

جامعة البعث - كلية العلوم
قسم الإحصاء الرياضي

مقرر

الإحصاء (4)

السنة الرابعة

الفصل الثاني للعام الدراسي 2013 - 2014

د. سلطان محمد الصلخدي

التحليل متعدد المتغيرات (Multivariate analysis)

دراسة متغير واحد : Matrices and Random vectors :

إذا كان لدينا عدة ظواهر :

	(1) سن الشخص	(2) سنة التعليم	(3) ذكر أو أنثى	...	(K) الوضع الاجتماعي مع الأخذ بعين الاعتبار تعلم الوالدين
No. 1	33	20	0	...	25
No. 2	25	19	1	...	22
⋮	⋮	⋮	⋮		⋮
⋮	⋮	⋮	⋮		⋮
⋮	⋮	⋮	⋮		⋮
No. n	35	22	1	...	50

وهذه الظواهر أو المتغيرات مرتبطة مع بعضها البعض , فيلزم لدراسة تحليل متعدد المتغيرات مبادئ الجبر الخطي Linear Algebra وسندرس في البداية المتجهات Vectors .

المتجهات Vectors:

تعريف : المتجه هو أية مجموعة من الأعداد الحقيقية وتكتب على الشكل التالي :

$$\underline{X} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_k \end{pmatrix}$$

إن للمتجه تفسير هندسي تربطه بالهندسة الإقليدية Geometrical Meaning of vectors

فمثلاً إذا أخذنا المتجه $\begin{pmatrix} 1 \\ 2 \\ 3 \end{pmatrix}$ نستطيع أن نمثله على الشكل التالي بترتيب على شكل صندوق (box) من هذه النقاط.



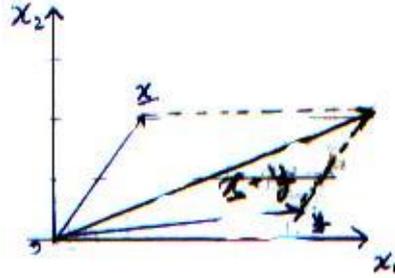
وهناك متجهات لها أكثر من ثلاث متغيرات .

العمليات على المتجهات:

1 - جمع متجهين: إذا كان لدينا متجهين x , y عندئذ يكون الجمع بينهما هو :

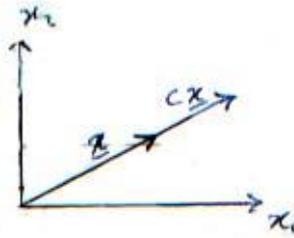
$$\underline{x} + \underline{y} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_k \end{pmatrix} + \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_k \end{pmatrix} = \begin{pmatrix} x_1 + y_1 \\ \vdots \\ x_k + y_k \end{pmatrix}$$

وللجمع معنى هندسي هو :



2 - ضرب متجه بمقدار سلمي: لضرب متجه بمقدار سلمي نضرب كل مركبة من مركباته بهذا المقدار السلمي أي:

$$c \underline{x} = c \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} c x_1 \\ c x_2 \\ \vdots \\ c x_n \end{pmatrix}$$



3 - طول متجه: إذا كان لدينا $\underline{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ فإن طول المتجه يعطى بالصيغة: $L(\underline{x}) = \sqrt{\sum_{i=1}^n x_i^2}$

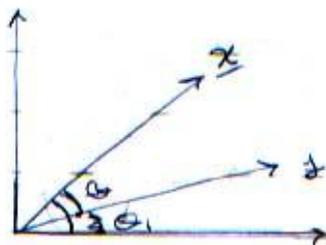
4 - ضرب متجهين: إذا كان لدينا متجهين $\underline{x}, \underline{y}$ بحيث إن :

$$\underline{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_k \end{pmatrix} \quad \text{و} \quad \underline{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_k \end{pmatrix}$$

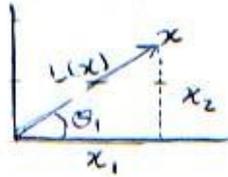
فإن جداء المتجهين يعطى بالصيغة الآتية : $\underline{x} \underline{y} = \sum x_i y_i = \underline{y} \cdot \underline{x}'$

إذا نستطيع أن نكتب طول أي متجه بالشكل: $L(\underline{x}) = \sqrt{\underline{x}' \underline{x}}$

5 - الزوية بين متجهين:



لحساب الزاوية بين متجهين نتبع الطريقة الآتية : $\cos \theta = \cos (\theta_1 - \theta_2) = \cos \theta_1 \cos \theta_2 + \sin \theta_1 \sin \theta_2$



$$x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

ولكن نجد من الشكل أن :

$$\sin \theta_1 = \frac{x_2}{L(x)} , \quad \cos \theta_2 = \frac{y_1}{L(y)}$$

$$\cos \theta = \frac{x_1}{L(x)} \cdot \frac{y_1}{L(y)} + \frac{x_2}{L(x)} \cdot \frac{y_2}{L(y)} = \frac{x_1 y_1 + x_2 y_2}{L(x) \cdot L(y)} = \frac{\underline{x}' \underline{y}}{\sqrt{\underline{x}' \underline{x}} \sqrt{\underline{y}' \underline{y}}}$$

وهو يسمى عامل بيرسون أو عامل الارتباط $\cos \theta = \frac{\underline{x}' \underline{y}}{L(\underline{x}) L(\underline{y})}$

مثال : احسب الزاوية بين المتجهين :

$$\underline{x} = \begin{pmatrix} 5 \\ 1 \\ 3 \end{pmatrix} , \quad \underline{y} = \begin{pmatrix} -1 \\ 3 \\ 1 \end{pmatrix}$$

$$\cos \theta = \frac{-5 + 3 + 3}{(25 + 1 + 4)^{1/2} (1 + 4 + 1)^{1/2}} = \frac{1}{\sqrt{35 \times 11}} = \frac{1}{\sqrt{385}}$$

تعريف :

If \underline{x} and \underline{y} two vectors , they are linearly independent provided that $c_1 \underline{x} + c_2 \underline{y} = 0$ then c_1 and c_2 are zeros .

نقول عن \underline{x} و \underline{y} إنهما مستقلين خطياً إذا كان معامل الارتباط يساوي الصفر .

مثال: هل هذا المتجهات الثلاثة مستقلة عن بعضها البعض:

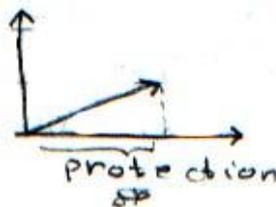
$$\underline{x}_1 = \begin{pmatrix} 1 \\ 2 \\ 1 \end{pmatrix} , \quad \underline{x}_2 = \begin{pmatrix} 1 \\ 0 \\ -1 \end{pmatrix} , \quad \underline{x}_3 = \begin{pmatrix} 1 \\ -2 \\ 1 \end{pmatrix}$$

الحل: لدينا $c_1 \underline{x}_1 + c_2 \underline{x}_2 + c_3 \underline{x}_3 = 0$ نعوض بشرط :

$$\left. \begin{array}{l} c_1 + c_2 + c_3 = 0 \\ 2c_1 - 2c_3 = 0 \\ c_1 - c_2 + c_3 = 0 \end{array} \right\} \Rightarrow c_1 = c_2 = c_3 = 0$$

إذا فالمتجهات مستقلة عن بعضها البعض .

Def : the protection (shade) of vector \underline{x} is $L(\underline{x}) \cos \theta = L(\underline{x}) \cdot \frac{|\underline{x}' \underline{y}|}{L(\underline{x}) L(\underline{y})} = \frac{|\underline{x}' \underline{y}|}{L(\underline{y})}$



ما أهمية الاستقلال الخطي: إذا كان لديك مجموعة من المتجهات المستقلة عندئذ يمكننا تحويلها إلى مجموعة من المتجهات المتعامدة المتكافئة فيما بينها .

let x_1, \dots, x_n be a set of linearly independent vector , then there is a set of perpendicular , vectors $u_1 \dots u_n$ such that

$$\begin{aligned} \underline{u}_1 &= \underline{x}_1 \\ \underline{u}_2 &= \underline{x}_2 - \frac{\underline{x}_2 \cdot \underline{u}_1}{L(\underline{u}_1)} \cdot \underline{u}_1 \\ &\vdots \\ \underline{u}_n &= \underline{x}_n - \frac{\underline{x}_n \cdot \underline{u}_1}{L(\underline{u}_1)} \underline{u}_1 - \dots - \frac{\underline{x}_n \cdot \underline{u}_{n-1}}{L(\underline{u}_{n-1})} \underline{u}_{n-1} \end{aligned}$$

مثال: ليكن لدينا المتجهين المستقلين

$$\underline{x}_1 = \begin{pmatrix} 4 \\ 0 \\ 0 \\ 2 \end{pmatrix}, \quad \underline{x}_2 = \begin{pmatrix} 3 \\ 1 \\ 0 \\ -1 \end{pmatrix}$$

فالتحويلات هي :

$$\begin{aligned} \underline{u}_1 &= \underline{x}_1 \\ L(\underline{u}_1) &= 20 \\ \underline{x}_2 \cdot \underline{u}_1 &= 10 \end{aligned}$$

$$\underline{u}_2 = \begin{pmatrix} 3 \\ 1 \\ 0 \\ -1 \end{pmatrix} - \frac{10}{20} \begin{pmatrix} 4 \\ 0 \\ 0 \\ 2 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 0 \\ -2 \end{pmatrix}$$

تعريف المتجه العشوائي: هو مجموعة من المتغيرات العشوائية التي يصعب الفصل بينها ، وهو تركيب من المتجهات وتسمى المصفوفات matrix

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \dots & \vdots \\ a_{k1} & a_{k2} & \dots & a_{kn} \end{bmatrix}$$

أو نعرّف المصفوفة كما يلي :

Def : A matrices is arrangement of a set vectors in rows or columns .

$$A = (\underline{a}_1, \underline{a}_2, \dots, \underline{a}_k) = \begin{pmatrix} \underline{a}_1 \\ \underline{a}_2 \\ \vdots \\ \underline{a}_k \end{pmatrix} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1P} \\ a_{21} & a_{22} & \dots & a_{2P} \\ \vdots & \vdots & \dots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nP} \end{bmatrix}_{(n \times P)} = \{a_{ij}\}_{(n \times P)}$$

وهي مكونة من أعداد حقيقية .

العمليات على المصفوفات (Operations of matrices):

1 - جمع المصفوفات (Addition):

لتكن لدينا المصفوفتين $A_{(n \times p)}$ and $B_{(n \times p)}$ المتشابهتان عندها يكون حاصل جمع المصفوفتين معرف بالشكل:

$$A \pm B = \begin{bmatrix} a_{11} \pm b_{11} & a_{12} \pm b_{12} & \cdots & a_{1p} \pm b_{1p} \\ \vdots & \vdots & \cdots & \vdots \\ a_{n1} \pm b_{n1} & a_{n2} \pm b_{n2} & \cdots & a_{np} \pm b_{np} \end{bmatrix}$$

2 - ضرب المصفوفات (Scalar Multiplication):

Let A and B be two matrices such that the number of columns in A its equal to the number of rows in B :

$$A_{(n \times p)} \cdot B_{(p \times r)} = \begin{bmatrix} a_{11} & \cdots & a_{1p} \\ \vdots & \cdots & \vdots \\ a_{n1} & \cdots & a_{np} \end{bmatrix} \cdot \begin{bmatrix} b_{11} & \cdots & b_{1r} \\ \vdots & \cdots & \vdots \\ b_{p1} & \cdots & b_{pr} \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^p a_{i1} b_{i1} & \cdots & \sum_{i=1}^p a_{i1} b_{ir} \\ \vdots & \cdots & \vdots \\ \sum_{i=1}^p a_{ni} b_{i1} & \cdots & \sum_{i=1}^p a_{ni} b_{ir} \end{bmatrix}$$

$$\Rightarrow A \cdot B = \left\{ \sum_{\ell=1}^p a_{i\ell} b_{\ell j} \right\}_{(n \times r)}$$

خواص ضرب المصفوفات:

- 1) $A \cdot B \neq B \cdot A$ قانون التبديل
- 2) $A (B + C) = A \cdot B + A \cdot C$ قانون التوزيع

منقول مصفوفة (transpose of A): إذا بدلنا أسطر مصفوفة بأعمدتها وأعمدتها بأسطرها , فإننا ندعو المصفوفة

الجديدة بمنقول المصفوفة الأصلية ونكتب : $A' = \text{transpose of } A$

مقلوب مصفوفة (Inverse Matrix):

Let A be as square matrix , if there is an ather matrix B such that :

$$A B = B \cdot A = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 0 & 0 & \vdots & 1 \end{bmatrix} = I$$

We say that B is the inverse of A . . A^{-1} ونرمز لها بالرمز

خواص المقلوب:

- 1) $(A^{-1})' = (A')^{-1}$
- 2) $(A \cdot B)^{-1} = B^{-1} \cdot A^{-1}$

حساب مقلوب مصفوفة : إن مقلوب مصفوفة يعطى بالعلاقة:

$$A^{-1} = \frac{1}{|A|} \begin{bmatrix} |A_{11}| & -|A_{12}| & \cdots \\ \vdots & \vdots & \cdots \\ \vdots & \vdots & \cdots \end{bmatrix}$$

The determinant of a square matrix A is : $|A| = \sum_{i=1}^P a_{1i} (-1)^{i+1} |A_{1i}|$

$$|A| = a_{11} a_{22} + a_{12} (-1) a_{21} = a_{11} a_{22} - a_{12} a_{21} : \text{فإن } A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} : \text{إذا كان}$$

خواص المحددات :

- 1) $|AB| = |A| \cdot |B|$
- 2) $|CA| = C^P |A|$

طريقة حديثة لحساب المحددات :

Eigen values and Eigen vectors :

Let A be a square matrix ($P \times P$), a number λ is called an eigen value of A if $A\underline{X} = \lambda \underline{X}$ any vector \underline{X} . and the vector \underline{X} is called eigen vector .

السؤال: كيف نجد القيم الذاتية والمتجهات الذاتية لمصفوفة: القيم الذاتية للمصفوفة A هي حلول المعادلة:

$$|A - \lambda I| = 0 \Rightarrow \begin{vmatrix} a_{11} - \lambda & a_{12} & \cdots & a_{1P} \\ a_{21} & a_{22} - \lambda & \cdots & a_{2P} \\ \vdots & \ddots & \cdots & \vdots \\ \vdots & \vdots & \cdots & a_{PP} - \lambda \end{vmatrix} = 0$$

مثال : أوجد القيم الذاتية والمتجهات الذاتية للمصفوفة الآتية:

$$A = \begin{pmatrix} 1 & 0 \\ 1 & 3 \end{pmatrix} \Rightarrow A - \lambda I = \begin{pmatrix} 1 & 0 \\ 1 & 3 \end{pmatrix} - \begin{pmatrix} \lambda & 0 \\ 0 & \lambda \end{pmatrix} = \begin{pmatrix} 1-\lambda & 0 \\ 1 & 3-\lambda \end{pmatrix}$$

$$\Rightarrow |A - \lambda I| = (1 - \lambda)(3 - \lambda) - 0 = 0 \Rightarrow \lambda_1 = 1, \lambda_2 = 3$$

$$\lambda_1 \cdot \lambda_2 = 1 \times 3 = 3 = |A|$$

ولإيجاد المتجهات الذاتية للمصفوفة نطبق المعادلة : $A\underline{X} = \lambda \underline{X}$:

$$\text{من أجل } \lambda_1 = 1 \quad \begin{pmatrix} 1 & 0 \\ 1 & 3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 1 \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \Rightarrow \begin{pmatrix} x_1 \\ x_1 + 3x_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$$x_1 = x_1 \Rightarrow \text{أي } x_1 \text{ اختيارية}$$

$$x_1 + 3x_2 = x_2 \Rightarrow x_1 = -2x_2 \Rightarrow x_2 = -\frac{x_1}{2}$$

$$\underline{X}_1 = \begin{pmatrix} a \\ -\frac{a}{2} \end{pmatrix} \leftarrow \text{بأخذ } x_1 = a \text{ أي عنصر } \leftarrow \text{من أجل } \lambda_1 = 1$$

من أجل : $\lambda_2 = 3$

$$\Rightarrow \begin{pmatrix} 1 & 0 \\ 1 & 3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 3 \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$$\Rightarrow \begin{pmatrix} x_1 \\ x_1 + 3x_2 \end{pmatrix} = \begin{pmatrix} 3x_1 \\ 3x_2 \end{pmatrix}$$

لا يتحقق إلا إذا كان $x_1 = 0$ $\Rightarrow x_1 = 3x_1$
 $\Rightarrow x_1 + 3x_2 = 3x_2 \Rightarrow x_2 = x_2$ أي اختيارية x_2
 بأخذ $a = 1$ نجد أن المتجهتان هما :

$$\begin{pmatrix} 1 \\ -\frac{1}{2} \end{pmatrix} \text{ و } \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

والمتجهات المميزة هي : $e_i = \frac{x_i}{\sqrt{x_i x_i}}$ أي أن المتجهين المميزين لهذه المصفوفة ، هما :

$$e_1 = \begin{pmatrix} \frac{1}{\sqrt{5/4}} \\ \frac{1/2}{\sqrt{5/4}} \end{pmatrix}, \quad e_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

نظرية: يمكن أن نأخذ أي مصفوفة ونمثلها جبرياً بحيث تربطها علاقة خطية مع الجذور المميزة والمتجهات المميزة .

نظرية التمثيل: (Representation theorem)

أي مصفوفة مربعة لها تغير يربط جذورها المميزة .

Any square matrix a with eigen values $\lambda_1, \dots, \lambda_p$ and eigen vectors e_1, \dots, e_p

can be represent A as : $A = \lambda_1 e_1 \cdot e_1' + \lambda_2 \cdot e_2 e_2' + \dots + \lambda_p e_p e_p'$ (*)

ولنطبق نفس المثال في النظرية :

$$A = 1 \begin{pmatrix} 1 \\ \frac{1}{\sqrt{5/4}} \\ -\frac{1/2}{\sqrt{5/4}} \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{5/4}} & -\frac{1/2}{\sqrt{5/4}} \end{pmatrix} + 3 \begin{pmatrix} 0 \\ 1 \end{pmatrix} \begin{pmatrix} 0 & 1 \end{pmatrix}$$

$$\begin{bmatrix} 13 & -4 & 2 \\ -4 & 13 & -2 \\ 2 & -2 & 10 \end{bmatrix}$$

مثال : أوجد القيم لذاتية والمتجهات الذاتية المميزة للمصفوفة:

$$\lambda_1 = 9, \quad \lambda_2 = 9, \quad \lambda_3 = 18$$

$$e_1 = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \\ 0 \end{pmatrix}, \quad e_2 = \begin{pmatrix} \frac{1}{\sqrt{18}} \\ -\frac{1}{\sqrt{18}} \\ 4 \end{pmatrix}, \quad e_3 = \begin{pmatrix} \frac{2}{3} \\ -\frac{2}{3} \\ \frac{1}{3} \end{pmatrix}$$

$$\Lambda = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{pmatrix} : \text{حيث , } E = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_p \end{pmatrix}, \quad A = E \Lambda E'$$

مصفوفة الجذر التربيعي (Square Root Matrix):

لتكن لدينا مصفوفة A متناظرة و محدودة موجبة

Let A be matrix which is Symmetric and Positive definite

عندها نضع : $A = P \Lambda P'$ حيث P هي مصفوفة متعامدة (P is orthogonal)

$$\Rightarrow A^{-1} = P' \begin{pmatrix} 1 \\ \lambda_i \end{pmatrix} P$$

من هذا التعريف يمكن أن نعرف مصفوفة $A^{-1} = \sum \frac{1}{\lambda_i} e_i e_i'$ ← $A = \sum \lambda_i e_i e_i'$

تعريف : مصفوفة الجذر التربيعي لـ A هي $A^{1/2} = \sum \sqrt{\lambda_i} e_i e_i'$

Def : The square Root matrix of A is $A^{1/2} = \sum \sqrt{\lambda_i} e_i e_i'$

إن مصفوفة الجذر التربيعي تحقق الخواص الآتية :

$$1) \quad A^{1/2} \cdot A^{1/2} = A$$

$$2) \quad \left(A^{1/2} \right)^{-1} = \left(A^{-1} \right)^{1/2}$$

$$3) \quad \left(A^{1/2} \right) \left(A^{-1/2} \right) = I$$

المصفوفات غير المتكافئة : Matrix inequivalent , cauchy وهي هامة في الإحصاء

سنستخدم متراجحة كوشي لاحقاً وهي:

$$| \text{Cov}(X, Y) | \leq \sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}$$

$$(\text{Cov}(x, Y))^2 \leq \text{Var}(x) \cdot \text{Var}(Y) \quad \text{أو} \quad \rho^2 \leq 1$$

ليكن $a_{(P \times 1)}$, $b_{(P \times 1)}$ أي متجهين ولتكن $C_{(P \times P)}$ مصفوفة مربعة من المرتبة $(P \times P)$ فإن :

$$1 - (a'b)^2 \leq (a'a)(b'b)$$

وبصورة عامة:

$$2 - (a'b)^2 \leq (a'Ca)(b'C^{-1}b)$$

وتكون المساواة محققة إذا وفقط إذا $a = mC^{-1}b$ أو $b = mCa$ من أجل ثابت m .

الإثبات :

1 - نلاحظ أن المتراجحة محققة من أجل $a = 0$ أو $b = 0$.

2 - ليكن x أي عدد نعرف المتجه $(a - xb)$ عندها :

$$(a - xb)'(a - xb) = a'a - 2xa'b + x^2 b'b = \psi(x)$$

$$\psi'(x) = -2a'b + 2xb'b = 0 \Rightarrow x = \frac{a'b}{b'b}$$

إن أصغر قيمة لـ ψ تكون :

$$a'a - \frac{(a'b)^2}{b'b} > 0$$

$$(a'b)^2 < (a'a)(b'b)$$

وبالتالي :

3 - لنفرض أن مصفوفة الجذر التربيعي $C^{\frac{1}{2}} = \sum_1^P \sqrt{\lambda_i} e_i e_i'$ حيث e_i المتجهات الذاتية و λ_i القيم الذاتية

$$C^{\frac{1}{2}} = \sum_1^P \frac{1}{\sqrt{\lambda_i}} e_i e_i' \quad \text{عندها يكون :}$$

$$a'b = a'Ib = a'C^{\frac{1}{2}} C^{-\frac{1}{2}} b = \left(C^{\frac{1}{2}} a \right)' \left(C^{-\frac{1}{2}} b \right) \quad \text{ينتج من ذلك}$$

$$\cdot \left(C^{-\frac{1}{2}} b \right) \text{ و } \left(C^{\frac{1}{2}} a \right) \quad \text{وبالتالي فإن (*) تكون محققة من أجل المتجهين}$$

إذا كان لدينا متغير عشوائي X فهو يعرف عن طريق دالتين هما :

$$1) \quad F(x) = P(X \leq x)$$

$$2) \quad \text{If } X \text{ is discrete} \Rightarrow f(x) = P(X = x)$$

$$3) \quad \text{If } X \text{ is continuous} \Rightarrow f(x) = \frac{d}{dx} F(x) = \lim_{\Delta \rightarrow 0} \frac{F(x+\Delta x) - F(x)}{\Delta}$$

والمشكلة تظهر عندما يكون المتغير المدروس منقطع في قسم ومستمر في قسم آخر وبين المنقطع والمستمر في قسم

ثالث عندئذ ما الحل ؟ ، لذلك سندرس النظرية الآتية (نظرية كرامير) **Cramer's theorem** :

إذا أخذنا دالة توزيع لأي متغير عشوائي هي :

$$F(x) = C_1 F_a(x) + C_2 F_s(x) + C_3 F_{as}(x)$$

وبين بين منقطع مستمر

وبالتالي يمكن أن تأخذ الثوابت $c_1 = 0, c_2 = 0, c_3 = 0$ أو إثنان أو واحدة معدومة حسب تابع التوزيع الذي لدينا .

تحويل المتغيرات :

إذا كان لدينا متغير X له دالة توزيع F ودالة كثافة f ولدينا $Y = g(X)$ ونريد دالة توزيع أو الكثافة فإننا نوجد ذلك من

أجل التحويلات التفاضلية أو التكاملية . أي :

$$G(y) = P(y \leq y) = P(g(X) \leq y) \\ = P(X \leq g^{-1}(y)) = F(g^{-1}(y))$$

مثلاً تحويل التربيع لـ $Y = X^2$:

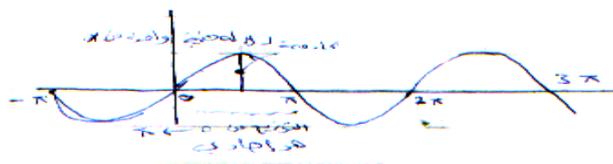
$$G(y) = P(Y \leq y) = P(X^2 \leq y) = P(-\sqrt{y} \leq X \leq \sqrt{y}) \\ = F(\sqrt{y}) - F(-\sqrt{y})$$

والتوزيعات غير التقابلية (الأحادية) الهندسية مثلاً $g = \sin X$ من $[0, 2\pi]$ تتكرر ولو أخذنا موجة واحدة لتصبح

دالة أحادية في $[0, 2\pi]$ ولن نهتم بمثل هذه التوزيعات .

إنه ليس أحادياً لأن هناك قيمتين لـ x . ونعني بالدالة الأحادية ، إذا كان الخط الثاني لها له موجة واحدة ويقابل كل

قيمة لـ y قيمة واحدة x ومثال ذلك :



أما في المجال $[0, 3\pi]$ نجد أنه ليس أحادياً لأن لكل y قيمتين لـ x .

المتجهات العشوائية والمصفوفات العشوائية :

وهي وضع مجموعة من المتغيرات العشوائية في متجه أو مصفوفة.

تعريف : لتكن $\{X_{ij}\}$ متجهات عشوائية عندئذ تسمى المصفوفة التالية بالمصفوفة العشوائية:

$$\underline{X} = \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1n} \\ X_{21} & X_{22} & \cdots & X_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ X_{p1} & X_{p2} & \cdots & X_{pn} \end{bmatrix} = \begin{pmatrix} \underline{X}_1 \\ \underline{X}_2 \\ \vdots \\ \underline{X}_p \end{pmatrix} = (\underline{X}_1, \underline{X}_2, \dots, \underline{X}_p)'$$

ويكون حساب العزوم على الشكل :

$$E \underline{X} = \begin{bmatrix} E X_{11} & E X_{12} & \cdots & E X_{1n} \\ E X_{21} & E X_{22} & \cdots & E X_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ E X_{p1} & E X_{p2} & \cdots & E X_{pn} \end{bmatrix}$$

أي أنه لحساب توقع مصفوفة متغيرات عشوائية يجب حساب توقع كل عنصر من عناصر هذه المصفوفة .

خواص التوقع الرياضي للمتجهات أو للمصفوفات العشوائية:

إذا كان لدينا مصفوفتين عشوائيتين \underline{X} و \underline{Y} وكانت A و B مصفوفتي ثوابت , فإنه يكون :

$$1) \quad E(\underline{X} + \underline{Y}) = E \underline{X} + E \underline{Y}$$

$$2) \quad E(A \underline{X} B) = A(E \underline{X})B$$

سنقوم بالدراسة التفصيلية على المتجهات العشوائية:

$$F(\underline{x}) = P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_p \leq x_p) \quad \underline{X} = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{pmatrix} \quad \text{ليكن}$$

$$F(\underline{x}) = \prod_{i=1}^p P(X_i \leq x_i) = \prod_{i=1}^p F_i(x_i) \quad \text{فإذا كانت } X_1, X_2, \dots, X_p \text{ متغيرات عشوائية مستقلة عندئذ :}$$

لن نقوم بدراسة الحالة التي يكون من أجلها المتغيرات العشوائية X_1, X_2, \dots, X_p بعضها منقطع وبعضها مستمر، ولكن سندرسها عندما تكون جميعها منقطعة أو جميعها مستمرة .

$$(1) \quad \text{إذا كانت } \underline{X} \text{ منقطع فإن : } f(\underline{x}) = P(X_1 = x_1, \dots, X_p = x_p)$$

$$(2) \quad \text{إذا كانت } \underline{X} \text{ مستمر فإن : } f(\underline{x}) = \frac{\partial^p}{\partial x_1, \dots, \partial x_p} F(\underline{x})$$

$$E \underline{X} = \begin{pmatrix} E X_1 \\ \vdots \\ E X_p \end{pmatrix} = \underline{\mu} \quad \text{تعريف : العزم الأول لـ } \underline{X} \text{ حول المتجه الصفري هو } \underline{\mu}$$

التباين لمتغير واحد : $\text{Var}(X) = E(X - \mu)^2 = \sigma^2$ ويعطى التباين للمتجه \underline{X} بالشكل :

$$\begin{aligned} \text{Cov}(\underline{X}) &= E(\underline{X} - \underline{\mu})(\underline{X} - \underline{\mu})' = E \begin{pmatrix} X_1 - \mu_1 \\ X_2 - \mu_2 \\ \vdots \\ X_P - \mu_P \end{pmatrix} (X_1 - \mu_1 \quad X_2 - \mu_2 \quad \dots \quad X_P - \mu_P)' \\ &= \begin{bmatrix} E(X_1 - \mu_1)^2 & E(X_1 - \mu_1)(X_2 - \mu_2) & \dots & E(X_1 - \mu_1)(X_P - \mu_P) \\ E(X_2 - \mu_2)(X_1 - \mu_1) & E(X_2 - \mu_2)^2 & \dots & E(X_2 - \mu_2)(X_P - \mu_P) \\ \vdots & \vdots & \dots & \vdots \\ E(X_P - \mu_P)(X_1 - \mu_1) & \dots & \dots & E(X_P - \mu_P)^2 \end{bmatrix} = \\ &= \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1P} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2P} \\ \vdots & \vdots & \dots & \vdots \\ \sigma_{P1} & \sigma_{P2} & \dots & \sigma_{PP} \end{bmatrix} = \Sigma \end{aligned}$$

تسمى المصفوفة Σ بمصفوفة التباينات والتغايرات .

مثال: ليكن $\begin{pmatrix} X_1 \\ X_2 \end{pmatrix}$ متجه عشوائي منقطع قانون توزيعه الاحتمالي معرف بالجدول الآتي:

$X_1 \backslash X_2$	- 1	0	1	marginal X_2
0	0. 24	0. 16	0. 40	0. 80
1	0,06	0.14	0.00	0.20
marginal X_1	0.30	0.30	0.40	

إن مصفوفة التباينات والتغايرات هي المصفوفة: $\Sigma = \begin{pmatrix} 0.69 & -0.08 \\ -0.08 & 0.16 \end{pmatrix}$

مصفوفة الارتباط **Correlation Matrix**: هي المصفوفة ρ التي تحقق $\rho = V^{-\frac{1}{2}} \Sigma V^{-\frac{1}{2}}$ أو $\Sigma = V^{\frac{1}{2}} \rho V^{\frac{1}{2}}$ حيث:

$$V^{\frac{1}{2}} = \begin{bmatrix} \sqrt{\sigma_{11}} & 0 & \dots & 0 \\ 0 & \sqrt{\sigma_{22}} & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & \dots & \dots & \sqrt{\sigma_{PP}} \end{bmatrix} \Rightarrow$$

$$\rho = \begin{bmatrix} 1 & \frac{\sigma_{12}}{\sqrt{\sigma_{11}\sigma_{22}}} & \dots & \frac{\sigma_{1P}}{\sqrt{\sigma_{11}\sigma_{PP}}} \\ \vdots & \ddots & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\sigma_{PP}}{\sqrt{\sigma_{PP}\sigma_{11}}} & \dots & \dots & 1 \end{bmatrix} = \begin{bmatrix} 1 & \rho_{12} & \dots & \rho_{1P} \\ \rho_{12} & 1 & \dots & \rho_{2P} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{1P} & \rho_{2P} & \dots & 1 \end{bmatrix}$$

$$\rho = \begin{bmatrix} 1 & \frac{-0.08}{\sqrt{0.69 \times 0.14}} \\ \frac{-0.08}{\sqrt{0.14 \times 0.69}} & 1 \end{bmatrix} \quad \text{في المثال السابق نعطي: } V^{\frac{1}{2}} = \begin{bmatrix} \sqrt{0.69} & 0 \\ 0 & \sqrt{0.16} \end{bmatrix} \quad \text{وبالتالي فإن:}$$

نماذج عشوائية : لتكن $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_n$ عينة عشوائية حجمها n مأخوذة من توزيع مشترك متجه متوسطاته $\underline{\mu}$ ومصفوفة تبايناته وتغايراته Σ ، فإن \bar{X} مقدر غير منحاز لـ $\underline{\mu}$ ومصفوفة تبايناته وتغايراته $\frac{1}{n} \Sigma$.

$$E \bar{X} = \underline{\mu} \quad \text{أي أن:}$$

وأن مصفوفة تبايناته وتغايراته \bar{X} هي مصفوفة تباينات وتغايرات المجتمع مقسومة على n .

$$Cov(\bar{X}) = \frac{1}{n} \Sigma \quad \text{أي أن:}$$

أما بالنسبة لمصفوفة تباينات وتغايرات العينة S_n فإن: $E(S_n) = \left(\frac{n-1}{n}\right) \Sigma = \Sigma - \frac{1}{n} \Sigma$

$$E\left(\frac{n}{n-1} S_n\right) = \Sigma \quad \text{أي أن}$$

وبالتالي فإن $\frac{n}{n-1} S_n$ مقدر غير منحاز بالنسبة للمصفوفة Σ ، بينما S_n مقدر منحاز للمصفوفة Σ ومقدار التحيز

$$E(S_n) - \Sigma = -\frac{1}{n} \Sigma \quad \text{هو:}$$

البرهان:

$$\begin{aligned} E(\bar{X}) &= E\left(\frac{1}{n} \underline{X}_1 + \frac{1}{n} \underline{X}_2 + \dots + \frac{1}{n} \underline{X}_n\right) \\ &= E\left(\frac{1}{n} \underline{X}_1\right) + E\left(\frac{1}{n} \underline{X}_2\right) + \dots + E\left(\frac{1}{n} \underline{X}_n\right) \\ &= \frac{1}{n} E(\underline{X}_1) + \frac{1}{n} E(\underline{X}_2) + \dots + \frac{1}{n} E(\underline{X}_n) \\ &= \frac{1}{n} \underline{\mu} + \frac{1}{n} \underline{\mu} + \dots + \frac{1}{n} \underline{\mu} = \underline{\mu} \end{aligned}$$

لايجاد مصفوفة تباينات وتغايرات \bar{X}

$$Cov(\bar{X}) = E(\bar{X} - \underline{\mu})(\bar{X} - \underline{\mu})'$$

وبالاعتماد على العلاقة:

$$\begin{aligned} (\bar{X} - \underline{\mu})(\bar{X} - \underline{\mu})' &= \left(\frac{1}{n} \sum_{i=1}^n (\underline{X}_i - \underline{\mu})\right) \left(\frac{1}{n} \sum_{j=1}^n (\underline{X}_j - \underline{\mu})\right)' \\ &= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n (\underline{X}_i - \underline{\mu})(\underline{X}_j - \underline{\mu})' \end{aligned}$$

علماً أن:

$$\bar{X} - \underline{\mu} = \frac{1}{n} \sum_{i=1}^n \underline{X}_i - \underline{\mu} = \frac{1}{n} \sum_{i=1}^n \underline{X}_i - \frac{1}{n} \sum_{i=1}^n \underline{\mu} = \frac{1}{n} \sum_{i=1}^n (\underline{X}_i - \underline{\mu})$$

نجد أن:

$$Cov(\bar{X}) = E(\bar{X} - \underline{\mu})(\bar{X} - \underline{\mu})' = \frac{1}{n^2} \left(\sum_{i=1}^n \sum_{j=1}^n E(\underline{X}_i - \underline{\mu})(\underline{X}_j - \underline{\mu})' \right)$$

ومن أجل $i \neq j$ نجد أن: $E(\underline{X}_i - \underline{\mu})(\underline{X}_j - \underline{\mu})' = 0$

وذلك لأن التباين بين عنصرين مختلفين من عناصر العينة المستقلة يساوي الصفر. وبالتالي نجد:

$$\text{Cov}(\bar{X}) = \frac{1}{n^2} \left(\sum_{i=1}^n E(\underline{X}_i - \underline{\mu})(\underline{X}_i - \underline{\mu})' \right)$$

وبما أن المصفوفة $\Sigma = E(\underline{X}_i - \underline{\mu})(\underline{X}_i - \underline{\mu})'$ هي مصفوفة تباينات وتغايرات المجتمع من أجل المتجه \underline{X}_i فإن:

$$\begin{aligned} \text{Cov}(\bar{X}) &= \frac{1}{n^2} \left(\sum_{i=1}^n E(\underline{X}_i - \underline{\mu})(\underline{X}_i - \underline{\mu})' \right) = \frac{1}{n^2} (\Sigma + \Sigma + \dots + \Sigma) \\ &= \frac{1}{n^2} (n \Sigma) = \left(\frac{1}{n} \right) \Sigma \end{aligned}$$

لنوجد الآن قيمة التوقع الرياضي لمصفوفة تباينات وتغايرات العينة S_n

$$\sum_{i=1}^n (\underline{X}_i - \bar{X})(\underline{X}_i - \bar{X})' = \sum_{i=1}^n (\underline{X}_i - \bar{X}) \underline{X}_i' + \sum_{i=1}^n (\underline{X}_i - \bar{X})(-\bar{X}') = \sum_{i=1}^n \underline{X}_i \underline{X}_i' - n \bar{X} \bar{X}'$$

$$\sum_{i=1}^n (\underline{X}_i - \bar{X}) = 0, \quad \sum_{i=1}^n \underline{X}_i' = n \bar{X}' \quad \text{وذلك لأن:}$$

وبأخذ التوقع الرياضي للطرفين نجد:

$$\begin{aligned} E \left[\sum_{i=1}^n (\underline{X}_i - \bar{X})(\underline{X}_i - \bar{X})' \right] &= \sum_{i=1}^n E(\underline{X}_i \underline{X}_i') - n E(\bar{X} \bar{X}') \\ &= \sum_{i=1}^n (\Sigma + \underline{\mu} \underline{\mu}') - n \left(\frac{1}{n} \Sigma + \underline{\mu} \underline{\mu}' \right) \\ &= n \Sigma + n \underline{\mu} \underline{\mu}' - \Sigma - n \underline{\mu} \underline{\mu}' \\ &= (n-1) \Sigma \end{aligned}$$

وبملاحظة أن مصفوفة تباينات وتغايرات العينة تعطى بالشكل:

$$S_n = \frac{1}{n} \sum_{i=1}^n (\underline{X}_i - \bar{X})(\underline{X}_i - \bar{X})' = \frac{1}{n} \sum_{i=1}^n \underline{X}_i \underline{X}_i' - \bar{X} \bar{X}'$$

$$E(S_n) = \left(\frac{n-1}{n} \right) \Sigma \quad \text{فإن التوقع الرياضي لهذه المصفوفة يصبح بالشكل:}$$

ويضرب الطرفين بالمقدار $\left(\frac{n}{n-1} \right)$ فإننا نحصل على مقدر غير منحاز بالنسبة لمصفوفة التباين ونكتب:

$$S = \left(\frac{n}{n-1} \right) S_n = \frac{1}{n-1} \sum_{i=1}^n (\underline{X}_i - \bar{X})(\underline{X}_i - \bar{X})'$$

تعريف (1): التباين الكلي هو قيمة محدد مصفوفة التباين S .

تعريف (2): التباين الكلي هو حاصل مجموع التباينات فقط، في S أي $\det(S) = \sum_{i=1}^p S_{ii}$

نتائج:

- 1- إذا كانت $n \leq P$ فإن $|S| = 0$
- 2- إذا كانت $C' \underline{X}_i = k$ فإن $|S| = 0$
- 3- إذا كان $\text{Var}(C' \underline{X}_i) > 0$ فإن $|S| > 0$ وذلك $\forall C \neq 0, P < n$

التوزيع الطبيعي متعدد المتغيرات

تعريف التوزيع الطبيعي متعدد المتغيرات:

$$f(x) = \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma} \right)^2}$$

لتكن لدينا دالة الكثافة لتوزيع طبيعي:

$$(x-\mu) \frac{1}{\sigma^2} (x-\mu)$$

يمكننا كتابة الأس بالشكل :

وبذلك نستطيع أن نكتب سياقاً على ذلك دالة الكثافة للمتجه $(\underline{X}_1, \underline{X}_1, \dots, \underline{X}_p)$ بالشكل:

$$f(x_1, x_2, \dots, x_p) = \left(\frac{1}{\sqrt{2\pi}} \right)^p \frac{1}{|\Sigma|^{1/2}} \exp \left\{ -\frac{1}{2} (\underline{x} - \underline{\mu})' \Sigma^{-1} (\underline{x} - \underline{\mu}) \right\}$$

ونقول أن توزيع المتجه $(\underline{X}_1, \underline{X}_1, \dots, \underline{X}_p)$ هو توزيع طبيعي متعدد متوسطه $\underline{\mu}$ ومصفوفة تبايناته وتغايراته Σ .

حالة خاصة: التوزيع الطبيعي الثنائي:

$$\underline{X} = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}, \quad \underline{\mu} = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$$

ليكن لدينا:

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{pmatrix} = \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix}$$

$$Q(x_1, x_2) = \begin{pmatrix} x_1 - \mu_1 & x_2 - \mu_2 \end{pmatrix} \frac{1}{\sigma_1^2 \sigma_2^2 (1 - \rho^2)} \begin{pmatrix} \sigma_2^2 & -\rho \sigma_1 \sigma_2 \\ -\rho \sigma_1 \sigma_2 & \sigma_1^2 \end{pmatrix} \begin{pmatrix} x_1 - \mu_1 \\ x_2 - \mu_2 \end{pmatrix}$$

$$= \left(\frac{1}{1 - \rho^2} \right) \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right\}$$

$$f(x_1, x_2) = \frac{1}{2\pi \sigma_1 \sigma_2 \sqrt{1 - \rho^2}} \exp \left(-\frac{1}{2(1 - \rho^2)} \right) \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right\}$$

يمكن كتابة القوس عن طريق إتمام مربعات على شكل مجموع حدين :

$$\begin{aligned} Q(x_1, x_2) &= \left\{ \frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right\} \\ &= \frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) + \rho^2 \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - \rho^2 \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 \\ &= \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 + \left(\frac{x_2 - \mu_2}{\sigma_2} - \rho \frac{x_1 - \mu_1}{\sigma_1} \right)^2 - \rho^2 \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 \\ &= (1 - \rho^2) \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 + \left[\frac{x_2 - \mu_2}{\sigma_2} - \rho \frac{x_1 - \mu_1}{\sigma_1} \right]^2 \end{aligned}$$

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)}\right) \left\{ (1-\rho^2)\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 + \left[\frac{x_2-\mu_2}{\sigma_2} - \rho\frac{x_1-\mu_1}{\sigma_1}\right]^2 \right\}$$

$$= \underbrace{\frac{1}{\sqrt{2\pi}\sigma_1} \exp\left\{-\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2\right\}}_{N(\mu_1, \sigma_1^2)} \underbrace{\frac{1}{\sqrt{2\pi}\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\frac{1}{2}\frac{1}{\sigma_2^2(1-\rho^2)}\left[x_2-\mu_2-\rho\frac{\sigma_2}{\sigma_1}(x_1-\mu_1)\right]^2\right\}}_{N\left(\mu_2+\rho\frac{\sigma_2}{\sigma_1}(x_1-\mu_1), \sigma_2^2(1-\rho^2)\right)}$$

$$= N(\mu, \sigma_1^2) \cdot N\left(\mu_2 + \rho\frac{\sigma_2}{\sigma_1}(x_1 - \mu_1), \sigma_2^2(1-\rho^2)\right)$$

أي نستطيع أن نكتب : $E(X_2|X_1) = \mu_2 + \rho\frac{\sigma_2}{\sigma_1}(X_1 - \mu_1) = a + bX_1$

أي توقع المتغير الثاني بشرط الأول هو عبارة عن علاقة خطية في الأول .

نتيجة: ليكن Y_1 و Y_2 مجموعتين من المتغيرات الطبيعية: $X_1 = a + bY_1 + cY_2$, $X_2 = d + eY_1 + fY_2$

فإن $\begin{pmatrix} X_1 \\ X_2 \end{pmatrix}$ هي BVN متغيرات طبيعية ثنائية .

بناء المتغيرات الطبيعية المتعددة :

$$\underline{X} = A \begin{pmatrix} 1 \\ \underline{Y} \end{pmatrix} \text{ وليكن } N(0, 1) \text{ متجه } \underline{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_p \end{pmatrix} \text{ ليكن}$$

عندئذ يتوزع \underline{X} وفق $MUN(\underline{\mu}, \underline{\Sigma})$ حيث $\underline{\mu} = \underline{a}$ و $\underline{\Sigma} = A'A$ إذا المتغير الطبيعي المتعدد المتغيرات ما هو إلا تحويله خطية على متغيرات معيارية طبيعية مستقلة .

خواص التوزيع الطبيعي متعدد المتغيرات MUN :

$$1 - \text{ إذا كان } \underline{X} \sim MUN(\underline{\mu}, \underline{\Sigma}) \text{ عندها } A\underline{X} \sim MUN\left(A\underline{\mu}, \underbrace{A\underline{\Sigma}A'}\right)$$

البرهان:

$$E(A\underline{X}) = AE(\underline{X}) = A\underline{\mu}$$

$$\text{Var}(A\underline{X}) = E[A\underline{X} - E(A\underline{\mu})][A\underline{X} - E(A\underline{\mu})]'$$

$$= E[A\underline{X} - AE(\underline{\mu})][A\underline{X} - AE(\underline{\mu})]'$$

$$= E\{A[\underline{X} - E(\underline{\mu})]\}\{A[\underline{X} - E(\underline{\mu})]\}'$$

$$= E\{A[\underline{X} - E(\underline{\mu})][\underline{X} - E(\underline{\mu})]A'\}$$

$$= AE[\underline{X} - E(\underline{\mu})][\underline{X} - E(\underline{\mu})]A'$$

$$= A\underline{\Sigma}A'$$

$$2 - \text{ إذا كان } \underline{X} \sim MUN(\underline{\mu}, \underline{\Sigma}) \text{ عندها } \underline{X} + \underline{b} \sim MUN(\underline{\mu} + \underline{b}, \underline{\Sigma})$$

مثال : لتكن : $A = \begin{pmatrix} 1 & -1 & 0 \\ 0 & 1 & -1 \end{pmatrix}$ أوجد $A\underline{X}$ ثم أوجد وسيطاه ؟

الحل :

$$A\underline{X} = \begin{pmatrix} 1 & -1 & 0 \\ 0 & 1 & -1 \end{pmatrix} \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} = \begin{pmatrix} X_1 - X_2 \\ X_2 - X_3 \end{pmatrix}$$

لنوجد الآن توقع $A\underline{X}$ حسب الخاصة (2) :

$$A\underline{\mu} = \begin{pmatrix} \mu_1 - \mu_2 \\ \mu_2 - \mu_3 \end{pmatrix}$$

ولنوجد التباين :

$$A \Sigma A' = \begin{pmatrix} 1 & -1 & 0 \\ 0 & 1 & -1 \end{pmatrix} \begin{pmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} \\ \sigma_{21} & \sigma_{22} & \sigma_{23} \\ \sigma_{31} & \sigma_{32} & \sigma_{33} \end{pmatrix} \begin{pmatrix} 1 & 0 \\ -1 & 1 \\ 0 & -1 \end{pmatrix}$$

$$= \begin{pmatrix} \sigma_{11} - 2\sigma_{12} + \sigma_{22} & \sigma_{12} - \sigma_{22} - \sigma_{13} + \sigma_{23} \\ \sigma_{21} - \sigma_{22} - \sigma_{31} + \sigma_{32} & \sigma_{22} - 2\sigma_{23} + \sigma_{33} \end{pmatrix}$$

$$A\underline{X} = \begin{pmatrix} X_1 - X_2 \\ X_2 - X_3 \end{pmatrix} \sim \text{MUN} \left(\begin{pmatrix} \mu_1 - \mu_2 \\ \mu_2 - \mu_3 \end{pmatrix}, \begin{pmatrix} \sigma_{11} - 2\sigma_{12} + \sigma_{22} & \sigma_{12} - \sigma_{22} - \sigma_{13} + \sigma_{23} \\ \sigma_{21} - \sigma_{22} - \sigma_{31} + \sigma_{32} & \sigma_{22} - 2\sigma_{23} + \sigma_{33} \end{pmatrix} \right) \quad \text{إذاً :}$$

3 - إذا كان $\underline{X} \sim \text{MUN}(\underline{\mu}, \Sigma)$ وقسمنا \underline{X} إلى $\underline{X} = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}$ عندئذٍ :

$$(i) \quad \underline{X}_1 \sim \text{MUN}(\underline{\mu}_1, \Sigma_{11})$$

$$\underline{X}_2 \sim \text{MUN}(\underline{\mu}_2, \Sigma_{22})$$

$$(ii) \quad \underline{X}_1 | \underline{X}_2 \sim \text{MUN}(\underline{\mu}_1 + \Sigma_{12} \Sigma_{22}^{-1} (\underline{X}_2 - \underline{\mu}_2), \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21})$$

$$\underline{X}_2 | \underline{X}_1 \sim \text{MUN}(\underline{\mu}_2 + \Sigma_{21} \Sigma_{11}^{-1} (\underline{X}_1 - \underline{\mu}_1), \Sigma_{22} - \Sigma_{21} \Sigma_{11}^{-1} \Sigma_{12})$$

البرهان :

برهان (i) يتم باستخدام الخاصة (2) حيث نأخذ $A = [1 : 0]$ عندئذٍ :

$$A\underline{X} = \underline{X}_1, \quad A\underline{\mu} = \underline{\mu}_1, \quad A \Sigma A' = \Sigma_{11}$$

وينفس الطريقة من أجل \underline{X}_2 .

برهان (ii) يتم أيضاً باستخدام الخاصة (2) حيث نأخذ $A = \begin{pmatrix} I & -\Sigma_{12} \Sigma_{22}^{-1} \\ 0 & I \end{pmatrix}$ عندها :

$$A(\underline{X} - \underline{\mu}) = A \begin{pmatrix} \underline{X}_1 - \underline{\mu}_1 \\ \underline{X}_2 - \underline{\mu}_2 \end{pmatrix} = \begin{pmatrix} \underline{X}_1 - \underline{\mu}_1 - \Sigma_{12} \Sigma_{22}^{-1} (\underline{X}_2 - \underline{\mu}_2) \\ \underline{X}_2 - \underline{\mu}_2 \end{pmatrix} \sim \text{MUN}(0, A \Sigma A')$$

مع القيمة الوسطية $A\underline{\mu} = \underline{0}$ ومصفوفة التغاير :

$$A \Sigma A' = \begin{pmatrix} I & -\Sigma_{12} \Sigma_{22}^{-1} \\ 0 & I \end{pmatrix} \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} \begin{pmatrix} I & 0 \\ -\Sigma_{12} \Sigma_{22}^{-1} & I \end{pmatrix}$$

$$= \begin{pmatrix} \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} & 0 \\ 0 & \Sigma_{22} \end{pmatrix}$$

وبالتالي فإن $(\underline{X}_1 - \underline{\mu}_1 - \Sigma_{12} \Sigma_{22}^{-1} (\underline{X}_2 - \underline{\mu}_2))$ ، $\underline{X}_2 - \underline{\mu}_2$ مستقلين وكل منهما MUN.

$$(\underline{X}_1 - \underline{\mu}_1 - \Sigma_{12} \Sigma_{22}^{-1} (\underline{X}_2 - \underline{\mu}_2)) \sim \text{MUN} \left(0, \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} \right)$$

كما أن : $\underline{X}_2 - \underline{\mu}_2 \sim \text{MUN}(0, \Sigma_{22})$

4 - إذا كانت $\underline{X} = \begin{pmatrix} X_1 \\ X_2 \end{pmatrix}$ عندئذٍ X_1, X_2 مستقلة إذا فقط إذا كان : $\Sigma_{12} = 0$.

5 - ليكن $(\underline{X} \sim \text{MUN}(\underline{\mu}, \Sigma))$ عندئذٍ :

$$(a) (\underline{X} - \underline{\mu})' \Sigma^{-1} (\underline{X} - \underline{\mu}) \sim \chi^2(P)$$

$$(b) P \left\{ \underline{X}; (\underline{X} - \underline{\mu})' \Sigma^{-1} (\underline{X} - \underline{\mu}) \leq \chi^2_\alpha(P) \right\} = 1 - \alpha$$

البرهان : لاحظ أن $Z_i \sim N(0,1)$ و $Z_i^2 \sim \chi^2(1)$

ولكن : $\Sigma^{-1} = \sum_{i=1}^P \frac{1}{\lambda_i} e_i e_i'$ عند ذلك :

$$(\underline{X} - \underline{\mu})' \Sigma^{-1} (\underline{X} - \underline{\mu}) = \sum_{i=1}^P \frac{1}{\lambda_i} (\underline{X} - \underline{\mu})' e_i e_i' (\underline{X} - \underline{\mu})$$

$$= \sum_{i=1}^P \left(\frac{1}{\sqrt{\lambda_i}} e_i' (\underline{X} - \underline{\mu}) \right)^2 = \sum_{i=1}^P Z_i^2$$

$$\underline{Z} = A(\underline{X} - \underline{\mu}) \quad \text{و} \quad A = \left(\frac{1}{\sqrt{\lambda_1}} e_1', \frac{1}{\sqrt{\lambda_2}} e_2', \dots, \frac{1}{\sqrt{\lambda_p}} e_p' \right) \quad \text{حيث :}$$

و $(\underline{X} - \underline{\mu}) \sim \text{MUN}(\underline{0}, \Sigma)$ وبالتالي $\underline{Z} \sim \text{MUN}(\underline{0}, A \Sigma A')$

ولكن :

$$A \Sigma A' = \begin{pmatrix} \frac{1}{\lambda_1} e_1' \\ \vdots \\ \frac{1}{\lambda_p} e_p' \end{pmatrix} \left(\sum_{i=1}^P \lambda_i e_i e_i' \right) \begin{pmatrix} \frac{1}{\sqrt{\lambda_1}} e_1 & \dots & \frac{1}{\sqrt{\lambda_p}} e_p \end{pmatrix}$$

$$= \begin{pmatrix} \frac{1}{\lambda_1} e_1' \\ \vdots \\ \frac{1}{\lambda_p} e_p' \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{\lambda_1}} e_1 & \dots & \frac{1}{\sqrt{\lambda_p}} e_p \end{pmatrix} = I$$

هذا يؤدي إلى أن : $\sum_{i=1}^P Z_i^2 \sim \chi^2(P)$ ومنه : $\underline{Z} \sim \text{MUN}(0, I)$

6 - لتكن $X_i \sim \text{MUN}(\mu_i, \Sigma)$ $i = 1, \dots, n$ عينة مستقلة ، عندئذ :

$$(I) \quad \underline{V}_1 = \sum_i c_i \underline{X}_i \sim \text{MUN} \left(\sum c_i \underline{\mu}_i, \left(\sum c_i^2 \right) \Sigma \right)$$

$$(II) \quad \begin{pmatrix} \underline{V}_1 \\ \underline{V}_2 \end{pmatrix} \sim \text{MUN} \left(\begin{pmatrix} \sum c_i \underline{\mu}_i \\ \sum d_i \underline{\mu}_i \end{pmatrix}, \begin{pmatrix} \sum c_i^2 \Sigma & \left(\sum c_i d_i \right) \Sigma \\ \left(\sum c_i d_i \right) \Sigma & \left(\sum d_i^2 \right) \Sigma \end{pmatrix} \right)$$

فإن \underline{V}_1 ، \underline{V}_2 مستقلين إذا فقط إذا $\sum c_i d_i = 0$

البرهان : من الفرض :

$$\underline{X} = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{pmatrix} \sim \text{MUN} \left(\begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{pmatrix}, \begin{pmatrix} \Sigma & & & \\ & \Sigma & & 0 \\ & & \ddots & \\ & 0 & & \Sigma \end{pmatrix} \right)$$

سنختار A كما يأتي :

$$A = \begin{pmatrix} c_1 I & c_2 I & \dots & c_n I \\ d_1 I & d_2 I & \dots & d_n I \end{pmatrix}$$

عند ذلك :

$$A \underline{X} = \begin{pmatrix} \sum_i c_i X_i \\ \sum_i d_i X_i \end{pmatrix} = \begin{pmatrix} \underline{V}_1 \\ \underline{V}_2 \end{pmatrix} \sim \text{MUN}(A \underline{\mu}, A \Sigma_K A')$$

$$A \underline{\mu} = \begin{pmatrix} \sum_i c_i \mu_i \\ \sum_i d_i \mu_i \end{pmatrix}$$

حيث :

$$A' \Sigma_K A = \begin{pmatrix} c_1 I & d_1 I \\ c_2 I & d_2 I \\ \vdots & \vdots \\ c_n I & d_n I \end{pmatrix} \begin{pmatrix} \Sigma & & & \\ & \Sigma & & 0 \\ & & \ddots & \\ & 0 & & \Sigma \end{pmatrix} \begin{pmatrix} c_1 I & c_2 I & \dots & c_n I \\ d_1 I & d_2 I & \dots & d_n I \end{pmatrix}$$

$$= \begin{pmatrix} \sum_i c_i^2 \Sigma & \left(\sum_i c_i d_i \right) \Sigma \\ \left(\sum_i c_i d_i \right) \Sigma & \left(\sum_i d_i^2 \right) \Sigma \end{pmatrix} = \Sigma^*$$

نلاحظ أنه عندما $\sum c_i d_i = 0$ فإن \sum^* تصبح $\begin{pmatrix} \sum_i c_i^2 \sum & 0 \\ 0 & \sum_i d_i^2 \sum \end{pmatrix}$ وبالتالي V_1, V_2 مستقلين . وهو المطلوب .

إن أي علاقة خطية من توزيع طبيعي تبقى توزيعاً طبيعياً .

إن وسطاء توزيع طبيعي متعدد المتغيرات هي $\sum_{(P \times P)}$ و $\underline{\mu}_{(P \times 1)}$ وبالتالي يكون عدد المجاهيل في هذه الحالة :

$$P + \frac{P(P+1)}{2} = \frac{P(P+3)}{2}$$

لإيجاد مقدرات لهذه المعالم عن طريق دالة الإمكانية الأعظمي حسب طريقة التفاضل يكون متعذراً .
ولذلك سنلجأ إلى :

إيجاد مقدرات لوسطاء التوزيع الطبيعي متعدد المتغيرات:

إيجاد دالة الإحتمالية العظمي:

سوف نجد دالة الإحتمالية العظمي بطريقة خاصة لاتعتمد على التفاضل:

لتكن $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_n$ عينة عشوائية مأخوذة من مجتمع إحصائي له التوزيع الطبيعي المتعدد أي من الشكل:
 $MUN(\underline{\mu}, \underline{\Sigma})$, عندئذ تعطي دالة الإحتمالية العظمي بالشكل :

$$\begin{aligned} L(\underline{X}_1, \dots, \underline{X}_n, \underline{\mu}, \underline{\Sigma}) &= \prod_{i=1}^n f(\underline{X}_i, \underline{\mu}, \underline{\Sigma}) \\ &= \prod_{i=1}^n \left(\frac{1}{2\pi} \right)^{\frac{P}{2}} \frac{1}{|\underline{\Sigma}|^{\frac{1}{2}}} e^{-\frac{1}{2}(\underline{X}_i - \underline{\mu})' \underline{\Sigma}^{-1}(\underline{X}_i - \underline{\mu})} \\ &= \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|\underline{\Sigma}|^{\frac{1}{2}}} e^{-\frac{1}{2}(\underline{X}_i - \underline{\mu})' \underline{\Sigma}^{-1}(\underline{X}_i - \underline{\mu})} \end{aligned}$$

أولاً نبحث عن مقدر لمتجه المتوسط $\underline{\mu}$:

نلاحظ أن $\underline{\mu}$ لا تدخل في L في الأس ونلاحظ أيضاً أن الأس سالبة . لذلك نبحث عن قيمة $\underline{\mu}$ التي تجعل المقدار التالي أصغر ما يمكن :

نضيف ونطرح $\bar{\underline{X}}$: مقدر

$$\begin{aligned} \sum_{i=1}^n (\underline{X}_i - \underline{\mu})' \underline{\Sigma}^{-1} (\underline{X}_i - \underline{\mu}) &= \\ &= \sum_{i=1}^n ((\underline{X}_i - \bar{\underline{X}}) + (\bar{\underline{X}} - \underline{\mu}))' \underline{\Sigma}^{-1} ((\underline{X}_i - \bar{\underline{X}}) + (\bar{\underline{X}} - \underline{\mu})) \\ &= \sum_{i=1}^n (\underline{X}_i - \bar{\underline{X}}) \underline{\Sigma}^{-1} (\underline{X}_i - \bar{\underline{X}}) + n (\bar{\underline{X}} - \underline{\mu})' \underline{\Sigma}^{-1} (\bar{\underline{X}} - \underline{\mu}) \end{aligned}$$

يكون هذا المقدار أصغر ما يمكن عندما يساوي الصفر وليكون هذا المقدار مساوياً الصفر يجب أن يكون كل من الحدين على طرفي إشارة + مساوياً إلى الصفر ومنه :

$$(\bar{X} - \underline{\mu})' \sum (\bar{X} - \underline{\mu}) = 0 \Rightarrow \boxed{\hat{\underline{\mu}} = \bar{X}} \quad (1)$$

وبالتالي يصبح :

$$L(X_1, \dots, X_n, \sum) = A \frac{1}{|\sum|^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n (x_i - \bar{x}) \sum^{-1} (x_i - \bar{x})}$$

ثانياً - نبحث عن مقدر مصفوفة التباين \sum :

لقد أوجدنا مقدر لمتجه المتوسط $\underline{\mu}$ والذي هو $\hat{\underline{\mu}} = \bar{X}$ عندئذ تصبح دالة الاحتمالية العظمى بالشكل :

$$L(X_1, \dots, X_n, \sum) = \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|\sum|^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n (x_i - \bar{x}) \sum^{-1} (x_i - \bar{x})}$$

الخطوة الأولى :

الآن لإيجاد مقدر \sum لناخذ المجموع :

$$\sum_i^n (x_i - \bar{x}) \sum^{-1} (x_i - \bar{x}) = \text{tr} \left(\sum^{-1} \underbrace{\sum_i^n (x_i - \bar{x})(x_i - \bar{x})'}_B \right)$$

الخطوة الثانية :

$$\frac{1}{|\sum|^{\frac{n}{2}}} e^{-\frac{1}{2} \text{tr} \sum^{-1} B} \leq \frac{1}{|B|^{\frac{n}{2}}} n^{\frac{nP}{2}} e^{-\frac{nP}{2}}$$

الخطوة الثالثة :

يحدث التساوي في العلاقة السابقة عند اختيار $\hat{\sum} = \frac{1}{n} B$

$$\cdot B = \sum_i^n (x_i - \bar{x})(x_i - \bar{x})' \quad \text{حيث :}$$

البرهان :

الخطوة الأولى : لاحظ أن :

$$\begin{aligned} \sum_{i=1}^n (x_i - \bar{x})' \sum^{-1} (x_i - \bar{x}) &= \text{tr} \sum_{i=1}^n (x_i - \bar{x})' \sum^{-1} (x_i - \bar{x}) \\ &= \sum_{i=1}^n \text{tr} (x_i - \bar{x})' \sum^{-1} (x_i - \bar{x}) \\ &= \sum_{i=1}^n \text{tr} \left(\sum^{-1} (x_i - \bar{x})(x_i - \bar{x})' \right) \end{aligned}$$

وحسب الخاصة $\text{tr} AB = \text{tr} BA$:

$$\begin{aligned} &= \text{tr} \sum^{-1} \left(\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})' \right) \\ &= \text{tr} \sum^{-1} B \end{aligned}$$

الخطوة الثانية : لنضع $b = \frac{n}{2}$ ولتكن $B^{\frac{1}{2}}$ هي مصفوفة الجذر التربيعي لـ B متناظرة .

عندئذٍ :

$$\text{tr}(\Sigma^{-1} B) = \text{tr}\left(\Sigma^{-1} B^{\frac{1}{2}}\right) B^{\frac{1}{2}} = \text{tr} B^{\frac{1}{2}} \Sigma^{-1} B^{\frac{1}{2}} = \sum_{i=1}^P \eta_i$$

$$\left| B^{\frac{1}{2}} \Sigma^{-1} B^{\frac{1}{2}} \right| = \prod_{i=1}^P \eta_i \quad (1) \quad \text{ومنه يمكن أن نضع :}$$

$$\begin{aligned} \left| B^{\frac{1}{2}} \Sigma^{-1} B^{\frac{1}{2}} \right| &= \left| B^{\frac{1}{2}} \right| \left| \Sigma^{-1} \right| \left| B^{\frac{1}{2}} \right| = \left| \Sigma^{-1} \right| \left| B^{\frac{1}{2}} \right| \left| B^{\frac{1}{2}} \right| \\ &= \left| \Sigma^{-1} \right| |B| = \frac{|B|}{|\Sigma|} \quad (2) \end{aligned}$$

عندئذٍ من (1) و (2) نجد :

$$\frac{|B|}{|\Sigma|} = \prod_{i=1}^P \eta_i \Rightarrow \frac{1}{|\Sigma|} = \frac{\prod_{i=1}^P \eta_i}{|B|}$$

وبالتالي بالتعويض في :

$$\frac{1}{|\Sigma|^b} e^{-\frac{1}{2} \text{tr}(\Sigma^{-1} B)} = \left(\frac{\prod_{i=1}^P \eta_i}{|B|} \right)^b e^{-\sum_{i=1}^P \frac{\eta_i}{2}} = \frac{1}{|B|^b} = \prod_{i=1}^P \eta_i^b e^{-\frac{\eta_i}{2}}$$

وبالتالي يؤول إيجاد القيمة العظمى لـ Σ إلى إيجاد القيمة العظمى لـ

$$\varphi(\eta) = \eta^b e^{-\frac{\eta}{2}}$$

$$\varphi'(\eta) = b \eta^{b-1} e^{-\frac{\eta}{2}} - \frac{1}{2} \eta^b e^{-\frac{\eta}{2}} = \underbrace{\left(\eta^{b-1} e^{-\frac{\eta}{2}} \right)}_{\neq 0} \underbrace{\left(b - \frac{1}{2} \eta \right)}_0 = 0$$

حسب ما افترض : $\eta = 2b = n$

الخطوة الثالثة : بتعويض ما حصلنا عليه في الخطوة الأولى والثانية نجد :

$$L(\underline{X}_1, \dots, \underline{X}_n, \hat{\underline{\mu}}, \hat{\Sigma}) = \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|\hat{\Sigma}|^{n/2}} e^{-\frac{1}{2} \text{tr} \hat{\Sigma}^{-1} B} \leq \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|B|^{\frac{n}{2}}} n^{\frac{nP}{2}} e^{-\frac{nP}{2}}$$

$$(2) \quad \boxed{\hat{\Sigma} = \frac{1}{n} B = \frac{n-1}{n} S} \quad \text{وهذان الطرفان يتساويان إذا فقط إذا كان}$$

$$\text{حيث : } B = \sum_{i=1}^n (\underline{X}_i - \bar{\underline{X}})(\underline{X}_i - \bar{\underline{X}})' = (n-1)S$$

وبذلك نكون قد أوجدنا مقدر $\hat{\Sigma}$ بطريقة غير طريقة الاثبات المعروفة .

وبالتالي إن أكبر قيمة للتابع L هي :

$$L \left(\hat{\underline{\mu}}, \hat{\underline{\Sigma}} \right) = \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|\hat{\underline{\Sigma}}|^{n/2}} e^{-\frac{nP}{2}}$$

* لنبرهن الآن على استقلال \bar{X} و S ويتم كالاتي :

$$\begin{aligned} L(\underline{X}_1, \dots, \underline{X}_n, \underline{\mu}, \underline{\Sigma}) &= \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|\underline{\Sigma}|^{n/2}} e^{-\frac{n}{2} \text{tr} \hat{\underline{\Sigma}} - \frac{n}{2} (\bar{X} - \underline{\mu})' \underline{\Sigma}^{-1} (\bar{X} - \underline{\mu})} \\ &= c_1 e^{-\frac{1}{2} (\bar{Y} - \underline{\mu})' \underline{\Sigma}^{-1} (\bar{Y} - \underline{\mu})} c_2 \frac{1}{|\underline{\Sigma}^*|^{n/2}} e^{-\frac{1}{2} \text{tr} \hat{\underline{\Sigma}}^*} \end{aligned}$$

أي دالتين يمكن فصلهما عن بعض فهما مستقلتين وبالتالي \bar{X} و $\hat{\underline{\Sigma}}$ مستقلين .

$$\bar{X} \sim \text{MUN} \left(\underline{\mu}, \frac{1}{n} \underline{\Sigma} \right) \quad \text{و} \quad \hat{\underline{\Sigma}} \sim W(\underline{\Sigma}) \quad \text{توزيع ويشرت .}$$

ويمكن استخدام التقديرات التي حصلنا عليها (1) و (2) لإيجاد مناطق الثقة ل μ واختبار الفرضيات .

1 - اختبار الفرضيات المتعلقة ب $\underline{\mu}$ في MUN :

لتكن $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_n$ عينة عشوائية من $\text{MUN}(\underline{\mu}, \underline{\Sigma})$ وكلاهما غير معلوم وسوف نقوم باختبار الفرضية

$$H_0 : \underline{\mu} = \underline{\mu}_0 \quad \text{مقابل} \quad H_1 : \underline{\mu} \neq \underline{\mu}_0 .$$

إن ترتيب الأعداد هو ترتيب كامل
لكن ترتيب المتجهات هو ترتيب غير كامل
لذلك تكون المقارنة < أو > غير معرفة

في حالة بعد واحد : كنا نقوم بما يلي : من أجل $X_1, X_1, \dots, X_n \sim (\mu, \sigma^2)$ ونريد اختبار $H_0 : \mu = \mu_0$ و

$$H_0 : \mu \begin{matrix} > \\ < \end{matrix} \mu_0 \quad \text{نحسب المقدار} \quad t = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} .$$

وبالتالي $\left(\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \right)^2 = t^2 \sim F(1, n-1)$ ومنه :

$$\frac{n(\bar{X} - \mu_0)^2}{S^2} = n(\bar{X} - \mu_0) S^{-2} (\bar{X} - \mu_0)$$

$$t^2 \sim F(1, n-1) \quad t \sim t(n-1) \quad \text{أو} \quad t$$

في حالة المتعدد المتغيرات : يكون : $T^2 = n(\bar{X} - \underline{\mu}_0)' S^{-1} (\bar{X} - \underline{\mu}_0)$

$$S = \frac{1}{n-1} \sum_1^n (\underline{X}_i - \bar{X})(\underline{X}_i - \bar{X})', \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n \underline{X}_i \quad \text{حيث :}$$

وبالتالي :

$$T^2 \sim F(P, n-P) \frac{(n-1)P}{n-P}$$

$$T^2 = n(\bar{\underline{X}} - \underline{\mu}_0)' S^{-1} (\bar{\underline{X}} - \underline{\mu}_0)$$

مثال :

	1	2	3	4	5	6	7	8	9	10
X ₁	3.7	5.7	3.8	3.2	3.1	4.6	2.4	7.2	6.7	5.4
X ₂	48.5	65.1	47.2	53.2	55.5	36.1	24.8	33.1	47.4	54.1
X ₃	9.3	8.0	10.9	12.0	9.7	74.0	14.0	7.6	8.5	11.3

	11	12	13	14	15	16	17	18	19	20
X ₁	3.9	4.5	3.5	4.5	1.5	8.5	4.5	6.5	4.1	5.5
X ₂	36.9	58.8	27.8	40.2	13.5	56.4	71.6	52.8	44.1	40.9
X ₃	12.7	12.3	9.8	8.4	10.1	7.1	8.2	10.9	11.2	9.4

$$\alpha = 0.10 \text{ بمستوى أهمية } H_0 : \underline{\mu} = \begin{pmatrix} 4 \\ 50 \\ 10 \end{pmatrix} \text{ اختيار الفرضية :}$$

الحل :

$$\bar{\underline{X}} = \begin{pmatrix} 4.64 \\ 45.40 \\ 9.97 \end{pmatrix}, S = \begin{bmatrix} 2.879 & 10.002 & -1.810 \\ 10.002 & 199.798 & -5.627 \\ -1.810 & -5.627 & 3.628 \end{bmatrix}$$

عندئذ :

$$S^{-1} = \begin{bmatrix} 0.586 & -0.022 & 0.258 \\ -0.022 & 0.006 & -0.002 \\ 0.258 & -0.002 & 0.402 \end{bmatrix}$$

$$T^2 = 20 \left[\begin{matrix} (4.640 - 4) & (45.40 - 50) & (9.94 - 10) \end{matrix} \right] \begin{bmatrix} 0.586 & -0.022 & 0.258 \\ -0.022 & 0.006 & -0.002 \\ 0.258 & -0.002 & 0.402 \end{bmatrix}.$$

$$\cdot \begin{bmatrix} 4.640 - 4 \\ 45.40 - 50 \\ 9.94 - 10 \end{bmatrix} = 9.74$$

$$F_{\alpha}(P, n-P) = F_{0.10}(3, 17) = 2.44$$

$$\frac{(n-1)P}{n-P} F_{\alpha}(P, n-P) = 8.18 < T^2$$

وبالتالي نرفض الفرضية H₀ عند المستوى α = 0.10 .

نسبة الاحتمالية العظمى من أجل متغير واحد :

لتكن (X₁, X₁, ..., X_n) ~ (μ, σ²) عينة عشوائية ونريد اختيار نسبة الاحتمالية العظمى :

$$\lambda = \frac{\max_{H_0} L(X_1, X_2, \dots, X_n, \mu_0, \sigma_0^2)}{\max L(X_1, X_2, \dots, X_n, \mu, \sigma^2)}$$

وبالتالي دالة الاحتمالية العظمى:

$$L(X_1, X_1, \dots, X_n, \mu, \sigma^2) = \left(\frac{1}{\sqrt{2\pi\sigma}} \right)^n e^{-\frac{1}{2\sigma^2} \sum_1^n (x_i - \mu)^2}$$

$$\max_{H_0} L(X_1, X_1, \dots, X_n, \mu_0, \hat{\sigma}_0^2) = \left(\frac{1}{\sqrt{2\pi\hat{\sigma}_0}} \right)^n e^{-\frac{n}{2}} : \mu = \mu_0, \hat{\sigma}_0^2 = \frac{1}{n} \sum_1^n (X_i - \mu)^2$$

ومقام λ هو :

$$\max L(X_1, X_1, \dots, X_n, \mu, \sigma^2) = \left(\frac{1}{\sqrt{2\pi\sigma}} \right)^n e^{-\frac{n}{2}} : \sigma^2 = \frac{1}{n} \sum_1^n (X_i - \bar{X}), \mu = \bar{X}$$

ومنه :

$$\lambda = \frac{\left(\frac{1}{2\pi\hat{\sigma}_0} \right)^{\frac{n}{2}} e^{-\frac{n}{2}}}{\left(\frac{1}{2\pi\sigma^2} \right)^{\frac{n}{2}} e^{-\frac{n}{2}}} = \left(\frac{\hat{\sigma}_0^2}{\sigma^2} \right)^{-\frac{n}{2}} = \left(\frac{\sum (X_i - \mu_0)^2}{\sum (X_i - \bar{X})^2} \right)^{-\frac{n}{2}} = \left(\frac{\sum_1^n (X_i - \bar{X})^2 + n(\bar{X} - \mu_0)^2}{\sum (X_i - \bar{X})^2} \right)^{-\frac{n}{2}}$$

$$\lambda = \left(1 + \frac{n(\bar{X} - \mu_0)^2}{\sum_i (X_i - \bar{X})^2} \right)^{-\frac{n}{2}} = \left(1 + \frac{n}{n+1} t^2 \right)^{-\frac{n}{2}} \quad \text{أي أن :}$$

$$t^2 = \left[\lambda^{\frac{2}{n}} - 1 \right] \frac{n-1}{n} \quad \text{حيث إن الاختيار :}$$

نسبة الاحتمالية العظمى من أجل حالة متعدد المتغيرات :

في هذه الحالة سوف يكون لدينا المقدرات النقطية هي $\underline{\mu} = \bar{X}$ و $\underline{\Sigma} = \frac{1}{n} \sum_1^n (X_i - \bar{X})(X_i - \bar{X})'$ ويكون :

$$L(\underline{X}_1, \dots, \underline{X}_n, \underline{\mu}, \underline{\Sigma}) = \left(\frac{1}{2\pi} \right)^{\frac{nP}{2}} \frac{1}{|\underline{\Sigma}|^{\frac{n}{2}}} e^{-\frac{1}{2} \sum_1^n (\underline{X}_i - \underline{\mu})' \underline{\Sigma}^{-1} (\underline{X}_i - \underline{\mu})}$$

$$\max L = (2\pi)^{-\frac{nP}{2}} \frac{1}{|\underline{\Sigma}|^{\frac{n}{2}}} e^{-\frac{nP}{2}} \quad (1)$$

$$\max L_0 = (2\pi)^{-\frac{nP}{2}} \frac{1}{|\underline{\Sigma}|^{\frac{n}{2}}} e^{-\frac{1}{2} \sum_1^n (\underline{X}_i - \underline{\mu}_0)' \underline{\Sigma}_0^{-1} (\underline{X}_i - \underline{\mu}_0)}$$

$$= (2\pi)^{-\frac{nP}{2}} \frac{1}{|\hat{\Sigma}|^{\frac{n}{2}}} e^{-\frac{1}{2} \text{tr} \hat{\Sigma}_o^{-1} \left(\sum_1^n (\underline{X}_i - \underline{\mu}_o)(\underline{X}_i - \underline{\mu}_o)' \right)}$$

نعوض الآن $\hat{\Sigma}_o$ حيث :

$$\hat{\Sigma}_o = \frac{1}{n} \sum_1^n (\underline{X}_i - \underline{\mu}_o)(\underline{X}_i - \underline{\mu}_o)'$$

$$\max L_o = (2\pi)^{-\frac{nP}{2}} \frac{1}{|\hat{\Sigma}_o|^{\frac{n}{2}}} e^{-\frac{nP}{2}} \quad (2)$$

بتعويض (1) و (2) في نسبة الاحتمالية العظمى Λ نجد :

$$\Lambda = \left(\frac{|\hat{\Sigma}_o|}{|\hat{\Sigma}|} \right)^{-\frac{n}{2}}$$

لكن :

$$\hat{\Sigma}_o = \frac{1}{n} \sum_1^n (\underline{X}_i - \underline{\mu}_o)(\underline{X}_i - \underline{\mu}_o)' = \hat{\Sigma} + n(\bar{\underline{X}} - \underline{\mu}_o)(\bar{\underline{X}} - \underline{\mu}_o)'$$

ومنه :

$$\Lambda^{-\frac{2}{n}} = \frac{|\hat{\Sigma}_o|}{|\hat{\Sigma}|} = \left(1 + \frac{T^2}{n-1} \right) = 1 + \frac{T^2}{n-1}$$

$$\Lambda^{\frac{2}{n}} = \left(1 + \frac{T^2}{n-1} \right)^{-1} \Rightarrow \Lambda = \left(\frac{|\hat{\Sigma}|}{|\hat{\Sigma}_o|} \right)^{\frac{n}{2}} = \left(1 + \frac{n}{n-1} T^2 \right)^{-\frac{n}{2}}$$

مناطق الثقة :

إن العبارة الآتية :

$$P \left(\bar{\underline{X}} - t_{\frac{\alpha}{2}}(n-1) \sqrt{\frac{S^2}{n}} \leq \mu \leq \bar{\underline{X}} + t_{\frac{\alpha}{2}}(n-1) \sqrt{\frac{S^2}{n}} \right) = 1 - \alpha$$

ليست مقبولة لأن ما بين القوسين ليس حدياً . وبالتالي نكتب :

$$P \left(\bar{\underline{X}} \mp t_{\frac{\alpha}{2}}(n-1) \sqrt{\frac{S^2}{n}} \text{ في المجال } \mu \right) = 1 - \alpha$$

تعريف : لتكن $\underline{X}_1, \dots, \underline{X}_n$ عينة عشوائية من توزيع متعدد له شعاع المتوسط θ ، عندئذٍ يقال عن المنطقة

$R(\underline{X}_1, \dots, \underline{X}_n)$ إنها منطقة ثقة بمستوى $100(1-\alpha)\%$ إذاً :

$$P(R(\underline{X}_1, \dots, \underline{X}_n) \text{ وقوع } \theta \text{ في المنطقة}) = 1 - \alpha$$

وهكذا يكون :

$$P \left[n(\bar{X} - \underline{\mu})' S^{-1}(\bar{X} - \underline{\mu}) \leq \frac{(n-1)P}{n-P} F_{\alpha}(P, n-P) \right] = 1 - \alpha$$

نتائج : يمكن إنشاء منطقة ثقة لـ $\underline{\mu}$ بطرائق .

1. Individual Inference

لتكن $\underline{X} \sim \text{MUN}(\underline{\mu}, \underline{\Sigma})$ ولتكن لدينا عينة عشوائية $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_n$ لها نفس التوزيع . وليكن $\underline{\ell}$ متجه ثابت معروف ، عندئذٍ نحصل على :

$$P \left[\underline{\ell}' \bar{X} - t_{\frac{\alpha}{2}}(n-1) \sqrt{\frac{\underline{\ell}' S \underline{\ell}}{n}} \leq \underline{\ell}' \underline{\mu} \leq \underline{\ell}' \bar{X} + t_{\frac{\alpha}{2}}(n-1) \sqrt{\frac{\underline{\ell}' S \underline{\ell}}{n}} \right] = 1 - \alpha$$

وذلك من أجل $\underline{\ell}$ ثابت (مثبت) .

2. Suimultaneour Inference :

من أجل أي $\underline{\ell}$.

$$P \left[\underline{\ell}' \bar{X} - \sqrt{\frac{P(n-1)}{n-P} F_{\alpha}(P, n-P) \underline{\ell}' S \underline{\ell}} \leq \underline{\ell}' \underline{\mu} \leq \underline{\ell}' \bar{X} + \sqrt{\frac{P(n-1)}{n-P} F_{\alpha}(P, n-P) \underline{\ell}' S \underline{\ell}} \right] = 1 - \alpha$$

3 - طريقة (Ben Ferronis Method)

$$P \left[\bar{X}_i - t_{\frac{\alpha}{2P}}(n-1) \sqrt{\frac{S_{ii}}{n}} \leq \mu_i \leq \bar{X}_i + t_{\frac{\alpha}{2P}}(n-1) \sqrt{\frac{S_{ii}}{n}}, i=1 \dots P \right] \geq 1 - \alpha$$

البراهين لهذه الطرق :

برهان الطريقة (1) :

لنضع $Z_i = \underline{\ell}' \underline{X}_i$ عندئذٍ يكون $\bar{Z} = \underline{\ell}' \bar{X} = \frac{1}{n} \sum_1^n Z_i$ ، أيضاً يكون :

$$E Z_i = \underline{\ell}' \underline{\mu}$$

$$V(Z_i) = \underline{\ell}' \underline{\Sigma} \underline{\ell} \quad \text{و}$$

عند ذلك $Z_1, \dots, Z_n \sim N(\underline{\ell}' \underline{\mu}, \underline{\ell}' \underline{\Sigma} \underline{\ell})$ ومنه :

$$\frac{\bar{Z} - \underline{\ell}' \underline{\mu}}{\sqrt{V(\bar{Z})}} = \frac{\sqrt{n} (\bar{Z} - \underline{\ell}' \underline{\mu})}{\sqrt{\underline{\ell}' S \underline{\ell}}} \sim N(0,1)$$

وبالتالي :

$$t = \frac{\sqrt{n} (\bar{Z} - \underline{\ell}' \underline{\mu})}{\sqrt{\underline{\ell}' S \underline{\ell}}} \sim t(n-1)$$

وبالتالي ينتج المطلوب (1) .

إثبات الطريقة (2) :

$$t^2 = \frac{n \left(\underline{\ell}' - (\bar{X} - \underline{\mu}) \right)^2}{\underline{\ell}' S \underline{\ell}} \quad \text{نتيجة :}$$

يمكن برهان أن $\max_{\underline{\ell}} t^2 = T^2$ من أجل ذلك نأخذ :

توطئة : لتكن $B_{(P \times P)}$ معرفة موجبة $\underline{d}_{(P \times 1)}$ متجه عندئذ :

$$\max_{\underline{x} \neq 0} \frac{(\underline{X}' \underline{d})^2}{\underline{X}' B \underline{X}} = \underline{d}' B^{-1} \underline{d}$$

فإذا أخذنا $\underline{X} = \underline{\ell}$ و $\underline{d} = \bar{X} - \underline{\mu}$ و $B = S$ نحصل على :

$$\max_{\underline{\ell}} = \frac{n \left[\underline{\ell}' (\bar{X} - \underline{\mu}) \right]^2}{\underline{\ell}' S \underline{\ell}} = n (\bar{X} - \underline{\mu})' S^{-1} (\bar{X} - \underline{\mu}) = T^2$$

بعد ذلك من أجل أي $\underline{\ell}$:

$$P \left[\frac{n \left[\underline{\ell}' \bar{X} - \underline{\ell}' \underline{\mu} \right]^2}{\underline{\ell}' S \underline{\ell}} \leq c \right] = 1 - \alpha$$

$$P \left[\underline{\ell}' \bar{X} - c \sqrt{\frac{\underline{\ell}' S \underline{\ell}}{n}} \leq \underline{\ell}' \underline{\mu} \leq \underline{\ell}' \bar{X} + c \sqrt{\frac{\underline{\ell}' S \underline{\ell}}{n}} \right] = 1 - \alpha$$

ولكن $c = \frac{(n-1)P}{n-P} F_{\alpha}(P, n-P)$

بالتعويض ينتج المطلوب (2) .

وبالتالي يمكن أن ينتج عن ذلك أن :

$$1) \quad P \left[\bar{X}_i - \sqrt{\frac{(n-1)P}{n-p} F_{\alpha}(p, n-p)} \sqrt{\frac{S_{ii}}{n}} \leq \mu_i \leq \bar{X}_i + \sqrt{\frac{(n-1)P}{n-p} F_{\alpha}(p, n-p)} \sqrt{\frac{S_{ii}}{n}} \right] = 1 - \alpha$$

من أجل $i = 1, 2, \dots, p$

2) ومن أجل $i \neq j$ فإن فترة الثقة للفرق بين متوسطي متجهين تعطى بالشكل:

$$\left[\bar{X}_i - \bar{X}_j - \sqrt{\frac{S_{ii} - 2S_{ij} + S_{jj}}{n} \frac{(n-1)P}{n-p} F_{\alpha}(p, n-p)}, \bar{X}_i - \bar{X}_j + \sqrt{\frac{S_{ii} - 2S_{ij} + S_{jj}}{n} \frac{(n-1)P}{n-p} F_{\alpha}(p, n-p)} \right]$$

وهكذا

برهان الطريقة (3) : يعتمد برهان (3) على بديهية في الاحتمالات هي :

$$P \left(\bigcap_{i=1}^P c_i \right) = 1 - P \left(\bigcup_{i=1}^P c_i' \right) \geq 1 - \sum_{i=1}^P P(c_i') = 1 - \sum_{i=1}^P \alpha_i$$

$$P \left[\bar{X}_i - t_{n-1} \left(\frac{\alpha}{2P} \right) \sqrt{\frac{S_{ii}}{n}} \leq \mu_i \leq \bar{X}_i + t_{n-1} \left(\frac{\alpha}{2P} \right) \sqrt{\frac{S_{ii}}{n}}, i=1, \dots, P \right] \geq 1 - \alpha$$

وهو المطلوب برهانه .

مقارنة الطرق الثلاثة: إذا كانت $\underline{X}_1, \underline{X}_2, \dots, \underline{X}_P$ مستقلة عن بعضها أي $(T_i) = \sum$ قطرية . عندئذ :

$$1) P \left[\bar{X}_i - t_{\frac{\alpha}{2}} (n-1) \sqrt{\frac{S_{ii}}{n}} \leq \mu_i \leq \bar{X}_i + t_{\frac{\alpha}{2}} (n-1) \sqrt{\frac{S_{ii}}{n}}, i=1, \dots, P \right] = (1-\alpha)^P$$

$$2) P \left[\bar{X}_i - \sqrt{\frac{(n-1)p}{n-p}} F_{\alpha}(p, n-p) \sqrt{\frac{S_{ii}}{n}} \leq \mu_i \leq \bar{X}_i + \sqrt{\frac{(n-1)p}{n-p}} F_{\alpha}(p, n-p) \sqrt{\frac{S_{ii}}{n}} \right] = 1 - \alpha$$

, $i=1, 2, \dots, P$

$$3) P \left[\bar{X}_i - t_{\frac{\alpha}{2P}} (n-1) \sqrt{\frac{S_{ii}}{n}} \leq \mu_i \leq \bar{X}_i + t_{\frac{\alpha}{2P}} (n-1) \sqrt{\frac{S_{ii}}{n}}, i=1, \dots, P \right] \geq 1-\alpha$$

أي إذا كانت الـ X مستقلة عن بعضها فإنها تعطي في الحالة الأولى $(1-\alpha)^P$ معامل وفي الحالة الثانية نحصل على

معامل $\left(1 - \frac{\alpha}{2P}\right)^P$ وبالتالي الثالثة أفضل من الأولى .

نتيجة: لتكن $\underline{X}_1, \dots, \underline{X}_n$ عينة عشوائية من $MUN(\underline{\mu}, \underline{\Sigma})$ و $(n > 2)$ ونريد اختبار الفرضية: $H_0 : \underline{\mu} = \underline{\mu}_0$

ضد الفرضية: $H_1 : \underline{\mu} \neq \underline{\mu}_0$

يمكننا القيام بذلك حسب C L T .

$$\text{نتيجة : } \bar{X} = \frac{1}{n} \sum_{i=1}^n \underline{X}_i \quad \text{و} \quad S = \frac{1}{n-1} \sum_{i=1}^n (\underline{X}_i - \bar{X})(\underline{X}_i - \bar{X})'$$

$$\sqrt{n}(\bar{X} - \underline{\mu}) \sim AMUN(0, \underline{\Sigma}) \quad \text{عندئذ :}$$

$$\text{من أجل } (n - P > 2) : n(\bar{X} - \underline{\mu})' S^{-1}(\bar{X} - \underline{\mu}) \sim A\chi_{\alpha}^2(P)$$

$$\text{فلاختبار الفرضية السابقة : } n(\bar{X} - \underline{\mu}_0)' S^{-1}(\bar{X} - \underline{\mu}_0) > \chi_{\alpha}^2(P)$$

(لاحظ أن : إذا كانت العينة كبيرة كفاية وبالتالي $P - n$ كبيرة فإن الاختبار يتم وفق T^2 أو ما تساويه

وإذا كانت العينة غير معروف حجمها أو حجمها صغير فإننا نلجأ إلى $\chi_{\alpha}^2(P)$.