحليل العاملي العام أساس كل طرق تحليل المعطيات للمتغيرات الكمية، و الفكرة الأساسية للتحليل العاملي العام هي البحث عن فضاء شعاعي جزئي اقل درجة عادةً ما يكون ذو البعد 2 يسمح لنا بأحسن تمثيل للبيانات و يحفظ لنا اكبر كمية من المعلومات، و يكون هذا بالنسبة للأفراد و المتغيرات.

1. التحليل في \mathbb{R}^p

ليكن $X(n,p)$ الجدول الأولي للمعطيات الذي يحتوي على n فرد ممثلين في الأسطر و p متغير أو خاصية ممثلة في الأعمدة، و نكتب:

$$X(n,p) = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & j & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ \vdots \\ i \\ \vdots \\ n \end{matrix} & \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1j} & \dots & x_{1p} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{i1} & x_{i2} & \dots & x_{ij} & \dots & x_{ip} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nj} & \dots & x_{np} \end{pmatrix} \end{matrix} \quad i = \overline{1, n} \quad ; \quad j = \overline{1, p}$$

حيث أن: x_{ij} هو العنصر المولد للمصفوفة $X(n,p)$ و يمثل قيمة الفرد i عند المتغير j ؛

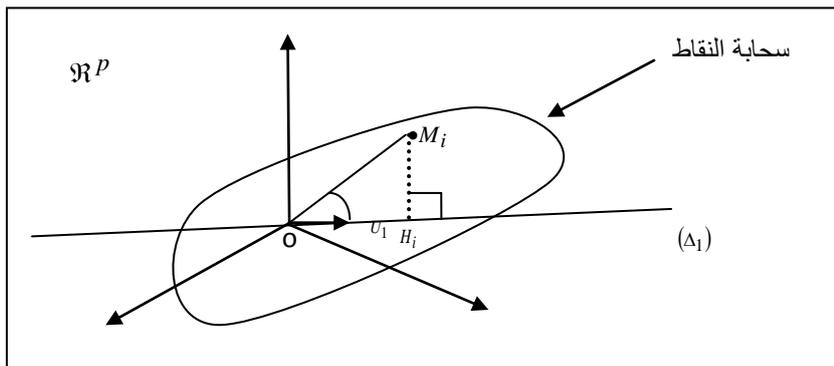
x_i هو شعاع سطر و يمثل كل قيم الفرد i ؛

x^j هو شعاع عمود و يمثل كل قيم المتغير j ؛

ان المقصود بالتحليل في \mathbb{R}^p هو دراسة و تحليل n فرد في فضاء المتغيرات ذو P محور، فالتمثيل

البياني لـ n فرد في الفضاء \mathbb{R}^p يعطي لنا سحابة نقاط موضحة في الشكل التالي:

الشكل (1): التمثيل البياني للتحليل في \mathbb{R}^p



إن التمثيل البياني السابق هو صورة توضيحية لـ n فرد في الفضاء \mathbb{R}^p أي الفضاء الذي يحتوي على p محور، غير أن تحليل ودراسة التمثيل السابق لا يكون إلا على سطح الورقة أو سطح المكتب أي على فضاء شعاعي جزئي ذو البعد 2، وعليه فإن الصورة السابقة تصبح غير واضحة المعالم ولا يمكننا ملاحظة أشياء كثيرة منها. وعلى أساس هذا التحليل فإننا نبحت عن فضاء شعاعي جزئي أقل درجة عادةً ما يكون ذو البعد 2 (سطح الورقة أو سطح المكتب) يسمح لنا بأحسن تمثيل للبيانات.

غير أننا نعلم أن الانتقال من فضاء ذو بعد أعلى إلى فضاء جزئي أقل درجة يؤدي بنا إلى احتمال فقدان جزء من المسافات أي إمكانية فقدان جزء من المعلومات، وبالتالي فإن البحث عن فضاء شعاعي جزئي أقل درجة يسمح لنا بأحسن تمثيل للبيانات ويحفظ لنا أكبر كمية من المعلومات.

فإذا اعتبرنا أن (Δ_1) هو أحد محاور الفضاء الشعاعي الجزئي المراد البحث عنه، حيث أن (Δ_1) يخترق المبدأ 0 ، فإن المسافة الحقيقية هي $[OM_i]$ أما $[OH_i]$ فتمثل مسافة إسقاط $[OM_i]$ على المحور (Δ_1) أي صورة المعلومات للفرد i على هذا المحور، وكما نعلم مسبقاً فإن مسافة الإسقاط دوماً أقل أو تساوي المسافة الحقيقية ونكتب:

$$[OH_i] \leq [OM_i]$$

أي أن الانتقال من الفضاء الأصلي إلى المحور (Δ_1) يؤدي بنا إلى إمكانية فقدان جزء من المسافات أي إمكانية فقدان جزء من المعلومات، وأنت كباحث لا تحبذ فقدان المعلومات أي أننا نبحت عن المحور (Δ_1) الذي يقلل من فقدان المعلومات أي الذي يُعظم المسافة OH_i ، وعلى أساس أن OH_i هي إحداثية النقطة M_i على (Δ_1) فإنه قد تكون القيمة OH_i سالبة وبالتالي يجب تعظيم القيمة OH_i^2 ، كما أننا نبحت عن المحور (Δ_1) الذي يقلل من فقدان المعلومات ليس فقط بالنسبة للنقطة i وإنما بالنسبة لكل النقط وبالتالي يجب تعظيم القيمة:

$$Q = \sum_{i=1}^n OH_i^2$$

ليكن U_1 شعاع توجيه المحور (Δ_1) أي أن:

$$U_1^t U_1 = 1 \Rightarrow (u_1 \ u_2 \ \dots \ u_j \ \dots \ u_p) \otimes \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_j \\ \vdots \\ u_p \end{pmatrix} = \sum_{j=1}^p u_j^2 = 1$$

وإذا كان إسقاط النقطة M_i على المحور (Δ_1) يعطينا النقطة H_i ، فإن البعد OH_i يمثل إحداثية

$$OH_i = x_i \times U_1 \quad \text{النقطة } i \text{ على المحور } (\Delta_1) \text{، ونكتب:}$$

حيث أن x_i تمثل إحداثية الفرد i في الفضاء \mathbb{R}^p :

$$x_i = (x_{i1}; x_{i2}; \dots x_{ij}; \dots x_{ip})$$

نرمز بـ F_1 لإحداثيات كل الأفراد على المحور (Δ_1) و نكتب:

$$F_1 = XU_1 = \begin{pmatrix} OH_1 \\ OH_2 \\ \cdot \\ \cdot \\ OH_i \\ \cdot \\ \cdot \\ OH_n \end{pmatrix} = \begin{pmatrix} F_1(1) \\ F_1(2) \\ \cdot \\ \cdot \\ F_1(i) \\ \cdot \\ \cdot \\ F_1(n) \end{pmatrix}$$

فالقائمة $OH_1 = F_1(1)$ تمثل إحداثية الفرد الأول على المحور (Δ_1) و القيمة $OH_2 = F_1(2)$ تمثل
إحداثية الفرد الثاني و القيمة $OH_n = F_1(n)$ تمثل إحداثية الفرد n على نفس المحور (Δ_1) .
وبغرض كتابة القيمة Q على شكل مصفوفاتي فإنه لدينا:

$$F_1' F_1 = (OH_1 \quad OH_2 \quad \dots \quad OH_i \quad \dots \quad OH_n) \times \begin{pmatrix} OH_1 \\ OH_2 \\ \cdot \\ \cdot \\ OH_i \\ \cdot \\ \cdot \\ OH_n \end{pmatrix} = \sum_{i=1}^n OH_i^2 = Q$$

وعليه يمكننا أن نكتب:

$$Q = \sum_{i=1}^n OH_i^2 = F_1' F_1 = (XU_1)' (XU_1) = U_1' X X U_1$$

ويصبح المشكل المطلوب حله هو:

$$\begin{cases} \text{MAX } Q = \sum_{i=1}^n OH_i^2 = U_1' X X U_1 \\ S/C \\ U_1' U_1 = 1 \end{cases}$$

وبغرض حل المشكل أعلاه فإننا نستعمل دالة لاغرانج:

$$L(U_1, \lambda_1) = U_1' X X U_1 - \lambda_1 (U_1' U_1 - 1)$$

وحتى نحصل على القيمة العظمى للدالة Q يجب أن يكون مشتق دالة لاغرانج $L(U_1, \lambda_1)$ بالنسبة لـ U_1 وبالنسبة لـ λ_1 معدوم ونكتب:

$$\begin{cases} \frac{\partial L(U_1, \lambda_1)}{\partial U_1} = 0 \\ \frac{\partial L(U_1, \lambda_1)}{\partial \lambda_1} = 0 \end{cases} \Rightarrow \begin{cases} 2XXU_1 - 2\lambda_1 U_1 = 0 \\ U_1' U_1 - 1 = 0 \end{cases} \Rightarrow \begin{cases} XXU_1 = \lambda_1 U_1 \dots \dots \dots (1) \\ U_1' U_1 = 1 \dots \dots \dots (2) \end{cases}$$

من المعادلة (1) يمكننا القول أن U_1 هو شعاع ذاتي للمصفوفة (XX) و المرفق بالقيمة الذاتية λ_1 . غير أننا نعلم أن المصفوفة $(X'_{p \times n} X_{n \times p})_{p \times p}$ هي مصفوفة مربعة ذات p سطر و p عمود تملك p قيمة ذاتية، فأي قيمة ذاتية نأخذ؟ من المعادلة (1) يمكننا أن نكتب:

$$(1) \Rightarrow XXU_1 = \lambda_1 U_1 \Rightarrow U_1' XXU_1 = U_1' \lambda_1 U_1 = \lambda_1 U_1' U_1$$

ومن المعادلة (2) لدينا: $U_1' U_1 = 1$ وبالتعويض في العبارة أعلاه نجد أن:

$$Q = U_1' XXU_1 = \lambda_1$$

و على أساس أن المشكل هو تعظيم القيمة $Q = U_1' XXU_1$ ووجدنا أن $Q = \lambda_1$ فإننا نأخذ أكبر قيمة ذاتية λ_1 من بين كل القيم الذاتية المستخرجة للمصفوفة (XX) كقيمة تسمح لنا باستخراج الشعاع الذاتي U_1 و الذي يعتبر شعاع توجيه للمحور (Δ_1) و الذي يعتبر أحسن محور على الإطلاق يحفظ لنا أكبر كمية من المعلومات و يعطينا أحسن تمثيل للبيانات، وعليه فإننا نقوم بتحليل المصفوفة (XX) و استخراج p قيمة ذاتية ثم نرتبها ترتيباً تنازلياً القيمة الأكبر ثم التي تليها و بعد ذلك نجد الأشعة الذاتية المرافقة لها ونكتب:

$$\begin{aligned} & \lambda_1; \lambda_2; \lambda_3 \dots \dots \dots; \lambda_p \text{ : القيم الذاتية} \\ & U_1; U_2; U_3 \dots \dots \dots; U_p \text{ : الأشعة الذاتية} \\ & \Delta_1; \Delta_2; \Delta_3 \dots \dots \dots; \Delta_p \text{ : المحاور} \end{aligned}$$

فالمحور (Δ_1) ذو شعاع توجيه U_1 يعتبر أحسن محور على الإطلاق يحفظ لنا أكبر كمية من المعلومات و يعطينا أحسن تمثيل للبيانات، ثم المحور (Δ_2) ذو شعاع توجيه U_2 ثم المحور الذي يليه و هكذا بهذا الترتيب. وعليه فإن المستوي الأول $(\Delta_1 \otimes \Delta_2)$ المشكل من المحورين الأول (Δ_1) و الثاني (Δ_2) هو المستوي الأفضل على الإطلاق يعطينا أحسن تمثيل و يحفظ لنا أكبر كمية من المعلومات.

1.1. الكثافة الكلية للبيانات

إن الكثافة الكلية للبيانات هي مجموع مربعات بعد كل النقاط عن المبدأ (O) أي بمعنى آخر هي التشتت الكلي بالنسبة للمبدأ، ونكتب:

$$I_t = \sum_{i=1}^n d(o, i)^2 = \sum_{\alpha=1}^p F_{\alpha}' F_{\alpha} = \sum_{\alpha=1}^p \lambda_{\alpha} = Tr(X'X)$$

أي أن مجموع القيم الذاتية يمثل الكثافة الكلية للبيانات والتي تعبر عن نوعية التمثيل أو التقدير البياني، ويمكننا كذلك أن نسمي الكثافة الكلية للبيانات بالجمود الكلي.

2.1. نسب تمثيل البيانات على المحاور

إن الانتقال من الفضاء الأصلي إلى المحور (Δ_{α}) يؤدي بنا إلى فقدان جزء من المعلومات واكتساب جزء من المعلومات على هذا المحور، فالنسبة المكتسبة على هذا المحور هي نسبة تمثيل البيانات على المحور، وتعطي هذه النسبة بالعلاقة التالية:

$$\tau_{\alpha} = \frac{\lambda_{\alpha}}{I_t} = \frac{\lambda_{\alpha}}{\sum_{\alpha=1}^p \lambda_{\alpha}}$$

أي أن $\tau_{\alpha} \%$ من بيانات المصفوفة X ممثلة على المحور (Δ_{α}) .

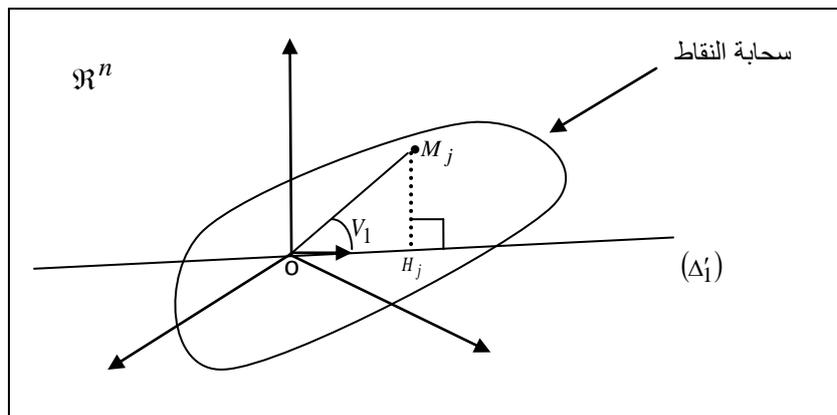
$$\tau_1 = \frac{\lambda_1}{I_t} \quad \text{فنسبة التمثيل على المحور الأول هي:}$$

$$\tau_2 = \frac{\lambda_2}{I_t} \quad \text{فنسبة التمثيل على المحور الثاني هي:}$$

$$\tau(\Delta_1 \otimes \Delta_2) = \frac{\lambda_1 + \lambda_2}{I_t} \quad \text{فتكون نسبة التمثيل على المستوي الأول $(\Delta_1 \otimes \Delta_2)$ هي:}$$

2. التحليل في \mathbb{R}^n

كما هو معلوم سابقاً فإن المقصود بالتحليل في \mathbb{R}^n هو دراسة وتحليل P متغير في فضاء الأفراد ذو n محور، فالتمثيل البياني لـ P متغير في الفضاء \mathbb{R}^n يعطي لنا سحابة نقاط موضحة في الشكل التالي:
الشكل (2) : التمثيل البياني للتحليل في \mathbb{R}^n



إن التمثيل البياني السابق هو صورة توضيحية لـ P متغير في الفضاء \mathbb{R}^n أي الفضاء الذي يحتوي على n محور، غير أن تحليل ودراسة التمثيل السابق لا يكون إلا على سطح الورقة أو سطح المكتب أي على فضاء شعاعي جزئي ذو البعد 2، وعليه فإن الصورة السابقة تصبح غير واضحة المعالم و لا يمكننا ملاحظة أشياء كثيرة منها. و على أساس هذا التحليل فإننا نبحث عن فضاء شعاعي جزئي اقل درجة عادةً ما يكون ذو البعد 2 (سطح الورقة أو سطح المكتب) يسمح لنا بأحسن تمثيل للمتغيرات، غير أننا كما نعلم مسبقاً أن الانتقال من فضاء ذو بعد أعلى إلى فضاء جزئي اقل درجة يؤدي بنا إلى احتمال فقدان جزء من المسافات أي إمكانية فقدان جزء من المعلومات، وبالتالي فإن البحث عن فضاء شعاعي جزئي اقل درجة يسمح لنا بأحسن تمثيل للبيانات ويحفظ لنا اكبر كمية من المعلومات.

فإذا اعتبرنا أن (Δ'_1) هو احد محاور الفضاء الشعاعي الجزئي المراد البحث عنه، حيث أن (Δ'_1) يخترق المبدأ O ، فإن المسافة الحقيقية هي $|OM_j|$ أما $|OH_j|$ فتمثل مسافة إسقاط $[OM_j]$ على المحور (Δ'_1) أي صورة المعلومات للمتغير j على هذا المحور، وكما نعلم مسبقاً فإن مسافة الإسقاط دوماً اقل أو تساوي المسافة الحقيقية ونكتب:

$$|OH_j| \leq |OM_j|$$

أي أن الانتقال من الفضاء الأصلي إلى المحور (Δ'_1) يؤدي بنا إلى إمكانية فقدان جزء من المسافات أي إمكانية فقدان جزء من المعلومات، وأنت كباحث لا تحبذ فقدان المعلومات أي أننا نبحث عن المحور (Δ'_1) الذي يقلل من فقدان المعلومات وبالتالي الذي يُعظم المسافة OH_j ، و على أساس أن OH_j هي إحداثية النقطة M_j على (Δ'_1) فإنه قد تكون القيمة OH_j سالبة وبالتالي يجب تعظيم القيمة $.OH_j^2$.

كما أننا نبحث عن المحور (Δ'_1) الذي يقلل من فقدان المعلومات ليس فقط بالنسبة للنقطة j

$$Q' = \sum_{j=1}^p OH_j^2 \quad \text{فقط وإنما بالنسبة لكل النقط وبالتالي يجب تعظيم القيمة:}$$

ليكن V_1 شعاع توجيه المحور (Δ'_1) أي أن:

$$V_1' V_1 = 1 \Rightarrow (v_1 \ v_2 \ \dots \ v_i \ \dots \ v_n) \otimes \begin{pmatrix} v_1 \\ v_2 \\ \cdot \\ v_i \\ \cdot \\ v_n \end{pmatrix} = \sum_{i=1}^n v_i^2 = 1$$

و إذا كان إسقاط النقطة M_j على المحور (Δ'_1) يعطينا النقطة H_j ، فإن البعد OH_j يمثل إحداثية

$$OH_j = (x^j) \times V_1 \quad \text{النقطة } j \text{ على المحور } (\Delta'_1) \text{ ونكتب:}$$

حيث أن (x^j) تمثل إحداثية المتغير j في الفضاء \mathcal{R}^n :

$$(x^j) = (x_{1j}; x_{2j}; \dots \dots \dots x_{ij}; \dots \dots \dots ; x_{nj})$$

نرمز بـ G_1 لإحداثيات كل المتغيرات على المحور (Δ'_1) ونكتب:

$$G_1 = X V_1 = \begin{pmatrix} OH_1 \\ OH_2 \\ \cdot \\ OH_j \\ \cdot \\ OH_p \end{pmatrix} = \begin{pmatrix} G_1(1) \\ G_1(2) \\ \cdot \\ G_1(j) \\ \cdot \\ G_1(p) \end{pmatrix}$$

فالقيمة $OH_1 = G_1(1)$ تمثل إحداثية المتغير الأول على المحور (Δ'_1) و القيمة $OH_2 = G_1(2)$ تمثل

إحداثية المتغير الثاني و القيمة $OH_p = G_1(p)$ تمثل إحداثية المتغير p على نفس المحور (Δ'_1) .

وبغرض كتابة القيمة Q' على شكل مصفوفاتي فإنه لدينا:

$$G_1' G_1 = (OH_1 \quad OH_2 \quad \dots \quad OH_j \quad \dots \quad OH_p) \times \begin{pmatrix} OH_1 \\ OH_2 \\ \cdot \\ OH_j \\ \cdot \\ OH_p \end{pmatrix} = \sum_{j=1}^p OH_j^2 = Q'$$

وعليه يمكننا أن نكتب:

$$Q' = \sum_{j=1}^p OH_j^2 = G_1' G_1 = (X V_1)' (X V_1) = V_1' X X V_1$$

ويصبح المشكل المطلوب حله هو:

$$\begin{cases} \text{MAX } Q' = \sum_{j=1}^p OH_j^2 = V_1' X X V_1 \\ S/C \\ V_1' V_1 = 1 \end{cases}$$

وبغرض حل المشكل أعلاه فإننا نستعمل دالة لاغرانج:

$$L(V_1, \mu_1) = V_1' XX' V_1 - \mu_1 (V_1' V_1 - 1)$$

وحتى نحصل على القيمة العظمى للدالة Q' يجب أن يكون مشتق دالة لاغرانج $L(V_1, \mu_1)$ بالنسبة

لـ V_1 وبالنسبة لـ μ_1 معدوم ونكتب:

$$\begin{cases} \frac{\partial L(V_1, \mu_1)}{\partial V_1} = 0 \\ \frac{\partial L(V_1, \mu_1)}{\partial \mu_1} = 0 \end{cases} \Rightarrow \begin{cases} 2XX' V_1 - 2\mu_1 V_1 = 0 \\ V_1' V_1 - 1 = 0 \end{cases} \Rightarrow \begin{cases} XX' V_1 = \mu_1 V_1 \dots \dots \dots (1) \\ V_1' V_1 = 1 \dots \dots \dots (2) \end{cases}$$

من المعادلة (1) يمكننا القول أن V_1 هو شعاع ذاتي للمصفوفة (XX') و المرفق بالقيمة الذاتية μ_1 . غير أننا نعلم أن المصفوفة $(X_{n \times p} X'_{p \times n})_{n \times n}$ هي مصفوفة مربعة ذات n سطرو n عمود تملك n قيمة ذاتية، فأى قيمة ذاتية نأخذ؟ من المعادلة (1) يمكننا أن نكتب:

$$(1) \Rightarrow XX' V_1 = \mu_1 V_1 \Rightarrow V_1' XX' V_1 = V_1' \mu_1 V_1 = \mu_1 V_1' V_1$$

ومن المعادلة (2) لدينا: $V_1' V_1 = 1$ وبالتعويض في العبارة أعلاه نجد أن:

$$Q' = V_1' XX' V_1 = \mu_1$$

و على أساس أن المشكل هو تعظيم القيمة $Q' = V_1' XX' V_1$ ووجدنا أن $Q' = \mu_1$ فإننا نأخذ أكبر قيمة ذاتية μ_1 من بين كل القيم الذاتية المستخرجة للمصفوفة (XX') كقيمة تسمح لنا باستخراج الشعاع الذاتي V_1 والذي يعتبر شعاع توجيه للمحور (Δ_1') والذي يعتبر أحسن محور على الإطلاق يحفظ لنا أكبر كمية من المعلومات و يعطينا أحسن تمثيل للبيانات، وعليه فإننا نقوم بتحليل المصفوفة (XX') و استخراج n قيمة ذاتية ثم نرتبها ترتيباً تنازلياً القيمة الأكبر ثم التي تليها و بعد ذلك نجد الأشعة الذاتية المرافقة لها ونكتب:

$$\begin{aligned} \text{القيم الذاتية: } & \mu_1; \mu_2; \mu_3 \dots \dots \dots; \mu_n \\ \text{الأشعة الذاتية: } & V_1; V_2; V_3 \dots \dots \dots; V_n \\ \text{المحور: } & \Delta_1'; \Delta_2'; \Delta_3' \dots \dots \dots; \Delta_n' \end{aligned}$$

فالمحور (Δ_1') ذو شعاع توجيه V_1 يعتبر أحسن محور على الإطلاق يحفظ لنا أكبر كمية من المعلومات و يعطينا أحسن تمثيل للبيانات، ثم المحور (Δ_2') ذو شعاع توجيه V_2 ثم المحور الذي يليه و

هكذا بهذا الترتيب. وعليه فان المستوي الأول $(\Delta_1' \otimes \Delta_2')$ المشكل من المحورين الأول (Δ_1') و الثاني (Δ_2') هو المستوي الأفضل على الإطلاق يعطينا أحسن تمثيل ويحفظ لنا اكبر كمية من المعلومات.

3. العلاقة بين التحليل في \mathbb{R}^p و التحليل في \mathbb{R}^n

من خلال نتائج التحليل في الفرعين السابقين وجدنا أن:

$$\text{التحليل في } \mathbb{R}^p : (1) \quad \alpha = \overline{1, p} \quad (XX) U_\alpha = \lambda_\alpha U_\alpha$$

$$\text{التحليل في } \mathbb{R}^n : (2) \quad \beta = \overline{1, n} \quad (XX') V_\beta = \mu_\beta V_\beta$$

في البداية نضرب المعادلة (1) من اليسار في المصفوفة X فنجد أن:

$$(1) \Rightarrow (XX)U_\alpha = \lambda_\alpha U_\alpha \Rightarrow X(XX)U_\alpha = X\lambda_\alpha U_\alpha \Rightarrow (XX')(XU_\alpha) = \lambda_\alpha (XU_\alpha)$$

و يمكننا أن نقرأ العبارة أعلاه أن الشعاع (XU_α) هو شعاع ذاتي للمصفوفة (XX') و المرفق بالقيمة الذاتية λ_α ، غير أننا نعلم من التحليل في \mathbb{R}^n أن μ_β هي القيمة الذاتية الأكبر للمصفوفة

$$(XX') \text{ وعليه يكون: } \mu_\beta \geq \lambda_\alpha$$

و من جهة أخرى يمكننا أن نضرب المعادلة (2) من اليسار في المصفوفة X' فنجد أن:

$$(2) \Rightarrow (XX')V_\beta = \mu_\beta V_\beta \Rightarrow X'(XX')V_\beta = X'\mu_\beta V_\beta \Rightarrow (XX)(X'V_\beta) = \mu_\beta (X'V_\beta)$$

و يمكننا أن نقرأ العبارة أعلاه أن الشعاع $(X'V_\beta)$ هو شعاع ذاتي للمصفوفة (XX) و المرفق بالقيمة الذاتية μ_β ، غير أننا نعلم من التحليل في \mathbb{R}^p أن λ_α هي القيمة الذاتية الأكبر للمصفوفة (XX)

$$\text{وعليه يكون: } \lambda_\alpha \geq \mu_\beta$$

و على أساس هاتين النتيجةين فان: $\mu_\beta \geq \lambda_\alpha$ و $\lambda_\alpha \geq \mu_\beta$ يكون من الضروري: $\lambda_\alpha = \mu_\beta$

كما أننا نعلم أن عدد الأفراد عادةً أكبر أو يساوي عدد المتغيرات: $n \geq p$ أي أن سلسلة قيم α

اقل من سلسلة قيم β ، و بغرض تحقيق التطابق بين قيم λ_α و قيم μ_β يجب أن يكون طول قيم السلسلة الأولى مساوي لطول قيم السلسلة الثانية و مساوية للعدد الأقل و هو α و يحدث ذلك بفعل

$$\text{التطابق، و نكتب: } \lambda_\alpha = \mu_\alpha \quad \alpha = \overline{1, p}$$

و من خلال النتيجة السابقة يمكننا أن نكتب:

$$\text{التحليل في } \mathbb{R}^p : (1) \quad \alpha = \overline{1, p} \quad (XX) U_\alpha = \lambda_\alpha U_\alpha$$

$$\text{التحليل في } \mathbb{R}^n : (2) \quad \alpha = \overline{1, p} \quad (XX') V_\alpha = \lambda_\alpha V_\alpha$$

4. عبارات الانتقال بين \mathbb{R}^p و \mathbb{R}^n

و على أساس نتائج التحليل السابقة يمكننا أن نستنتج عبارات الانتقال التالية، وهذه العبارات تسمح لنا بالانتقال من تحليل إلى آخر، وفائدة عبارات الانتقال هي تبسيط و تسهيل الحسابات و توفير الوقت.

1.4. عبارة أول انتقال من \mathbb{R}^p نحو \mathbb{R}^n

إذا قمنا بالتحليل في \mathbb{R}^p أي أننا نملك القيم الذاتية λ_α والأشعة الذاتية U_α و نرغب الآن في الانتقال إلى \mathbb{R}^n بغيت دراسة و تحليل المتغيرات، أي يجب علينا تحليل المصفوفة (XX') و استخراج القيم الذاتية λ_α والأشعة الذاتية V_α . غير أننا من التحليل السابق وجدنا أن الشعاع (XU_α) هو شعاع ذاتي للمصفوفة (XX') و المرفق بالقيمة الذاتية λ_α ، يمكننا أن نضع مرحلياً:

$$V_\alpha = XU_\alpha$$

و حتى يكون الشعاع الذاتي أعلاه شعاع توجيه للمحور α يجب أن تكون طويلة هذا الشعاع تساوي الواحد، غير أن طويلة هذا الشعاع هي:

$$\|V_\alpha\| = \sqrt{V_\alpha' V_\alpha} = \sqrt{(XU_\alpha)'(XU_\alpha)} = \sqrt{U_\alpha' X' X U_\alpha} = \sqrt{\lambda_\alpha} \neq 1$$

وحتى يكون هذا الشعاع الذاتي وحدوي يجب تقسيم مركبات هذا الشعاع على الطويلة، يكون:

$$V_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} XU_\alpha \quad ; \quad V_\alpha' V_\alpha = 1$$

و تمثل هذه العبارة أول عبارات الانتقال، فهي تمكننا من حساب الشعاع الذاتي الوحدوي V_α انطلاقاً من الشعاع الذاتي الوحدوي U_α . كما انه يمكننا تبسيط العبارة السابقة على النحو التالي:

$$V_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} XU_\alpha \Rightarrow V_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} F_\alpha \Rightarrow F_\alpha = \sqrt{\lambda_\alpha} V_\alpha$$

حيث أن F_α تمثل إحداثيات كل الأفراد على المحور α .

2.4. عبارة ثاني انتقال من \mathbb{R}^n نحو \mathbb{R}^p

إذا قمنا بالتحليل في \mathbb{R}^n أي أننا نملك القيم الذاتية λ_α والأشعة الذاتية V_α و نرغب الآن في الانتقال إلى \mathbb{R}^p بغيت دراسة و تحليل الأفراد، أي يجب علينا تحليل المصفوفة (XX) و استخراج القيم الذاتية λ_α والأشعة الذاتية U_α .

غير أننا من التحليل السابق وجدنا أن الشعاع (XV_α) هو شعاع ذاتي للمصفوفة (XX) و المرفق

$$U_\alpha = XV_\alpha \quad \text{بالقيمة الذاتية } \lambda_\alpha \text{، يمكننا أن نضع مرحلياً:}$$

و حتى يكون الشعاع الذاتي أعلاه شعاع توجيهه للمحور α يجب أن تكون طولية هذا الشعاع تساوي الواحد، غير أن طولية هذا الشعاع هي:

$$\|U_\alpha\| = \sqrt{U_\alpha' U_\alpha} = \sqrt{(XV_\alpha)'(XV_\alpha)} = \sqrt{V_\alpha' XX' V_\alpha} = \sqrt{\lambda_\alpha} \neq 1$$

وحتى يكون هذا الشعاع الذاتي وحدوي يجب تقسيم مركبات هذا الشعاع على الطويلة، يكون:

$$U_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} XV_\alpha \quad ; \quad U_\alpha' U_\alpha = 1$$

و تمثل هذه العبارة ثاني عبارات الانتقال، فهي تمكننا من حساب الشعاع الذاتي الوحدوي U_α انطلاقاً من الشعاع الذاتي الوحدوي V_α . كما انه يمكننا تبسيط العبارة السابقة على النحو التالي:

$$U_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} XV_\alpha \Rightarrow U_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} G_\alpha \Rightarrow G_\alpha = \sqrt{\lambda_\alpha} U_\alpha$$

حيث أن G_α تمثل إحداثيات كل المتغيرات على المحور α .

5. عبارة إعادة تشكيل البيانات

إذا كنا نملك القيم الذاتية λ_α والأشعة الذاتية U_α و V_α ، و نرغب في إعادة تشكيل عناصر المصفوفة X فان عبارة إعادة تشكيل البيانات تعطى على النحو التالي:

$$X = \sum_{\alpha=1}^p \sqrt{\lambda_\alpha} V_\alpha U_\alpha'$$