

أعمال تطبيقية رقم (05) حول تحليل المركبات الرئيسية

مثال تطبيقي (01)

يحتوي الجدول الموالي على بيانات عن (10) منتجات product، تشمل سعر المنتج price، وتقييم جودته من خلال بعض المواصفات، كالذوق taste، الحجم size، مدى التوفر في avaibility، جودة التغليف packaging، وطريقة العرض (الصورة) merchandising، وذلك على سلم من 1 إلى 10، ويريد مدير التسويق توزيع هذه المنتجات في السوق على حسب السعر والمواصفات.

الصورة	التغليف	التوفر	الحجم	الذوق	السعر	المنتجات
9,30	8,32	9,37	6,32	8,18	4,40	منتج 1
8,20	7,18	8,68	5,90	7,12	4,32	منتج 2
5,63	5,84	6,79	5,12	5,33	6,11	منتج 3
7,97	7,78	6,70	5,93	7,07	4,62	منتج 4
7,38	6,73	6,14	6,38	6,72	5,00	منتج 5
5,80	5,02	8,67	5,18	5,08	7,28	منتج 6
3,65	2,83	7,88	3,13	2,83	8,32	منتج 7
4,15	3,64	7,63	4,00	3,42	7,93	منتج 8
6,39	7,30	5,29	3,73	4,34	4,82	منتج 9
2,76	2,38	4,43	2,81	2,38	7,59	منتج 10

المطلوب: إجراء تحليل المكون أو المكونات الرئيسية لجدول البيانات المعطاة.

الحل:

قبل القيام بعملية التحليل البيانات باستخدام المركبات الرئيسية، يجب توفر (5) شروط في البيانات حتى تكون النتائج صحيحة:

الشرط الأول: يجب أن تكون المتغيرات قياسية (كمية) مستمرة، على الرغم من استخدام المتغيرات الترتيبية كثيرا في كثير من الدراسات في العالم الحقيقي.

الشرط الثاني: يجب أن تكون هناك علاقة خطية بين جميع المتغيرات. وسبب هذا الشرط هو أن التحليل بالمركبات الرئيسية يعتمد على معاملات ارتباط بيرسون. وعلى هذا النحو يجب أن تكون هناك علاقة خطية بين المتغيرات.

الشرط الثالث: يجب أن يكون هناك كفاية في حجم العينة، وبشكل عام توصي المراجع بحد أدنى من 150 مفردات، أو من 5 إلى 10 مفردات لكل متغير كحد أدنى لحجم العينة، ومن بين اختبارات كفاية العينة مقياس كايزر ماير أولكين (KMO) لكفاية أخذ العينات لمجموعة البيانات الإجمالية؛ ومقياس KMO لكل متغير فردي.

الشرط الرابع: يجب أن هناك لديك ارتباطات كافية بين المتغيرات من أجل تقليل المتغيرات إلى عدد أقل من المكونات. والطريقة التي يستخدمها SPSS لاكتشاف ذلك هي اختبار Bartlett للكروية.

الشرط الخامس: يجب ألا يكون هناك قيم متطرفة كبيرة. لأنه سيكون لها تأثير سيئ على نتائج التحليل، ويمكن اختبار ذلك بواسطة مسافة Mahalanobis.

الخطوة (01): إدخال البيانات وتسمية المتغيرات

يتم فتح برنامج SPSS، ثم إدخال بيانات المثال إلى نافذة البيانات Data View، وهذا انطلاقا من ملف Exel المرفق، ثم يتم تسمية المتغيرات وتحديد خصائصها: product (متغير اسمي)؛ والمتغيرات: السعر (price)؛ الذوق (taste)؛ الحجم (size)؛ التوافر (avaibility)؛ جودة التغليف (packaging)؛ طريقة العرض (merchandising)، وهي كلها متغيرات كمية قياسية Scale.

product	price	taste	size	avaibility	packaging	merchandising
1	4.40	8.18	6.32	9.37	8.32	9.30
2	4.32	7.12	5.90	8.68	7.18	8.20
3	6.11	5.33	5.12	6.79	5.84	5.63
4	4.62	7.07	5.93	6.70	7.78	7.97
5	5.00	6.72	6.38	6.14	6.73	7.38
6	7.28	5.08	5.18	8.67	5.02	5.80
7	8.32	2.83	3.13	7.88	2.83	3.65
8	7.93	3.42	4.00	7.63	3.64	4.15
9	4.82	4.34	3.73	5.29	7.30	6.39
10	7.59	2.38	2.38	4.43	2.38	2.76


Name	Type	Width	Decimals	Label	Values	Missing	Columns	Align	Measure
product	Numeric	8	0		None	None	8	Right	Nominal
price	Numeric	8	2		None	None	8	Right	Scale
taste	Numeric	8	2		None	None	8	Right	Scale
size	Numeric	8	2		None	None	8	Right	Scale
avaibility	Numeric	8	2		None	None	8	Right	Scale
packaging	Numeric	8	2		None	None	8	Right	Scale
merchandise...	Numeric	8	2		None	None	9	Right	Scale

الخطوة (2): التحقق من شروط تحليل المركبات الرئيسية (من 2 وحتى 5) باستخدام SPSS.

الشرط (1): المتغيرات المستقلة كمية، واضح أنه متحقق، هنا سنتحقق من التوزيع الطبيعي للمتغيرات (إضافي)، وعدم وجود قيم شاذة في البيانات (شرط 5)، أما بقية شروط: العلاقة خطية بين المتغيرات (شرط 2)، كفاية حجم العينة (شرط 3)، كفاية الارتباطات (شرط 4) فسننتحقق منها ضمن إجراءات تحليل المركبات الرئيسية.

1. اختبار التوزيع الطبيعي:

هناك عدة طرق للتأكد من أن البيانات تتبع التوزيع الطبيعي، من أهمها: اختبار Kolmogorov-Smirnov، ويطبق هذا الاختبار من خلال اختيار Analyze، ثم Nonparametric Tests، ثم Legacy Dialogs، وأخيراً 1-Sample K-S...، فيظهر صندوق الحوار: One-Sample Kolmogorov-Smirnov Test، نقوم بإدخال المتغيرات المستقلة الكمية الستة price؛ taste؛ size؛ avaibility؛ packaging؛ merchandising تحت Test Variable List، ونؤشر على الخانة Normal في مجموعة الخيارات Test Distribution كما يلي:



نضغط على OK، فتظهر عدة جداول أهمها الجدول التالي:

One-Sample Kolmogorov-Smirnov Test

		price	taste	size	avaibility	packaging	merchandising
N		10	10	10	10	10	10
Normal	Mean	6.039	5.247	4.807	7.158	5.7020	6.1230
Parameters ^{a,b}	Std. Deviation	1.596	1.996	1.413	1.582	2.13404	2.13790
Most Extreme	Absolute	.242	.170	.188	.130	.185	.122
Differences	Positive	.242	.120	.133	.092	.133	.122
	Negative	-.181	-.170	-.188	-.130	-.185	-.122
Kolmogorov-Smirnov Z		.766	.537	.593	.412	.585	.386
Asymp. Sig. (2-tailed)		.600	.936	.873	.996	.883	.998

a. Test distribution is Normal.

b. Calculated from data.

من الجدول أعلاه يتبين أن البيانات المجمعة في كل من المتغيرات الخمسة تتبع التوزيع الطبيعي، حيث أن مستوى دلالة اختبار Kolmogorov-Smirnov لكل منها أكبر من 0.05، وهو مستوى المعنوية المعتمد لهذه الدراسة.

2. اختبار غياب القيم الشاذة

يمكن التأكد من عدم وجود قيم شاذة للبيانات في كافة المتغيرات المستقلة من خلال اختبار Mahalanobis، وذلك من خلال اختيار القائمة الرئيسية Analyze، ثم القائمة Regression، ثم بعد ذلك الضغط على Linear، وإدخال المتغير product في المستطيل المعنون Dependent، والمتغيرات المستقلة الكمية الستة في المستطيل المعنون Independents. اضغط على المفتاح Save ليظهر صندوق الحوار Linear Regression: Save، قم بالتأشير داخل المربع الصغير مقابل اختبار Mahalanobis تحت Distances. ثم اضغط على Continue للعودة إلى الصندوق الأصلي المتعلق بالانحدار الخطي، وأخيرا اضغط OK، فتظهر فتظهر المخرجات المتعلقة بالانحدار الخطي، من أهمها جدول البقايا الإحصائية Residuals Statistics التالي:

Residuals Statistics^a

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	4.1343	8.2667	6.0390	1.57607	10
Std. Predicted Value	-1.209	1.413	.000	1.000	10
Standard Error of Predicted Value	.208	.380	.291	.068	10
Adjusted Predicted Value	3.6827	8.2218	6.1774	1.63391	10
Residual	-.59024	.27060	.00000	.25689	10
Std. Residual	-1.532	.702	.000	.667	10
Stud. Residual	-1.876	1.133	-.063	.957	10
Deleted Residual	-1.42632	.71730	-.13841	.67891	10
Stud. Deleted Residual	-4.691	1.191	-.382	1.711	10
Mahal. Distance	1.712	7.854	4.500	2.419	10
Cook's Distance	.000	1.942	.349	.610	10
Centered Leverage Value	.190	.873	.500	.269	10

a. Dependent Variable: price

نركز على سطر Mahal. Distance، حيث أقصى مسافة في السطر (القيمة التي يمكن أن تكون شاذة) هي 7.854، نبحث عن قيمة اختبار كاي تربيع χ^2 ، عند درجة حرية 5 $ddl = 6 - 1 = 5$ ومستوى دلالة $\alpha = 0.05$ من الجدول الإحصائي χ^2 ، نجد: $\chi^2_{(ddl=5, 5\%)} = 11.07$ ، وبما أن أقصى مسافة Mahal 7.854 هي أصغر من قيمة χ^2 الجدولية، فإننا نستنتج أنه لا توجد قيم شاذة في البيانات المعطاة.


وعند إغلاق نافذة المخرجات بدون حفظ، والعودة إلى نافذة البيانات Data View. نلاحظ وجود متغير جديد باسم MAH_1 كما في الشكل التالي:

product	price	taste	size	avaibility	packaging	merchandising	MAH_1
1	4.40	8.18	6.32	9.37	8.32	9.30	4.76641
2	4.32	7.12	5.90	8.68	7.18	8.20	2.10123
3	6.11	5.33	5.12	6.79	5.84	5.63	6.75557
4	4.62	7.07	5.93	6.70	7.78	7.97	1.71155
5	5.00	6.72	6.38	6.14	6.73	7.38	6.69452
6	7.28	5.08	5.18	8.67	5.02	5.80	2.26463
7	8.32	2.83	3.13	7.88	2.83	3.65	3.21169
8	7.93	3.42	4.00	7.63	3.64	4.15	2.46764
9	4.82	4.34	3.73	5.29	7.30	6.39	7.85397
10	7.59	2.38	2.38	4.43	2.38	2.76	7.17278


نلاحظ من هذا الجدول، في العمود الأخير لمسافات Mahal لكل المنتجات الـ 10، أن أقصى مسافة هي 7.884 (المنتج 9)، وهذه المسافة أقل من قيمة اختبار كاي تربيع χ^2 عند درجة حرية (عدد المتغيرات - 1 = 5)، ومستوى معنوية 5% (وجدناها سابقا 11.07)، ومنه لا توجد أي قيمة شاذة بالنسبة للمتغيرات أو المنتجات.

الخطوة (3): إجراء تحليل المركبات الرئيسية (أو التحليل العاملي بطريقة المركبات الرئيسية)


1. من القائمة الرئيسية Analyze، يتم اختيار Dimension Reduction، ثم Factor كما في الرسم التالي:



2. تظهر نافذة حوار Factor Analysis، ننقل المتغيرات إلى مربع Variable (المتغيرات الكمية فقط وليس المتغير product لأنه متغير نوعي). كما في الشكل التالي:



3. نضغط على صندوق الحوار (Descriptives)، فتظهر نافذة بعدة مجموعات بها خيارات كما في الشكل التالي:



في المجموعة إحصائيات (Statistics)، نؤشر على الخيارات التالية:

- الوصف وحيد المتغير (Univariate descriptives): يسمح هذا الخيار بعرض الاحصاءات الوصفية للمتغيرات، مثل المتوسط الحسابي والانحراف المعياري وعدد المشاهدات الصالحة لكل متغير.
- الحل المبدئي (Initial solution): يسمح هذا الخيار بعرض: مصفوفة التشبعات (loadings)، الجذور الكامنة (Eigenvalues)-القيم الذاتية (Valeurs propres)، والنسب المئوية المتراكمة للتباين المفسر (Percentage and Cumulative percentage of Variance)، مصفوفة الشيوخ (Communalities): وهي مجموع إسهامات المتغير في العوامل المختلفة التي أمكن استخالصها في المصفوفة العاملية، وحيث أن المتغير الواحد يسهم بمقادير مختلفة في كل عامل، سواء كانت إسهاماته جوهرية أو كانت غير ذات دلالة، فإن مجموع مربعات هذه الإسهامات أو التشبعات loadings على عوامل المصفوفة هي قيمة شيوخ المتغير أو الاشتراكيات.

في مجموعة مصفوفة الارتباط Correlation Matrix نختار:

- Coefficients لحساب معاملات مصفوفة الارتباط، ومن خلال التأشير على مستويات المعنوية (الدلالة) Significance levels نحصل على معنوية مصفوفة الارتباطات من أجل الاطلاع عليها والتأكد من شرط عدم

وجود ارتباط عالي بين المتغيرات، أي أعلى من 90 % بين أي متغيرين، حيث يتم استبعاد تلك المتغيرات التي بينها هذه النسبة العالية من الارتباط.

- من خلال التأشير على المحدد (Determinant) نحصل على محدد المصفوفة، وذلك لقياس مشكلة الارتباط الذاتي، إذ يجب ألا تقل قيمة المحدد عن 0.0001، فإذا كانت قيمته أقل من ذلك ننظر إلى المتغيرات المرتبطة عالياً، أكثر من 0.80 ونحذف أحدها.

- ونؤشر على KMO and Bartlett's test of sphericity لنحصل من خلال قياس KMO على مدى كفاية عدد أفراد العينة، ويجب أن تكون قيمته أكبر من 0.5، حتى تكون العينة كافية، وهذا شرط أساسي يجب تحقيقه، أما فيما يتعلق باختبار Bartlett's للدائرية Sphericity فهو مؤشر للعلاقة بين المتغيرات، إذ يجب أن يكون مستوى الدلالة لهذه العلاقة أقل من 0.05، وذلك حتى نستطيع التأكيد على أن هذه العلاقة دالة إحصائياً، وأن مصفوفة الارتباط الأصلية ليست بمصفوفة الوحدة. الفرضية الصفرية لاختبار بارتلليت للكروية، هي H_0 : مصفوفة الارتباط هي مصفوفة الوحدة (عناصر القطر الرئيسي = 1، وباقي العناصر = 0).

ملاحظة:


اختبار Kaiser-Meyer-Olkin (KMO) هو مقياس لمدى ملائمة البيانات لتحليل العوامل، يقيس الاختبار مدى كفاية أخذ العينات لكل متغير في النموذج والنموذج الكامل. ويأخذ KMO قيمة بين 0 و 1 وكقاعدة أساسية تشير قيم KMO بين 0.8 و 1 إلى أن أخذ العينات مناسب، وتشير قيم KMO الأقل من 0.6 إلى أن حجم العينة غير كاف وأنه ينبغي اتخاذ إجراء علاجي. وقد وضع بعض المؤلفين هذه القيمة عند 0.5، لذا يتم استخدام الحكم الخاص للقيم بين 0.5 و 0.6، وتعني قيم KMO القريبة من الصفر أن هناك ارتباطات جزئية كبيرة مقارنة بمجموع الارتباطات. بمعنى آخر، هناك ارتباط واسع الانتشار يمثل مشكلة كبيرة لتحليل العوامل.

- التأشير على معكوس (Inverse)، لإعطاء المصفوفة العكسية لمصفوفة الارتباطات إذا رغبت في ذلك.

- التأشير على إعادة تقدير المصفوفة (Reproduced) إذا رغبت في ذلك.

- التأشير على مصفوفة الارتباطات الجزئية الصورية العكسية (Anti-Image)، لاختبار كفاية حجم العينة لكل متغير، ويتم الحصول على مصفوفة الارتباطات الجزئية، التي يمكننا من خلالها معرفة مدى كفاية أخذ العينات لكل متغير على حدة. ويجب أن تكون قيم معاملات الارتباط في قطر المصفوفة أكبر من أو تساوي 0.5، وكل متغير معامل ارتباطه أقل من 0.5 يحذف ويعاد التحليل.

4. نضغط على صندوق الحوار استخراج (Extraction)، فتظهر نافذة بعدة مجموعات بها خيارات كما في الشكل التالي:



في طريقة الاستخراج Method، توجد سبعة طرق لاستخراج المركبات (تسمى المحاور أو العوامل)، نختار منها طريقة المكونات الرئيسية Principle Components Analysis.

- في مجموعة Analyze تتضمن المصفوفة المراد تحليلها، من خلال التأشير على الحقل Correlation Matrix نحصل على مصفوفة الارتباط، ومن خلال التأشير على الحقل Covariance Matrix نحصل على مصفوفة التباين المشترك والتباين.

- تحت الخيار عرض (Display)، ومن خلال التأشير على Unrotated factor solution، نحصل على حل العوامل قبل التدوير، وذلك من أجل مقارنة نتائجه مع نتائج حل العوامل مع التدوير Rotated factor solution، فإذا كانت متفقة مع بعضها من حيث عدد العوامل تكون النتائج دقيقة، أما إذا اختلفت النتيجة فإننا نقوم بفحص الاشتراكات لنقرر عدد العوامل، وعادة يستخدم هذا الخيار عندما يكون عدد المتغيرات كبيراً، أي أكثر من 200 متغير.


- ومن خلال التأشير على Scree plot والذي يعني الرسم البياني (سكري)، يطلق عليه كذلك اسم منحى الصخرة، ويستخدم لتحديد العدد الأقصى من العوامل التي يمكن استخلاصها قبل أن يبدأ التباين الخاص في السيطرة على التباين العام. يقوم البرنامج بالتمثيل البياني لرقم الجذر المميز على المحور الأفقي وقيمة الجذر على المحور الرأسي، فيكون عدد العوامل مساوياً لرقم الجذر المميز المناظر إلى الإنحناء المرفقي للمنحنى (Corresponding to an elbow in curve)، فالنقطة التي ينتهي عندها هذا الإنحناء تتوقف عندها الجذور المميزة الكبيرة وتبدأ الجذور المميزة الصغيرة، والتي يتم استبعادها من التحليل.

- في مجموعة Extract، يتم التأشير على Eigenvalues نحصل على قيمة الجذور الكامنة/القيم الذاتية، والبرنامج يحدد قيمة الجذر الكامنة لتكون أكبر من 1 (حسب محك كايزر)، ومن خلال التأشير على الحقل Number of Factors، يتم استخراج عدد من العوامل بعد أن يتم تحديدها. على أن استخدام هذا الخيار يلغي الخيار الأول، والمتعلق بقيمة الجذر الكامنة.

- يوجد في أسفل صندوق الحوار خياراً لتحديد الحد الأعلى لعدد تكرارات الخوارزمية الضرورية للوصول للحل المناسب (Maximum iterations for Convergence 25)، ويمكن تغيير هذا الرقم المحدد مسبقاً من قبل البرنامج بما يتناسب مع أهداف وطبيعة الدراسة.

وللعودة إلى النافذة الأولية: Factor Analysis، نضغط على Continue:

5. نضغط على صندوق الحوار: دوران (Rotation)، فتظهر نافذة بها عدة خيارات كما في الشكل التالي:




- في خيارات الطريقة Method، نختار طريقة التدوير ليتم تدوير العوامل. وتوجد خمسة طرق لعملية التدوير:

- None: وتعني عدم إجراء عملية التدوير.
- طريقة التدوير المتعامدة (Varimax): هي طريقة تؤدي إلى زيادة تباين مربع تشبعات العوامل على كافة المتغيرات، وهي من أفضل طرق التدوير المتعامد، لافتراضها وجود استقلالية بين العوامل.
- طريقة قائمة على التدوير المائل (Direct Oblimin): تؤدي إلى قيم أعلى للجذور الكامنة.

- طريقة (Quartimax): وهي طريقة أخرى للتدوير المتعامد، تؤدي إلى تخفيض عدد العوامل التي تحتاجها لتفسير كل متغير.
- طريقة (Equamax): تقع في الوسط بين طريقتي Varimax و Quartimax .
- طريقة (Promax): طريقة أخرى للتدوير المائل وهي أسرع في العمليات الحسابية من طريقة Direct Oblimin، لذلك فهي تستخدم في بعض الأحيان في العينات الكبيرة العدد.
- في خيارات العرض (Display)، نجد الخيارات التالية:
 - العوامل بعد التدوير Rotated Solution: هذا الحقل محدد سلفاً من قبل البرنامج.
 - الرسوم البيانية للتشبعات Loading Plot(s): بالإمكان تحديد هذا الحقل وإضافته للحقل الأول.
 - عدد مرات تدوير العوامل Maximum Iterations for Convergence: نتركها كما هي 25 دورة، في غالب الأحيان ربما لا يصل البرنامج لهذا العدد من الدورات.

وللعودة إلى النافذة الأولية: Factor Analysis، نضغط على Continue:


6. نضغط على صندوق الحوار نتائج Factor Scores، فتظهر نافذة بها عدة خيارات كما في الشكل التالي:



- نختار Save as variables ليتم حفظ العوامل المستخرجة كمتغيرات. وعند تحديد هذا الحقل فإنه سيتم تفعيل طرق حساب الدرجات، التي يمكن استخدامها في إجراء عمليات إحصائية إضافية وفقاً لاحتياجات البحث، ويمكن اختيار طريقة الحفظ (Regression)، أو طريقة Bartlett أو بطريقة Anderson-Rubin.
- ملاحظة:** في مثالنا سنحدد طريقة الانحدار، لاستخدام العوامل المستخرجة في تحليل الانحدار فيما بعد.
- نؤشر على Display factor score coefficient matrix لعرض مصفوفة معاملات الدرجات.

وللعودة إلى النافذة الأولية: Factor Analysis، نضغط على Continue:

7. نضغط على صندوق الحوار (Options)، فتظهر نافذة بها عدة مجموعات خيارات كما في الشكل التالي:



- في طريقة معالجة القيم المفقودة Mssing Values، نختار اهمال القيم المفقودة (Exlude Values)، وهذا لأنه لا توجد قيم مفقودة في المثال.
- نختار طريقة عرض المعاملات (Coefficient Disply Format)، بطريقة الإخراج حسب الحجم Sorted by size، يتم ترتيب التشبعات على العوامل وفقا لمقدارها. كما يمكننا إخفاء عرض القيم المطلقة للتشبعات التي تقل عن قيمة معينة (Suppress absolute values less than)، وبالتأشير على المربع الصغير أمام هذا الخيار يتم تفعيل القيم التي نرغب بوضعها لإخفاء المعلومات المتعلقة بالتشبعات القيم الأقل، علما بأن هذه القيمة محددة سلفا في البرنامج بـ 0.10، وفي مثالنا نجعلها 0.30، مما يعني أن كل متغير تشبعه على مركبة (محور أو عامل) معينة أقل من 0.30 يتم إخفاؤه.

وللعودة إلى النافذة الأولية: Factor Analysis، نضغط على Continue.

نضغط أخيرا على ok، فتظهر المخرجات التالية:

Warnings

Only one component was extracted. Component plots cannot be produced.

قد يظهر هذا التحذير Warning، الذي يخبرنا هذا التحذير أنه قد تم فقط استخراج مركبة أساسية واحدة، لذلك لن يتم عرض التمثيل البياني للمحاور العاملة. وقد حصلنا على هذه النتيجة لأننا استخدمنا محك كايزر في تحديد عدد العوامل المستخرجة، مما يعني وجود عامل واحد فقط جذره الكامن أكبر من الواحد الصحيح. كما سنرى فيما بعد عند تحليل جدول العوامل الكامنة.

الجدول الأول: جدول الإحصاءات الوصفية

Descriptive Statistics

	Mean	Std. Deviation	Analysis N
price	6.0390	1.59687	10
taste	5.2470	1.99612	10
size	4.8070	1.41304	10
avaibility	7.1580	1.58298	10
merchandising	6.1230	2.13790	10
packaging	5.7020	2.13404	10

يعرض هذا الجدول المتوسط الحسابي والانحراف المعياري للمتغيرات التي أدخلناها للتحليل وعدد المفردات (N) الأفراد مقابل المتغيرات).

الجدول الثاني: مصفوفة الارتباطات

Correlation Matrix^a

	price	taste	size	avaibility	merchandising	packaging
price	1.000	-.859	-.734	-.092	-.913	-.953
taste	-.859	1.000	.956	.479	.974	.904
size	-.734	.956	1.000	.516	.900	.816
avaibility	-.092	.479	.516	1.000	.450	.263
merchandising	-.913	.974	.900	.450	1.000	.960
packaging	-.953	.904	.816	.263	.960	1.000
price		.001	.008	.400	.000	.000
Sig. (1-tailed) taste	.001		.000	.081	.000	.000
size	.008	.000		.063	.000	.002

avaibility	.400	.081	.063		.096	.232
merchandising	.000	.000	.000	.096		.000
packaging	.000	.000	.002	.232	.000	

a. Determinant = 1.803E-006

يتضح من الجدول بأننا حصلنا على مصفوفة معاملات الارتباطات بين المتغيرات الستة، التي **تعد الحل الأولي للعلاقات بين المتغيرات** الداخلة في التحليل العاملي. ونلاحظ أن قيمة المحدد تساوي: 0.000001374 (Determinant = 1,374E-6)، وهي أقل بكثير من 0.0001، وبالتالي يتوجب علينا أن ننظر في المتغيرات التي قيمة معامل الارتباط بينها أعلى من 0.80 ونحذف إحداها، ثم نعيد التحليل. يمكننا من ملاحظة مصفوفة الارتباط، أن نجد أن معامل الارتباط بين الحجم والذوق مرتفع جدا (0.956) ودال إحصائيا، وكذلك الحال بين التغليف والسعر، وبين صورة المنتج والسعر (ارتباط عكسي ذو دلالة إحصائية)، وبين صورة المنتج والذوق... الخ.

الجدول الثالث: قياس جودة الاختبار، ومدى صلاحية البيانات للتحليل العاملي

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.	.712
Approx. Chi-Square	81.561
Bartlett's Test of Sphericity df	15
Sig.	.000

يتضح من الجدول بأننا قد حصلنا على قيمة قياس KMO، تساوي 0.712، وهي أكبر من 0.5، وهذا يدل على زيادة الاعتمادية للعوامل التي نحصل عليها من التحليل العاملي، وكذلك نحكم بكفاية حجم العينة، كما نجد أن قيمة مستوى الدلالة لاختبار بارتلل للدائرية تساوي 0.0001، وهي أقل من 0.05، وهذا يؤكد على وجود علاقة دالة إحصائية بين المتغيرات، وأن مصفوفة الارتباط ليست مصفوفة الوحدة، وبذلك يمكن إجراء التحليل العاملي.

الجدول الرابع: مصفوفة الارتباطات الجزئية

Anti-image Matrices

	price	taste	size	avaibility	merchandising	packaging
price	.724 ^a	.266	-.504	-.775	.441	.192
taste	.266	.738 ^a	-.794	.024	-.573	.515
size	-.504	-.794	.756 ^a	.222	.106	-.293
avaibility	-.775	.024	.222	.387 ^a	-.702	.291
merchandising	.441	-.573	.106	-.702	.712 ^a	-.692
packaging	.192	.515	-.293	.291	-.692	.781 ^a

a. Measures of Sampling Adequacy(MSA)

تبين لنا هذه المصفوفة مدى كفاية كل متغير للتحليل المركبات الرئيسية والتحليل العاملي، لذلك يجب أن تكون الارتباطات الجزئية لكل متغير في القطر أكبر من 0.5، وكل متغير أقل من هذه القيمة علينا حذفه. في حالتنا علينا حذف متغير التوفر (0.387) وإعادة التحليل.

الجدول الرابع: مصفوفة الاشتراكات (الشيوع)

Communalities

	Initial	Extraction
price	1.000	.811
taste	1.000	.974
size	1.000	.871
avaibility	1.000	.212
merchandising	1.000	.990
packaging	1.000	.908

Extraction Method: Principal Component Analysis.

القاعدة أنه كلما كانت قيمة الاستخلاص (Extraction) أكبر من 0.75 (أي 75%)، فذلك دليل على أنها تمثل البيانات تمثيلاً جيداً. مثلاً الذوق لديه أكبر تشبع (0.977)

الجدول الخامس: جدول التباين المفسر، وهو من أهم الجداول لدينا

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	4.766	79.441	79.441	4.766	79.441	79.441
2	.998	16.626	96.067			
3	.181	3.022	99.089			
4	.039	.643	99.732			
5	.011	.188	99.920			
6	.005	.080	100.000			

Extraction Method: Principal Component Analysis.


يفسر هذا الجدول المركبات (العوامل)، وأياً أكثر تأثيراً، من خلال قيمة الجذور الكامنة/ القيم الذاتية (Eigenvalues)، كلما كانت قيمة هذا الأخير أكبر من واحد (1)، كانت المركبة المتحصل عليها تساهم في تفسير التباين بين المتغيرات، ونلاحظ أن Eigenvalues للمكون/ العامل الأول يساوي 4.766، وهو أكبر من 1، ونسبة تفسيره للتباين: $79.44\% = 4.766 \div 6$ ، وقد تم القسمة على 6، لأن التباين الكلي = عدد المتغيرات = 6، وعلى ذلك، واستناداً لمحك كايذر فقد تم استخراج مركبة/ عامل فقط (الأولى)، واستبعدت بقية المركبات/ العوامل.

ويمثل العمود الأول من الجدول عدد المركبات المستخلصة (6 عوامل) وهو بعدد المتغيرات الكمية، ويحتوي العمود الثاني على قيمة الجذر الكامنة- القيمة الذاتية لكل مكون، فيما يعرض العمود الثالث نسبة تفسير التباين لكل مكون (النسبة 79.34% تحسب بقسمة الجذر الكامنة 4.761 على 6 عدد المتغيرات 6، ويعرض العمود الرابع على التباين النسبي التجميعي المفسر.

ملاحظة مهمة: تم عرض المركبات- العوامل قبل التدوير فقط، ولم يعرض المركبات- العوامل بعد التدوير، بسبب أن هناك مركبة- عامل واحد فقط قد تم استخلاصها.

ملاحظة: دائماً عدد الجذور الكامنة يساوي عدد المتغيرات (6 جذور كامنة و6 متغيرات).

الرسم البياني Scree Plot:



إن هذا الرسم البياني يمثل رقم المكون على محور الفواصل، وقيم الجذور الكامنة لكل عامل على محور الترتيب، ويعتبر الرسم البياني معياراً آخر يمكن استخدامه- بالإضافة إلى معيار الإبقاء على العوامل التي يزيد جذرها الكامن عن الواحد الصحيح- لتحديد العوامل في تحليل المكونات الرئيسية، والإبقاء فقط على تلك التي تكون في المنطقة شديدة الانحدار . ولاحظ أنّ هناك عامل واحد فقط جذره الكامن أكبر من واحد، ويوجد عامل ثاني يقع في المرفق، ويساوي الواحد تقريباً، يمكننا أخذه إذا اعتمدنا على محكات أخرى بخلاف محك كايزر.

ملاحظة: لو عدنا إلى نافذة البيانات (Data View)، سنجد أن البرنامج قد استخرج العامل الأول وأنشأ له متغير جديد (FAC1_1).

الجدول السادس: مصفوفة العوامل قبل التدوير

Component Matrix^a

	Component
	1
price	-.901
taste	.987
size	.933
availability	.461
merchandising	.995
packaging	.953

Extraction Method: Principal Component Analysis.

a. 1 components extracted.

يمكننا من خلال هذا الجدول إلقاء نظرة أولية على تمثيل المتغيرات في العامل المستخرج، القاعدة أنّ كل متغير تقترب قيمة تشبّعه على المركبة/ العامل من 1، يكون أكبر تأثيراً في تلك المركبة. مثلاً متغير صورة المنتج merchandising قيمة تشبّعه على المركبة 0.995، وكذلك متغيرات: الذوق والتغليف والحجم والسعر، فكلها قيم تشبّعها على العامل الأول مرتفعة، ماعدا متغير التوفر فقيمة تشبّعه ضعيفة نوعاً ما. كما تشير القيم السالبة إلى ارتباط سالب للمتغير مع العامل.

ملاحظة: تشبّع متغير على مركبة- عامل يساوي معامل الارتباط بين ذلك المتغير وتلك المركبة، وكلما اقترب من 1 أو -1، دل ذلك أن ذلك المتغير في تلك المركبة (متغير نشط)، في حالة استبيان: الفقرة (متغير) تنتمي إلى البعد (مركبة).

الجدول السابع: مصفوفة الارتباطات المُعاد إنتاجها Reproduced Correlations

مصفوفة الارتباط المُعاد إنتاجها هي مصفوفة ارتباط قائمة على المركبات/ العوامل المستخلصة. يجب أن تكون قيم المصفوفة المُعاد إنتاجها قريبة قدر الإمكان من قيم مصفوفة الارتباط الأصلية، أي أن تكون معظم المتبقيات Residual (الفرق بين الارتباطات الفعلية والارتباطات المُعاد إنتاجها)، والممثلة في الجزء السفلي من مخرجات مصفوفة الارتباطات المُعاد إنتاجها والتي تنشأ من نموذج تحليل العوامل بناءً على البيانات المُحللة: أقل من 0.05، وهنا سيتم الاحتفاظ بالمركبات التي تم إنشاؤها بواسطة النموذج إذا تجاوز عدد قليل من المتبقيات (الفرق بين الارتباطات التجريبية والمُعاد إنتاجها ") فرقاً قدره 0.05 بين الارتباطات الفعلية والارتباطات المُعاد إنتاجها، أما إذا اختلف أكثر من 50% ارتباطات مُعاد إنتاجها عن الارتباطات الأصلية بمقدار يزيد عن 0.05 (ب + أو -)، فقد يتوجب تضمين المزيد من المركبات.

Reproduced Correlations

		price	taste	size	availability	packaging	merchandising
Reproduced Correlation	price	.811 ^a	-.889	-.841	-.415	-.858	-.896
	taste	-.889	.974 ^a	.921	.455	.941	.982
	size	-.841	.921	.871 ^a	.430	.889	.928

	avaibility	-.415	.455	.430	.212 ^a	.439	.458
	packaging	-.858	.941	.889	.439	.908 ^a	.948
	merchandising	-.896	.982	.928	.458	.948	.990 ^a
Residual ^b	price		.030	.107	.323	-.095	-.017
	taste	.030		.035	.024	-.037	-.008
	size	.107	.035		.086	-.074	-.028
	avaibility	.323	.024	.086		-.176	-.008
	packaging	-.095	-.037	-.074	-.176		.013
	merchandising	-.017	-.008	-.028	-.008	.013	

Extraction Method: Principal Component Analysis.

a. Reproduced communalities

b. Residuals are computed between observed and reproduced correlations. There are 6 (40.0%) nonredundant residuals with absolute values greater than 0.05.

نلاحظ من الجدول السابق المتبقيات Residuals المحسوبة في الجزء السفلي في مصفوفات الارتباطات المعاد إنتاجها، بين الارتباطات الأصلية (في مصفوفة الارتباطات السابقة) والارتباطات المعاد إنتاجها بنموذج المركبة الرئيسية الأولى، أن 6 من هذه المتبقيات (أي 40% من 15 معامل ارتباط) هي أكبر من 0.05 (ملونة بالأزرق)، مما يعني أنه تم المحافظة على أكثر من 50% من الارتباطات ضمن الحدود المقبولة، عند استخدام نموذج المركبة/ العامل الأول، وهو ما يشير إلى جودة اختزال المتغيرات الستة في مركبة/ عامل واحد.

الجدول الثامن: مصفوفة العوامل بعد التدوير

Rotated Component Matrix^a

--

a. Only one component was extracted. The solution cannot be rotated.

بسبب استخلاص عامل واحد فقط لن تتم عملية التدوير، وبالتالي الجدول لا يحتوي على أي معلومات، بسبب بعدم إجراء التدوير.

الجدول التاسع: مصفوفة التشبعات (الارتباطات) Component Score/ Coefficient Matrix

Component Score Coefficient Matrix

	Component
	1
price	-.189
taste	.207
size	.196
avaibility	.097
merchandising	.209
packaging	.200

Extraction Method: Principal Component Analysis.

Rotation Method: Varimax with Kaiser Normalization.

يعرض الجدول معاملات الارتباط بين المتغيرات الستة والمركبة (العامل) الرئيسية الوحيدة، وهذه المعاملات تبين أهمية ومساهمة هذه المتغيرات في المركبة، حيث يحتل متغير عرض المنتج (الصورة merchandising) المرتبة الأولى بمعامل ارتباط 0.209، أما السعر price فله معامل ارتباط سالب مع المركبة المستخرجة (علاقة عكسية)، ونلاحظ أن متغير التوافر avaibility يساهم مساهمة ضعيفة في المركبة (معامل ارتباط 0.097)، وبالتالي يمكن إهماله وحذفه من المركبة.

الجدول العاشر: مصفوفة التباينات المشتركة Component Score/ Variance Matrix

Component Score Covariance Matrix

Component	1
1	1.000


Extraction Method: Principal Component Analysis.

Rotation Method: Varimax with Kaiser Normalization.

يعرض الجدول تباين المركبة-المكون الأولى (الوحيدة المستخرجة)، وبما أن المركبة تتبع التوزيع الطبيعي المعياري، فإن تباينها في الجدول يساوي 1.000.

الخطوة (04): إضافة مركبة رئيسية (عامل) ثانية في التحليل

كما أسلفنا، وبالنظر إلى معيار التمثيل البياني للقيم الذاتية، يمكننا أخذ عامل ثاني. نعيد التحليل بنفس الطريقة: Factor Analysis → Dimension Reduction → Analyse، فتظهر صندوق الحوار Factor Analysis، فلا نغير فيها شيئاً، كما لا نغير شيئاً في الصناديق الفرعية، إلا في صندوق الحوار Extraction فقط، حيث نحدد عدد المركبات (العوامل) المستخلصة ونجعلها 2، أو نحدد استخلاص الجذور الكامنة (القيم الذاتية) أكبر من 0.50، كما في الشكلان التاليان:



بعد ذلك نعود لصندوق الحوار الرئيسي Factor Analysis، ونضغط Ok، وسنجد أنه لا يتغير أي شيء في أغلب الجداول فقط سيكون التغيير في بعضها، كما يلي:

جدول التباين المفسر Total Variance Explained:

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	4.766	79.441	79.441	4.766	79.441	79.441
2	.998	16.626	96.067	.998	16.626	96.067
3	.181	3.022	99.089			
4	.039	.643	99.732			
5	.011	.188	99.920			
6	.005	.080	100.000			

Extraction Method: Principal Component Analysis.

نلاحظ أنه عند تحديد عدد المركبات/ العوامل المستخلصة بـ 2، المركبتين/ العاملين معاً يفسران 96.067 % من التباين. وقد عرض لنا برنامج SPSS العوامل بعد التدوير، أي أنّ عملية التدوير قد تمت.

ولو عدنا إلى نافذة البيانات Data View، سنجد أن برنامج SPSS قد استخرج العاملين الأول والثاني، وأنشأ لهما متغيرين جديدين (FAC1_1, FAC2_1) كما في الشكل التالي:

product	price	taste	size	avaibility	packaging	merchandising	FAC1_1	FAC2_1
1	4.40	8.18	6.32	9.37	8.32	9.30	1.05405	1.18019
2	4.32	7.12	5.90	8.68	7.18	8.20	.78327	.71642
3	6.11	5.33	5.12	6.79	5.84	5.63	.04178	-.15336
4	4.62	7.07	5.93	6.70	7.78	7.97	1.04174	-.33746
5	5.00	6.72	6.38	6.14	6.73	7.38	.86480	-.46171
6	7.28	5.08	5.18	8.67	5.02	5.80	-.54544	1.13976
7	8.32	2.83	3.13	7.88	2.83	3.65	-1.50969	.56504
8	7.93	3.42	4.00	7.63	3.64	4.15	-1.11842	.47990
9	4.82	4.34	3.73	5.29	7.30	6.39	.53828	-1.56083
10	7.59	2.38	2.38	4.43	2.38	2.76	-1.15036	-1.56795

يعطي الجدول السابق احداثيات المنتجات الـ 10 في المعلم الجديد، أي بالنسبة للمركبتين المستخلصتين (FAC1_1, FAC2_1).

جدول المركبات/ العوامل قبل التدوير: الارتباطات بين المتغيرات والمتغيرات

Component Matrix^a

	Component	
	1	2
price	-.901	.398
taste	.987	
size	.933	
avaibility	.461	.872
packaging	.953	
merchandising	.995	

Extraction Method: Principal Component Analysis.

a. 2 components extracted.

يمكننا من خلال هذه المصفوفة ملاحظة أنه فيما عدى متغير التوفر avaibility الذي يتشعب على المركبة/العامل الثاني أفضل من المركبة/ العامل الأول، أما بقية المتغيرات تتشعب على العامل الأول (معامل الارتباط مع المركبة/العامل الأول مرتفع جدا (قريب من +1 أو -1). لذا سنقوم بعملية التدوير لنضبط ارتباط كل متغير بالمركبة/ العامل المناسب.

جدول المركبات/ العوامل المدورة (بعد التدوير):

Rotated Component Matrix^a

	Component	
	1	2
price	-.983	
taste	.909	.388
size	.821	.471
avaibility		.978
packaging	.972	
merchandising	.940	.325


Extraction Method: Principal Component Analysis.

Rotation Method: Varimax with Kaiser Normalization.

a. Rotation converged in 3 iterations.

كما عرفنا سابقا، القاعدة أنّ كل متغير تقترب قيمة تشبّعه على مركبة/ عامل من 1، يكون أكبر تأثيرا في ذلك المركبة/ العامل، فمثلا متغير صورة المنتج merchandising قيمة تشبّعه على المركبة الأولى 0.940، وغير متشبع على المركبة الثانية (0.325)، فيكون في المركبة/ العامل الأول، وكذلك المتغيرات: الذوق taste والتغليف packaging والحجم size، كلها قيم تشبّعها على المركبة/العامل الأول أفضل من الثاني. بينما نلاحظ أنّ متغير السعر price متشبع على المركبة/ العامل الأول، لكن بقيمة سالبة، القيمة السالبة هنا تعني أنّ هذا المتغير له ارتباط عكسي مع العامل. أمّا متغير التوفّر availability فإنّه متشبع على العامل الثاني أفضل من الأول. **كما نلاحظ من المعلومات المرفقة أسفل الجدول أن عدد مرات التدوير قليلة (3 فقط)**، وهذا كان متوقعا لأن في جدول العوامل قبل التدوير كان واضحا أن متغير يتشبع بقوة مع إحدى المركبتين.

الرسم البياني Secree Plot



نلاحظ من الرسم أن الخط الأفقي الذي يقطع محور الترتيب عند 0.5، وهي قيمة الجذر الكامن التي حددناها لاستخلاص العوامل/المركبات الرئيسية، حيث يظهر فوق هذا الخط وجود جذرين كامنين (رقمهما على محور الفواصل 1 و 2)، وبالتالي تم استخلاص عاملين/ مركبتين، أما بقية الجذور الزائدة (على محور الفواصل الجذر الثالث 3، الرابع 5، الخامس، السادس 6)، فمساهمة كل منها في تباين المتغيرات المستقلة ضعيفة (أقل من 0.5)، وبالتالي يمكن إهمالها، والاكتفاء باستخلاص عاملين/ مركبتين، حيث تساهمان معا بمعظم التباين الكلي في المتغيرات الستة المستقلة.

جدول مصفوفة الارتباطات المعاد إنتاجها Reproduced Correlations

Reproduced Correlations

		price	taste	size	availability	packaging	merchandising
Reproduced Correlation	price	.969 ^a	-.870	-.778	-.068	-.948	-.905
	taste	-.870	.977 ^a	.929	.497	.930	.981
	size	-.778	.929	.896 ^a	.567	.854	.925
	availability	-.068	.497	.567	.973 ^a	.242	.439
	packaging	-.948	.930	.854	.242	.959 ^a	.953
	merchandising	-.905	.981	.925	.439	.953	.990 ^a
Residual ^b	price		.010	.044	-.024	-.005	-.008
	taste	.010		.027	-.018	-.026	-.007
	size	.044	.027		-.051	-.038	-.025
	availability	-.024	-.018	-.051		.021	.011
	packaging	-.005	-.026	-.038	.021		.008
	merchandising	-.008	-.007	-.025	.011	.008	

Extraction Method: Principal Component Analysis.

a. Reproduced communalities


b. Residuals are computed between observed and reproduced correlations. There are 1 (6.0%) nonredundant residuals with absolute values greater than 0.05.

نلاحظ من الجزء السفلي من مصفوفات الارتباطات المعاد إنتاجها، أن كل المتبقيات Residual (الفروق بين الارتباطات الأصلية والارتباطات المعاد إنتاجها بالمركبات) هي أقل من 0.05، باستثناء معامل الارتباط بين الحجم size والتوافر availability، حيث كان يساوي معامل الارتباط في مصفوفة الارتباطات الأصلية 0.516، وصار يساوي في مصفوفة الارتباطات المعاد إنتاجها بالمركبات 0.567، ومنه وجود فرق Residual يساوي -0.051، أي أن نموذج المركبتين يحافظ على علاقات الارتباط بين المتغيرات، ومنه لا حاجة لزيادة عدد المركبات/ العوامل (مركبة/ عامل واحد كافي).

الخطوة (05): إنشاء المحاور العاملية ورسم المتغيرات والمنتجات

لم يتم إنشاء الرسم البياني لإسقاط المتغيرات ولإسقاط المنتجات عند اختيار عامل واحد (مركبة أساسية واحدة)، لكن عند اختيار مركبتين/عاملين فإنه يمكن إنشاء الرسم البياني على المستوي. ويمكننا من خلاله اتخاذ القرار بشأن توزيع المنتجات في السوق.

1. إسقاط ورسم المتغيرات على المحاور/ المركبات الرئيسية:



يمكننا ملاحظة أنّ جميع المتغيرات، ما عدى متغير التوفر avaibility، قريبة من محور الفواصل، الذي يمثل العامل الأول (المركبة الرئيسية الأولى)، ومتغير التوفر avaibility قريب من محور الترتيب، الذي يمثل العامل الثاني (المركبة الرئيسية الثانية). لكن ماذا تعني لنا هذه النتائج؟ ماذا يعرض لنا المركبة/ العامل الأول وماذا يعرض المركبة/العامل الثاني؟


لاحظ تموضع مواصفات المنتجات الأربعة (متغيرات: الحجم size، الذوق taste، الصورة merchandising، التغليف packaging) حول المركبة/ المحور الأول في جهة اليمين، ويقابله في جهة اليسار السعر price، فمركبة/المحور الأول يعرض جودة المنتجات مقارنة بالسعر، هذا يعني أنّ المنتجات التي تحمل المواصفات الأربعة السابقة، منتجات بمواصفات أو جودة عالية، وسعرها مرتفع، وعلى المؤسسة توزيع تلك المنتجات أو بيعها في مناطق أصحاب الدخل المرتفع. بينما المنتجات التي تتموضع في يسار المركبة/المحور الأول، فهي منتجات متوسطة أو قليلة الجودة، وسعرها منخفض.

أما المركبة/ المحور الثاني فيعرض لنا التوفر، فالمنتجات التي تكون أعلى هذا المحور (قريب من مواصفة التوفر avaibility) هي منتجات متوفرة في السوق ويمكن الحصول عليها بسهولة، والمنتجات التي تتموضع أسفله هي منتجات غير متوفرة في السوق ولا يمكن الحصول عليها بسهولة.


2. إسقاط ورسم المنتجات على المحاور/ المركبات الرئيسية

برنامج SPSS ينشئ لنا فقط رسماً للمتغيرات في فضاء المركبات/العوامل، لكننا نحتاج لرسم تموضع المنتجات وكيفية توزيعها في السوق على حسب مواصفات كل منتج وسعره، ولرسم المنتجات في فضاء المركبات/العوامل، نقوم برسم المنحنى البياني الخاص بالمنتجات، من خلال عمل الآتي: نختار من شريط الأدوات Graphs، ثم نختار Scatter/ Dot، ثم نضغط على Define، فتظهر نافذة تسمية محاور الإحداثيات Simple Scatterplot، نقوم فيها بما يلي:

1. ننقل العامل Fac1_1 إلى محور العينات (Y): قمنا بتغيير اسم المتغير إلى Principal Component _2
2. ننقل العامل Fac2_1 إلى محور السينات (X): قمنا بتغيير اسم المتغير إلى Principal Component _1
3. ننقل متغير المنتجات product إلى خانة (Label Cases by): تسمية الحالات بواسطة
4. نضغط Options، ونختار Display chart with case labels، ثم Continue
5. نضغط Ok. فنحصل على الرسم التالي:



نقوم بالضغط على هذا الرسم مرتين، فيتظلل، مع ظهور نافذة Chart Editor وعليها رسم إسقاطات الرسم السابق، وهنا نقوم بوضع المحور/ المركبة الأولى (الأفقية) والمحور/ المركبة الثانية (العمودية)، والضغط على أداة Show Data Labels، حتى تظهر أسماء المنتجات على الرسم، كما يوضحه الشكل التالي:



يظهر الرسم المنتجات الـ 10 في معلم مستوي أساسه المركبتين، على محور الفواصل المركبة/ العامل الأول، وعلى محور الترتيب المركبة/العامل الثاني، وبما أن المركبتان ممركتان معياريتان، فإن إحداثيات المنتجات في الرسم تقع في المجال $[-1, +1]$.

بما أن المركبة/ المحور الأول ترتبط بـ 5 متغيرات (السعر، الذوق، الحجم، التغليف والصورة)، فهي تشير إلى الجودة، وبما أن المركبة/ المحور الثاني يرتبط فقط بمتغير التوافر في السوق availability، كما توصلنا في مصفوفة المركبات/العوامل قبل وبعد التدوير، فإنه من خلال إسقاط ورسم المنتجات الـ 10 على معلم مستوى المركبتين، يمكننا أن نستنتج خصائص المنتجات وطريقة توزيعها الأنسب في السوق.

من الرسم، يمكننا ملاحظة أنّ المنتجات: 1، 2، 4، و5 تتموضع على يمين المركبة/ المحور الأول، مما يدل على أنها منتجات ذات جودة عالية، وسعرها مرتفع. بينما المنتجات 7، 8، 10 تتموضع يسار المركبة/ المحور الأول، مما يعني أنها منتجات أقل جودة، وأسعارها منخفضة. والمنتج رقم 6 هو المنتج الأكثر توفراً في السوق (لاحظ أنّه قريب من مكان وجود خاصية التوفر availability). والمنتج 9 غير متوفر في السوق، أما المنتج 3 فهو غير ممثل تمثيلاً جيد في التحليل، بمعنى أنه منتج غير مرغوب فيه.

الخطوة (06): اختبار التعددية الخطية

تساعدنا طريقة المركبات الرئيسية في التخلص من مشكلة التعددية الخطية بين المتغيرات أثناء استخدام تحليل الانحدار المتعدد، فلو اخترنا تحليل الانحدار بين السعر price ومواصفات المنتجات العشرة (الذوق taste، الحجم size، التوفر availability، التغليف packaging، الصورة merchandising).

حتى نتأكد من عدم وجود تعددية خطية (ارتباط عالي بين المتغيرات المستقلة)، والذي يؤثر وجوده في درجة دقة النتائج، فإننا نقوم باستخراج قيمة عامل تضخم التباين Variance Inflation Factor (VIF)، ويمكن إجراء هذا الاختبار من خلال اختيار القائمة الرئيسية Analyze، ثم القائمة Regression، ثم بعد ذلك الضغط على Linear، فيظهر صندوق الحوار Linear Regression، نقوم بنقل متغير السعر price إلى خانة Dependent، والمتغيرات الكمية المتبقية (الخمس) إلى خانة Independent، وفي القائمة Statistics نختار العناصر الموضحة في الشكل التالي:

Linear Regression: Statistics

Regression Coefficients

☒ Estimates

☒ Confidence intervals

Level(%): 95

☐ Covariance matrix

☒ Model fit

☐ R squared change

☐ Descriptives

☐ Part and partial correlations

☒ Collinearity diagnostics

Residuals

☐ Durbin-Watson

☐ Casewise diagnostics

☒ Outliers outside: 3 standard deviations

☒ All cases

Continue Cancel Help

أما في القائمة Save فنختار كل عناصر المجموعة Predicted Values فقط، وفي القائمة Options نختار فقط Include constant in equation، ثم نعود لصندوق الحوار Linear Regression ونضغط Ok، فتظهر عدة مخرجات أهمها:

جدول نموذج الإنحدار

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.987 ^a	.974	.942	.38534

a. Predictors: (Constant), merchandising, availability, size, packaging, taste

b. Dependent Variable: price

نلاحظ من الجدول أن هناك ارتباط قوي جدا بين السعر ومواصفات المنتج، بلغ معامل الارتباط 0.987، كما أن المواصفات الخمسة للمنتج تفسر 97.4% من تغير السعر ارتفاعا أو انخفاضاً، بمعنى أنه إذا كانت المواصفات جيدة فالسعر يكون مرتفع كثيراً والعكس صحيح.

جدول تحليل التباين الأحادي ANOVA

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	22.356	5	4.471	30.112	.003 ^b
	Residual	.594	4	.148		
	Total	22.950	9			

a. Dependent Variable: price

b. Predictors: (Constant), merchandising, availability, size, packaging, taste

يظهر من جدول تحليل التباين الأحادي ANOVA أن الاختبار دال إحصائياً، حيث أن مستوى الدلالة Sig=0.003، هو أقل من 0.05، وما يؤكد ذلك أن إحصائية فيشر المحسوبة F_{cal} تساوي 30.11، وهي أكبر من إحصائية فيشر الجدولية $F_{tab} = 6,39$ عند درجتَي حرية: $\nu_1 = 5$ و $\nu_2 = 4$ ، ومستوى معنوية $\alpha = 5\%$ ، وهو ما يؤكد وجود علاقة خطية بين السعر وباقي المتغيرات.

جدول اختبار التعددية الخطية (إزدواج الخطي) Collinearity test:

حتى نتأكد من عدم وجود ارتباط عالي بين المتغيرات المستقلة، والذي يؤثر وجوده في درجة دقة النتائج، فإننا نقوم باستخراج قيمة عامل تضخم التباين (Variance Inflation Factor (VIF)، فإذا كانت قيمته قريبة من 1، فذلك يشير إلى عدم وجود علاقة ارتباط خطية بين متغير التنبؤ (التبع) والمتغيرات المستقلة، وإذا كانت قيمته بين 1 و5، فذلك يشير إلى زيادة مستويات الخطية المتعددة، وإذا كانت قيمته بين 5 و10، فذلك يشير إلى أن الارتباط عالي وقد يكون ذلك مشكلة محتملة، أما إذا تجاوزت قيمته 10، فيمكن افتراض أن معاملات الانحدار الأصلية بين المتغيرات يتم تقديرها بشكل سيء بسبب التعدد الخطي الشديد.

ويمكن إجراء هذا عبر اختبار التعددية الخطية Collinearity، من خلال اختيار القائمة الرئيسية Analyze، ثم القائمة Regression، ثم بعد ذلك الضغط على Linear، وإدخال متغير product تحت المستطيل المعنون Dependent، وهذا لأنه لا يوجد لدينا متغير تابع، أي أننا نستخدم product كمتغير تابع وهمي، أم المتغيرات الخمسة الأخرى فننقلها تحت المستطيل المعنون Independents.

نضغط على المفتاح Statistics ليظهر صندوق الحوار Linear Regression: Statistics، نقوم بالتأشير داخل المربع الصغير مقابل اختبار Collinearity Diagnostics تحت Regression Coefficients. نضغط Continue، أما باقي المفاتيح: Plots؛ Save؛ Options فلا نؤشر على أي خانة منها، نضغط على Ok، فتظهر عدة جداول أهمها الجدول التالي:

Coefficients^a

Model	Collinearity Statistics	
	Tolerance	VIF
(Constant)		
price	.026	38.640
taste	.012	81.255
size	.044	22.598
avaibility	.146	6.865
packaging	.028	36.224
merchandising	.007	143.999

a. Dependent Variable: product

وفي مثالنا هذا أغلبية قيم معامل تضخم التباين عالية جداً، ما عدى القيمة المقابلة لصفة التوفر avaibility، التي تساوي 6.865، مما يدل على وجود تعددية خطية مرتفعة بين المتغيرات.

تحليل الإنحدار بين السعر والمركبات العوامل المستخلصة

نجري الآن تحليل الانحدار المتعدد بين السعر والعوامل المستخلصة بطريقة المكونات الأساسية بنفس الطريقة، فقط في مكان المتغيرات المستقلة (المواصفات) نختار العوامل المستخلصة، وهما العاملين (FAC1_1) و (FAC2_1). وذلك من خلال اختيار القائمة الرئيسية Analyze، ثم القائمة Regression، ثم بعد ذلك الضغط على Linear، وإدخال متغير price إلى المستطيل Dependent، وننقل المركبين/العاملين (FAC1_1) و (FAC2_1) إلى المستطيل Independents.

نضغط على المفتاح Statistics ليظهر صندوق الحوار Linear Regression: Statistics، نقوم بالتأشير داخل المربع الصغير مقابل Estimates و Model fit. نضغط Continue، وفي مفتاح Options نؤشر على Include constant in equation، أما باقي المفاتيح: Plots؛ Save؛ فلا نؤشر على أي خانة منها، نضغط على Ok، فتظهر عدة جداول أهمها الجداول التالية:

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.985 ^a	.969	.961	.31690

a. Predictors: (Constant), Principal Component_2, Principal Component_1

نلاحظ أن معاملي الارتباط 0.985، ومعامل التفسير (التحديد) 0.969 تقريبا نفسيهما، وهما مرتفعان ومتقاربان، مما يدل على أن الارتباط القوي بين المركبتين/العاملين المستخلصين والسعر، وارتفاع مساهمتهما في تفسير التباين في السعر.

ANOVA^a

Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regression	22.247	2	11.123	110.765	.000 ^b
Residual	.703	7	.100		
Total	22.950	9			

a. Dependent Variable: price

b. Predictors: (Constant), Principal Component_2, Principal Component_1

نلاحظ من الجدول أن اختبار علاقة الانحدار بين المركبتين/العاملين المستخلصين والسعر هو اختبار معنوي عند مستوى دلالة 0.0001، مما يدل على قوة نموذج الانحدار الخطي بين المركبتين والمتغير التابع السعر.

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
(Constant)	6.039	.100		60.262	.000
1 Principal Component_1	-1.569	.106	-.983	-14.856	.000
Principal Component_2	.096	.106	.060	.908	.394

a. Dependent Variable: price

نلاحظ من جدول معاملات الانحدار الخطي، أن المركبة/العامل الأول له علاقة خطية ذات دلالة مع السعر (Sig= 0.000 < 5%)، مما يدل على مواصفات المنتجات (الذوق، الحجم، التغليف والصورة) التي تدرج في المركبة الأولى لها تأثير في أسعار المنتجات، أما المركبة/العامل الأول فليس له علاقة ذات دلالة معنوية مع السعر (Sig= 0.394 > 5%)، مما يدل على أن متغير التوافر **avaibility** هو المتغير الوحيد الذي يدرج تحت المركبة/العامل، والذي ليس له تأثير في تحديد أسعار المنتجات.

التعددية الخطية بين المركبات المستخلصة والسعر

بنفس طريقة اختبار التعددية الخطية (الإزدواج الخطي أو الارتباط الذاتي) كما مر معنا، نقوم بتقييم عامل تضخم التباين كما في الجدول الموالي:

Coefficients^a

Model	Collinearity Statistics	
	Tolerance	VIF
1 Principal Component_1	1.000	1.000
Principal Component_2	1.000	1.000

a. Dependent Variable: price

نلاحظ من الجدول أن قيم معامل تضخم التباين VIF تساوي واحد، وهي أقل من 5، مما يعني عدم وجود تعددية خطية بين المتغيرات المستقلة (وهي هنا المركبتين/العاملين)، رغم أننا قد وجدنا سابقا تعددية خطية قوية بين المتغيرات المستقلة الستة)، وهو ما يعني أن اختزال المتغيرات عبر تحليل المركبات الرئيسية يسمح بالتخلص من مشكلة التعددية الخطية (الارتباطات المرتفعة بين المتغيرات المستقلة)، والتي تؤثر على نتائج الدراسة (نموذج الانحدار الخطي المتعدد).