

التقدير النقطي

في كثير من المسائل الإحصائية يتطلب تقدير القانون الاحتمالي للتقدير عنوائى الذي يمثل ظاهرة معينة للتحقق المبرهن لهذا الغرض نأخذ متتالية مستقلة من المتغيرات X_1, X_2, \dots, X_n التي لها نفس التوزيع الجبرول ودون تكرار التجربة التي تعرف بالتقدير الأساسى n مرة ثم نعرف (نقطة) تابع التوزيع المتابع التجريبي $F_x^{(n)}(\alpha)$ كما عرفناه للمتغيرين $X_{(1)} \dots X_{(n)}$

كما يلي $F_x^{(n)}(\alpha)$ هو عدد عناصر العينة (القيم) التي تكون أصغر من α مقسوماً على حجم العينة n واستقاراً لمبرهنات وقوانين إحصائية فإن $F_x^{(n)}(\alpha)$ يعبر بنظام عند n تقرب من التوزيع F_x الى التوزيع المتبع للمتغير X

وفي بعض الحالات تكون كل دراسة من نوع القانون الاحتمالي f_x للمتغير X لكننا نجرب وسطاء f_x وعندها تقدم بتقدير تلك الوسطاء بدلالة العينة X_1, X_2, \dots, X_n أو بتغير n والارواح X وهذا العمل يدعى بالتقدير النقطي، وهناك عدة طرق (وسائل) إحصائية لإثبات التقدير، من هذه الطرق: طريقة العزوم والتي نأخذها كما يلي

(أ) من مبرهنات للصيغة الرباعية لـ f_x في ب العزوم $F(x), E(x^2), \dots, E(x^k)$ ، ثم حيث k عدد لوسطاء وهي عبارات تحتوي على وسطاء العينة (x_1, x_2, \dots, x_n) f_x

(ب) في ب عزوم العينة $M_k = \frac{1}{n} \sum_{i=1}^n x_i^k$

(ج) نظائره بين العزوم النظرية وعزوم العينة $E(x^k) = \frac{1}{n} \sum_{i=1}^n x_i^k$ ، $F(x^2) = \frac{1}{n} \sum_{i=1}^n x_i^2$ ، $F(x) = \frac{1}{n} \sum_{i=1}^n x_i$ عند k عدد k تتصل الوسطاء التي هي مماثلين ونعتبر ان المتتالية لها والتي هي عبارات

لو اعتبرنا ان قيم العينة

$$x_1 = 13, x_2 = 10, x_3 = 0.9, x_4 = 11, x_5 = 15$$

$$x_6 = 10, x_7 = 14, x_8 = 13, x_9 = 11, x_{10} = 14$$

فتكون قيمة العينة \bar{x} هي تقديري لـ μ

$$\hat{\mu} = \frac{2}{10} \sum x_i = 2.4$$

وبالتالي نعتبر

$$X \text{ دالة عشوائية مستقلة } f_X = \frac{1}{2.4} \text{ لـ } x \in (0, 2.4)$$

مثال اذا كانت: 0.9 و 0.8 و 0.1 و 0.3 و 0.7 : x_i
قيم عينة بحجم $n = 3$ لتوزيع أسي وسطه μ مجهول

أوجد تقدير العزوم للوسط μ

$$f_X(x) = \alpha e^{-\alpha x}, x \in \mathbb{R}^+$$

الكثافة الاحتمالية لـ X

$$m_1 = \mu = E(X) = \frac{1}{\alpha}$$

والعزم الأول لـ X هو

$$M_1 = \frac{1}{n} \sum x_i = \bar{x}$$

فطابقه بين m_1 والعزم الأول للعينة

نحصل على الإحصاء التالي

$$\hat{\alpha} = \frac{1}{\bar{x}}$$

$$\bar{x} = \frac{1}{3} \sum x_i = 0.8$$

$$\hat{\alpha} = \frac{1}{0.8} = 1.25 \text{ بالقيمة}$$

تمرين . أوجد تقدير العزوم لـ λ وسط متطوّر بواسون بولاية
عينة بحجم n : x_1, \dots, x_n

مثال : افرضه $X \sim \mu, \sigma^2$ واتي طبيعي وسطه μ و σ^2 : $\alpha_1 = \mu, \alpha_2 = \sigma^2$

أوجد تقديري العزوم للوسط μ بولاية عينة بحجم n : x_1, \dots, x_n

الحل :

نعلم بالنسبة الطبيعي انه

$$E(X) = \mu \quad V(X) = \sigma^2$$

$$\sigma^2 = E(X - \mu)^2 = E(X^2) - (E(X))^2$$

$$E(X^2) = \sigma^2 + \mu^2$$

$$\hat{\mu} = \frac{1}{n} \sum x_i$$

$$M_2 = E X^2 = \frac{1}{n} \sum x_i^2$$

فإن $m_1 = M_1$

ومن $m_2 = M_2$

بالتالي

$$\sigma^2 + \mu^2 = \frac{1}{n} \sum x_i^2$$

أي $\hat{\mu} = \bar{x}$

$$\hat{\sigma}^2 = \frac{1}{n} \sum x_i^2 - (\bar{x})^2 \quad \text{و} \quad \hat{\mu} = \bar{x}$$

ملاحظة: يمكن التعبير عن σ^2 بدلالة S^2 (تباين العينة)

$$\hat{\sigma}^2 = M_2 - M_1^2 = \frac{n-1}{n} S^2$$

$$S^2 = \frac{n}{n-1} (M_2 - M_1^2)$$

مثال: افترض X متوزع على المجال (a, b)

وبنصف x_1, \dots, x_n عينة له. أوجد مقدر العزم العينة a و b

الحل: نعلم أن $x \in (a, b)$: $f_x(x) = \frac{1}{b-a}$

$$m_2 - m_1^2 = V(x) = \frac{(b-a)^2}{12} \quad m_1 = E(x) = \frac{a+b}{2}$$

$$m_2 = \frac{(b-a)^2}{12} + \left(\frac{a+b}{2}\right)^2 = \frac{a^2 + ab + b^2}{3} \quad \text{أو} \quad m_1 = \frac{a+b}{2}$$

نطابق عزم العينة مع عزم العينة ونكتب

$$M_1 = m_1 \Rightarrow \bar{x} = \frac{a+b}{2} \quad \text{و} \quad M_2 = m_2 \Rightarrow \frac{1}{n} \sum x_i^2 = \frac{a^2 + ab + b^2}{3}$$

$$3M_2 = b^2 - 2ab + 4M_1^2 - 3M_1^2 \quad \text{أي} \quad 3M_2 = b^2 - 2ab + M_1^2$$

$$b = \frac{1}{2} (2M_1 \mp \sqrt{4M_1^2 - 16M_1^2 + 12M_2}) = M_1 \mp \sqrt{3(M_2 - M_1^2)}$$

$$a = 2M_1 - b = M_1 + \sqrt{3(M_2 - M_1^2)} \quad \text{و} \quad b = M_1 - \sqrt{3(M_2 - M_1^2)}$$

حيث اخترنا القيم التي تحقق $a > b$ ، فرضنا القيم التي تحقق $a > b$

مثال: لنفرض X متغير عشوائي بسيط p و x_1, \dots, x_n عينته L أو تقدير المقبولية القطبي للوسيط $p = \alpha$.

الحل: نعلم أنه $f_X(i) = p^{\alpha} (1-p)^{1-\alpha}$ و $\alpha = 0$ ونكتب توزيعاً

$$L(x_1, \dots, x_n, p) = \prod_{i=1}^n p^{\alpha} (1-p)^{1-\alpha} \\ = p^{\sum x_i} (1-p)^{n - \sum x_i}$$

هذه الدالة كمرى بالاضافة للمتغيرات x_1, \dots, x_n فهي الوسيط p وقيمة الوسيط التي تجعل هذه الدالة تأخذ اعظم قيمة لها من أجل أي x_1, \dots, x_n هي القيمة التي نعدها المشتقة الجزئية بالنسبة لـ p و يبين ان هذه الدالة تبلغ قيمته اعظم

عندما $K(p) = \log L(p)$ يبلغ قيمة اعظمى أي

نحس المعادلة $\frac{dk}{dp} = 0$: $\frac{d^2k}{dp^2} < 0$

$$(K(p))'_p = 0 \Rightarrow \left(\sum x_i \log(p) + (n - \sum x_i) \log(1-p) \right)'_p = 0$$

$$\Rightarrow \frac{1}{p} \sum x_i - \frac{1}{1-p} (n - \sum x_i) = 0$$

$$\Rightarrow (1-p) \sum x_i - p(n - \sum x_i) = 0 \Rightarrow p = \frac{1}{n} \sum x_i$$

$$(K(p))''_p = -\frac{1}{p} \sum x_i - \frac{n - \sum x_i}{(1-p)^2} < 0$$

$$\hat{p} = M_1 = \frac{1}{n} \sum x_i$$

فيكون تقدير المقبولية القطبي

مثال إذا كانت x_1, \dots, x_n عينته لتقدير X طبيعي وسيطه μ و σ^2 مجهولين، أو تقدير المقبولية القطبي للوسيط p .

الحل نكتب توزيعاً عشوائياً والتي نكتبها دالة في (μ, σ^2)

$$L(\mu, \sigma^2, x_1, \dots, x_n) = \prod_{i=1}^n \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{x_i - \mu}{\sigma}\right)^2\right)$$

$$= (2\pi\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2} \sum \left(\frac{x_i - \mu}{\sigma}\right)^2\right)$$

$$K(\mu, \sigma^2) = \log L = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum (x_i - \mu)^2$$

$$\frac{\partial K}{\partial \mu} = 0 \Rightarrow \frac{1}{\sigma^2} \sum (x_i - \mu) = 0$$

$$\frac{\partial K}{\partial \sigma^2} = 0 \Rightarrow -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum (x_i - \mu)^2 = 0$$

$$\mu = \bar{x}, \quad \sigma^2 = \frac{1}{n} \sum (x_i - \bar{x})^2$$

بالقول
أي مقدري المتولية العظمى

$$\hat{\mu} = M_1 = \frac{1}{n} \sum x_i, \quad \hat{\sigma}^2 = \frac{1}{n} \sum (x_i - \bar{x})^2 = \frac{n-1}{n} S^2$$

تمرين: أوجد مقدري الغرور لـ μ و σ^2 بواسطة طريقة ماكسيمال ليكلير
بدلالة x_1, \dots, x_n عينة عشوائية بسيطة n و p

نصائح المقدرات

تقنياً طريقتان لتقدير وسط توزيع وهناك طرق أخرى وليس بالضرورة أن تتطابق
النتائج في الظروف المختلفة فقد تحصل على مصدرين مختلفين لوسيط لأول
هنا نختار المقدر الأفضل يجب أن يكون هناك معايير لدرجة الاختيار

تعريف المقدر النصف (غير صفاتي)

نقول عن الدالة $g(x_1, \dots, x_n) = \hat{\theta}$ أنه مقدر للوسيط θ للكثافة

$f(x)$ إذا حققه الشرط التالي

$$E(\hat{\theta}) = \theta$$

مثال

بفرض x_1, x_2, \dots, x_n عينة لمقدر X . نكتب نظاماً

$$\hat{\theta} = \bar{X} = E(X) = \mu$$

فإنه مقدر X يعبر عن وسيط $\theta = \mu$

فإنه مقدر X يعبر عن وسيط $\theta = \mu$

من البولي الذي $E(X) = p$ وسيطه

البواسوني الذي $E(X) = \lambda$

الطبيعي الذي يعبر عن (الوسيط $\mu - E(X)$)

لأن هذه الخصائص للثلاث خصائص مبرهنة فيرو ولكنها ليست كافية فهناك

عدة مقدرات لوسيط طبيعي مفضلة تأتي تحت مبرهنة:

مثلاً لو كانت $\hat{\theta}_1, \hat{\theta}_2$ مقدرين مفضلين فثابتاً θ

$$E(\hat{\theta}_1) = E(\hat{\theta}_2) = \theta$$

$$P(|\hat{\theta}_1 - \theta| \leq 1) = 0.5 \text{ و } P(|\hat{\theta}_2 - \theta| \leq 1) = 0.5$$

أي أن إذا كررنا التجربة عدة مرات ¹⁰⁰ نصل على 100 قيمة ل $\hat{\theta}_1$

وكذلك 100 قيمة للدالة الثاني $\hat{\theta}_2$ لكن نسبة قيم $\hat{\theta}_1$ التي

تقع في جوار θ نصف قطره 1 90% نسبة القيم ل $\hat{\theta}_2$ التي

تقع في نفس الجوار θ 50% لذلك نفضل $\hat{\theta}_1$ على $\hat{\theta}_2$ كقدر

للسيط θ

تعريف المقدم الأكثر فعالية

بفرض $\hat{\theta}_1$ و $\hat{\theta}_2$ مقديين مصغرين ل θ نقول ان $\hat{\theta}_1$ هناك
 اكثر من $\hat{\theta}_2$ اذا كان $Var(\hat{\theta}_1) < Var(\hat{\theta}_2)$

فك اذا كانت X_1, X_2, \dots, X_{10} عينة مستقلة طبيعية ذات
 المتوسط μ و التباين σ^2 ولنفرض

فأى المقديين $\hat{\theta}_1 = \frac{1}{5}(X_1 + \dots + X_5)$ و $\hat{\theta}_2 = \frac{1}{10}(X_1 + \dots + X_{10})$ فنأى المقديين
 تفضل

الكل واضح ان $E \hat{\theta}_1 = E \hat{\theta}_2 = EX = \mu$

$V(\hat{\theta}_1) = \frac{5}{25} \sigma_x^2 = \frac{\sigma_x^2}{5}$ و $V(\hat{\theta}_2) = \frac{10}{100} \sigma_x^2 = \frac{\sigma_x^2}{10}$

اذن $V(\hat{\theta}_2) < V(\hat{\theta}_1)$ وبالتالي $\hat{\theta}_2 = \frac{1}{10}(X_1 + \dots + X_{10})$ افضل

تعريف افضل مقدم خطي مصغر ل θ

نقول ان $\hat{\theta} = g(X_1, \dots, X_n)$ افضل مقدم خطي مصغر للوسط

θ للمتوسط $f_x(x, \theta)$ للمقمر x اذا عقده الشروط التاليه

(1) $\hat{\theta} = \alpha_1 X_1 + \dots + \alpha_n X_n + \beta$ عبارة خطية في العينة

(2) $E(\hat{\theta}) = \theta$ اي انه مصغر

(3) $Var(\hat{\theta}^*) \geq Var(\hat{\theta})$ حيث $\hat{\theta}^*$ اي مقدم آخر يحقق (1) و (2)

مباشرة بفرض $X \sim N(\mu, \sigma^2)$ و $E(X) = \mu$ و $Var(X) = \sigma^2$ و بفرض

X_1, \dots, X_n عينة ل X ذات \bar{X} افضل مقدم خطي مصغر

للموسط μ

الاثبات:

ان $\bar{X} = \frac{1}{n} X_1 + \frac{1}{n} X_2 + \dots + \frac{1}{n} X_n$ و $E(\bar{X}) = \mu$

اي \bar{X} يحققه اولاً شرطه

الثاني نفرض ان $M = \sum a_i X_i + b$ مقدم آخر ل μ

تقدير أولي طبيعي أي

$$EM = \mu \quad \text{أي} \quad \sum a_i (\mu x_i + b) = \mu \quad \text{أو} \quad \sum a_i = 1$$

$$\sum_{i=1}^n a_i = 1, \quad b = 0$$

$$M = \sum_{i=1}^n a_i x_i \quad \text{و} \quad \sum a_i = 1$$

$$V(M) = \sum a_i^2 v(x_i) = \sigma^2 \sum a_i^2$$

ميكانيك x أفضل تقدير خطي غير متجانس μx إذا كانت

$$a_1 = a_2 = \dots = a_n = \frac{1}{n}$$

من العلاقة $\sum a_i = 1$ $\Leftrightarrow a_1 = 1 - \sum_{i=2}^n a_i$ ولتأكد من قيم a_i التي تحقق $\sum a_i^2 = Q$ أصغر ما يمكن

$$Q = a_1^2 + \sum_{i=2}^n a_i^2 = (1 - \sum_{i=2}^n a_i)^2 + \sum_{i=2}^n a_i^2$$

$$\frac{\partial Q}{\partial a_2} = 0, \quad \frac{\partial Q}{\partial a_3} = 0, \quad \dots, \quad \frac{\partial Q}{\partial a_n} = 0$$

ونفس العمل المشترك. أي نعرف $j = 2, 3, \dots, n$

$$\frac{\partial Q}{\partial a_j} = -2(1 - \sum_{i=2}^n a_i) + 2a_j = 0 \Rightarrow a_j + \sum_{i=2}^n a_i = 1 = 0$$

$$\Rightarrow a_j = 1 - \sum_{i=2}^n a_i = a_1 \quad j = 2, 3, \dots, n$$

أي القيم المحققة هي المتساوية والتي مجموعها 1 أي

$$j = 2, 3, \dots, n \quad a_j = \frac{1}{n} \quad \text{و} \quad \text{التالي ميكانيك المعدل المظهر هو} \quad \bar{x} = \frac{1}{n} \sum x_i$$

أي \bar{x} هو أفضل تقدير خطي متجانس μ

وهذا ينطبق على التوزيعات: البرنولي - البواسوني (الطبيعي)

تعريف المعدل المتحرك (المتحرك)

نعرف x_1, \dots, x_n عينة مستقلة كفاية $f_x(a, \theta)$

وبفرض λ_n مقدر للوسيط θ . فنقول أن λ_n مقدر θ إذا تحققت الشرط التالي

$$\forall \epsilon > 0 \quad \lim_{n \rightarrow \infty} P(|\lambda_n - \theta| > \epsilon) = 0$$

أي أن المتغير العشوائي (المحصلة) λ_n تتكاثف قيمه وتتجمع حول الوسيط θ كلما زادت قيمة n

مبرهنة إذا ما كان $\lim_{n \rightarrow \infty} E(\lambda_n) = \theta$ و $\lim_{n \rightarrow \infty} \text{Var}(\lambda_n) = 0$ يكون λ_n مقدرًا مقاربًا للوسيط θ .

مثال بفرض X_1, \dots, X_n عينة عشوائية لمتغير عشوائي طبيعي متوسطه μ وتباينه σ^2 ولنفرض \bar{X} متوسط العينة والتي كالنظام

$$E(\bar{X}) = \mu \quad \text{و} \quad \text{Var}(\bar{X}) = \frac{\sigma^2}{n}$$

إذا نظرنا لـ \bar{X} بأنه مقدر للوسيط μ فإن \bar{X} تحقق

$$E\bar{X} \rightarrow \mu \quad \text{و} \quad \text{Var}(\bar{X}) = \frac{\sigma^2}{n} \rightarrow 0 \quad \text{ك} \quad n \rightarrow \infty$$

إذا \bar{X} مقدر مقارب لـ μ

تمرين: μ X مقدر مقارب للوسيط مقدر بواسون λ

تمرين: $\bar{X} =$ لوسيط مقدر α

مثال بفرض X_1, \dots, X_n عينة عشوائية طبيعية بوسيط μ و σ^2

$$\sigma^2 \quad \mu \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \text{مقدر مقارب لـ } \sigma^2$$

$$\frac{n-1}{\sigma^2} S^2 = \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\sigma^2} \quad \text{الكل نظام أن}$$

مقدر عشوائي يتبع توزيع كاي مربع درجة حرية $n-1$ ونظام كذا

$$E\left(\frac{n-1}{\sigma^2} S^2\right) = n-1 \quad \text{و} \quad \text{Var}\left(\frac{n-1}{\sigma^2} S^2\right) = 2(n-1)$$

$$E(S^2) = \sigma^2, \quad V(S^2) = \frac{\sigma^4}{(n-1)^2} \cdot 2(n-1) = \frac{2\sigma^4}{n-1}$$

شروط المبرهنة محققة والمقدر S^2 له σ^2 مقدر متساو

تعريف المقدر الكافي

نقول عن إحصاء $T = T(X_1, \dots, X_n)$ تابع في العينة (أي إحصاء كافي بسيط θ) إذا كانت تتضمن بيانات كافية عن الربط θ ويعني آخر لا يوجد إحصاء آخر يتضمن بيانات تزيد عن البيانات (المعطيات) التي يتضمنها T .

صيغة بدهن X_1, \dots, X_n عينة عشوائية مستقلة لمتغير X كثافته $f(x, \theta)$ تحتوي وسيط θ . إن البسيط θ والعملي T يكونان الإحصاء $T = T(X_1, \dots, X_n)$ مقراً كافياً لـ θ إذا ما تخطت كتابة كثافة العينة

$$f(x_1, \dots, x_n, \theta) = g(T(x_1, \dots, x_n)) H(x_1, \dots, x_n)$$

حيث $g(y, \theta)$ كثافة الإحصاء T و $H(x_1, \dots, x_n)$ صيغة لا تحتوي وسيط θ .

أي الكثافة المتحركة (كثافة العينة) هي عبارة تابعية للدول كثافة المقدم والثاني يتعلقت بالعينة وتقل عن البسيط θ

مثال بفرض $f(x) = \theta^{1-x} (1-\theta)^x$ كثافة بئرلي X وسيط θ هو $T = X_1 + \dots + X_n$ إحصاء كافي لـ θ من أي

العينة X_1, X_2, \dots, X_n متغير ثنائي وسيط θ و n هو "لأنه مجموع عينة بئرلية" وكثافته

$$g_T = \binom{n}{y} \theta^y (1-\theta)^{n-y}$$

$$L(x_1, \dots, x_n, \theta) = f(x_1, \theta) \cdot f(x_2, \theta) \cdot \dots \cdot f(x_n, \theta)$$

$$= \theta^{x_1} (1-\theta)^{1-x_1} \cdot \theta^{x_2} (1-\theta)^{1-x_2} \cdot \dots \cdot \theta^{x_n} (1-\theta)^{1-x_n}$$

$$= \theta^{\sum x_i} (1-\theta)^{n-\sum x_i} = \binom{n}{\sum x_i} \theta^{\sum x_i} (1-\theta)^{n-\sum x_i} \frac{1}{\binom{n}{\sum x_i}}$$

$$Y(x_1, \dots, x_n) = x_1 + x_2 + \dots + x_n = \sum x_i \quad \text{دعونا نكتب}$$

$$\binom{n}{\sum x_i} \theta^{\sum x_i} (1-\theta)^{n-\sum x_i} = g_Y(\sum x_i) = g_Y(y = \sum x_i)$$

وهو تابع عن صفة $y = \sum x_i$ وفق كفاءة الاستدلال
 (الفئة) $Y = x_1 + \dots + x_n$

و تابع لا يتغير الوسط θ و
 متعلق بالصيغة x_1, \dots, x_n

أي أن $Y = \sum x_i$ احصاء كافي لـ θ

مثال لكثير X متغيراً عشوائياً كالتالي

$$f(x, \theta) = e^{\theta-x} \quad ; \quad x > \theta$$

$Y = Y(x_1, \dots, x_n)$ و x_1, \dots, x_n عينات عشوائية لـ X و

$$= \min(x_1, \dots, x_n) = X_{(1)}$$

وهو $Y = \min(x_1, \dots, x_n) = X_{(1)}$ احصاء كافي لـ θ

الحل:

$$F_X(x) = \int_{\theta}^x e^{\theta-u} du = 1 - e^{\theta-x} \quad ; \quad x > \theta$$

وهذا في صيغة عامة

$$f_{X_{(1)}}(x) = n(1 - F_X(x))^{n-1} f_X(x)$$

$$f_{X_{(1)}}(x) = n e^{(n-1)(\theta-x)} e^{\theta-x} = n e^{n(\theta-x)} = n e^{\theta-nx}$$

$$L(n, \theta) = f_{X_{(1)}}(x_1, \theta) \dots f_{X_{(1)}}(x_n, \theta) = e^{\theta-x_1} \dots e^{\theta-x_n} = e^{\theta-nx}$$

$$= e^{n\theta - \sum x_i} = n e^{n\theta} e^{-n \min(x_1, \dots, x_n)} \cdot e^{-\sum x_i}$$

$$\Rightarrow L(n, \theta) = f_{X_{(1)}}(\min(x_1, \dots, x_n)) \cdot H(x_1, \dots, x_n)$$

اذن اكتب كثافة كثافة العينة على صيغة تايبيه الاولي

صيغة $y = \min(n_1, \dots, n_n)$ وفق كثافة الاصل $Y = X_{(1)}$

والثاني $H = \frac{e^{-2x}}{n e^{n \min(n_1, \dots, n_n)}}$ تتفر عن الوسط θ

توزيع (المتوسط) $\sigma > 0, \mu > 0$ $f_X(x) = \frac{1}{\sigma} e^{-\frac{x}{\sigma}}$

متفر $Y_1 = X_1 + X_2$ $Y_2 = X_2$ $n=2$

من اقر العينة X_1, X_2 المتفر $n=2$

(ا) اكتب كثافة العينة (الكثافة المشتركة) (Y_1, Y_2)

(ب) اثبت ان Y_1 متفر كاف للوسط λ

(ج) عينة $f_{Y_1, Y_2} = g_2$

تفر (ب) متفر X_1, \dots, X_6 عينة طبيعية لتفر (μ, σ^2) $X \sim N(\mu, \sigma^2)$

متفر $Y_1 = \frac{1}{6} ((X_1 - X_2)^2 + (X_3 - X_4)^2 + (X_5 - X_6)^2)$

$Y_2 = \frac{1}{5} ((X_1 - \bar{x})^2 + \dots + (X_6 - \bar{x})^2)$

اثبت ان Y_1 متفر غير متواز σ^2 وان Y_1 متفر غير متواز σ^2 $n=6$ متفر