

## الفصل الثالث: طريقة التحليل بالمركبات الأساسية

### Analyse En Composante Principale (ACP)

#### تمهيد

نتناول في هذا الفصل طريقة التحليل بالمركبات الأساسية (ACP)، و تستخدم هذه الطريقة في تحليل الجداول الإحصائية بشرط أن تكون كل متغيرات الجدول الإحصائي ذات طبيعة كمية. وتهدف هذه الطريقة إلى البحث عن فضاء شعاعي جزئي اقل درجة عادةً ما يكون ذو البعد 2، يسمح لنا هذا الفضاء الشعاعي الجزئي بأحسن تمثيل ويحفظ لنا اكبر كمية من المعلومات. حيث أننا نستعمل هذه الطريقة بتوضيح مبدأ و جوهر الفكرة لطريقة التحليل بالمركبات الأساسية، ثم نتطرق لبعض خصائص و نتائج تحليل الأفراد في الفضاء  $\mathbb{R}^p$ ، ثم نهتم بدراسة و تحليل خصائص المتغيرات في الفضاء  $\mathbb{R}^n$  و هذا يخص فقط حالة طريقة التحليل بالمركبات الأساسية المرجحة (ACP - Normé).

#### 1. المبدأ الأساسي لطريقة التحليل بالمركبات الأساسية

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


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

حيث أن  $\eta_{ij}$  هو العنصر المولد للمصفوفة  $R(n,p)$ .

كما هو معلوم سابقاً فان المقصود بالتحليل في  $\mathbb{R}^p$  هو دراسة و تحليل الأفراد، فالتمثيل البياني لـ

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

الشكل (3) : التمثيل البياني للتحليل في  $\mathbb{R}^p$



وبيانياً المتوسطات الحسابية لـ  $P$  متغير تمثل إحداثيات مركز سحابة النقاط  $g$ .


$$g = (\bar{\eta}_1 \quad \bar{\eta}_2 \quad \dots \quad \bar{\eta}_j \quad \dots \quad \bar{\eta}_p)$$

$$\forall j = 1, p : \bar{\eta}_j = \sum_{i=1}^n \eta_{ij}$$

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.

و على أساس هذا التحليل فإننا نبحث عن فضاء شعاعي جزئي أقل درجة عادةً ما يكون ذو البعد 2 (سطح الورقة أو سطح المكتب) يسمح لنا بأحسن تمثيل للبيانات و يحفظ لنا أكبر كمية من المعلومات. ليكن  $(\Delta)$  احد محاور الفضاء الشعاعي الجزئي المراد البحث عنه، حيث أن  $(\Delta)$  يخترق المركز  $g$ ، ونريد تعظيم المسافة بين فردين على هذا المحور و التمثيل البياني التالي يوضح هذه الوضعية:

الشكل (4) : التمثيل البياني للإسقاط العمودي على المحور  $(\Delta)$



$$d^2(i, i') \geq d_{\Delta}^2(i, i') = (h_i - h_{i'})^2 \quad \text{لاحظ أن:}$$

و حتى يكون المحور  $(\Delta)$  يعطي أحسن تمثيل يجب أن يتم تعظم القيمة:

$$Q = \sum_{i=1}^n \sum_{i'=1}^n d_{\Delta}^2(i, i')$$

لدينا:

$$\begin{aligned}
Q &= \sum_{i=1}^n \sum_{i'=1}^n d_{\Delta}^2(i, i') = \sum_{i=1}^n \sum_{i'=1}^n (h_i - h_{i'})^2 = \sum_{i=1}^n \sum_{i'=1}^n (h_i^2 - 2h_i h_{i'} + h_{i'}^2) \\
&= \sum_{i=1}^n \sum_{i'=1}^n (h_i^2) - 2 \sum_{i=1}^n \sum_{i'=1}^n (h_i h_{i'}) + \sum_{i=1}^n \sum_{i'=1}^n (h_{i'}^2) \\
&= n \sum_{i=1}^n (h_i^2) - 2n^2 \left( \frac{1}{n} \sum_{i=1}^n h_i \right) \left( \frac{1}{n} \sum_{i'=1}^n h_{i'} \right) + n \sum_{i'=1}^n (h_{i'}^2)
\end{aligned}$$

وعلى أساس أن  $i$  أو  $i'$  يأخذون نفس القيم وهي من 1 إلى  $n$ ، يمكننا أن نكتب:

$$\begin{aligned}
\sum_{i=1}^n (h_i^2) &= \sum_{i'=1}^n (h_{i'}^2) \\
\left( \frac{1}{n} \sum_{i=1}^n h_i \right) &= \left( \frac{1}{n} \sum_{i'=1}^n h_{i'} \right) = \bar{h}
\end{aligned}$$

حيث أن  $\bar{h}$  يمثل إحداثية إسقاط مركز سحابة النقاط  $g$  على المحور  $(\Delta)$ .  
ومنه يكون:

$$\begin{aligned}
Q &= n \sum_{i=1}^n (h_i^2) - 2n^2 \left( \frac{1}{n} \sum_{i=1}^n h_i \right) \left( \frac{1}{n} \sum_{i'=1}^n h_{i'} \right) + n \sum_{i'=1}^n (h_{i'}^2) \\
&= 2n \sum_{i=1}^n (h_i^2) - 2n^2 \bar{h}^2 \\
&= 2n \left( \sum_{i=1}^n (h_i^2) - n \bar{h}^2 \right) \\
&= 2n \sum_{i=1}^n (h_i - \bar{h})^2 \\
&= 2n \times d_{\Delta}^2(i, g)
\end{aligned}$$

وعلى اعتبار أن  $n$  يمثل عدد الأفراد وهو ثابت يكون تعظيم القيمة  $Q = 2n \times d_{\Delta}^2(i, g)$  يستلزم


تعظيم القيمة  $d_{\Delta}^2(i, g)$ ، وهذه النتيجة تعني تعظيم مسافات الإسقاط بين كل النقاط ومركز السحابة على المحور  $(\Delta)$ .

فإذا قمنا بنقل المعلم من المبدأ  $(0)$  إلى مركز سحابة النقاط  $g$ ، فإن  $X$  هي مصفوفة البيانات الممركزة والتي تمثل إحداثيات الأفراد في المعلم ذو المبدأ  $g$ ، ونكتب:

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

$$i = \overline{1, n} ; j = \overline{1, p}$$

الشكل (5): التمثيل البياني لنقل المعلم من المبدأ  $0$  إلى مركز سحابة النقاط  $g$



وبعد نقل المعلم من  $0$  نحو  $g$  يكون  $(0 \equiv g)$  ويصبح عندئذٍ المشكل المطروح هو تعظيم المسافة بين مبدأ المعلم وإسقاطات النقاط على المحور  $(\Delta)$ ، وكما تتذكر أن هذا المشكل تمت معالجته في الفصل السابق أي باستعمال طريقة التحليل العاملي العام (AFG).

وعليه فإن طريقة التحليل بالمركبات الأساسية (ACP) تقتضي نقل البيانات من المعلم الأصلي ذو المبدأ  $0$  نحو المعلم الجديد ذو المبدأ  $g$  وتحديد المصفوفة  $X$  ثم تطبيق طريقة التحليل العاملي العام (AFG) على المصفوفة  $X$ ، غير أنه يتم استخراج القيم الذاتية والأشعة الذاتية من المصفوفة  $\left(\frac{XX}{n}\right)$  وهذا من أجل معاني تفسيرية فقط، ويمكننا أن نميز الحالتين التاليتين:

### 1.1. طريقة التحليل بالمركبات الأساسية البسيطة (ACP – Non normé)

يمكننا استعمال هذه الطريقة في حالة تجانس المتغيرات، أي أن تكون كل متغيرات الجدول الأولي للمعطيات لها نفس وحدة القياس، وفي هذه الحالة تكون المصفوفة  $X$  مصفوفة ممرزة وعلى النحو التالي:

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

$$i = \overline{1, n} ; j = \overline{1, p}$$

أما استخراج القيم الذاتية والأشعة الذاتية فيكون من المصفوفة  $\left(\frac{XX}{n}\right)$ ، ونكتب:

$$\left(\frac{XX}{n}\right) = \frac{1}{n} \begin{pmatrix} x_{11} & x_{21} & \dots & x_{i1} & \dots & x_{n1} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{1j} & x_{2j} & \dots & x_{ij} & \dots & x_{nj} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{1p} & x_{2p} & \dots & x_{ip} & \dots & x_{np} \end{pmatrix} \times \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1j} & \dots & x_{1p} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{i1} & x_{i2} & \dots & x_{ij} & \dots & x_{ip} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nj} & \dots & x_{np} \end{pmatrix}$$

$$= \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n x_{i1}^2 & \frac{1}{n} \sum_{i=1}^n x_{i1}x_{i2} & \dots & \frac{1}{n} \sum_{i=1}^n x_{i1}x_{ij} & \dots & \frac{1}{n} \sum_{i=1}^n x_{i1}x_{ip} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \frac{1}{n} \sum_{i=1}^n x_{i1}x_{ij} & \frac{1}{n} \sum_{i=1}^n x_{i2}x_{ij} & \dots & \frac{1}{n} \sum_{i=1}^n x_{ij}^2 & \dots & \frac{1}{n} \sum_{i=1}^n x_{ij}x_{ip} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \frac{1}{n} \sum_{i=1}^n x_{i1}x_{ip} & \frac{1}{n} \sum_{i=1}^n x_{i2}x_{ip} & \dots & \frac{1}{n} \sum_{i=1}^n x_{ij}x_{ip} & \dots & \frac{1}{n} \sum_{i=1}^n x_{ip}^2 \end{pmatrix}$$

$$\frac{1}{n} \sum_{i=1}^n x_{ij}x_{ij}'$$

إن العنصر المولد للمصفوفة أعلاه هو:

$$x_{ij} = (\eta_{ij} - \overline{\eta_j})$$

وكما نعلم أن في المصفوفة الممرزة فان:

وبالتعويض يكون العنصر المولد للمصفوفة  $\left(\frac{XX}{n}\right)$  هو:  $\frac{1}{n} \sum_{i=1}^n (\eta_{ij} - \bar{\eta}_j)(\eta_{ij'} - \bar{\eta}_{j'})$

والقيمة أعلاه تعبر عن التباين المشترك للمتغيرين  $j$  و  $j'$ ، ونكتب:

$$Cov(j, j') = \frac{1}{n} \sum_{i=1}^n (\eta_{ij} - \bar{\eta}_j)(\eta_{ij'} - \bar{\eta}_{j'})$$

و عليه فان المصفوفة  $\left(\frac{XX}{n}\right)$  تعبر عن مصفوفة التباين و التباين المشترك للمتغيرات، و هي مصفوفة مربعة ذات  $p$  سطرو  $p$  عمود و متناظرة حيث أنها في القطر الأول تحتوي على تباينات المتغيرات أما باقي العناصر فهي التباينات المشتركة للمتغيرات.

و عليه فان مصفوفة التباين و التباين المشترك للمتغيرات تكتب على النحو التالي:

$$V = \frac{XX}{n} = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & j & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ \cdot \\ \cdot \\ j \\ \cdot \\ p \end{matrix} & \begin{pmatrix} V(1) & Cov(1,2) & \dots & Cov(1, j) & \dots & Cov(1, p) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ Cov(j,1) & Cov(j,2) & \dots & V(j) & \dots & Cov(j, p) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ Cov(p,1) & Cov(p,2) & \dots & Cov(p, j) & \dots & V(p) \end{pmatrix} \end{matrix}$$

$j = \overline{1, p}$

## 2.1. طريقة التحليل بالمركبات الأساسية المرجحة (ACP - Normé)

ويكون من الضروري استعمال هذه الطريقة في حالة عدم تجانس المتغيرات، أي أن تكون متغيرات الجدول الأولى للمعطيات ليس لها نفس وحدة القياس، وفي هذه الحالة تكون المصفوفة  $X$  مصفوفة ممركرة ومرجحة و هي على النحو التالي:

$$X(n, p) = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & j & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ \cdot \\ \cdot \\ i \\ \cdot \\ n \end{matrix} & \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1j} & \dots & x_{1p} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{i1} & x_{i2} & \dots & x_{ij} & \dots & x_{ip} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{n1} & x_{n2} & \dots & x_{nj} & \dots & x_{np} \end{pmatrix} \end{matrix} ; x_{ij} = \frac{(\eta_{ij} - \bar{\eta}_j)}{\sigma_j}$$

$i = \overline{1, n} ; j = \overline{1, p}$

حيث أن  $\sigma_j$  يعبر عن الانحراف المعياري للمتغير  $j$ .

و يتم كذلك بنفس الطريقة استخراج القيم الذاتية والأشعة الذاتية من المصفوفة  $\left(\frac{XX}{n}\right)$ ،  
وبنفس خطوات حساب  $\left(\frac{XX}{n}\right)$  يتم تحديد عناصر هذه المصفوفة غير أنها في هذه الحالة تكون على  
النحو التالي:

$$\frac{1}{n} \sum_{i=1}^n \frac{(n_{ij} - \bar{n}_j)(n_{ij'} - \bar{n}_{j'})}{\sigma_j \times \sigma_{j'}}$$

والقيمة أعلاه تعبر عن معامل الارتباط الخطي البسيط بين المتغيرين  $j$  و  $j'$ ، ونكتب:

$$r_{(j,j')} = \frac{1}{n} \sum_{i=1}^n \frac{(n_{ij} - \bar{n}_j)(n_{ij'} - \bar{n}_{j'})}{\sigma_j \times \sigma_{j'}}$$

و عليه فان المصفوفة  $\left(\frac{XX}{n}\right)$  تعبر عن مصفوفة الارتباطات، وهي مصفوفة مربعة ذات  $p$  سطرو  
 $p$  عمود و متناظرة حيث أنها في القطر الأول تحتوي على القيمة واحد وهي تعني معامل الارتباط الخطي  
البسيط للمتغير مع نفسه أما باقي العناصر فهي معاملات الارتباط الخطي البسيط للمتغيرات فيما بينها، و  
نكتب:

$$C = \frac{XX}{n} = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & j & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ \cdot \\ \cdot \\ j \\ \cdot \\ p \end{matrix} & \begin{pmatrix} 1 & r_{(1,2)} & \dots & r_{(1,j)} & \dots & r_{(1,p)} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ r_{(j,1)} & r_{(j,2)} & \dots & 1 & \dots & r_{(j,p)} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ r_{(p,1)} & r_{(p,2)} & \dots & r_{(p,j)} & \dots & 1 \end{pmatrix} \end{matrix}$$

$j = \overline{1, p}$

## 2. التحليل في $\mathbb{R}^p$

للتحليل في  $\mathbb{R}^p$  نهتم بالخصائص التالية للمركبات الأساسية:

### 1.2. المتوسط الحسابي للمركبات الأساسية

تعطى عبارة المركبات الأساسية للأفراد على المحور  $\alpha$  على النحو التالي:

$$F_\alpha = XU_\alpha = \begin{pmatrix} X^1 & \dots & X^j & \dots & X^p \end{pmatrix} \times \begin{pmatrix} U_\alpha(1) \\ \cdot \\ \cdot \\ U_\alpha(j) \\ \cdot \\ \cdot \\ U_\alpha(p) \end{pmatrix} = \sum_{j=1}^p X^j U_\alpha(j)$$

$$\forall \alpha = 1, p : \overline{F_\alpha} = \sum_{j=1}^p \overline{X_j} U_\alpha(j) = 0$$

ويكون المتوسط الحسابي للمركبات الأساسية هو:

$$\overline{X_j} = 0$$


## 2.2. تباين المركبات الأساسية

$$\begin{aligned} \text{Var}(F_\alpha) &= \frac{1}{n} \sum_{\alpha=1}^p (F_\alpha - \overline{F_\alpha})^2 = \frac{1}{n} \sum_{\alpha=1}^p (F_\alpha)^2 = \frac{1}{n} F'_\alpha F_\alpha = \frac{1}{n} (XU_\alpha)' (XU_\alpha) \\ &= U'_\alpha \left( \frac{XX}{n} \right) U_\alpha \\ &= \lambda_\alpha (U'_\alpha U_\alpha) = \lambda_\alpha \end{aligned} \quad \left( \frac{XX}{n} \right) U_\alpha = \lambda_\alpha U_\alpha$$

أي أن تباين المركبة الأساسية يساوي القيمة الذاتية للمحور.

## 3.2. نسب تمثيل الأفراد على المحاور

نعلم مسبقاً انه كلما كانت القيمة  $|F_\alpha(i)|$  كبيرة كان المحور  $(\Delta_\alpha)$  جيد في تمثيل الفرد  $i$ ، وهذا يجعل من النقطة  $i$  أكثر قرباً من المحور  $(\Delta_\alpha)$  وعندئذٍ تنقلص الزاوية  $\theta$ ، والشكل البياني يوضح ذلك: الشكل (6) : التمثيل البياني لنسب تمثيل الأفراد على المحاور



وعليه فإننا نقترح  $\text{Cos}^2 \theta_{i\alpha}$  كمؤشر يقيس نسبة تمثيل الفرد  $i$  على المحور  $\alpha$ ، ونكتب:

$$\text{Cos}^2 \theta_{i\alpha} = \frac{F_\alpha^2(i)}{d^2(g, i)} \quad ; \quad d^2(g, i) = \sum_{\alpha=1}^p F_\alpha^2(i)$$

$$-1 \leq \text{Cos} \theta_{i\alpha} \leq 1 \Rightarrow 0 \leq \text{Cos}^2 \theta_{i\alpha} \leq 1$$

وكما نعلم أن:

ويمكننا القول انه كلما كانت الزاوية  $\theta_{i\alpha}$  صغيرة كانت نسبة تمثيل الفرد  $i$  على المحور  $\alpha$  جيدة و هذا يجعل من  $\text{Cos}^2 \theta_{i\alpha}$  يقترب من الواحد، أما في الحالة العكسية عندما تكون الزاوية  $\theta_{i\alpha}$  كبيرة تكون نسبة تمثيل الفرد  $i$  على المحور  $\alpha$  سيئة وهذا يجعل من  $\text{Cos}^2 \theta_{i\alpha}$  يقترب من الصفر.

أما عن نسب تمثيل الفرد  $i$  على المستوي الأول فهي:

$$\text{Cos}^2 \theta_{i1} + \text{Cos}^2 \theta_{i2}$$

و على أساس أن مجموع نسب تمثيل الفرد  $i$  على المحور  $\alpha$  هو 100% يكون:  $\sum_{\alpha=1}^p \cos^2 \theta_{i\alpha} = 1$

#### 4.2. نسب مساهمة الأفراد في تشكيل المحاور

نقيس نسبة مساهمة الفرد  $i$  في تشكيل المحور  $\alpha$  بالعلاقة التالية:

$$C_i^\alpha = \frac{F_\alpha^2(i)}{\sum_{i=1}^n F_\alpha^2(i)} = \frac{F_\alpha^2(i)}{F'_\alpha F_\alpha} = \frac{F_\alpha^2(i)}{n\lambda_\alpha}$$

$C_i^\alpha$  % : نسبة مساهمة الفرد  $i$  في تشكيل المحور  $\alpha$


و على أساس أن مجموع نسب مساهمة كل الأفراد في تشكيل المحور  $\alpha$  هي 100% يكون:

$$\sum_{i=1}^n C_i^\alpha = \frac{\sum_{i=1}^n F_\alpha^2(i)}{\sum_{i=1}^n F_\alpha^2(i)} = 1$$


#### 5.2. حالة إضافة أفراد جُدد

في هذا الفرع نعمل على توضيح كيفية حساب إحداثيات الأفراد الجدد وذلك بالاعتماد على نتائج تحليل الجدول الأصلي للمعطيات، والشكل التالي يوضح ذلك:

الشكل (7): حالة طريقة التحليل بالمركبات الأساسية البسيطة



الشكل (8): حالة طريقة التحليل بالمركبات الأساسية المرجحة



وتعطي عبارة المركبات الأساسية للأفراد الجدد على المحاور على النحو التالي:

$$F_{\alpha}^{+} = X^{+} \times U_{\alpha}$$

$n_s \times 1 \quad n_s \times p \quad p \times 1$

3. التحليل في  $\mathbb{R}^n$

نهتم في هذا الفرع بطريقة التحليل بالمركبات الأساسية المرجحة (ACP - Normé) فقط، وعندئذٍ يتم استخراج القيم الذاتية والأشعة الذاتية من مصفوفة الارتباطات  $C$ ، أما المصفوفة  $X$  الممركزة و المرجحة تكون على النحو التالي:

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

$i = \overline{1, n} \quad ; \quad j = \overline{1, p}$

حيث أن  $\sigma_j$  يعبر عن الانحراف المعياري للمتغير  $j$ .

غير أننا بغيت تحقيق بعض النتائج نعمل إلى القيام بتحويل بسيط على المصفوفة  $X$  ، وهذا التحويل لا يخص إلا هذا الفرع، إذن لنضع:

$$C = \frac{XX'}{n} = \left( \frac{X'}{\sqrt{n}} \right) \left( \frac{X}{\sqrt{n}} \right) = \tilde{X}\tilde{X}$$

حيث أن:

$$\tilde{X}_{(n,p)} = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & j & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ \vdots \\ i \\ \vdots \\ n \end{matrix} & \begin{pmatrix} \tilde{x}_{11} & \tilde{x}_{12} & \dots & \tilde{x}_{1j} & \dots & \tilde{x}_{1p} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \tilde{x}_{i1} & \tilde{x}_{i2} & \dots & \tilde{x}_{ij} & \dots & \tilde{x}_{ip} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \tilde{x}_{n1} & \tilde{x}_{n2} & \dots & \tilde{x}_{nj} & \dots & \tilde{x}_{np} \end{pmatrix} \end{matrix} ; \quad \tilde{x}_{ij} = \frac{(\eta_{ij} - \bar{\eta}_j)}{\sigma_j \times \sqrt{n}}$$

$i = \overline{1, n} \quad ; \quad j = \overline{1, p}$

### 1.3. إحداثيات المتغيرات على المحاور

نعمل في هذا الفرع على تحديد إحداثيات المتغيرات على المحور  $\alpha$  و نتطرق لدلالة هذه الإحداثيات، ونعلم أن عبارة الإحداثيات على النحو التالي:

$$G_\alpha(j) = \tilde{X}V_\alpha$$

$$V_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} \tilde{X}U_\alpha \quad \text{ونعلم أن:}$$

$$G_\alpha(j) = \tilde{X}' \frac{1}{\sqrt{\lambda_\alpha}} \tilde{X}U_\alpha \quad \text{وبتعويض نجد أن:}$$

$$\tilde{X} = \frac{1}{\sqrt{n}} X \quad \text{و} \quad F_\alpha = XU_\alpha \quad \text{ومع أن:}$$

وبتعويض نجد أن:

$$G_\alpha(j) = \frac{1}{\sqrt{\lambda_\alpha}} \times \frac{1}{\sqrt{n}} \tilde{X}'F_\alpha = \frac{1}{\sqrt{\lambda_\alpha}} \times \frac{1}{\sqrt{n}} \sum_{i=1}^n \tilde{x}_{ij}F_\alpha(i)$$

$$\tilde{x}_{ij} = \frac{\eta_{ij} - \bar{\eta}_j}{\sigma_j \sqrt{n}} \quad \text{و} \quad \bar{F}_\alpha = 0 \quad V(F_\alpha) = \lambda_\alpha \quad \text{و مع العلم أن:}$$

و بتعويض نجد أن:

$$\begin{aligned} G_{\alpha}(j) &= \frac{1}{\sqrt{\lambda_{\alpha}}} \times \frac{1}{\sqrt{n}} \sum_{i=1}^n \tilde{x}_{ij} F_{\alpha}(i) \\ &= \frac{1}{\sqrt{\lambda_{\alpha}}} \times \frac{1}{\sqrt{n}} \sum_{i=1}^n \left( \frac{\eta_{ij} - \bar{\eta}_j}{\sigma_j \sqrt{n}} \right) (F_{\alpha}(i) - \bar{F}_{\alpha}) \\ &= \frac{\frac{1}{n} \sum_{i=1}^n (\eta_{ij} - \bar{\eta}_j) (F_{\alpha}(i) - \bar{F}_{\alpha})}{\sigma_j \times \sigma(F_{\alpha})} = r(\alpha, j) \end{aligned}$$

وهذا يعني إن إحداثية المتغير  $J$  على المحور  $\alpha$   $G_{\alpha}(j)$  تعبر عن معامل الارتباط الخطي البسيط بين المتغير  $J$  والمحور  $\alpha$  أي أن  $G_{\alpha}(j) = r(\alpha, j)$ .  
2.3. المسافة بين المبدأ والمتغيرات

نقوم في هذا الفرع بحساب المسافة بين المبدأ ( $g \equiv o$ ) والمتغيرات، أي نحسب المسافة  $d(g, j)$ ، ونكتب:

$$\begin{aligned} g(0 \dots \dots \dots 0 \dots \dots \dots 0) & \text{ لدينا: إحداثيات المبدأ هي:} \\ j(\tilde{x}_{1j} \dots \dots \dots \tilde{x}_{ij} \dots \dots \dots \tilde{x}_{nj}) & \text{ إحداثيات المتغير } j \text{ هي:} \end{aligned}$$

تكون المسافة على النحو التالي:

$$d(g, j) = \sqrt{\sum_{i=1}^n (\tilde{x}_{ij} - 0)^2} = \sqrt{\sum_{i=1}^n \left( \frac{\eta_{ij} - \bar{\eta}_j}{\sigma_j \sqrt{n}} \right)^2} = \sqrt{\frac{\frac{1}{n} \sum_{i=1}^n (\eta_{ij} - \bar{\eta}_j)^2}{\sigma_j^2}}$$

$$\sigma_j^2 = \frac{1}{n} \sum_{i=1}^n (\eta_{ij} - \bar{\eta}_j)^2$$


و مع العلم أن:

و بتعويض نجد أن:

$$d(g, j) = \sqrt{\frac{\sigma_j^2}{\sigma_j^2}} = 1$$

وهذه النتيجة تعني أن كل المتغيرات تقع على سطح كرة مركزها المبدأ ( $g \equiv o$ ) و نصف قطرها يساوي الواحد. و إسقاط هذه الكرة على المستوى الأول و هو المستوى الأفضل على الإطلاق، يعطينا قرص مركزها المبدأ ( $g \equiv o$ ) و نصف قطرها يساوي الواحد، و الشكل التالي يوضح ذلك:

الشكل (9): التمثيل البياني لإسقاط المتغيرات على المستوى



و على أساس النتيجة السابقة فان كل المتغيرات تقع داخل هذا القرص و من غير الممكن أن تقع خارجه، فالمتغيرات  $(x_1, x_2, x_3, x_4)$  و التي تقع بالقرب من المركز سيئة التمثيل على المستوى المقترح للدراسة و سبب ذلك أن هذه المتغيرات في وضعها الحقيقي تقع في اعلي أو أسفل الكرة أي أنها بعيدة جداً عن المستوى الأول و بالتالي تستثنى من التحليل و الدراسة، أما باقي المتغيرات و التي تقع بالقرب من محيط القرص  $(x_5, x_6, x_7, x_8, x_9, x_{10})$  جيدة التمثيل على المستوى المقترح للدراسة و سبب ذلك أن هذه المتغيرات في وضعها الحقيقي تقع بالقرب من المستوى الأول و بالتالي مقبولة في التحليل و الدراسة.

### 3.3. المسافة بين متغيرين

نقوم في هذا الفرع بحساب المسافة بين متغيرين، أي نحسب المسافة  $d(j, j')$  ، و نكتب:

لدينا: إحدائيات المتغير  $j$  هي:  $j(\tilde{x}_{1j} \dots \tilde{x}_{ij} \dots \tilde{x}_{nj})$

إحدائيات المتغير  $j'$  هي:  $j'(\tilde{x}_{1j'} \dots \tilde{x}_{ij'} \dots \tilde{x}_{nj'})$

تكون المسافة على النحو التالي:

$$d(j, j') = \sqrt{\sum_{i=1}^n (\tilde{x}_{ij} - \tilde{x}_{ij'})^2} = \sqrt{\sum_{i=1}^n \tilde{x}_{ij}^2 - 2 \sum_{i=1}^n \tilde{x}_{ij} \tilde{x}_{ij'} + \sum_{i=1}^n \tilde{x}_{ij'}^2}$$

و مع العلم أن:

$$\sum_{i=1}^n \tilde{x}_{ij}^2 = \sum_{i=1}^n \tilde{x}_{ij'}^2 = 1 \quad \text{و} \quad \tilde{x}_{ij} = \frac{\eta_{ij} - \bar{\eta}_j}{\sigma_j \sqrt{n}} \quad \text{و} \quad \tilde{x}_{ij'} = \frac{\eta_{ij'} - \bar{\eta}_{j'}}{\sigma_{j'} \sqrt{n}}$$

و بتعويض نجد أن:

$$\begin{aligned} d(j, j') &= \sqrt{\sum_{i=1}^n (\tilde{x}_{ij} - \tilde{x}_{ij'})^2} = \sqrt{2 - 2 \sum_{i=1}^n \left( \frac{\eta_{ij} - \bar{\eta}_j}{\sigma_j \sqrt{n}} \right) \times \left( \frac{\eta_{ij'} - \bar{\eta}_{j'}}{\sigma_{j'} \sqrt{n}} \right)} \\ &= \sqrt{2 - 2 \frac{\frac{1}{n} \sum_{i=1}^n (\eta_{ij} - \bar{\eta}_j) \times (\eta_{ij'} - \bar{\eta}_{j'})}{\sigma_j \times \sigma_{j'}}} \\ d(j, j') &= \sqrt{2(1 - r_{j, j'})} \end{aligned}$$

حيث أن  $r_{j, j'}$  يمثل معامل الارتباط الخطي البسيط بين المتغيرين  $j$  و  $j'$ .  
 $-1 \leq r_{j, j'} \leq 1 \Rightarrow 0 \leq d(j, j') \leq 2$

وهذه النتيجة تعني أن المسافة بين المتغيرات تعطي بدلالة الارتباط فيما بينهم، و على أساس هذه النتيجة يمكننا أن نميز الحالات الثلاثة التالية:


A. حالة الارتباط القوي الموجب

إذا كانت المسافة بين المتغيرين  $j$  و  $j'$  تؤول إلى الصفر فإن الارتباط بين هاذين المتغيرين قوي و

$$[d(j, j') \rightarrow 0] \Leftrightarrow [r_{j, j'} \rightarrow 1]$$

موجب، ونكتب:

الشكل (10) : حالة الارتباط القوي الموجب



وفي الشكل أعلاه يمكننا القول أن المتغيرين  $x_1$  و  $x_2$  يرتبطان ارتباط قوي و موجب، و نفس الشيء بالنسبة للمتغيرين  $x_3$  و  $x_4$  لهما ارتباط قوي و موجب فيما بينهما.


B. حالة الارتباط القوي السالب

إذا كانت المسافة بين المتغيرين  $j$  و  $j'$  أعظمية فإن الارتباط بين هاذين المتغيرين قوي و سالب، و

$$[d(j, j') \rightarrow 2] \Leftrightarrow [r(j, j') \rightarrow -1]$$

نكتب:

الشكل (11): حالة الارتباط القوي السالب



وفي الشكل أعلاه يمكننا القول أن المتغيرين  $x_1$  و  $x_2$  يرتبطان ارتباط قوي و سالب، و نفس الشيء بالنسبة للمتغيرين  $x_3$  و  $x_4$  لهما ارتباط قوي و سالب فيما بينهما.


C. حالة الاستقلالية

إذا كانت المسافة بين المتغيرين  $j$  و  $j'$  تؤول إلى العدد  $\sqrt{2}$  فإن هاذين المتغيرين مستقلين عن

$$[d(j, j') \rightarrow \sqrt{2}] \Leftrightarrow [r(j, j') \rightarrow 0]$$

بعض، و نكتب:

الشكل (12): حالة الاستقلالية




وفي الشكل أعلاه يمكننا القول أن المتغيرين  $x_1$  و  $x_2$  مستقلين عن بعض، ونفس الشيء بالنسبة للمتغيرين  $x_3$  و  $x_4$  فهما مستقلين عن بعض.


#### 4. حالة إضافة متغيرات جُدد

في هذا الفرع نعمل على توضيح كيفية حساب إحداثيات المتغيرات الجدد وذلك بالاعتماد على نتائج تحليل الجدول الأصلي للمعطيات، والشكل التالي يوضح ذلك:

الشكل (13) : حالة طريقة التحليل بالمركبات الأساسية البسيطة



الشكل (14) : حالة طريقة التحليل بالمركبات الأساسية المرجحة



وتعطى عبارة إحداثيات المتغيرات الجدد على المحاور على النحو التالي:  $G_{\alpha}^{+} = X^{+} \times V_{\alpha}$   
 $p_s \times 1$      $p_s \times n$      $n \times 1$

