

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي
جامعة الشهيد حمدة لخضر الوادي-
كلية العلوم الاقتصادية والتجارية وعلوم التسيير

مطبوعة دروس على الخط:

تحليل المعطيات

موجهة لطلبة السنة الثانية ماستر اقتصاد كمي

إعداد: د. جديدي موسى

2022/2021

فهرس المحتويات	
الصفحة	المحتويات
	المحور الاول: طريقة تحليل المركبات الاساسية ACP
	1. التقديم النظري لطريقة المركبات الاساسية
	2. التحليل في فضاء المتغيرات
	3. التحليل في فضاء العينة للعينات
	4. طرق التدوير:
	5. مثال حسابي
	6. مثال تدريبي
	المحور الثاني: التحليل العاملي المتناظر AFC
	1. مجالات التطبيق
	2. البيانات المستخدمة
	3. أهداف التحليل العاملي المتناظر AFC
	4. التشابه والجمع بين الفئات
	5. مثال حسابي:
	المحور الثالث: التحليل العاملي التمييزي AFD
	1. الدالة التمييزية:
	2. قوة دالة التمييز
	3. تقدير معاملات الدالة التمييزية الخطية
	4. الاهمية النسبية للمتغيرات
	5. اختبار قدرة دالة التمييز في التمييز بين مجموعتين
	6. النقطة الفاصلة
	7. نسبة الخطأ
	المحور الرابع: أمثلة تطبيقية
	1. مثال تطبيقي للتحليل بطريقة مركبات الأساسية باستخدام SPSS
	2. مثال تطبيقي التحليل العاملي المتناظر باستخدام SPSS

المحور الاول: طريقة تحليل المركبات الاساسية ACP

1. التقديم النظري لطريقة المركبات الاساسية

استعملت هذه الطريقة لأول مرة من طرف karl pearson سنة 1901 ، و أول من ضمها إلى الإحصاء الرياضي هو Harold Hotelling سنة 1933 ، غير أنها لم تصبح واسعة الإستعمال إلا في التسعينات، ذلك لظهور الحاسوب و البرامج الإحصائية التي سهلت العمل بهذه التقنية.

تعتبر طريقة تحليل المركبات الرئيسية أو المكونات الأساسية Analyse en composantes principales

إحدى أهم طرق التحليل العاملي حيث تهتم بتقليص أكبر قدر ممكن من المتغيرات أو الأفراد إلى عوامل أو مركبات رئيسية تحتوي على أكبر قدر من المعلومات أو التباينات الموجودة في المتغيرات أو الأفراد باستخدام التحليل الوصفي، وأيضاً تعمل على اسقاطات النقاط في المستوي باستخدام العديد من أساليب تدوير المحاور لأجل الحصول على أحسن تمثيل.

كما يعتبر التحليل في المركبات الأساسية أحد تقنيات تحليل التي تختص في اختزال البيانات ذات الأبعاد الكبير ، أي اختزال عدد كبير من المتغيرات الخام إلى عدد أقل من المتغيرات الجديدة في شكل مركبات وتكون غالباً أهداها أقل بكثير من المتغيرات الخام

وعلى خلاف تحليل الإنحدار أو تحليل التباين الذان يعتبران متغير واحد تابع و البقية مستقلة فإن التحليل في المكونات الأساسية كل متغير يقارن ببقية المتغيرات، وإيجاد الجذور المميزة و المتجهات المميزة لمصفوفة التباين و التباين

المشترك للمتغيرات التوضيحية، أو إيجاد الجذور المميزة لمصفوفة الارتباط، و هذا يعتمد على طبيعة البيانات.

2. التحليل في فضاء المتغيرات

تشكل مصفوفة البيانات x_{np} سحابة من n نقطة في فضاء بعده p ، أو سحابة من نقاط p في فضاء ذو بعد n . يتكون الرسم التخطيطي الثنائي من إسقاط هذه النقاط على اثنين أو أكثر من الأبعاد المختارة بشكل عشوائي. يتمثل PCA من إسقاط النقاط على خط مستقيم، مستوى ... مساحة فرعية من أبعاد s (مع $p > s$) تم اختيارها لتحسين معيار معين. بشكل حدسي، سوف نبحث عن الفضاء الجزئي الذي يعطي أفضل تصور ممكن لسحابة النقاط الخاصة بنا. الاختيار الجيد هو البحث عن أكبر تشنت ممكن أكبر انتشار في الفضاء الجزئي المختار. وبالتالي، فإننا قادرين على البحث عن دوران لنظامنا الأولي من المحاور (المتغيرات) مما يسمح لنا برؤية السحابة بشكل أفضل. دعونا نحدد الشعاع المطلوب $(u_1' u_1 = 1)$ ؛ والذي يعطي أكبر تشنت للإسقاطات.

لتكن المصفوفة $X_{n \times p}$ ؛ كل سطر يمثل ملاحظة. يمثل كل عمود متغيراً. سنفترض أن كل متغير يتم توسيطه، أي أننا طرحنا متوسط كل متغير مسبقاً. يتم ذلك بطريقة تجعل مركز ثقل نقطة السحابة متزامناً مع المركز.

تُعطى إسقاطات الملاحظات n على الشعاع u_1 من خلال:

$$C = Xu_1$$

مجموع مربعات هذه السقاطات هو:

$$C'C = u_1'X'Xu_1$$

سنختار u_1 لتعظيم هذه الكمية الأخيرة. لذا فإن المشكلة هي:

$$\text{تعظيم } u_1'X'Xu_1 \text{ وفقاً لـ } u_1'u_1 = 1$$

هذه مشكلة يمكن حلها بطريقة لاغرانج.

نشكل لاغرانج:

$$L = u_1'X'Xu_1 - \lambda (u_1'u_1 - 1)$$

نشق المعادلة بالنسبة لكل مكونات p للشعاع u_1 وكذلك بالنسبة إلى

مضاعف لاغرانج (λ) ونساوي المشتقات الجزئية لـ صفر.

$$2(X'Xu_1 - \lambda u_1) = 0$$

$$u_1'u_1 = 1$$

بعد التبسيط نجد:

$$X'Xu_1 = \lambda u_1$$

$$u_1'u_1 = 1$$

الشكل السابق يمثل معادلة الأشعة الذاتية والقيم الذاتية للمصفوفة $X'X$.
وبالتالي ، فإن الشعاع الذي يعطي الإسقاطات ذات التشبت الأكبر هو
الشعاع الذاتي الأول لمصفوفة التباين - التباين لـ X .

ملاحظات:

- مصفوفة العدديّة ($X'X$) هي مصفوفة متماثلة وموجبة. هذا يعني أن القيم الذاتية و الأشعة الذاتية ستكون عدديّة. بالإضافة الى ذلك ، ستكون قيم القيم الذاتية موجبة أو صفرية.
- الأشعة الذاتية لمصفوفة متماثلة تكون دائماً متعامدة مع بعضها البعض ، أي $u_1'u_2=0$.
- تحدد الإسقاطات الموجودة على الشعاع u_1 متغيراً جديداً وهو عبارة عن مجموعة خطية من المتغيرات الأصلية. يتم إعطاء تباين هذا المتغير الجديد من خلال:

$$1/n (u_1'X'Xu_1) = 1/n (u_1'\lambda_1u_1) = 1/n \lambda_1$$

وبالتالي فإن تباين الإسقاطات يساوي (للعامل $1/n$) للقيمة الذاتية. وهكذا يتم الوصول إلى الحد الأقصى مع القيمة الذاتية الأولى. هذا هو السبب في الاحتفاظ بالشعاع الذاتي الأول.

- نعلم أن مجموع القيم الذاتية للمصفوفة يساوي أثر المصفوفة الأصلية. لذلك لا يتغير الحجم الإجمالي للتباين.

- تشير النسبة $\lambda_1/(\sum \lambda_i)$ إلى نسبة التباين الكلي الذي يدعمه الشعاع الذاتي الأول.

السؤال 1: ما هي العلاقة بين الأشعة الذاتية والقيم الذاتية لـ $X'X$ وتلك الخاصة بـ $X'X/n$ ؟

إيجاد الشعاع الثاني u_2 .

نبحث عن الشعاع u_2 الذي يحقق:

$$u_2'X'Xu_2 \text{ تعظيم}$$

$$\text{يخضع لـ } u_2'u_1 = 0$$

$$\text{و } u_2'u_2 = 1$$

الحل يكمن في استخدام طريقة لاغرانج كما يلي:

$$L = u_2'X'Xu_2 - w(u_2'u_1) - \lambda_2(u_2'u_2 - 1)$$

نشق لاغرانج فيما يتعلق بكل مكون من مكونات الشعاع u_2 وفيما يتعلق بـ

u_1 .

بعد التبسيط ، نجد:

$$X'X u_2 = \lambda_2 u_2$$

$$u_2'u_2 = 1$$

$$u_1'u_2 = 0$$

الشعاع الذي تم العثور عليه هو الشعاع الذاتي المرتبط بثاني أكبر قيمة ذاتية لمصفوفة التباين والتغاير. يمكن تعميم هذه النتائج بسهولة على عدة أبعاد ونجد ما يلي:

الفضاء ذو البعد s بحيث $s \leq p$ الذي يعطي أفضل تفسير يتم تعريفه بواسطة الأشعة الذاتية لـ $X'X$ المرتبطة بأكبر قيم للقيم الذاتية.

3. التحليل في فضاء العينة للعينات

لقد درسنا كيف يمكن تطبيق ACP لتحليل سحابة n من المشاهدات في فضاء المتغيرات p . يمكن أيضاً أن نقوم بالتحليل سحابة المتغيرات p في فضاء n من المشاهدات. نحن نبحث عن فضاء فرعي للبعد $(s \leq p)$ حيث يكون مجموع مربعات الإسقاطات هو الحد الأقصى.

نطبق نفس التقنية السابقة ونجد أن حل الشعاع الأول يتم الحصول عليه من خلال:

$$XX'v_1 = \beta_1 v_1$$

$$v_1'v_1 = 1$$

الشعاع الذاتي الأول لـ XX' هو الذي يزيد من تباين الإسقاطات. ، نشكل معادلة تعظيم تباين الإسقاطات من الشعاعين الذاتيين الأول والثاني ، إلى آخره.

نظرية: قيم الذاتية λ_i و β_i متطابقة.

لنضرب المعادلة بـ X' :

نجد:

$$X'XX'v_i = \beta_i X'v_i$$

نلاحظ من خلال هذه المعادلة أن $X'v_i$ هو الشعاع ذاتي لـ $X'X$ مرتبط بقيمة

$$\beta_i. \text{ ولدينا القيم الذاتية لـ } X'X \text{ تعطى بواسطة } \lambda_i. \text{ ومنه نستنتج أن } \beta_i = \lambda_i$$

ملاحظة: من خلال مما سبق فإنه ليس من الضروري البحث بشكل مباشر

عن القيم الذاتية والأشعة الذاتية لـ XX' ، ويتم إيجاد الأشعة الذاتية u_i

بواسطة $X'v_i$ ويمكن توضيح ذلك كما يلي:

$$v_i'XX'v_i = \lambda_i$$

ومنه:

$$u_i = \frac{1}{\sqrt{\lambda_i}} X'v_i$$

وبالضرورة يكون

$$v_i = \frac{1}{\sqrt{\lambda_i}} Xu_i$$

تسمى هذه الصيغة بصيغة الانتقال.

يمكن كتابتها في شكل مصفوفة كالتالي:

$$V = XU\Lambda^{-1/2} \quad U = X'V\Lambda^{-1/2}$$

مثال:

x	3	4	6	6	6	7	7	8	9	9	9	01	11	21	21	31	31	31	31	41	51	71	71	81	02
y	2	01	5	8	01	2	31	9	5	8	41	7	21	01	11	6	41	51	71	7	31	31	71	91	02

نطبق التحليل بالمركبات الرئيسة لمصفوفة التغير

$$\Sigma = \begin{pmatrix} 20.28 & 15.59 \\ 15.59 & 24.06 \end{pmatrix}$$

4. طرق التدوير:

أ. التدوير المتعامد:

هناك أكثر من طريقة تحقق التعامد بين العوامل، أشهرها طريقة تعظيم التباين Varimax، وبدل التعامد على استقلالية المحاور العاملة، وتسمح هذه الطريقة بالاحتفاظ بالتعامد القائم بين العوامل الأصلية. مما يعني أن المحور العامل الأول و المحور العامل الثاني متعامدين لا يرتبطان مهما تغير موضع المحورين.

ب. التدوير المائل:

يختلف هذا النوع من التدوير عن السابق في كونه يفترض ارتباط العوامل. هذا النوع من التدوير صعب ومعقد. ومع هذا بعض الباحثين يفضلون استخدامه بدلاً عن التدوير المتعامد لسببين:

- يتصف بالفاعلية في التعامل مع البيانات كبيرة الحجم

- يسمح بتفسير أبسط تكوين ممكن للبنية العاملية والتوصل إلى حلول يمكن من خلالها تفسير وتعليل العلاقات البينية.

ت. طريقة تعظيم التباين:

كطريقة التعظيم الرباعي Quartimax وطريقة ايكويماكس Equimax، تهدف هذه الطريقة الى تقليل عدد المتغيرات التي تتشعب بشكل قوي بكل عامل، عن طريق تدوير جميع العوامل الممكنة مثنى مثنى على حدة إلى أن يتم تعظيم مجموع تباينات مربعات التشعبات في أعمدة المصفوفة العاملية، والوصول في النهاية إلى أن يكون لكل متغير تشعب واحد عال على أحد العوامل ومنخفض على العوامل الأخرى. وينتج من هذه العمليات إحداث تكافؤ في أهمية المتغيرات مما يؤدي إلى التقليل من عدد المتغيرات لكل عامل، وبالتالي يكون العامل أكثر وضوحا ويسهل قراءته وتفسير مكوناته.

5. مثال حسابي

لتكن المصفوفة X بحيث

$$X = \begin{pmatrix} 1 & 1 \\ 1 & 4 \\ 3 & 1 \end{pmatrix}$$

1. احسب المتوسط لكل متغير
2. احسب التباين لكل متغير σ
3. استنتج المصفوفة الممركز والمعممة
4. احسب مصفوفة الارتباط

5. احسب القيم الذاتية لمصفوفة الارتباط

6. احسب الأشعة الذاتية لمصفوفة الارتباط

7. قارن بين $\sum \lambda_i$ و $\text{tr}(r)$

الحل:

1.

$$\bar{X}_1 = \frac{1}{n} \sum X_{1i} = \frac{1}{3} (1 + 1 + 3) = \frac{5}{3}$$

$$\bar{X}_2 = \frac{1}{n} \sum X_{2i} = \frac{1}{3} (1 + 4 + 1) = 2$$

2.

$$\begin{aligned} \sigma_{x_1}^2 &= \frac{1}{n} \sum (X_{1i} - \bar{X}_1)^2 \\ &= \frac{1}{3} \left[\left(1 - \frac{5}{3}\right)^2 + \left(1 - \frac{5}{3}\right)^2 + \left(3 - \frac{5}{3}\right)^2 \right] = \frac{8}{9} \end{aligned}$$

$$\begin{aligned} \sigma_{x_2}^2 &= \frac{1}{n} \sum (X_{2i} - \bar{X}_2)^2 \\ &= \frac{1}{3} [(1 - 2)^2 + (4 - 2)^2 + (1 - 2)^2] = 2 \end{aligned}$$

3.

نحسب المصفوفة الممركزة والمعممة من خلال العلاقة التالية $Z = \frac{X_i - \bar{X}_i}{\sigma_i}$

$$Z = x_i - \bar{x}_i = \begin{pmatrix} 1 - \frac{5}{3} & 1 - 2 \\ 1 - \frac{5}{3} & 4 - 2 \\ 3 - \frac{5}{3} & 1 - 2 \end{pmatrix} = \begin{pmatrix} \frac{-2}{3} & -1 \\ \frac{-2}{3} & 2 \\ \frac{4}{3} & -1 \end{pmatrix}$$

$$Z = \frac{x_i - \bar{x}_i}{\sigma_i} = \begin{pmatrix} \frac{\frac{-2}{3}}{\frac{2}{3}\sqrt{2}} & \frac{-1}{\sqrt{2}} \\ \frac{\frac{-2}{3}}{\frac{2}{3}\sqrt{2}} & \frac{2}{\sqrt{2}} \\ \frac{\frac{4}{3}}{\frac{2}{3}\sqrt{2}} & \frac{-1}{\sqrt{2}} \end{pmatrix}$$

$$Z = \frac{1}{\sqrt{2}} \begin{pmatrix} -1 & -1 \\ -1 & 2 \\ 2 & -1 \end{pmatrix}$$

.4

نحسب مصفوفة الارتباط من خلال العلاقة التالية $r = \frac{1}{n} Z'Z$

$$r = \frac{1}{3} \times \frac{1}{\sqrt{2}} \begin{pmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \end{pmatrix} \times \frac{1}{\sqrt{2}} \begin{pmatrix} -1 & -1 \\ -1 & 2 \\ 2 & -1 \end{pmatrix}$$

$$r = \begin{pmatrix} 1 & -0.5 \\ -0.5 & 1 \end{pmatrix}$$

.5

نقوم بحساب القيم الذاتية بتطبيق العلاقة التالية $|r - \lambda I| = 0$

$$\left| \begin{pmatrix} 1 & -0.5 \\ -0.5 & 1 \end{pmatrix} - \lambda \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right| = 0$$

$$\left| \begin{pmatrix} 1 & -0.5 \\ -0.5 & 1 \end{pmatrix} - \begin{pmatrix} \lambda & 0 \\ 0 & \lambda \end{pmatrix} \right| = 0$$

$$\left| \begin{pmatrix} 1 - \lambda & -0.5 \\ -0.5 & 1 - \lambda \end{pmatrix} \right| = 0$$

$$(1 - \lambda)^2 \times \left(-\frac{1}{2}\right)^2 = 0$$

$$\left(1 - \lambda - \frac{1}{2}\right) \times \left(1 - \lambda + \frac{1}{2}\right) = 0$$

$$\begin{cases} \lambda_1 = \frac{2}{3} = 1.5 \\ \lambda_2 = \frac{1}{2} = 0.5 \end{cases}$$

.6

الشعاع الذاتي الاول u_1

نحسب الشعاع u_1 من خلال العلاقة التالية:

$$(r - \lambda_1 I)u_1 = 0$$

$$\left(\begin{pmatrix} 1 & -0.5 \\ -0.5 & 1 \end{pmatrix} - 1.5 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right) \begin{pmatrix} x \\ y \end{pmatrix} = 0$$

$$\begin{cases} -0.5x - 0.5y = 0 \\ -0.5x - 0.5y = 0 \end{cases}$$

حلول المتراجحة السابقة من الشكل $y = -x$

$$u_1 = \begin{pmatrix} x \\ -x \end{pmatrix} \text{ ومنه}$$

$$u_1 = x \begin{pmatrix} 1 \\ -1 \end{pmatrix}$$

$$u_1' u_1 = 1 \text{ لدينا}$$

$$u_1' u_1 = x(1 \quad -1) \times x \begin{pmatrix} 1 \\ -1 \end{pmatrix} = 1$$

$$x = \sqrt{\frac{1}{2}} \text{ بعد حل المعادلة نختار}$$

$$u_1 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ -1 \end{pmatrix} \text{ اذا الشعاع الذاتي الأول هو}$$

الشعاع الذاتي الثاني u_2

نحسب الشعاع u_2 من خلال العلاقة التالية:

$$(r - \lambda_2 I)u_2 = 0$$

$$\left(\begin{pmatrix} 1 & -0.5 \\ -0.5 & 1 \end{pmatrix} - 0.5 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right) \begin{pmatrix} x \\ y \end{pmatrix} = 0$$

$$\begin{cases} 0.5x - 0.5y = 0 \\ -0.5x + 0.5y = 0 \end{cases}$$

حلول المتراجحة السابقة من الشكل $y=x$

$$u_1 = \begin{pmatrix} x \\ x \end{pmatrix} \text{ ومنه}$$

$$u_1 = x \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$u_1' u_1 = 1 \text{ لدينا}$$

$$u_1' u_1 = x(1 \ 1) \times x \begin{pmatrix} 1 \\ 1 \end{pmatrix} = 1$$

$$x = \sqrt{\frac{1}{2}} \text{ بعد حل المعادلة نختار}$$

$$u_2 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ 1 \end{pmatrix} \text{ اذا الشعاع الذاتي الثاني هو}$$

.7

$$\text{tr}(r) = \sum a_{ii} = 1 + 1 = 2$$

$$\sum \lambda_i = 1.5 + 0.5 = 2$$

$$\text{tr}(r) = \sum \lambda_i \text{ نلاحظ أن}$$

6. مثال تدريبي:

مصفوفة البيانات

$$\begin{pmatrix} 21 & 38 & 52 \\ 4 & 51 & 67 \\ 67 & 83 & 0 \\ 67 & 3 & 38 \\ 93 & 5 & 6 \end{pmatrix}$$

المصفوفة الممركز

$$\begin{pmatrix} -29.4 & 2 & 19.4 \\ -46.4 & 15 & 34.4 \\ 16.6 & 47 & 32.6 \\ 16.6 & -33 & 5.4 \\ 42.6 & -31 & -26.6 \end{pmatrix}$$

مصفوفة التباين والتباين المشترك

$$\begin{pmatrix} 1076.6 & -368.6 & -750.24 \\ -368.6 & 897.6 & -66.2 \\ -750.24 & -66.2 & 671.84 \end{pmatrix}$$

القيم الذاتية:

$$\lambda_1 = 1732.20$$

$$\lambda_2 = 906.65$$

$$\lambda_3 = 7.28$$

الاشعة الذاتية:

	u_1	u_2	u_3
x_1	0.79	-0.06	0.62
x_2	-0.30	-0.90	0.31
x_3	-0.54	0.43	0.73

احداثيات المشاهدات

	u_1	u_2	u_3
1	-34.15	8.16	-3.40
2	-59.54	3.84	1.03
3	16.25	-57.29	1.07
4	20.21	31.14	3.94
5	57.24	14.14	-2.65

إحداثيات المتغيرات

	u_1	u_2	u_3
x_1	-32.73	-1.66	1.66

x_2	12.68	-27.13	0.83
x_3	22.37	12.95	1.96

جودة تمثيل المشاهدات

	u_1	u_2	u_3
1	0.94	0.05	0.01
2	1.00	0.00	0.00
3	0.07	0.93	0.00
4	0.29	0.70	0.01
5	0.94	0.06	0.00

جودة تمثيل المتغيرات

	u_1	u_2	u_3
x_1	0.99	0.00	0.00
x_2	0.18	0.82	0.00
x_3	0.74	0.25	0.01

مساهمة المشاهدات

	u_1	u_2	u_3
1	0.13	0.01	0.32
2	0.41	0.00	0.03
3	0.03	0.72	0.03
4	0.05	0.21	0.43
5	0.38	0.04	0.19

مساهمة المتغيرات

	u_1	u_2	u_3
x_1	0.62	0.00	0.38
x_2	0.09	0.81	0.10
x_3	0.29	0.19	0.53

المحور الثاني: التحليل العاملي المتناظر AFC

يعد التحليل العاملي للمشاهدات من مجموعة التحليل العاملي التي طورت للتعامل مع معطيات تختلف عن طريقة المكونات الرئيسية، غير أن الاختلاف الجوهرى يكمن في نوع تغيرات لا في الطريقة، وبالتالي فإنهما لا يختلفان من حيث الهدف في تقديم اختزال للمعلومات في فضاء متعدد الأبعاد بحيث تكون القراءة واضحة ولا تختلف مع المعطيات الأولية عن طريق الحفاظ على أكبر قدر من المعطيات الخام .

يعود أصول الطريقة إلى jean paul benzcri حيث قام في سنة 1961 بدراسة العلاقة بين متغيرين كفيين باستعمال طريقة المركبات الرئيسية ليتم تطويرها و تعديلها لاحقا من قبله في 1990 عموما تستعمل طريقة أو تقنية AFC في الجداول المزدوجة (الاقتران أو التوافق) ذات المتغيرات الكيفية حيث تسمح بتمثيل نقاط الأسطر والأعمدة لجدول فئات أو صفات (modalité) المتغيرين انوعيين.

من الواضح أن جدول البيانات أكثر قابلية للإدارة ، من الناحية العملية ، من الجداول المنفصلة الكاملة ، خاصة إذا كان عدد الأفراد كبيرا.

من الضروري أن نلاحظ الآن أن هناك اختلافين رئيسيين بين ACP و AFC.

- المقياس المستخدم في AFC لتحديد القرب بين صفين أو عمودين هو مقياس Chi-square ، بينما تُستخدم المسافة الإقليدية في PCA.

- يسمح AFC بتمثيل متداخل لصفوف وأعمدة الجدول، بدلاً من تقديم رسمين بيانيين مستقلين ، أحدهما للمتغيرات والآخر للأفراد.

1. مجالات التطبيق

تم استخدام هذا التحليل عملياً لأنه مصمم لجداول التقابلية وبالتالي يسمح بدراسة الروابط الموجودة بين متغيرين اسميين. وبالتالي فإن مجالات تطبيق AFC تختلف عن تلك الخاصة بـ PCA ، وهي مناسبة لجداول القياسات المتجانسة أو غير المتجانسة.

بالنسبة لهذا التحليل ، يمكننا أيضاً تقديم قائمة طويلة من التخصصات التي وجدت إجابة لمشكلتها من خلال AFC. وهكذا ، فإن علم البيئة، وعلم النفس ، والاقتصاد ، وغير ذلك من العلوم التي قد يكون من المثير للاهتمام فيها بدراسة الروابط بين متغيرين اسميين ، قد قدمت قدرًا كبيراً من البيانات. المصمم للجداول التقابلية (أي الترددات) ، يمكن تطبيقه على جداول المقاييس المتجانسة (أي نفس نظام الوحدات) ، وجداول الدرجات ، والرتب ، والتفضيلات ، والجداول ذات القيم المنطقية (0 أو 1) ، وايضا على الجداول المأخوذة من استبيانات .

2. البيانات المستخدمة

على عكس ACP فإنه عند استعمال AFC يجب تنظيم البيانات، في جداول تقابلية (تسمى أيضاً جداول التبعية أو الجداول المتقاطعة).

الجدول التقابلية هي جدول للأرقام تم الحصول عليها من خلال تقاطع متغيرين نوعيين محددتين على نفس المجموعة المكونة من n من الأفراد.

مع n العدد الإجمالي للأفراد في الجدول الأولي. نلاحظ أن الصفوف والأعمدة في هذا النوع من الجداول تلعب دوراً متماثلاً. يمكن تعريف جدول الترددات النسبية الذي يؤخذ في الاعتبار ترددات f_{ij} تعطى بواسطة:

$$f_{ij} = \frac{k_{ij}}{n}$$

والهوامش بالعلاقة التالية:

$$f_{i\bullet} = \sum_{j \in J} f_{ij}$$

كما هو موضح في جدول التكرار النسبي

	1	j	J	
1	<div style="display: flex; justify-content: space-around; align-items: center;"> <div style="text-align: center;"> \vdots \vdots \vdots f_{ij} \vdots \vdots </div> <div style="text-align: center;"> \vdots \vdots \vdots $f_{i\bullet}$ \vdots \vdots </div> </div>				$f_{i\bullet}$	
\vdots					\vdots	
\vdots					\vdots	
\vdots					\vdots	
I					\vdots	
	$f_{\bullet j}$				1	

بحيث:

$$f_{\bullet j} = \sum_{i \in I} f_{ij}$$

و

$$\sum_{i \in I} f_{i \cdot} = \sum_{j \in J} f_{\cdot j} = \sum_{i \in I} \sum_{j \in J} f_{ij} = 1.$$

3. أهداف التحليل العاملي المتناظر AFC

أهداف AFC هي نفس أهداف ACP بمعنى أن AFC يسعى إلى الحصول على تصنيف الصفوف وتصنيف الأعمدة ، ثم ربط هذين النموذجين.

لذلك من الضروري إجراء تقييم لأوجه التشابه بين السطور (على التوالي

الأعمدة) الإجابة على أسئلة من كالتالي:

- ما هي الصفوف المتشابهة (الأعمدة)؟

- أيهما مختلف؟

- هل هناك مجموعات متجانسة من الصفوف (أعمدة على التوالي)؟

- هل من الممكن إبراز تصنيف السطور (على التوالي أعمدة)؟

ومع ذلك ، فإن فكرة التشابه بين صفين أو عمودين تختلف عن ACP. في الواقع يكون صفان (على التوالي عمودين) قريبين إذا كانا مرتبطين بنفس الطريقة مع جميع الأعمدة.

لذلك من الضروري البحث عن الصفوف (على التوالي الأعمدة) التي يكون توزيعها أكثر انحرافاً عن البقية ، وتلك التي تتشابه مع بعضها البعض وتلك التي تتعارض . من أجل ربط تصنيف الصفوف بمجموعة الأعمدة ، تتميز كل مجموعة من الصفوف بالأعمدة التي ترتبط بها هذه المجموعة.

ومن خلال التناظر ، تتميز كل مجموعة من الأعمدة بالصفوف التي ترتبط بها هذه المجموعة. وبالتالي يمكننا تفكيك الرابط بين متغيرين إلى مجموع ميول بسيطة وقابلة للتفسير وقياس أهمية كل منهما.

ستعامل مع الجدول من ناحية كسلسلة من الصفوف ، ثم كسلسلة من الأعمدة. عندما يتم التعامل مع الجدول في الصف ، تتم تسوية البيانات عن طريق القسمة على f_{i0} .

والغرض من هذا التسوية هو النظر في الروابط بين المتغيرين من خلال الفرق بين النسب المئوية في الصفوف.

	1	i	J							
1	<table border="1"> <tr> <td>⋮</td> </tr> <tr> <td>⋮</td> </tr> <tr> <td>$\frac{f_{ij}}{f_{i\bullet}}$</td> </tr> <tr> <td>⋮</td> </tr> <tr> <td>⋮</td> </tr> </table>					⋮	⋮	$\frac{f_{ij}}{f_{i\bullet}}$	⋮	⋮	<table border="1"> <tr> <td>1</td> </tr> </table>	1
⋮												
⋮												
$\frac{f_{ij}}{f_{i\bullet}}$												
⋮												
⋮												
1												
⋮												
⋮												
i												
⋮												
⋮												
I												

ونفس الشيء بالنسبة للصفوف

	1	i	J
1					
⋮					
⋮					
i		$\frac{f_{ij}}{f_{\bullet j}}$
⋮					
⋮					
I					

1

4. التشابه والجمع بين الفئات

يتم تحديد التشابه بين صفين أو بين عمودين بالمسافة بين الفئات. المسافة المستخدمة هي χ^2 ويتم تحديدها بشكل متماثل للصفوف والأعمدة. وبالتالي بين صفين i و i' يتم الحصول عليها بواسطة:

$$d_{\chi^2}(i, i') = \sum_{j \in J} \frac{1}{f_{\bullet j}} \left(\frac{f_{ij}}{f_{i\bullet}} - \frac{f_{i'j}}{f_{i'\bullet}} \right)^2$$

وبين عمودين j و j' بواسطة:

$$d_{\chi^2}(j, j') = \sum_{i \in I} \frac{1}{f_{i\bullet}} \left(\frac{f_{ij}}{f_{\bullet j}} - \frac{f_{ij'}}{f_{\bullet j'}} \right)^2$$

5. مثال حسابي:

	D	E	F	المجموع
A	15	12	3	30
B	10	18	4	32
C	15	5	8	28
المجموع	40	35	15	90

$$V_{11} = \begin{bmatrix} \frac{30}{90} & 0 & 0 \\ 0 & \frac{32}{90} & 0 \\ 0 & 0 & \frac{28}{90} \end{bmatrix}$$

$$V_{22} = \begin{bmatrix} \frac{40}{90} & 0 & 0 \\ 0 & \frac{35}{90} & 0 \\ 0 & 0 & \frac{15}{90} \end{bmatrix}$$

$$V_{12} = \begin{bmatrix} \frac{15}{90} & \frac{12}{90} & \frac{3}{90} \\ \frac{10}{90} & \frac{18}{90} & \frac{4}{90} \\ \frac{15}{90} & \frac{5}{90} & \frac{8}{90} \end{bmatrix}$$

$$(V_{11})^{-1} * V_{12} = \begin{bmatrix} \frac{15}{28} & \frac{12}{28} & \frac{3}{28} \\ \frac{30}{32} & \frac{30}{32} & \frac{30}{32} \\ \frac{10}{32} & \frac{18}{32} & \frac{4}{32} \\ \frac{15}{28} & \frac{5}{28} & \frac{8}{28} \end{bmatrix}$$

$$V_{12} * (V_{22})^{-1} = \begin{bmatrix} \frac{15}{40} & \frac{12}{35} & \frac{3}{15} \\ \frac{40}{40} & \frac{35}{35} & \frac{15}{15} \\ \frac{10}{40} & \frac{18}{35} & \frac{4}{15} \\ \frac{15}{40} & \frac{5}{35} & \frac{8}{15} \end{bmatrix}$$

تنشيط AWS
انتقل إلى إعدادات

$$(V_{11})^{-1} * V_{12} * (V_{22})^{-1} * V_{21} = (V_{11})^{-1} * V_{12} * (V_{22})^{-1} * (V_{12})' = A$$

$$A = \begin{bmatrix} 0.345 & 0.357 & 0.298 \\ 0.335 & 0.400 & 0.265 \\ 0.320 & 0.301 & 0.379 \end{bmatrix}$$

$$(V_{22})^{-1} * V_{21} * (V_{11})^{-1} * V_{12} = (V_{22})^{-1} * (V_{12})' * (V_{11})^{-1} * V_{12} = B$$

$$B = \begin{bmatrix} 0.466 & 0.358 & 0.176 \\ 0.409 & 0.452 & 0.139 \\ 0.469 & 0.325 & 0.206 \end{bmatrix}$$

المحور الثالث: التحليل العاملي التمييزي AFD

يعد التحليل التمييزي أحد المناهج الإحصائية المهمة في التحليل الإحصائي متعددة المتغيرات والذي يعني في كيفية التمييز بين مجموعتين أو أكثر من المجتمعات وأن الفكرة الأساسية للتمييز هي التفرقة بين مجتمعات متداخلة أو متشابهة لها الخصائص أو الصفات بمعنى آخر أن التحليل التمييزي هو أسلوب إحصائي يتم بموجبه استعمال مجموعه من المتغيرات للتمييز بين مجموعتين أو أكثر عن طريق دالة تمييزية محددة وهي توليفة خطية للمتغيرات التوضيحية و طريقة إيجاد هذه الدالة بإيجاد المعاملات للدالة وفقا للقياسات أو المعايير التي يتم الحصول عليها من المشاهدات .

إن عملية التصنيف وهي العملية اللاحقة لعملية تكوين الدالة التمييزية إذ يتم الاعتماد على هذه الدالة بالتنبؤ وتصنيف المفردة الجديدة لإحدى المجموعات قيد الدراسة بأقل خطأ تصنيف ممكن والتحليل التمييزي أيضا يمكن استخدامه في مختلف المجالات وفي حالة المجتمعات المتجانسة وغير المتجانسة.

أما الهدف الرئيسي من التحليل التمييزي تصنيف المشاهدة او مجموعة من المشاهدات إلى مجاميعها التصنيفية وبأقل خطأ تصنيف ممكن.

إن دالة التمييز الخطية والمستندة إلى تركيب خطي للمتغيرات لكي تكون مثالية يجب أن تنتج اصغر احتمال لخطأ التصنيف علماً بان هناك افتراضات يجب توافرها عند البيانات المستخدمة في التحليل ولكن غالباً ما نواجه اختراقاً لبعض الفرضيات ومن ثم فإن تقديرات دالة التمييز الخطية تفقد خواصها فمثلاً: عند عدم تساوي مصفوفة التباين والتباين المشترك فإن استعمال دالة التمييز التربيعية يكون ضرورياً.

1. الدالة التمييزية:

هي دالة يمكن من خلالها التمييز بين المجموعات (الفصل بين المشاهدات) ووضع كل مشاهدة في المجموعة التي تتبع لها بمعنى آخر هي الدالة التي يمكن بواسطتها تمييز (تصنيف) المشاهدات الجديدة (مجهولة الانتماء) إلى المجموعة الصحيحة التي يفترض انتمائهم إليها وفقاً للمعايير أو القياسات التي تم الحصول عليها من المشاهدات المعلومة سابقاً.

2. قوة دالة التمييز:

تعتمد دالة التمييز على سلامة توزيعها للمشاهدات (المفردات) على المجموعات الصحيحة (أي التي تنتمي لها المشاهدات فعلياً) وعليه فإن قوه داله التمييز ترتبط طردياً بالتوزيع السليم للمشاهدات.

3. أنواع دوال التمييز:

✓ دالة ال تمييز الخطية

✓ دالة التمييز غير الخطية

✓ دالة التمييز اللوجستية

4. تقدير معالم الدالة التمييزية الخطية:

لتقدير معالم الدالة التمييزية في حالة وجود مجموعتين نتبع الخطوات الآتية:

1- إيجاد متوسط كل متغير في كل مجموعة وكالاتي:

المجموعة الأولى:

$$\bar{X}_1^{(1)} = \sum_{i=1}^{n_1} \frac{X_{1i}}{n_1}$$

$$\bar{X}_2^{(1)} = \sum_{i=1}^{n_1} \frac{X_{2i}}{n_1}$$

$$\bar{X}_k^{(1)} = \sum_{i=1}^{n_1} \frac{X_{ki}}{n_1}$$

حيث $\bar{X}_i^{(1)}$ يمثل متوسط المتغير في المجموعة الأولى.

بنفس الطريقة للمجموعة الثانية:

$$\bar{X}_1^{(2)} = \sum_{i=1}^{n_2} \frac{X_{1i}}{n_2}$$

$$\bar{X}_2^{(2)} = \sum_{i=1}^{n_2} \frac{X_{2i}}{n_2}$$

⋮

$$\bar{X}_k^{(2)} = \sum_{i=1}^{n_2} \frac{X_{ki}}{n_2}$$

حيث $\bar{X}_i^{(2)}$ يمثل متوسط المتغير في المجموعة الثانية:

2/ إيجاد المسافة بين المتغيرين d_i من خلال إيجاد الفرق بين متوسطي كل

متغيرين من المجموعتين.

$$d_i = \bar{X}_{i(1)} - \bar{X}_{i(2)}, i = 1, 2, 3, \dots, k$$

$$d_i = \bar{X}_{1(1)} - \bar{X}_{1(2)}$$

$$d_i = \bar{X}_{2(1)} - \bar{X}_{2(2)}$$

⋮

$$d_k = \bar{X}_{k(1)} - \bar{X}_{k(2)}$$

يتم وضع هذه الفروق في شكل شعاع عمودي ويرمز له بالرمز d

$$d = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_k \end{bmatrix}$$

3/ حساب مجموع المربعات لكل متغير في كل مجموعة و كذلك مجموعة

حاصل ضرب كل متغيرين داخل كل مجموعة كالآتي:

$$SS_{x_1}^{(1)} = SS_{11}^{(1)} = \sum_{i=1}^{n_1} X_{1i}^2 - \frac{(\sum_{i=1}^{n_1} X_{1i})^2}{n_1}$$

⋮

$$SS_{kk}^{(1)} = \sum_{i=1}^{n_1} X_{ki}^2 - \frac{(\sum_{i=1}^{n_1} X_{ki})^2}{n_1}$$

نتابع الحساب بحيث

$$SS_{ii}^{(1)} = \sum_{i=1}^{n_1} X_{ii}^2 - \frac{(\sum_{i=1}^{n_1} X_{ii})^2}{n_1} \quad i = 1, 2, \dots, n_1$$

يمثل مجموع مربعات المتغير (i) في المجموعة الأولى

بنفس الطريقة للمجموعة الثانية بحيث

$$SS_{ii}^{(2)} = \sum_{i=1}^{n_2} X_{ii}^2 - \frac{(\sum_{i=1}^{n_2} X_{ii})^2}{n_2} \quad i = 1, 2, \dots, n_2$$

يمثل مجموع مربعات المتغير (i) في المجموعة الثانية

ويحسب حاصل ضرب المتغيرين بالعلاقة التالية:

$$S_{ii} = \sum X_{ij} - \frac{(\sum X_i)(\sum X_j)}{n}$$

4/ حساب مصفوفة التباين و التباين المشترك للمجموعتين

- حساب التباين

$$V_{ii} = \frac{S_{i(1)} + S_{i(2)}}{n_1 + n_2 - 2}$$

- حساب التباين

$$V_{ii} = \frac{S_{ij(1)} + S_{ij(2)}}{n_1 + n_2 - 2}$$

- حساب مصفوفة التباين و التباين (S_p^2) المشترك داخل المجموعتين

$$S_p^2 = \frac{[(n_1 - 1)S_{(1)} + (n_2 - 1)S_{(2)}]}{n_1 + n_2 - 2}$$

وعليه من المعادلات الأخيرة فإن مصفوفة التباين و التباين المشترك تكون

بالشكل التالي:

$$V = \begin{bmatrix} V_{11} & V_{12} & \dots & V_{1k} \\ V_{21} & V_{22} & \dots & V_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ V_{k1} & V_{k2} & \dots & V_{kk} \end{bmatrix}$$

ومن المعلوم أن مصفوفة التباين والتباين المشترك مربعة و متماثلة قطرها الرئيسي يمثل التباينات و عناصرها الأخرى تمثل التغيرات مشتركة.

5/ حساب قيم معاملات الدالة التمييزية الخطية

تحسب معاملات الدالة التمييزية الخطية من المعادلة التالية

$$\begin{bmatrix} V_{11} & V_{12} & \dots & V_{1k} \\ V_{21} & V_{22} & \dots & V_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ V_{k1} & V_{k2} & \dots & V_{kk} \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_k \end{bmatrix} = \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_k \end{bmatrix}$$

وعليه فإن معاملات الدالة التمييزية الخطية تكتب كالتالي:

$$\alpha = V^{-1} d$$

5. الأهمية النسبية للمتغيرات

أهمية التحليل التمييزي هو أنه يسمح بالمقارنة بين المتغيرات المستقلة من حيث أهميتها في عملية التمييز ، و تحسب الأهمية النسبية للمتغيرات من

الصيغة التالية:

$$\alpha_j^* = \alpha_j \sqrt{V_{jj}}$$

بحيث: $j = 1, 2, \dots, k$

نقوم بمقارنة القيم الناتجة من حساب α_j^* وترتيبهم تنازليا ، وعليه فإن أكبر قيمة من جملة القيمة هو أهم متغير له القدرة على عملية التمييز بين المجموعتين ويلبها ثاني أكبر قيمة له القدرة على التمييز إلى اخر قيمة.

6. اختبار قدرة دالة التمييز في التمييزين مجموعتين:

بعد حساب الدالة التمييزية فأن اختبار قدرتها على التمييز بين مجموعتين تعتبر مرحلة ذات أهمية بالغة في التحليل التمييزي ، ويتم اختبار قدرة الدالة على التمييز بين مجموعتين باختبار ستودنت t أو اختبار فيشر F:

1.6. اختبار ستودنت t لقدرة دالة التمييزية

1/ نحسب القيم التمييزية لكل مشاهدة في كل مجموعة وذلك بتعويض قيم المتغيرات X_i المستقلة.

نحسب القيمة التمييزية للمشاهدة الأولى في المجموعة الأولى :

$$L_{1(1)} = \alpha_1 X_{11} + \alpha_2 X_{21} + \dots + \alpha_k X_{k1}$$

نحسب القيمة التمييزية للمشاهدة الثانية في المجموعة الأولى :

$$L_{2(1)} = \alpha_1 X_{12} + \alpha_2 X_{22} + \dots + \alpha_k X_{k2}$$

بنفس الطريقة لباقي مشاهدات المجموعة الأولى

2/ نقوم بحساب الوسط الحسابي للقيم التمييزية لكل مجموعة :

- الوسط الحسابي للقيم التمييزية للمجموعة الاولى

$$\bar{L}_{(1)} = \frac{\sum_{i=1}^{n_1} L_i^{(1)}}{n_1}$$

حيث $i= 1,2,3,\dots,n_1$

- الوسط الحسابي للقيم التمييزية للمجموعة الثانية

$$\bar{L}_{(2)} = \frac{\sum_{i=1}^{n_2} L_i^{(2)}}{n_2}$$

حيث $i= 1,2,3,\dots,n_2$

نقوم باختبار الفرق بين متوسط المجموعتين ، ونستخدم لذلك الاختبار الإحصائي (t) للمقارنة بين المتوسطات الحسابية للمجموعات و ذلك لبيان أهمية دالة التصنيف ، ونقوم بإجراء الاختبار الإحصائي كالتالي:

بعيث فرضيات الاختبار تشكل كالتالي:

$$\begin{cases} H_0: \text{الدالة ليس لها القدرة على عملية التمييز} \\ H_1: \text{الدالة لها القدرة على عملية التمييز} \end{cases}$$

ويتم اختبار هذه الفرضية من خلال اختبار الفرق بين متوسطي القيم التمييزية للمجموعتين ، وتكتب الفرضية كالتالي:

$$\begin{cases} H_0: ML_1 = ML_2 \\ H_1: ML_1 \neq ML_2 \end{cases}$$

$$t = \frac{\bar{L}_{(1)} - \bar{L}_{(2)}}{\sqrt{S_p^2 \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

نقارن قيمة t المحسوبة مع الجدولية $t_{(n_1+n_2-2, \frac{\alpha}{2})}$

من الفرضية الصفرية متوسط القيمة التمييزية للمجموعة الأولى لا يختلف إحصائياً عن متوسط القيم التمييزية للمجموعة الثانية مع العلم بأن القيم التمييزية للمجموعتين حسبت من دالة واحدة ، فإذا قبلت هذه الفرضية فذلك يعني أن نمط القيم التمييزية في المجموعتين متشابهة وهذا يعنى عدم قدرة الدالة التمييزية على التمييز ، أما إذا رفضت الفرضية الصفرية فهذا يعنى قدرة الدالة التمييزية على التمييز.

2.6. اختبار فيشر F لقدرة دالة التمييزية:

يتم صياغة الفرضيات كالتالي:

$$\begin{cases} H_0: \text{الدالة ليس لها القدرة على عملية التمييز} \\ H_1: \text{الدالة لها القدرة على عملية التمييز} \end{cases}$$

ويتم اختبار هذه الفرضية من خلال اختبار الفرق بين متوسطي القيم التمييزية للمجموعتين ، وتكتب الفرضية كالتالي:

$$\begin{cases} H_0: ML_1 = ML_2 \\ H_1: ML_1 \neq ML_2 \end{cases}$$

نقوم بتكوين جدول تحليل التباين كالتالي:

S.O.V	d.f	S.S	M.S	F
Between X	k-1	SSB	MSB	$\frac{MSB}{MSE}$
Within X	n_1+n_2-k-1	SSE	MSE	
Total	n_1+n_2-2			

ونقوم بالحسابات التالية

- مجموع المربعات داخل المتغيرات

$$SSE = D^2$$

$$D^2 = \alpha_1 d_1 + \alpha_2 d_2 + \dots + \alpha_k d_k$$

- مجموع المربعات بين المتغيرات المستقلة

$$SSB = \frac{n_1 n_2}{(n_1 + n_2)(n_1 + n_2 - 2)} (D^2)^2$$

- مجموع المربعات الكلي

$$SST = SSB + SSE$$

نجد قيمة F المحسوبة كالآتي

$$F = \frac{n_1 + n_2 - m - 1}{(n_1 + n_2 - 2)m} T^2$$

بحيث m تمثل درجة حرية المتغيرات

أو من

$$F = \frac{MSB}{MSE} = \frac{n_1 n_2}{(n_1 + n_2)(n_1 + n_2 - 2)} D^2$$

بمقارنة قيمة F المحسوبة مع الجدولية $F_{(n_1+n_2-k-1, \alpha)}$ فإذا كانت القيمة المحسوبة أكبر من الجدولية نرفض الفرضية الصفرية ونقبل الفرضية البديلة أي أن الدالة التمييزية لها القدرة على التمييز.

7. النقطة الفاصلة

النقطة الفاصلة تمثل الحد الفاصل الذي يفصل بين المجموعتين، وتستخدم لغرض تصنيف المشاهدات إلى المجموعة الأقرب لها ،

فإذا كانت قيمة الدالة بعد تعويض قيمة المشاهدة فيها أكبر من الصفر فالمشاهدة تصنف في المجموعة الأولى ، أما إذا كانت قيمة الدالة أصغر من الصفر فيتم تصنيف المشاهدة في المجموعة الثانية ، ولكن عندما تكون الدالة التمييزية للمجموعة الأولى أكبر من قيمة الدالة التمييزية في المجموعة الثانية فإن المشاهدة تصنف في المجموعة الأولى كما يلي:

$$L > \frac{1}{2} \left(\bar{L}_1^{(1)} + \bar{L}_2^{(2)} \right)$$

تصنف المشاهدة في المجموعة الثانية إذا:

$$L < \frac{1}{2} \left(\bar{L}_1^{(1)} + \bar{L}_2^{(2)} \right)$$

بفرض أن:

$$\alpha_0 = \frac{1}{2} (\bar{L}_1^{(1)} + \bar{L}_2^{(2)})$$

للحصول على دالة التصنيف L^* نقوم بدمج النقطة الفاصلة 0α مع الدالة التمييزية فنحصل على:

$$L^* = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_k x_k$$

يتم تصنيف المشاهدات إلى المجموعات حسب العلاقات التالية:

$$\begin{cases} L^* > 0 & \text{تصنف المشاهد في المجموعة الاولى} \\ L^* < 0 & \text{تصنف المشاهد في المجموعة الثانية} \\ L^* = 0 & \text{لا يمكن إجراء التصنيف} \end{cases}$$

8. نسبة الخطأ:

عند تحديد النقطة الفاصلة بين المجموعتين فإنه قد يكون هناك تصنيف غير صحيح عند استعمال دالة L^* التمييز وقد تصنف مشاهدة معينة في المجموعة الاولى بينما تعود في الحقيقة إلى المجموعة الثانية والعكس. وهناك نوعان من أخطاء التصنيف

- خطأ التصنيف الظاهري:

و يحسب من جدول التصنيف التالي:

مجموع	تابع المجموعة الثانية	تابع المجموعة الاولى	المجموعة
n_1	n_{12}	n_{11}	الاولى
n_2	n_{22}	n_{21}	الثانية

n_{11} : عدد المشاهدات من المجموعة الأولى والتي تم تصنيفها في نفس المجموعة وبالتالي صُنفت بطريقة صحيحة

n_{12} : عدد المشاهدات من المجموعة الأولى والتي تم تصنيفها خطأ في المجموعة الثانية

n_{21} : عدد المشاهدات التي تنتمي إلى المجموعة الثانية وتم تصنيفها خطأ في المجموعة الأولى

n_{22} : عدد المشاهدات في المجموعة الثانية التي تم تصنيفها في نفس المجموعة و صُنفت بطريقة صحيحة

ونحسب الخطأ الظاهري كما يلي:

P_{12} : نسبة المشاهدات التي تنتمي للمجموعة الأولى وصُنفت خطأ في المجموعة الثانية

$$P_{12} = \frac{n_{12}}{n_1}$$

P_{21} : نسبة المشاهدات التي تنتمي للمجموعة الثانية وصُنفت خطأ في الأولى

$$P_{21} = \frac{n_{21}}{n_2}$$

ونحسب معدل الخطأ الظاهري كالتالي:

$$\frac{n_{12} + n_{21}}{n_1 + n_2}$$

• خطأ التصنيف الحقيقي

ويعتمد في تحديد احتمال خطأ التصنيف على D^2 إحصائية مهلونوبيس (Mahalanobis)

$$P_1 = P_2 = F\left(-\frac{\sqrt{D^2}}{2}\right)$$

وكما كانت صغيرة D^2 فهو دليل على صغر خطأ التصنيف والكفاءة دالة التمييز والعكس.

المحور الرابع: أمثلة تطبيقية

1. مثال تطبيقي للتحليل بطريقة مركبات الأساسية باستخدام SPSS

كلف مختبر صيدلاني بإجراء مسح لتحليل معايير اختيار معجون الأسنان.

طلب من 40 شخص تقييم أهمية الخصائص التالية المنسوبة إلى معجون

الأسنان:

X1=الجنس

X2=العمر

X3=يعطي نفسا لطيفا

X4=يبيض الأسنان

X5=يقوي اللثة

X6=مذاق جيد

X7=يمنع التسوس

الجدول التالي يبين معطيات المبحوثين:

	الجنس	العمر	يعطي نفسا لطيفا	يبيض الأسنان	يقوي اللثة	مذاق جيد	يمنع التسوس
1	1	3	1	1	3	1	2
2	2	1	2	2	1	2	1
3	4	5	4	4	5	4	2
4	1	2	1	4	1	1	1
5	5	1	5	5	1	5	2
6	2	2	2	2	2	2	1

7	3	2	3	3	2	3	1
8	4	1	4	4	1	4	1
9	1	2	3	3	2	3	1
10	5	2	1	5	2	5	1
11	4	5	4	1	5	3	2
12	2	5	3	2	2	3	1
13	1	3	1	1	3	1	2
14	3	4	3	3	4	3	2
15	4	5	4	4	5	4	2
16	2	4	2	2	4	2	2
17	1	1	1	1	1	1	1
18	2	3	2	2	5	2	2
19	3	2	3	3	2	3	1
20	4	2	2	2	2	2	1
21	2	1	2	2	1	2	1
22	2	2	2	2	2	2	1
23	3	2	1	1	1	1	1
24	2	3	2	2	3	2	2
25	5	2	5	5	2	5	1
26	2	1	2	2	1	2	1
27	2	2	2	2	2	2	1
28	5	2	3	5	2	3	1
29	2	1	2	2	1	2	1
30	3	2	3	3	2	3	1
31	4	2	4	4	2	4	1
32	5	1	5	5	1	5	1
33	4	3	4	4	2	4	1
34	1	2	1	1	2	1	2
35	3	3	2	3	1	3	2
36	2	2	2	2	2	2	2
37	1	2	1	1	3	1	1
38	5	2	3	5	2	3	2
39	1	3	1	1	3	1	2
40	1	1	1	1	2	1	1

بعد عملية إدخال بيانات الجدول السابق في برنامج SPSS نحصل على

المخرجات التالية:

Statistiques descriptives جدول الإحصاء الوصفي

Descriptive Statistics			
	Mean	Std. Deviation	Analysis N
نفس_منعش	2.25	1.214	40
بيض_الاسنان	2.68	1.385	40

يقوي_اللثة	2.48	1.240	40
مذاق_جيد	2.35	1.189	40
يمنع_التسوس	2.73	1.396	40

يقدم وصف للمتغيرات المستعملة من خلال مؤشرات الاحصاء الوصفي والمتمثلة في المتوسط والانحراف المعياري. ونلاحظ أن متوسط الافراد الذين يعتقدون أن معجون الاسنان هذا يعطي نفس منعش يساوي 2.25 بإنحراف معياري يساوي 1.214، وايضا الذين يرون أنه يمنع التسوس 2.73 بتشتت 1.396.

جدول مصفوفة الارتباط Matrice de corrélation

	نفس_منعش	بيض_الاسنان	يقوي_اللثة	مذاق_جيد	يمنع_التسوس
Correlation	نفس_منعش	بيض_الاسنان	يقوي_اللثة	مذاق_جيد	يمنع_التسوس
	1.000	-.133-	.106	.808	.011
	بيض_الاسنان	1.000	.690	-.069-	.802
	يقوي_اللثة	.690	1.000	.163	.744
	مذاق_جيد	-.069-	.163	1.000	.060
	يمنع_التسوس	.802	.744	.060	1.000
Sig. (1-tailed)	نفس_منعش	بيض_الاسنان	يقوي_اللثة	مذاق_جيد	يمنع_التسوس
	.206	.000	.257	.000	.472
	.206	.000	.000	.335	.000
	.257	.000	.000	.158	.000
	.000	.335	.158	.000	.358
	.472	.000	.000	.358	.000

a. Determinant = .046

نذكر هنا أن مصفوفة الارتباط هي مصفوفة متناظرة وبالتالي يمكن قراءة قيم الارتباط بين المتغيرات إما من المثلث العلوي أو السفلي.

كما أن الجدول يعطي المعنوية لكل قيمة ارتباط من خلال الجزء (1- Sig. tailed).

من مصفوفة الارتباط نلاحظ أن عدد قيم الارتباط الأكبر من 0.5 يساوي 5 وهو متساوي مع عدد قيم الارتباط الأقل من 0.5 وبالتالي يمكن متابعة التحليل.

ونلاحظ أن قيمة الارتباط بين (نفس منعش) والمتغير (مذاق جيد) يساوي 0.808 وهو ارتباط قوي حيث يجتمع أفراد العينة على أن النفس المنعش للمعجون لابد أن يرافقه المذاق الجيد، كما نلاحظ أن قيمة (Sig.(1-tailed) تساوي 0.00 وهي أكبر من 0.05 مستوى المعنوية المفترض، وبالتالي فإننا نقبل الفرضية الصفرية ونرفض الفرضية البديلة، أي أن الارتباط بين المتغير (نفس منعش) والمتغير (مذاق جيد) معنوي.

ونلاحظ أن قيمة الارتباط بين (يبض الاسنان) والمتغير (يقوي اللثة) يساوي 0.690 وهو ارتباط جيد حيث يجتمع أفراد العينة على أن عمل المعجون في تبيض الاسنان من شأنه تقوية اللثة، كما نلاحظ أن قيمة (Sig.(1-tailed) تساوي 0.00 وهي أكبر من 0.05 مستوى المعنوية المفترض، وبالتالي فإننا نقبل الفرضية الصفرية ونرفض الفرضية البديلة، أي أن الارتباط بين المتغير (يبض الاسنان) والمتغير (يقوي اللثة) معنوي.

ونلاحظ أن قيمة الارتباط بين المتغير (يمنع التسوس) والمتغير (يبض الاسنان) والمتغير (يقوي اللثة) يساوي 0.802 و 0.744 على التوالي وهي ارتباطات جيدة حيث يجتمع أفراد العينة على أن عمل المعجون في القضاء في منع التسوس يساهم في تبيض الاسنان و تقوية اللثة، كما نلاحظ أن قيمة (Sig.(1-tailed) تساوي 0.00 وهي أكبر من 0.05 مستوى المعنوية المفترض، وبالتالي فإننا نقبل

الفرضية الصفرية ونرفض الفرضية البديلة، أي أن الارتباط بين المتغير (يمنع التسوس) والمتغير (يبيض الاسنان) والمتغير (يقوي اللثة) معنوي.

كما يشير محدد المصفوفة الذي يساوي 0.046 وهو أكبر من 0.00001 إلى عدم وجود مشكل الارتباط الذاتي وجود الحد الأدنى من البيانات أي أن المصفوفة ليست مصفوفة فارغة.

Inverse of Correlation Matrix

	منعش نفس	الاسنان بيض	اللثة يقوي	جيد مذاق	التسوس يمنع
منعش نفس	2.960	.450	-.125-	-2.331-	-.162-
الاسنان بيض	.450	3.222	-.799-	.109	-2.000-
اللثة يقوي	-.125-	-.799-	2.511	-.291-	-1.209-
جيد مذاق	-2.331-	.109	-.291-	2.940	-.019-
التسوس يمنع	-.162-	-2.000-	-1.209-	-.019-	3.506

جدول مؤشر KMO واختبار بارلتت Bartlett's Test

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.	.654
Bartlett's Test of Sphericity	Approx. Chi-Square
	112.262
	df
	10
	Sig.
	.000

من خلال قياس مؤشر KMO الذي على أساسه نستدل على مدى كفاية عدد أفراد العينة ويجب أن تكون قيمته أكبر من 0.50 حتى تكون العينة كافية وهذا شرط أساسي يجب تحقيقه،

ومن الملاحظ أن مؤشر KMO يساوي 0.654 وبالتالي فإن حجم العينة كافي لإجراء الدراسة.

اختبار Bartlett لدائرية Sphericity فهو مؤشر للعلاقة بين المتغيرات ويجب أن يكون مستوى الدلالة لهذه العلاقة أقل من 0.05 وذلك حتى نستطيع التأكيد على أن هذه العلاقة دالة إحصائياً. ويظهر من الجدول أن قيمة اختبار Bartlett تساوي 112.262 وهي دالة إحصائياً حيث أن Sig. أقل من 0.05 ومنه نرفض الفرضية الصفرية و نقبل الفرضية البديلة أي أنه يوجد معاملات ارتباط غير معدومة.

Anti-image Matrices						
		منعش_نفس	الاسنان_بيض	اللثة_يقوي	جيد_مذاق	التسوس_يمنع
Anti-image Covariance	منعش_نفس	.338	.047	-.017-	-.268-	-.016-
	الاسنان_بيض	.047	.310	-.099-	.011	-.177-
	اللثة_يقوي	-.017-	-.099-	.398	-.039-	-.137-
	جيد_مذاق	-.268-	.011	-.039-	.340	-.002-
	التسوس_يمنع	-.016-	-.177-	-.137-	-.002-	.285
Anti-image Correlation	منعش_نفس	.512 ^a	.146	-.046-	-.790-	-.050-
	الاسنان_بيض	.146	.715 ^a	-.281-	.035	-.595-
	اللثة_يقوي	-.046-	-.281-	.805 ^a	-.107-	-.408-
	جيد_مذاق	-.790-	.035	-.107-	.519 ^a	-.006-
	التسوس_يمنع	-.050-	-.595-	-.408-	-.006-	.697 ^a

a. Measures of Sampling Adequacy(MSA)

جدول جودة التمثيل Communalities

Communalities		
	Initial	Extraction
نفس_منعش	1.000	.903
بيض_الاسنان	1.000	.856
يقوي_اللثة	1.000	.807
مذاق_جيد	1.000	.901
يمنع_التسوس	1.000	.871

Extraction Method: Principal

Component Analysis.

من جدول نوعية التمثيل فنلاحظ أن تمثيل كل المتغيرات أكبر من 0.4 وبالتالي كل المتغيرات تدخل في الدراسة ولا يتم استبعاد أي متغيرة.

كما نلاحظ أن كل المتغيرات ذات تمثيل عالي حيث كانت نسبة الاستخراج الاصغر 0.807 أي 80.70% للمتغير (يقوي اللثة).


جدول التباين الكلي المشروح Total Variance Explained

Component	Total Variance Explained								
	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	2.498	49.950	49.950	2.498	49.950	49.950	2.493	49.863	49.863
2	1.841	36.813	86.763	1.841	36.813	86.763	1.845	36.900	86.763
3	.288	5.759	92.522						
4	.196	3.919	96.441						
5	.178	3.559	100.000						

Extraction Method: Principal Component Analysis.

نلاحظ من الجدول أنه توجد قيمتين ذاتيتين أكبر من الواحد، وعليه سيتم اعتماد هاتين القيمتين وذلك حسب محك كايز وإقصاء باقي القيم الذاتية، وبالتالي يتم اختزال البيانات في محورين حيث يختزل الاول نسبة 49.86% من البيانات ويختزل المحور الثاني 36.90% من البيانات ومعاً يتحددان في اختزال ما نسبته 86.76% من مجمل البيانات وهي نسبة جد مقبولة حيث 13.34% فقط من البيانات لم تتمكن من تمثيلها.

ويمكن من الشكل الموالي إلقاء نظرة على انحدار القيم الذاتية



حيث نلاحظ أن بعد القيمتين الأولى والثانية ينحدر خط القيم الذاتية بشكل
جد معنوي ثم يأخذ الشكل الأفقي مع القيم الثلاثة المتبقية، وهو يدعم
اعتمادنا في عملية التحليل على القيمتين الأولى والثانية.

احداثيات المتغيرات قبل وبعد التدوير:

مصفوفة الاحداثيات قبل التدوير:

Component Matrix^a

	Component	
	1	2
نفس_منعش		.949
بيض_الاسنان	.900	
يقوي_اللثة	.895	
مذاق_جيد		.941
يمنع_التسوس	.932	

Extraction Method: Principal

Component Analysis.

a. 2 components extracted.

المحور الأول: نلاحظ أن المحور الأول يحتوي على المتغيرات بيض الاسنان والمتغير يقوي اللثة والمتغير يمنع التسوس، وهي متغيرات تعكس الجانب الصحي لمعجون الاسنان وبالتالي يمكن أن نسمي هذا المحور بعوامل صحية.

المحور الثاني: نلاحظ أن المحور الثاني يحتوي على المتغيرات نفس منعش، ومذاق جيد وهذه المتغيرات تعكس الجوانب الحسية وبالتالي يمكن أن نسمي المحور بعوامل حسية

Reproduced Correlations

		منعش_نفس	الاسنان_بيض	اللثة_يقوي	جيد_مذاق	التسوس_يمنع
Reproduced Correlation	منعش_نفس	.903 ^a	-.151-	.127	.900	.003
	الاسنان_بيض	-.151-	.856 ^a	.788	-.090-	.850
	اللثة_يقوي	.127	.788	.807 ^a	.186	.830
	جيد_مذاق	.900	-.090-	.186	.901 ^a	.065
	التسوس_يمنع	.003	.850	.830	.065	.871 ^a
Residual ^b	منعش_نفس		.018	-.020-	-.092-	.009
	الاسنان_بيض	.018		-.099-	.021	-.048-
	اللثة_يقوي	-.020-	-.099-		-.023-	-.085-
	جيد_مذاق	-.092-	.021	-.023-		-.005-
	التسوس_يمنع	.009	-.048-	-.085-	-.005-	

Extraction Method: Principal Component Analysis.

a. Reproduced communalities

b. Residuals are computed between observed and reproduced correlations. There are 3 (30.0%) nonredundant residuals with absolute values greater than 0.05.

مصفوفة الاحداثيات بعد التدوير:

Rotated Component Matrix^a

	Component	
	1	2
منعش_نفس		.950
الاسنان_بيض	.914	
اللثة_يقوي	.885	

جيد_مذاق	.948
التسوس_يمنع	.933

Extraction Method: Principal

Component Analysis.

Rotation Method: Varimax with


Kaiser Normalization.

a. Rotation converged in 3 iterations.

تسمح عملية التدوير بإختيار الموقع الانسب لتمثيل المتغيرات، ونلاحظ أنه

بعد عملية التدوير تعزز تمثيل المحاور ولو بشكل طفيف

شكل المكونات بعد التدوير



نلاحظ من الشكل السابق أن المتغيرات تنقسم إلى مجموعتين متميزتين الأولى

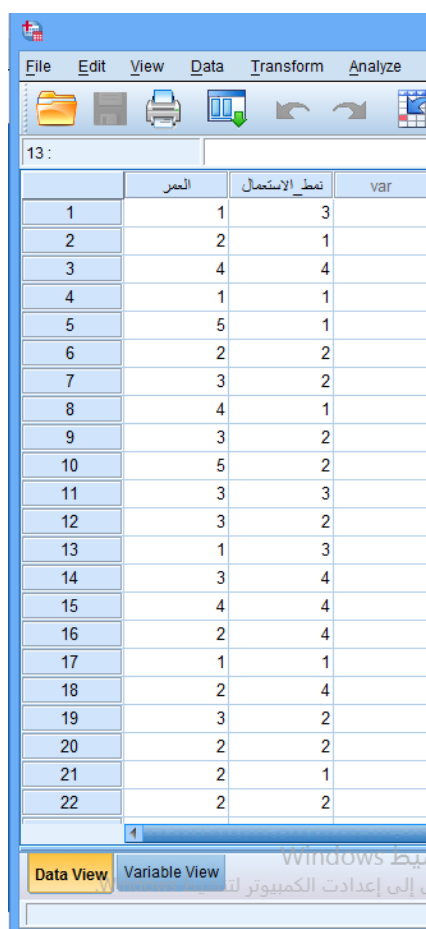
على المحور الاول والتي تظم ثلاثة متغيرات والمجموعة الثانية ممثلة على

المحور الثاني.

2. مثال تطبيقي التحليل العاملي المتناظر باستخدام SPSS:

تم طرح سؤاين على مجموعة من المنتسبين إلى بريد الجزائر حول طريقة استخدامهم للبطاقة الدفع الالكتروني "الذهبية" وتمحورت الاسئلة حول الفئة العمرية ونمط الاستخدام.

بعد ادخال البيانات في برنامج SPSS كالتالي:



	العمر	نمط_الاستعمال	var
1	1	3	
2	2	1	
3	4	4	
4	1	1	
5	5	1	
6	2	2	
7	3	2	
8	4	1	
9	3	2	
10	5	2	
11	3	3	
12	3	2	
13	1	3	
14	3	4	
15	4	4	
16	2	4	
17	1	1	
18	2	4	
19	3	2	
20	2	2	
21	2	1	
22	2	2	

نحصل على المخرجات التالية:

Case Processing Summary

	Cases					
	Valid		Missing		Total	
	N	Percent	N	Percent	N	Percent
الاستعمال_نمط * العمر	85	100.0%	0	0.0%	85	100.0%

نلاحظ أنه تم معالجة 85 حالة ولا توجد حالات مفقودة أو غير مدرجة.

جدول اختبار التوافق:

Symmetric Measures

		Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Nominal by Nominal	Phi	.733			.000
	Cramer's V	.423			.000
	Contingency Coefficient	.591			.000
Ordinal by Ordinal	Kendall's tau-b	-.011-	.093	-.118-	.906
	Kendall's tau-c	-.011-	.091	-.118-	.906
	Gamma	-.014-	.120	-.118-	.906
	Spearman Correlation	-.016-	.113	-.150-	.881 ^c
Interval by Interval	Pearson's R	-.010-	.108	-.090-	.929 ^c
Measure of Agreement	Kappa	.050	.063	.865	.387
N of Valid Cases		85			

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

c. Based on normal approximation.

نشير هنا إلى أنه لا يمكن استعمال معامل الارتباط ليرسّن لأن المتغيرات

نوعية وبالتالي نلجأ الي استعمال اختبار التوافق Coefficient Contingency

والذي يسمح باختبار الفرضية التالية:

$$\left\{ \begin{array}{l} \text{لا يوجد ارتباط بين الفئة العمرية و استعمال البطاقة الذهبية: } H_0 \\ \text{يوجد ارتباط بين الفئة العمرية و استعمال البطاقة الذهبية: } H_1 \end{array} \right.$$

ومن الجدول نجد أن قيمة معامل التوافق تساوي 0.591 وهي قيمة مقبولة، وذات معنوية ذلك لأن مستوي الدلالة يساوي 0.00 وهو أقل من 0.05 وبالتالي نرفض الفرضية الصفرية التي مفادها أنه لا يوجد ارتباط بين الفئة العمرية واستعمال البطاقة الذهبية، ونقبل الرضوية البديلة التي تؤكد على وجود ارتباط بين الفئة العمرية واستعمال البطاقة الذهبية.

الجدول المتقاطع

يوضح الجدول المتقاطع النسب بالنسبة للأسطر والأعمدة والعينة

Crosstabulation استعمال نمط * العمر							
		الاستعمال نمط				Total	
		بطريقة منتظمة	غالبا	في المناسبات	لا استعمالها		
العمر	20-30	Count	3	4	12	0	19
		% within العمر	15.8%	21.1%	63.2%	0.0%	100.0%
		% within نمط_الاستعمال	27.3%	11.1%	66.7%	0.0%	22.4%
		% of Total	3.5%	4.7%	14.1%	0.0%	22.4%
	30-40	Count	4	10	3	8	25
		% within العمر	16.0%	40.0%	12.0%	32.0%	100.0%
		% within نمط_الاستعمال	36.4%	27.8%	16.7%	40.0%	29.4%
		% of Total	4.7%	11.8%	3.5%	9.4%	29.4%
	40-50	Count	1	14	3	4	22
		% within العمر	4.5%	63.6%	13.6%	18.2%	100.0%
		% within نمط_الاستعمال	9.1%	38.9%	16.7%	20.0%	25.9%
		% of Total	1.2%	16.5%	3.5%	4.7%	25.9%
	50-60	Count	1	4	0	8	13
		% within العمر	7.7%	30.8%	0.0%	61.5%	100.0%
		% within نمط_الاستعمال	9.1%	11.1%	0.0%	40.0%	15.3%
		% of Total	1.2%	4.7%	0.0%	9.4%	15.3%
	60 من أكبر	Count	2	4	0	0	6
		% within العمر	33.3%	66.7%	0.0%	0.0%	100.0%
		% within نمط_الاستعمال	18.2%	11.1%	0.0%	0.0%	7.1%
		% of Total	2.4%	4.7%	0.0%	0.0%	7.1%

Total	Count	11	36	18	20	85
	% within العمر	12.9%	42.4%	21.2%	23.5%	100.0%
	% within نمط_الاستعمال	100.0%	100.0%	100.0%	100.0%	100.0%
	% of Total	12.9%	42.4%	21.2%	23.5%	100.0%

نأخذ كمثال الفئة العمرية التالية

40-50	Count	1	14	3	4	22
	% within العمر	4.5%	63.6%	13.6%	18.2%	100.0%
	% within نمط_الاستعمال	9.1%	38.9%	16.7%	20.0%	25.9%
	% of Total	1.2%	16.5%	3.5%	4.7%	25.9%
50-60	Count	1	1	0	0	12

الفئة العمرية تضم الاشخاص الذين تتراوح اعمارهم من 40 إلى 50 سنة

حيث نجد:

✓ استخدام البطاقة الذهبية بصفة منتظمة :

- شخص واحد يستخدم البطاقة الذهبية بصفة منتظمة
- 4.5% من الفئة العمرية 50-40 يستخدمون البطاقة الذهبية بصفة منتظمة

- 9.1% من الاشخاص الذين يستعملون البطاقة الذهبية بصفة منتظمة هم من الفئة العمرية 50-40 سنة.

- 1.2% هم اشخاص من الفئة العمرية 50-40 و يستعملون البطاقة الذهبية بصفة منتظمة.

✓ استخدام البطاقة الذهبية في غالب الاحيان:

- 14 شخص يستخدم البطاقة الذهبية في غالب الاحيان
- 63.6% من الفئة العمرية 50-40 يستخدمون البطاقة الذهبية في

غالب الاحيان

- 38.9% من الأشخاص الذين يستعملون البطاقة الذهبية في غالب

الاحيان هم من الفئة العمرية 40-50 سنة.

- 16.5% هم اشخاص من الفئة العمرية 40-50 و يستعملون البطاقة

الذهبية في غالب الاحيان.

تطبيق AFC بالخطوات التالية:

الجدول المعطيات الاساسية:

Correspondence Table

العمر	الاستعمال_نمط				Active Margin
	بطريقة منتظمة	غالبا	في المناسبات	لا استعمالها	
20-30	3	4	12	0	19
30-40	4	10	3	8	25
40-50	1	14	3	4	22
50-60	1	4	0	8	13
60 من أكبر	2	4	0	0	6
Active Margin	11	36	18	20	85

حيث يوضح مكونات عناصر الاسطر ومكونات عناصر الاعمدة والتكرارات .

جدول التكرارات النسبية للأسطر

Row Profiles

العمر	الاستعمال_نمط				Active Margin
	منتظمة بطريقة	غالبا	المناسبات في	استعملها لا	
20-30	.158	.211	.632	.000	1.000
30-40	.160	.400	.120	.320	1.000
40-50	.045	.636	.136	.182	1.000
50-60	.077	.308	.000	.615	1.000
60 من أكبر	.333	.667	.000	.000	1.000
Mass	.129	.424	.212	.235	

جدول التكرارات النسبية للأعمدة

Column Profiles					
العمر	الاستعمال_نمط				
	منتظمة بطريقة	غالبا	المناسبات في	استعملها لا	Mass
20-30	.273	.111	.667	.000	.224
30-40	.364	.278	.167	.400	.294
40-50	.091	.389	.167	.200	.259
50-60	.091	.111	.000	.400	.153
60 من أكبر	.182	.111	.000	.000	.071
Active Margin	1.000	1.000	1.000	1.000	

جدول العوامل المستخرجة:

Summary								
Dimensio n	Singular Value	Inertia	Chi Square	Sig.	Proportion of Inertia		Confidence Singular Value	
					Accounted for	Cumulati ve	Standard Deviation	Correlatio n
1	.613	.376			.700	.700	.077	.446
2	.343	.118			.219	.918	.090	
3	.209	.044			.082	1.000		
Total		.538	45.689	.000 ^a	1.000	1.000		

a. 12 degrees of freedom

حيث نلاحظ أنه تم تلخيص البيانات الأساسية في ثلاثة محاور المحور الاول
يختزل 70% من نسبة التشنتت أو من التباين الكلي، المحور الثاني يختزل
21.9% والمحور الثالث يختزل 8.2%.

ويوضح الجدول قيمت كاي مربع حيث يقىس وجود علاقة بين العمر
واستخدام البطاقة من عدمه ، وقد بلغت قيمة كاي مربع 45.86 وهي قيمة
مقبولة، وذات معنوية ذلك لأن مستوي الدلالة يساوي 0.00 وهو أقل من

0.05 وبالتالي نرفض الفرضية الصفرية التي مفادها أنه لا يوجد ارتباط بين الفئة العمرية واستعمال البطاقة الذهبية، ونقبل الرضوية البديلة التي تؤكد على وجود ارتباط بين الفئة العمرية واستعمال البطاقة الذهبية.

جدول خصائص الاسطر

Overview Row Points ^a									
العمر	Mass	Score in Dimension		Inertia	Contribution				
		1	2		Of Point to Inertia of Dimension		Of Dimension to Inertia of Point		
					1	2	1	2	Total
20-30	.224	-1.365-	-.334-	.264	.679	.073	.967	.032	1.000
30-40	.294	.311	-.090-	.023	.046	.007	.753	.035	.788
40-50	.259	.190	.508	.052	.015	.195	.110	.441	.551
50-60	.153	1.016	-.846-	.134	.257	.319	.720	.279	1.000
60 من أكبر	.071	.129	1.405	.064	.002	.406	.011	.746	.757
Active	1.000			.538	1.000	1.000			
Total									

a. Symmetrical normalization

✓ المساهمة في عطالة الابعاد:


- نلاحظ أن أكبر مساهمة للعطالة في المحور الاول هي للفئة العمرية 20-30 سنة

- نلاحظ أن أكبر مساهمة للعطالة في المحور الثاني هي للفئة العمرية أكبر من 60 سنة

✓ المساهمة في عطالة النقاط:

- يساهم المحور الاول في عتالة 96.7% بالنسبة للفتة العمرية 20-30 و75.3% بالنسبة للفتة العمرية 30-40 و72% بالنسبة للفتة العمرية 40-50 و60-50 سنة.
- يساهم المحور الثاني في عتالة 74.6% بالنسبة للفتة العمرية أكبر من 60 سنة.

كما هو موضح في الشكل التالي:



-
-
-

جدول خصائص الاعمدة

Overview Column Points^a

نمط_الاستعم ال	Mass	Score in Dimension		Inertia	Contribution				
		1	2		Of Point to Inertia of Dimension		Of Dimension to Inertia of Point		
					1	2	1	2	Total
بطريقة منتظمة	.129	-.206-	.294	.044	.009	.033	.077	.088	.165
غالبا	.424	.221	.576	.067	.034	.409	.191	.722	.912
في المناسبات	.212	-1.348-	-.447-	.252	.627	.123	.936	.058	.993
لا استعملها	.235	.927	-.796-	.175	.330	.435	.708	.292	1.000
Active	1.000			.538	1.000	1.000			
Total									

a. Symmetrical normalization

✓ المساهمة في عطالة الابعاد:

- نلاحظ أن أكبر مساهمة للعطالة في المحور الاول هي استخدام البطاقة
في المناسبات

- نلاحظ أن أكبر مساهمة للعطالة في المحور الثاني عدم استخدام
البطاقة


✓ المساهمة في عطالة النقاط:

- يساهم المحور الاول في عطالة 93.6% بالنسبة لاستخدام البطاقة في
المناسبات و70.8% بالنسبة لعدم استخدام البطاقة.

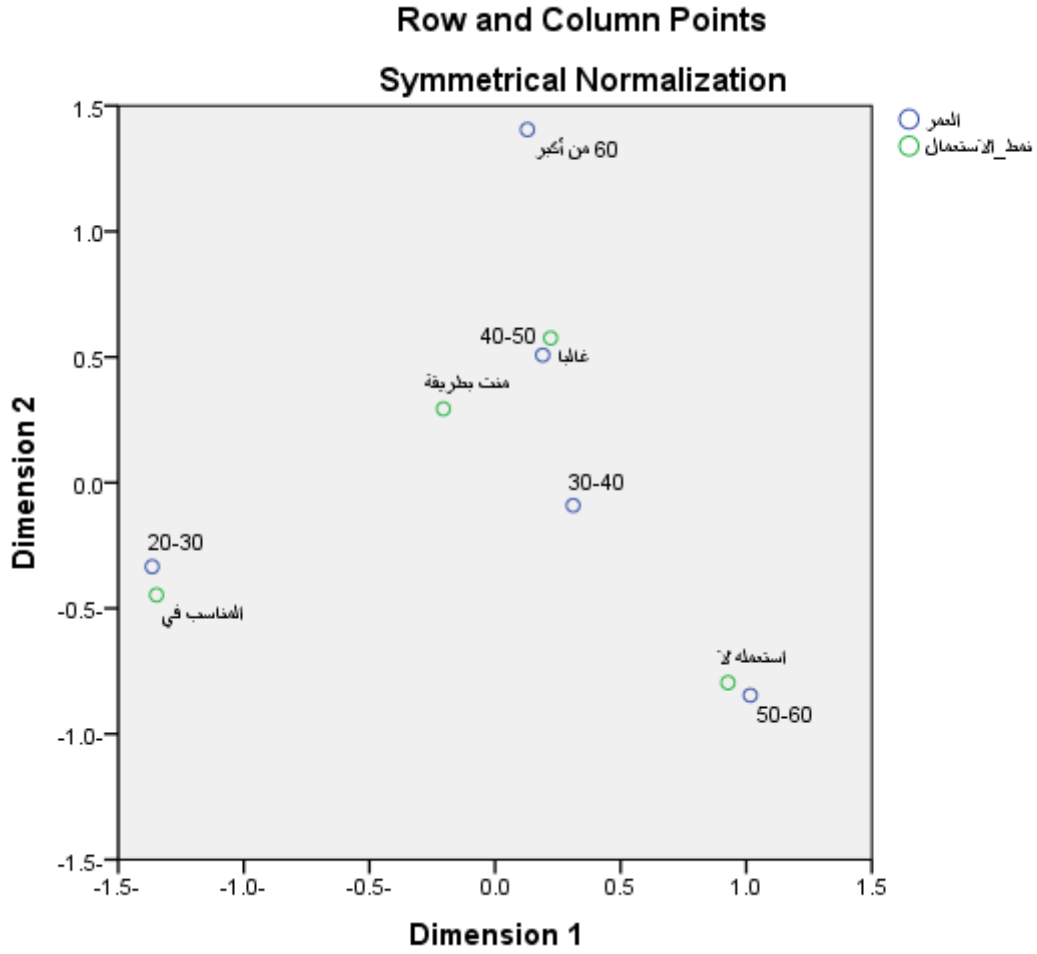
- يساهم المحور الثاني في عطالة 72.2% بالنسبة لاستخدام البطاقة
غالبا.

كما هو موضح في الشكل التالي:

نمط_الاستعمال
Symmetrical Normalization



تموقع نقاط الاسطر والأعمدة:



من الشكل السابق الذي يوضح تموقع نقاط الاسطر والأعمدة نستنتج ثلاثة مجموعات

- المجموعة الاولى: حيث تضم الاشخاص الذين لا يعملون البطاقة والفئة العمرية 50-60.
- المجموعة الثانية: تضم الاشخاص الذين يعملون البطاقة في المناسبات والفئة العمرية 20-30 سنة.

- المجموعة الثالثة: وتضم الأشخاص الذين يستعملون البطاقة في
غالب الأحيان أو بطريقة منتظمة والفئتين العمريتين 30-40 و40-50

سنة