

دراسة محاكاة لنظرية الغاية المركزية للمعوائل الاسية

وائل عبد اللطيف جاسم

المعهد التقني ، الموصل ، العراق

(تاريخ الاستلام: ٢٧ / ١٠ / ٢٠٠٨ ، تاريخ القبول: ١٢ / ٤ / ٢٠٠٩)

الملخص :

يظهر هذا البحث انه تحت شروط الانظام اذا كان X_1, \dots, X_n هي متغيرات عشوائية متماثلة التوزيع ومستقلة من k من المعلومات للعائلة الاسية المنتظمة باحصاءة ثامة وكافية $T_n = \sqrt{n}(T_n - \mu_T) \sim N_k(0, I(\eta))$ ، اذ ان $I(\eta)$ هي مصفوفة المعلومات للمعلمة الطبيعية للعائلة الاسية. كذلك يمكن باستخدام طريقة دلتا في ايجاد التوقع والتباين للدوال المعقدة . لقد تم في هذا البحث توليد اعداد عشوائية لتوزيعين مستمررين وتوزيعين مقطعين يعودون للعائلة الاسية وقد اظهرت نتائج المحاكاة بان نظرية الغاية المركزية تعطي تقرير جيد للتوزيع الطبيعي .

المقدمة

الثوابt_i و c ولجميع قيم X في العينة او فضاء المعلمة عندما لا

$$\text{ تكون جميع قيم } a_i = 0 \quad .$$

اذا كان $c = \sum_{i=1}^k a_i d_i(x)$ لجميع قيم x فقط و اذا

كان $a_1 = \dots = a_k = 0$ فان $d_i(x)$ لا تتحقق قيد الخطية
انظر (Johanson (1979, p. 3))

في الجبر الخطى يمكن القول بان (x, d_i) هي مستقلة خطيا اذا لم تتحقق شرط الخطية .

افرض ان $\tilde{\Omega}$ هي مجموعة محددة عندما يكون تكامل نواة الدالة محدد
وكما يلي :

$$\tilde{\Omega} = \{\eta = (\eta_1, \dots, \eta_k) : \frac{1}{c^*(\eta)} \equiv \int_{-\infty}^{\infty} h(y) \exp[\sum_{i=1}^k \eta_i t_i(y)] dy < \infty\} \quad (4)$$

ويبدل التكامل بالمجموع في حالة دالة الكثافة الاحتمالية .
الشروط مهمة جدا لمعرفة فيما اذا كانت العائلة الاسية منتظمة او كاملة
وهي :

١- فضاء المعلمة الطبيعى $\Omega = \tilde{\Omega}$.

٢- $\eta_i + t_i$ لا تتحقق شرط الخطية للمعلمة الطبيعية .

٣- Ω هي مجموعة مفتوحة ذات بعد k .

فإذا كانت الشروط الثلاثة متحققة فان العائلة الاسية هي عائلة اسية منتظمة (REF) ، واذا تحقق الشرطان الاول والثانى فقط فان العائلة الاسية تسمى عائلة اسية كاملة .

نلاحظ من تعريف Θ و Ω ان المعادلين (١) و (٣) تتحقق لكل $\eta \in \Omega$ ولكل $\theta \in \Theta$

ان المعلمة الطبيعية للتوزيعات المستمرة والمنقطعة يجب ان تكون موجودة ، فعلى سبيل المثال في توزيع ثانى الحدين (bin(n,p) وعلى فرض ان n معلومة ، فان المعلمة الطبيعية للتوزيع هي $\Theta = [0, 1] \cap \log(p/(1-p))$ ونلاحظ انه بدلا من استخدام $\Theta = \log(p/(1-p))$ نستخدم $\eta \in \Theta = (0,1)$ وعليه فان $p \in \Theta = (-\infty, \infty)$

يمكنا القول بان توزيع معين يتبع العائلة الاسية بـ k من المعلومات وذلك بوضع $(\theta) = w_i$ ، ومن ثم نفرض ان فضاء المعلمة الطبيعية هو

$$\Omega = \{(\eta_1, \dots, \eta_k) : \eta_i = w_i(\theta), \theta \in \Theta\} \quad .$$

ان $(\theta) = w_i$ تكون صحيحة لمعظم التوزيعات لان η هي دالة متباينة بالنسبة لـ θ وللمزيد انظر (Olive,2005) . لمعرفة فيما اذا

العائلة دالة الكثافة الاحتمالية (p.d.f) او دالة الكثافة الاحتمالية (p.m.f) $\{f(y|\theta) : \theta = (\theta_1, \dots, \theta_j) \in \Theta\}$ للمتغير العشوائي Y هي عائلة اسية اذا كانت

$$f(y|\theta) = h(y)c(\theta) \exp[\sum_{i=1}^k w_i(\theta)t_i(y)] \quad (1)$$

لـ $y \in Y$ حيث $c(\theta) \geq 0$. والدوال $c, h, t_1, w_1, \dots, t_k, w_k$ هي دوال ذات قيم حقيقة . من التعريف نلاحظ ان c, h, t_1, \dots, t_k لا تعتمد على y وان w_1, \dots, w_k لا تعتمد على θ . الدعم للتوزيع هو y وان فضاء المعلمة هو Θ . العائلة هي عائلة اسية بـ k من المعلومات اذا كانت k هي اصغر عدد صحيح عند تطبيق المعادلة (1) .

فإذا فرضنا ان Y_1, \dots, Y_n هي توزيعات عشوائية مستقلة ومتماثلة ،

فإن التوزيع المشترك لـ Y_1, \dots, Y_n يتبع ايضا العائلة الاسية أي ان :

$$f(y_1, \dots, y_n) = \prod_{i=1}^n f(y_i) = [\prod_{i=1}^n h(y_i)][c(\theta)]^n \prod_{i=1}^n \exp \quad (2)$$

$$[\sum_{j=1}^k w_j(\theta)t_j(y_i)]$$

$$= [\prod_{i=1}^n h(y_i)][c(\theta)]^n \cdot \exp[\sum_{j=1}^k w_j(\theta)(\sum_{i=1}^n t_j(y_i))]$$

من معادلة (2) ليكن بـ $c = [c(\theta)]^n$ و $h^*(y_1, \dots, y_n) = [\prod_{i=1}^n h(y_i)]$

$$t_j^*(y_1, \dots, y_n) = \sum_{i=1}^n t_j(y_i) \quad \text{و} \quad w_j^*(\theta) = w_j(\theta)$$

ان استخدام المعلمة الطبيعية η مفيد جدا عند تطبيق المعادلة (1) ، فلو

فرضنا ان Ω هو فضاء المعلمة الطبيعية لـ η ، فان المعلمة الطبيعية

للعائلة الاسية ستكون كما يلي :

$$f(y|\eta) = h(y)c^*(\eta) \exp[\sum_{i=1}^k \eta_i t_i(y)] \quad (3)$$

حيث ان $h(y)$ و $t_i(y)$ هي نفسها بالمعادلة (1) وان $\Omega \in \eta$

$f(y|\theta) = h(y)c(\theta) \exp[w(\theta)t(y)]$ ، فان العائلة الاسية بمعلمة واحدة

لها معلمة طبيعية وكالاتي :

$$f(y|\eta) = h(y)c^*(\eta) \exp[\eta t(y)]$$

سوف نستعرض الان العائلة الاسية المنتظمة والعائلة الاسية الكاملة .

افرض ان $d_i(y)$ تعرف (θ) ، w_i او $t_i(y)$ او η_i . قيد الخطية يتتحقق

$\sum_{i=1}^k a_i d_i(x) = c$ اذا كان $d_1(x), \dots, d_k(x)$ البعض

حيث ان فريشي كرامر - راو ل $\phi(\theta)$ هي

$$\text{FCRLB}_1(\phi(\theta)) = \frac{[\phi'(\theta)]^2}{I_1(\theta)}$$

ومعلومات فيشر التي تعتمد على حجم عينة واحدة هي

$$I_1(\theta) = -E_{\theta} \left[\frac{\partial^2}{\partial \theta^2} \log(f(y|\theta)) \right]$$

اما بالنسبة لنظرية الغاية المركزية فقد عرفت في القرن الثامن عشر لكن التطور الدقيق لهذه النظرية يعود الى علماء الرياضيات الروسيين وبالاخص شيبيشيف ، ماركوف وليابنوف وقد بلغت ذروتها في بداية القرن العشرين .

توصف نظرية الغاية المركزية بانها النظرية الاكثر اهمية في الاحصاء ، وتنص النظرية على انه اذا كانت لدينا عينات عشوائية مستقلة بحجم n من توزيع معين له وسط μ وتباعن σ^2 محددين (finite) . فان متوسطات العينات تتوزع محاذيا (عندما $n \rightarrow \infty$) توزيعا طبيعيا بوسط

$$\mu / \sqrt{n}$$

للمزيد انظر (Wackerly, Mendenhall III and Scheaffer, 2002) ان المهم في نظرية الغاية المركزية هو ان عناصر المتجهات هي متغيرات عشوائية .

نظرية الغاية المركزية وطريقة دلتا

Central Limit Theorem & Delta Method

ان نظرية الغاية المركزية تعتبر واحدة من النظريات المهمة في الاحصاء الرياضي وهي تستخدم تقريبا حيثما يستخدم الاحصاء الرياضي . ان الفائدة المتواحة من استخدام هذه النظرية تتمثل بتعريف بسيط هو ان نظرية الغاية المركزية في حالة توفر بعض الشروط المعينة فان توزيع الوسط الحسابي لعدد من المتغيرات العشوائية المستقلة يقترب من التوزيع الطبيعي عندما يقترب عدد المتغيرات العشوائية الى المalanهاية (infinity) .

كانت Ω هي مجموعة مفتوحة ذات بعد k يجب برهنة ان Ω هي حاصل ضرب فترات مفتوحة وكما موضح بالمثال التالي :

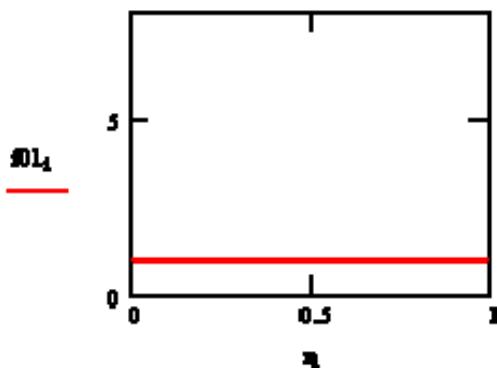
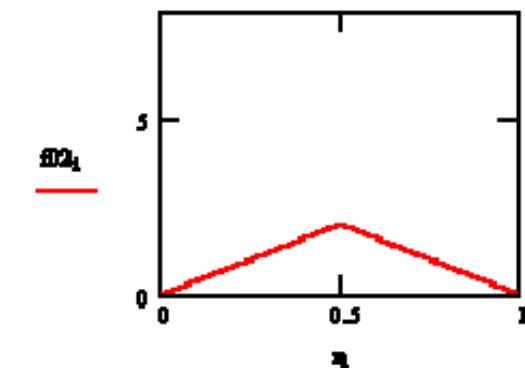
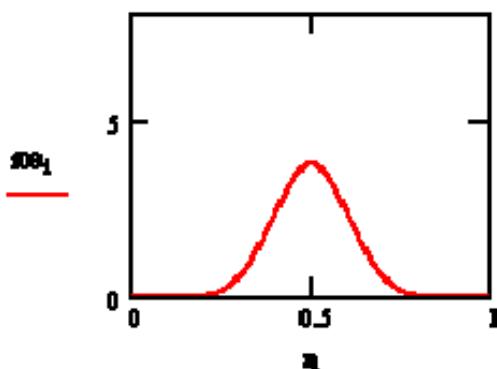
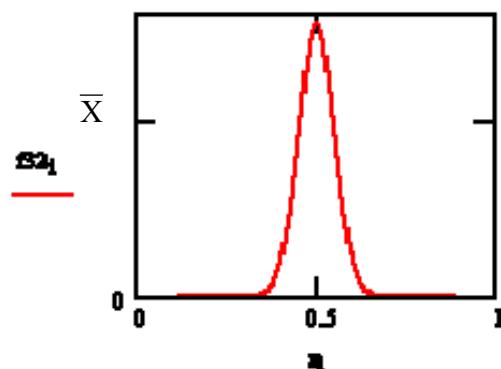
مثال : افرض ان $f(y|\mu, \sigma^2)$ تتابع التوزيع الطبيعي $N(\mu, \sigma^2)$ حيث ان $(\mu, \sigma) = (\mu, \sigma) > 0$ ، $-\infty < \mu < \infty$.

$$f(y|\theta) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(y-\mu)^2}$$

نلاحظ ان التوزيع الطبيعي هو عائلة اسية بمعاملتين $\eta_2 = \frac{\mu}{\sigma^2}$ ، $\eta_1 = \frac{-0.5}{\sigma^2}$ اذا كانت $\sigma > 0$ وان $(-\infty, \infty) \times (-\infty, \infty)$ لذلك فان العائلة هي عائلة اسية منتظمة بمعاملتين ، انظر (Olive, 2005) .

Casella and Berger (1982) ، Barndorff-Nielsen (1982) ، Schervish (1983) ، Lehmann (1974) ، Cox and Hinkley (1974) واخرين كثيرين اقترحوا بانه تحت شروط الانتظام ، اذا كان Y_1, \dots, Y_n هي توزيعات عشوائية مستقلة ومتباينة (لها نفس التوزيع) من عائلة اسية منتظمة بمعاملة واحدة وان $\hat{\theta}$ هي مقدر الامكان الاعظم ل θ ، فان

$$\sqrt{n}(\hat{\theta} - \theta) \sim N[0, \text{FCRLB}_1(\theta)] \quad (5)$$

NonNormal Distribution of \bar{X} Distribution of \bar{X} when sample size is 2Distribution of \bar{X} when sample size is 8Distribution of \bar{X} when sample size is 32

Sufficient Statistics & Exponential Family

الفكرة الأساسية للاحصاء الكافية $T(y|\theta)$ هو ان كل المعلومات المطلوبة من البيانات Y_1, \dots, Y_n حول المعلمة θ هي موجودة في الاحصاء $T(y|\theta)$. الاحصاء الكافية $T(y|\theta)$ هي اصغر احصاء كافية اذا كان لا ي احصاء كافية اخرى $T'(y|\theta)$ ، $T'(y|\theta)$ هي دالة $L(y|\theta)$.

سوف نتكلم الان عن نظريتين مهمتين للاحصاء الكافية :

أ- النظرية العاملية : Factorization Theorem

افرض ان $f(x|\theta)$ دالة الكثافة الاحتمالية او دالة الكثالة الاحتمالية للعينة

x . الاحصاء $T(x|\theta)$ هي احصاء كافية θ اذا كان :

$$f(x|\theta) = g(T(x|\theta))h(x)$$

اذ ان g و h هي دوال غير سالبة ، انظر (Olive, 2006)

البرهان :

اذا كان لدينا X_1, \dots, X_n هي توزيعات عشوائية متماثلة (identical) من العائلة الاسمية فان

$$f(x|\theta) = h(x)c(\theta)\exp[w_1(\theta)t_1(x) + \dots + w_k(\theta)t_k(x)]$$

ويستخدم المعلمة الطبيعية فان

$$f(x|\eta) = h(x)c^*(\eta)\exp[\eta_1t_1(x) + \dots + \eta_kt_k(x)]$$

لذلك فان دالة التوزيع الاحتمالي المشتركة ستكون كما يلي :

ان جمال نظرية الغایة المركزیة تکمن فی بساطتها ولتوضیح ذلك نأخذ عینات من التوزیع المنظم (Uniform Distribution) وبحجم عینة ۱ ،

۲ ، ۸ ، ۳۲ وكما موضح بالشكل رقم (۱) : (انظر Le Cam, L. (1986)

ان من فروض تطبيق نظرية الغایة المركزیة هي :

۱- ان تكون العینة المسحوبة من المجتمع لها توزیع عشوائی مستقل ومتماثل.

۲- المتغير المسحوب من العینة يجب ان يمتلك وسط وتباین محدد (finite) .

فاما ما توفرت الفروض اعلاه فان :

۱- متوسط العینة يتوزع توزیعا طبیعیا مهما يكن توزیع المتغير الأصلی . $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$

۲- متوسط العینة له نفس القيمة المتوقعة لمتوسط المجتمع μ أي ان $E(\bar{X}) = \mu$

۳- الانحراف المعياري لمتوسط العینة هو $\sqrt{n}(\bar{X} - \mu)$ أي ان $V(\bar{X}) = \frac{\sigma^2}{n}$

نظريّة (۱) : طريقة دلتا Delta Method

اذا كان $0 \neq g'(\theta) \sim N(0, \sigma^2)$ وان $\sqrt{n}(T_n - \theta) \sim N(0, \sigma^2)$ فان

$$\sqrt{n}(g(T_n) - g(\theta)) \sim N(0, \sigma^2[g'(\theta)]^2)$$

حيث ان $\theta^* \in \Omega^*$ وان Ω^* هي فضاء المعلمة المتحولة، للمزيد انظر (عبد المجيد حمزة الناصر، ١٩٨٨).

المقدر غير المتحيز ذي التباين القليل (UMVUE) والحد الادنى لمتباعدة فريشيه - راو كرامر (FCRLB)

افرض ان $R(\theta)$ هي دالة حقيقة ل θ وان $W = W(X_1, X_2, \dots, X_n)$ هو مقدر ل $R(\theta)$ فان الجزء المتحيز للمقدر W ل $R(\theta)$ هو

$$b(R(\theta)) = E(W) - R(\theta)$$

وان متوسط مربعات الاخطاء (mean square error) للمقدر W هو $R(\theta)$

$$Mse(R(\theta)) = E[W - R(\theta)]^2 = Var(W) + [b(R(\theta))]^2 \quad (6)$$

ان W هو مقدر غير متحيز ل $R(\theta)$ اذا كان $W = R(\theta)$ لجميع قيم $\theta \in \Theta$ وان W_U هو $R(\theta)$ (UMVUE) (اذا كان W_U مقدر غير متحيز ل $R(\theta)$) وان $Var(W_U) \leq Var(W)$ وان $R(\theta)$ لجميع قيم θ حيث ان W اي مقدر غير متحيز ل $R(\theta)$.

وللتعرف على ماهية (FCRLB) او متباعدة المعلومات ، نفرض ان X_1, X_2, \dots, X_n هي متغيرات عشوائية مستقلة بدالة كثافة (كثافة احتمالية مشتركة $f(x|\theta)$) والتي تحقق المعادلة (6). افرض ان

$$R(\theta) = E(W) \text{ فان } W(X_1, X_2, \dots, X_n)$$

$$VarW(X) \geq \frac{\frac{dE(W(X))}{d\theta}}{E[\frac{\partial}{\partial \theta} \log f(X|\theta)]^2} = \frac{[R'(\theta)]^2}{I_n(\theta)}$$

ان المقدار $FCRLB = \frac{[R'(\theta)]^2}{I_n(\theta)}$ هو الحد الادنى لمتباعدة فريشيه - راو كرامر للمقدرات غير المتحيزه ذي التباين القليل ل $R(\theta)$ ، للمزيد انظر Joshi(1973) و Wijsman(1973).

نظرية الغایة المركزیة لمعلمہ واحدہ من التوزیعات التي تتبع العائلة الاسیة :

ان العالمين Cox و Hinkley لاحظا في حالة العائلة الاسیة المنتظمة بمعلمہ واحدہ ان $T_n = \frac{1}{n} \sum_{i=1}^n t(X_i)$ هو مقدر غير متحيز منظم ذو تباين قليل (UMVUE) وان مقدر الامکان الاعظم (MLE) لتوقع هذا المقدر هو $[t(X)] = E_\theta(t(X))$ ، $\mu_T = E_\theta(T_n) = E_\theta[t(X)]$ ، $\sigma_T^2 = Var_\theta[t(X)]$. ان هذه القيم يمكن ايجادها باستخدام صيغ Berger Casella و كما يلي:

$$\mu_T = \frac{-c'(\theta)}{c(\theta)w'(\theta)} = \frac{-\partial}{\partial \eta} \ln(c^*(\eta)), \quad (7)$$

$$\sigma_T^2 = \frac{\frac{\partial^2}{\partial \theta^2} \ln(c(\theta)) - [w''(\theta)]\mu_T}{[w'(\theta)]^2} = \frac{-\partial^2}{\partial \eta^2} \ln(c^*(\eta)) \quad (8)$$

اذا كان $(\eta) = g(\eta)$ وان $\theta = g'(\eta) \neq 0$ فان $I_1(\theta) = \frac{I_1(\eta)}{[g'(\eta)]^2}$. هذا

هو التعريف المناسب عند استخدام طريقة دلتا او عندما تكون الدالة متباعدة شاملة .

$f(x_1, \dots, x_n | \eta) = [\prod_{i=1}^n h(x_i)] [c^*(\eta)]^n \exp[\eta_1 \sum_{i=1}^n t_1(x_i) + \dots + \eta_k \sum_{i=1}^k t_k(x_i)]$
ي عائلة اسية ب K من المعلمات . فان:

$$T(X) = \sum_{i=1}^n t_1(x_i), \dots, \eta_k \sum_{i=1}^k t_k(x_i)$$

هي احصاءة كافية ل η وذلك باستخدام النظرية العاملية فحصل على :

$$f(x_1, \dots, x_n | \eta) = [\prod_{i=1}^n h(x_i)] [c^*(\eta)]^n \exp[\eta_1 \sum_{i=1}^n t_1(x_i) + \dots + \eta_k \sum_{i=1}^k t_k(x_i)]$$

$h(x)$

$g(T(X) | \eta)$

ب- نظرية ليمان - شيفي لاصغر احصاءة كافية :

Lehman-Scheffé Theorem for Minimal Sufficient Statistics

افرض ان $f(x|\theta)$ هي دالة كثافة او كثافة احتمالية للعينة X وان

هو ثابت . وافرض ان هناك دالة اخرى $T(x)$. ان النسبة

$$= T(y) R_{x,y}(\theta) = \frac{f(x|\theta)}{f(y|\theta)} = C_{x,y}$$

(Olive,2006) فان $T(x)$ هي اصغر احصاءة كافية ل θ ، انظر

.

ولبرهنة ان $T(x)$ هي اصغر احصاءة كافية ل η اذا كانت Johanson (1979,p.3) η_1, \dots, η_n لتحقق شرط الخطية، انظر Lehman (1983,p.44) .

تقدير الامکان الاعظم Maximum Likelihood Estimation

افرض ان $f(x|\theta)$ هي دالة كثافة (كثافة) احتمالية للعينة X ، فان دالة

الامکان هي $L(\theta) = f(x|\theta)$ لكل $X = (X_1, X_2, \dots, X_n)$

قيمة المعلمہ $\hat{\theta}(X) \in \theta$ هي التي تجعل $L(\theta|X)$ معظمۃ عند ثبات X .

لذلك فان (MLE) للمعلمہ θ والتي تعتمد على العینة X هي $\hat{\theta}(X)$ للمزيد انظر Olive,2005 .

ان من الخواص المهمة في تقدير الامکان الاعظم والتي تكون مهمة بالنسبة للعائلة الاسیة هي خاصیة الالاتغير (Invariance Property) والتي تنص على :

اذا كان $\hat{\theta}$ هو تقدير امکان اعظم للمعلمہ θ بفضاء المعلمات Ω ،

فان $h(\hat{\theta})$ هي تقدير امکان اعظم ل $(h(\theta), \theta)$ ، اي ان (MLE) ثابت عندما تكون الدالة متباعدة .

وللتعرف على خاصیة الالاتغير نفرض ان $\theta^* = h(\theta)$ وعليه فان $\theta = h^{-1}(\theta^*)$ لذلك فان :

$$L(\theta|X_1, X_2, \dots, X_n) = L(h^{-1}(\theta^*)|X_1, X_2, \dots, X_n)$$

والتي يمكن الرمز لها ب $L^*(\theta^*|X_1, X_2, \dots, X_n)$ ، وبالتالي فان تقدير

الامکان الاعظم ل θ (اذا كان موجودا) يكون كما يلي

$$MaxL(\theta|X_1, X_2, \dots, X_n) = MaxL^*(\theta^*|X_1, X_2, \dots, X_n)$$

$$\frac{[w^{-1}(\eta)]^2}{I_1(\eta)} = \frac{1}{I_1(\theta)}$$

$$\therefore \sqrt{n}(\hat{\theta} - \theta) \sim N(0, \frac{1}{I_1(\theta)})$$

لذا فان T_n هو (UMVUE) لـ μ_T ، وللمزيد انظر .(Olive,D.J,2006)

نظريّة الغاية المركبة لـ K من المعلمات للتوزيعات التي تتبع العائلة الاسية :

افرض ان X_1, \dots, X_n هي متغيرات عشوائية مستقلة ولها نفس التوزيع من K من المعلمات ، فان اصغر احصاء كافية هي

$$T_n = \frac{1}{n} (\sum_{i=1}^n t_i(X_i), \dots, \sum_{i=1}^n t_k(X_i))$$

افرض ان $\mu_T = (E(t_1(X)), \dots, E(t_k(X)))$ Lehmann (1999, pp. 497, و Lehmann (1986, p. 66) انظر

499)

عندما $\eta \in \Omega$ فان

$$E(t_i(X)) = \frac{-\partial}{\partial \eta_i} \ln(c^*(\eta)) ;$$

$$\text{Cov}(t_i(X), t_j(X)) = \sigma_{ij} = \frac{-\partial^2}{\partial \eta_i \partial \eta_j} \ln(c^*(\eta)) \quad \text{فوفة}$$

المعلومات هي

حيث ان

$$I_{ij} = E[\frac{\partial}{\partial \eta_i} \ln(f(x|\eta)) \frac{\partial}{\partial \eta_j} \ln(f(x|\eta))] = -E[\frac{\partial^2}{\partial \eta_i \partial \eta_j} \ln(f(x|\eta))]$$

نظريّة (٣) : اذا كان X_1, \dots, X_n هي متغيرات عشوائية مستقلة ولها نفس التوزيع من العائلة الاسية المنتظمة بـ K من المعلمات ، فان

$$\sqrt{n}(T_n - \mu_T) \sim N_k(0, I(\eta))$$

البرهان:

باستخدام نظريّة الغاية المركبة متعددة المتغيرات

$$\sqrt{n}(T_n - \mu_T) \sim N_k(0, \Sigma)$$

$$\text{حيث ان } \sigma_{ij} = I_{ij}, \Sigma = [\sigma_{ij}] . \text{ فان}$$

$$\ln(f(x|\eta)) = \ln(h(x)) + \ln(c^*(\eta)) + \sum_{i=1}^k \eta_i t_i(x)$$

$$\frac{\partial}{\partial \eta_i} \ln(f(x|\eta)) = \frac{\partial}{\partial \eta_i} \ln(c^*(\eta)) + t_i(x)$$

$$I_{ij} = -E[\frac{\partial^2}{\partial \eta_i \partial \eta_j} \ln(f(x|\eta))] = \frac{\partial^2}{\partial \eta_i \partial \eta_j} \ln(c^*(\eta)) = \sigma_{ij}$$

وللتعرف اكثر على نظريّة الغاية المركبة متعددة المتغيرات انظر . (Olive,D.J,2006)

المحاكاة :

لقد تم كتابة برنامج باستخدام البرنامج الاحصائي R/Splus لعراض نظريّة الغاية المركبة للبيانات X_1, \dots, X_n والتي لها توزيع عشوائي متشابه من التوزيع الطبيعي ، توزيع كما ، توزيع شاناي الحدين و توزيع بواسون . الدالة تقوم بتوليد مجموعة من البيانات بحجم n ويتم حساب

نظريّة (٢) : افرض ان x_1, \dots, x_n هو توزيعات عشوائية مستقلة و متشابهة من عائلة اسية بمعلمة واحدة بـ $E(t(X)) = \mu_T = g(\eta)$

فان $\text{Var}(T(X)) = \sigma_T^2$ اذا كان

$$\sqrt{n}[T_n - \mu_T] \sim N(0, I_1(\eta))$$

حيث ان

$$I_1(\eta) = \sigma_T^2 = g'(\eta) = \frac{[g'(\eta)]^2}{I_1(\eta)}$$

فان T_n هي كفؤة محاذيا .

- ٢ - اذا كان $\eta = g^{-1}(\mu_T), \hat{\eta} = g^{-1}(T_n)$ وان $0 \neq g^{-1}(\mu_T)$ فان

$$\sqrt{n}(\hat{\eta} - \eta) \sim N(0, \frac{1}{I_1(\eta)})$$

- ٣ - اذا كان $w^{-1}'(\eta) \neq 0$ وان $\theta = w^{-1}(\eta), \hat{\theta} = w^{-1}(\hat{\eta})$ وان

$$\sqrt{n}(\hat{\theta} - \theta) \sim N(0, \frac{1}{I_1(\theta)})$$

البرهان:

- ١ - من نظريّة الغاية المركبة $I_1(\eta) = \sigma_T^2 = g'(\eta)$ فان

$$\ln(f(x|\eta)) = \ln(h(x)) + \ln(c^*(\eta)) + \eta t(x)$$

$$\frac{\partial}{\partial \eta} \ln(f(x|\eta)) = \frac{\partial}{\partial \eta} \ln(c^*(\eta)) + t(x) = -g(\eta) + t(x)$$

$$\frac{\partial^2}{\partial \eta^2} \ln(f(x|\eta)) = \frac{\partial^2}{\partial \eta^2} \ln(c^*(\eta)) = -g'(\eta)$$

$$\therefore I_1(\eta) = -E[\frac{\partial^2}{\partial \eta^2} \ln(f(x|\eta))] = \sigma_T^2 = g'(\eta) —$$

- ٤ - باستخدام طريقة دلنا

$$\text{and } \hat{\eta} = g^{-1}(\hat{\mu}_T) \because g(\eta) = \mu_T \Rightarrow \eta = g^{-1}(\mu_T)$$

فان

$$\sqrt{n}(g^{-1}(\hat{\mu}_T) - g^{-1}(\mu_T)) \sim N(0, \sigma_T^2 [g^{-1}'(\mu_T)]^2)$$

وان

$$g^{-1}'(\mu_T) = \frac{1}{g'(g^{-1}(\mu_T))} = \frac{1}{g'(\eta)}$$

كذلك

$$\sigma_T^2 [g^{-1}'(\mu_T)]^2 = \frac{[g'(\eta)]^2}{I_1(\eta)} \cdot \frac{1}{[g'(\eta)]^2} = \frac{1}{I_1(\eta)}$$

$$\Rightarrow \sqrt{n}(\hat{\eta} - \eta) \sim N(0, \frac{1}{I_1(\eta)})$$

- ٥ - باستخدام طريقة دلنا

$$\therefore \theta = w^{-1}(\eta), \hat{\theta} = w^{-1}(\hat{\eta})$$

فان

$$\sqrt{n}(\hat{\theta} - \theta) \sim N(0, \frac{[w^{-1}'(\eta)]^2}{I_1(\eta)})$$

وان

جدول (٢) : الأعداد العشوائية المسحوبة من توزيع كاما

0.792493187	0.263108794	0.290888799	0.044650348
0.120987701	0.075149900	0.086788011	0.598838366
0.229075753	0.251844302	0.086467557	0.106473160
0.374806471	0.553578053	0.256317768	0.054877577
0.506029919	0.762606687	0.082367438	0.093387638
0.058410616	0.052031138	0.372874707	0.237716091
0.038156948	0.688199621	0.074384842	0.579116217
0.304255992	1.327930901	1.528399738	0.103693919
0.204190880	0.456989452	0.335651375	0.032588828
0.122858672	0.032247917	0.224669904	0.107487511
0.092327629	0.153587957	0.481194960	0.131904236
0.588492664	0.001599823	0.646408002	0.482208929
0.806400397	0.276445922	0.621755841	0.006995997
0.077792808	0.022603013	1.119509485	0.754112191
0.015498341	0.400792800	0.075386828	0.633363121
0.321607888	0.047925482	0.290491730	0.498935134
0.218185537	0.105957748	0.029907883	0.159792400
0.208438538	0.406111482	0.230146012	0.141583034
0.192301687	0.020830336	0.680771865	0.110880609
0.140180929	0.145958005	0.597880118	0.272237764
0.059208227	0.406750402	0.137489879	0.247603674
0.056636466	0.293105436	0.931679219	0.476495053
0.271626734	0.043735458	0.872267369	0.072444185
0.821428820	0.438683801	0.015441771	0.117944394
0.606849452	0.503883471	0.428739308	0.352791323

جدول (٣) : الأعداد العشوائية المسحوبة من توزيع ثانوي الحدين

4	3	4	3	3	2	6	3	3	6
3	4	4	4	2	5	3	6	5	4
3	3	5	3	3	2	5	5	3	4
2	5	1	3	2	3	3	3	1	2
0	5	3	3	3	6	4	5	3	2
4	1	3	4	3	3	4	4	4	4
3	3	3	4	3	4	2	3	3	3
2	4	3	0	4	4	3	4	5	3
4	1	5	0	5	4	1	4	3	3
4	2	3	3	5	2	3	4	2	3

جدول (٤) : الأعداد العشوائية المسحوبة من توزيع بواسون

3	0	2	0	3	1	1	1	2	2
3	5	3	5	1	4	1	2	2	1
2	5	1	3	2	3	2	1	2	1
5	1	1	0	3	1	4	3	2	5
1	1	1	1	3	0	3	2	0	2
2	5	3	3	3	0	1	5	7	3
1	3	2	0	0	2	0	4	2	4
2	3	3	1	2	4	2	0	1	2
2	2	2	2	4	3	0	0	1	1
1	4	2	1	2	0	1	1	1	6

وكانت نتيجة المحاكاة للبيانات العشوائية المولدة اعلاه كما يلي :

من هذه البيانات . هذه الخطوة تكرر ١٠٠ مرة . فيظهر لدينا المتوجه $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_n$. المخططات لهذه الاوساط يجب ان تكون مشابهة لدالة التوزيع الطبيعي المتماثلة عندما تكون n كبيرة بشكل كافي. البرنامج كما يلي :

```
cltsim <- function(n=100, nruns=100){
  xbar <- 1:nruns
  for(i in 1:nruns){
    xbar[i] <- mean(rgamma(n,1,3))}
    list(xbar=xbar)
  z1 <- cltsim(n=1)
  z5 <- cltsim(n=5)
  z25 <- cltsim(n=25)
  z50 <- cltsim(n=50)
  z100 <- cltsim(n=100)
  par(mfrow=c(2,3))
  hist(z1$xbar)
  hist(z5$xbar)
  hist(z25$xbar)
  hist(z50$xbar)
  hist(z100$xbar)}
```

حيث نقوم بتغيير الخطوة الرابعة في البرنامج فنحصل على الرسومات الموجودة في الصفحتين (١٩-٢٢) من هذا البحث .

ان البيانات التي اجريت لها المحاكاة هي كما يلي :

جدول (١) : الأعداد العشوائية المسحوبة من التوزيع الطبيعي

4.471882	3.705662	7.582331	9.675885
7.152609	7.203354	4.865256	2.705655
4.219924	5.987487	3.403227	6.576371
4.881086	4.817792	5.803686	7.002315
5.791137	4.427378	5.089493	8.412478
5.990214	4.011861	8.921393	8.630030
7.395105	7.364920	6.365172	10.035282
7.091677	5.906635	6.564209	4.711267
8.287166	4.320424	4.970319	2.495526
7.639815	2.849497	5.539044	8.361741
4.843444	9.463603	7.186727	9.039826
7.944343	5.249753	3.943314	3.167953
10.634625	8.403656	6.247930	7.256564
7.512267	6.174204	3.853303	7.079254
3.176224	8.183669	7.574186	4.257860
6.072690	7.538367	3.642546	7.273978
5.277725	6.622952	6.469314	5.580786
6.962571	2.292401	4.979590	7.990239
8.247842	6.212651	7.497432	3.624177
4.937102	7.674392	8.894339	3.418695
6.476011	6.767703	8.824314	3.499203
6.145230	7.668136	6.316944	4.131584
5.435832	6.099950	7.646350	4.633205
3.649043	5.309545	4.353089	5.733341
5.391281	9.426679	8.096673	2.637288

جدول (٥) : الوسط الحسابي والانحراف المعياري للتوزيع الطبيعي بحجم عينة
١٠٠ ، ٥٠ ، ٢٥ ، ٥ على التوالي

Distribution	Sample Size	\bar{X}		Normal	
		mean	S.D.	mean	S.D.
Normal	1	5.879	2.035	6.000	2.000
	5	6.009	0.807	6.000	0.894
	25	5.987	0.396	6.000	0.400
	50	5.988	0.254	6.000	0.283
	100	6.004	0.193	6.000	0.200

نلاحظ من الجدول (٥) بأنه كلما كبر حجم العينة $n \geq 30$ كلما اقترب الوسط الحسابي والانحراف المعياري (التقريبي) للإعداد العشوائية المحسوبة (Normal) .

جدول (٦) : الوسط الحسابي والانحراف المعياري للتوزيع كاما بحجم عينة
١٠٠ ، ٥٠ ، ٢٥ ، ٥ على التوالي

Distribution	Sample Size	\bar{X}		Normal	
		mean	S.D.	mean	S.D.
Gamma	1	2.882	3.221	3.000	3.000
	5	2.977	1.206	3.000	1.342
	25	2.979	0.591	3.000	0.600
	50	2.978	0.379	3.000	0.424
	100	3.005	0.292	3.000	0.300

نلاحظ من الجدول (٦) بأنه كلما كبر حجم العينة $n \geq 30$ كلما اقترب الوسط الحسابي والانحراف المعياري (التقريبي) للإعداد العشوائية المحسوبة (Normal) .

جدول (٧) : الوسط الحسابي والانحراف المعياري للتوزيع ثانوي الحدين بحجم عينة
١٠٠ ، ٥٠ ، ٢٥ ، ٥ ، ١ على التوالي

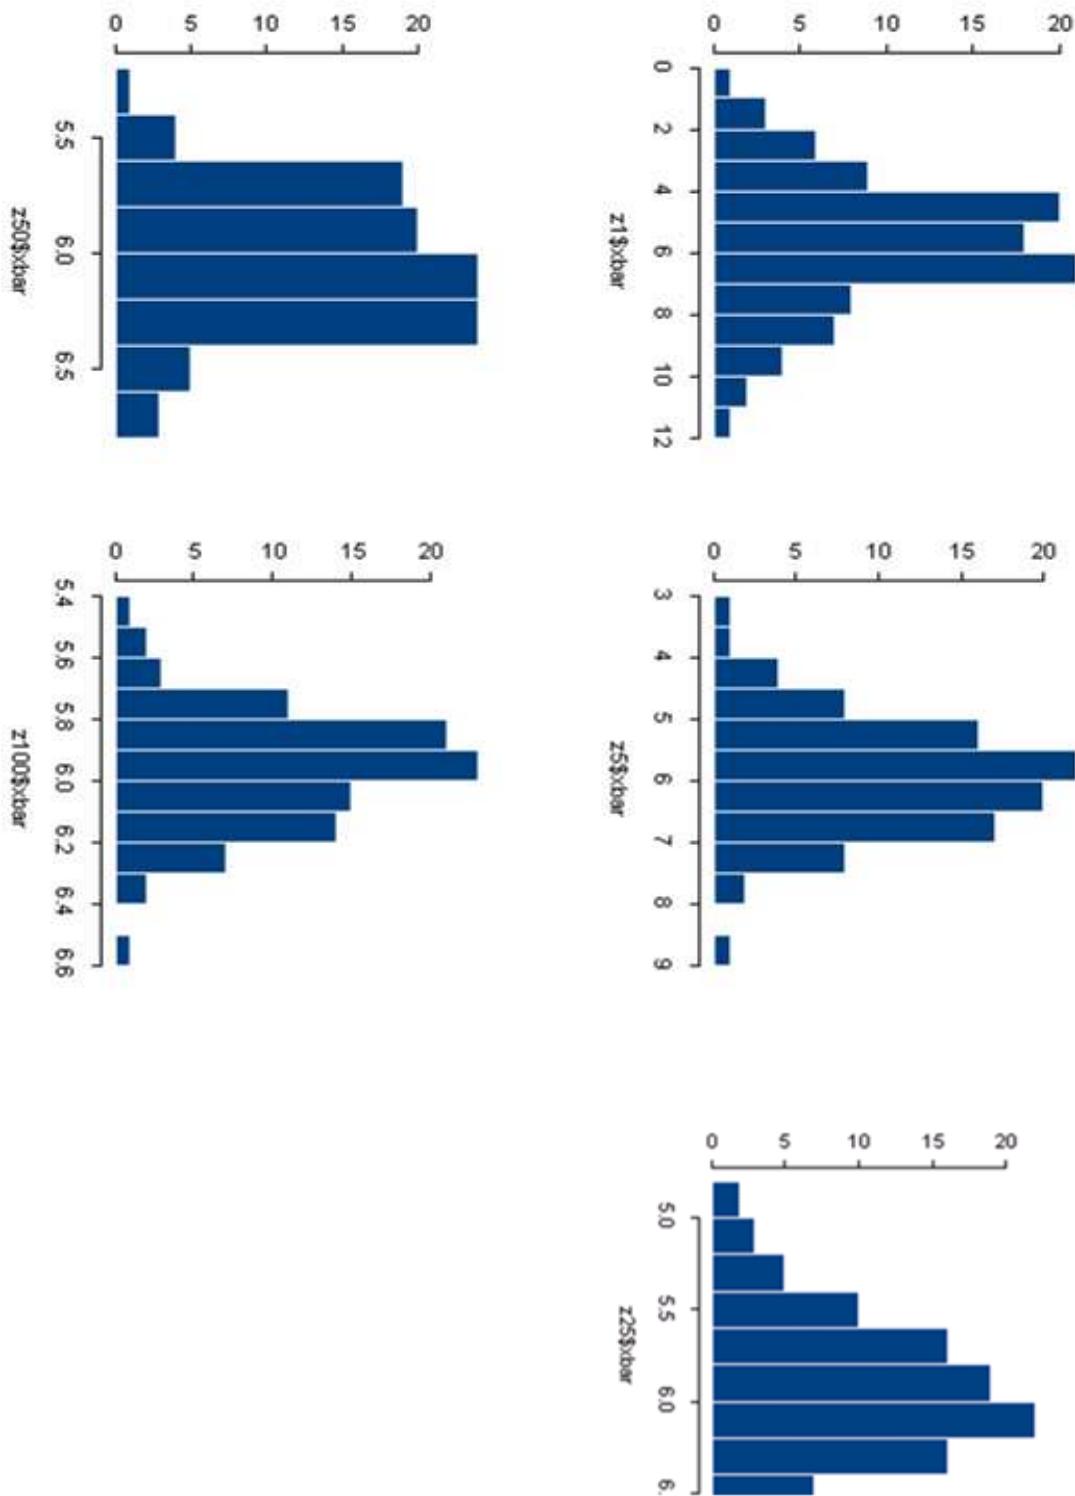
Distribution	Sample Size	\bar{X}		Normal	
		mean	S.D.	mean	S.D.
Binomial	1	3.255	1.322	3.200	1.386
	5	3.083	0.691	3.200	0.620
	25	3.201	0.261	3.200	0.277
	50	3.203	0.177	3.200	0.196
	100	3.205	0.132	3.200	0.139

نلاحظ من الجدول (٧) بأنه كلما كبر حجم العينة $n \geq 30$ كلما اقترب الوسط الحسابي والانحراف المعياري (التقريبي) للإعداد العشوائية المحسوبة (Normal) .

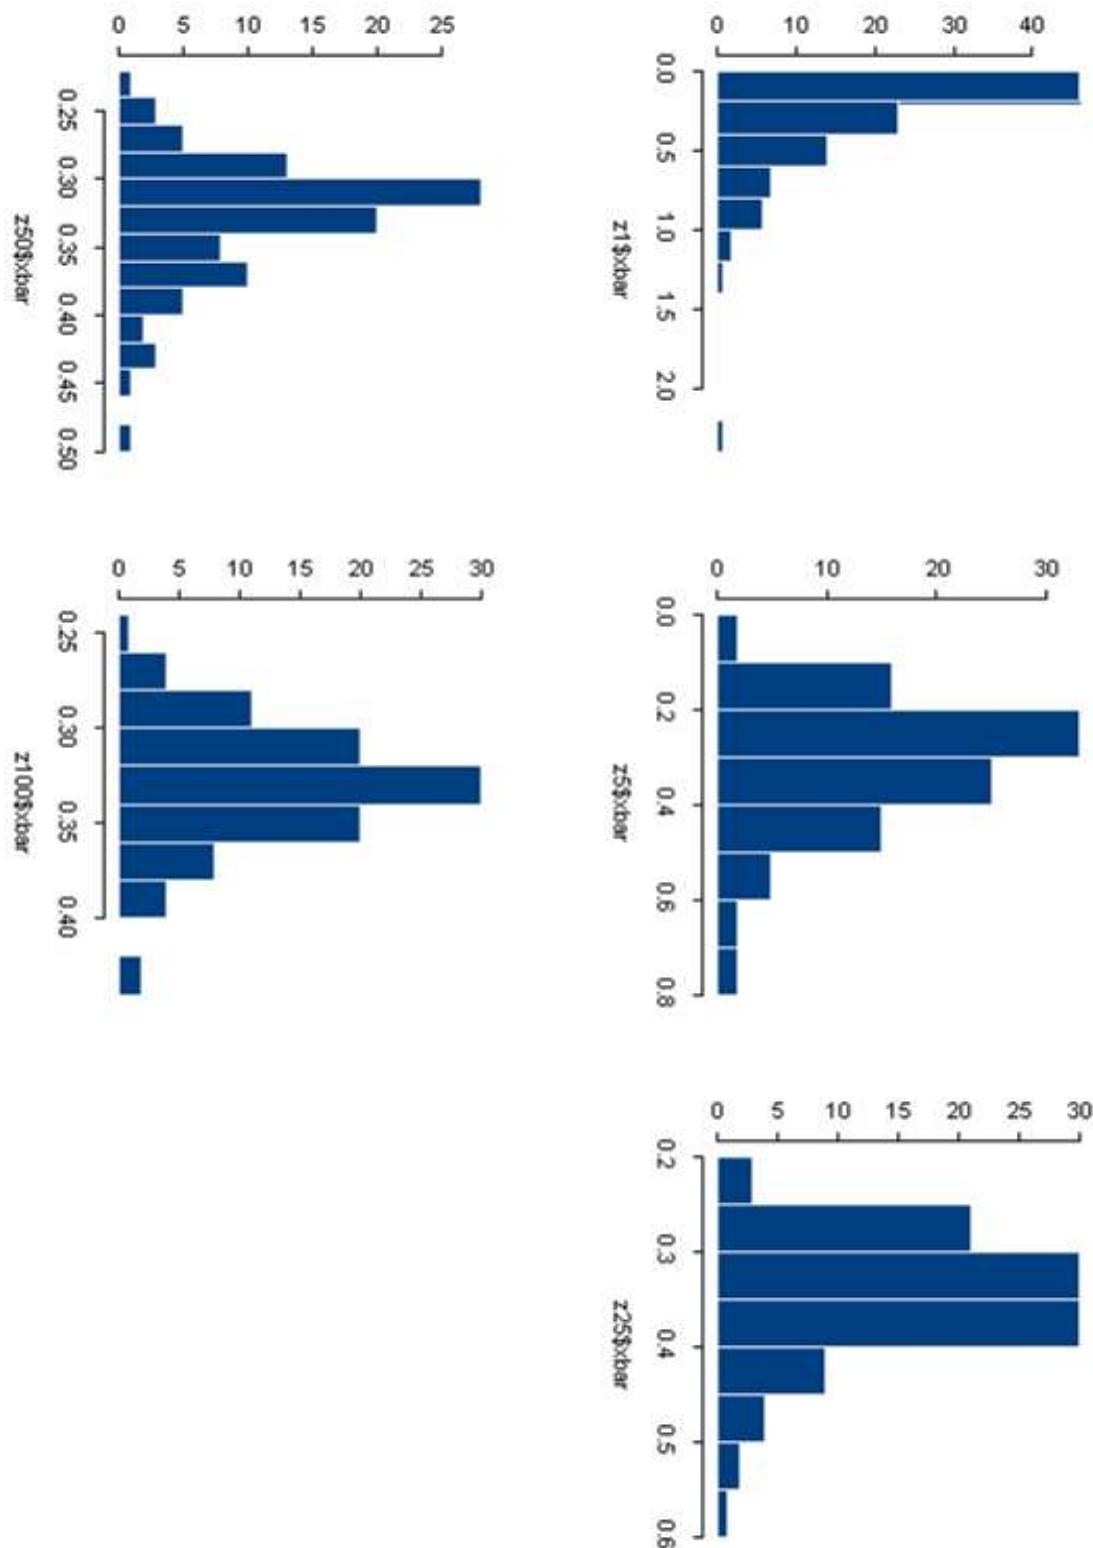
جدول (٨) : الوسط الحسابي والانحراف المعياري للتوزيع بواسون بحجم عينة
١٠٠ ، ٥٠ ، ٢٥ ، ٥ ، ١ على التوالي

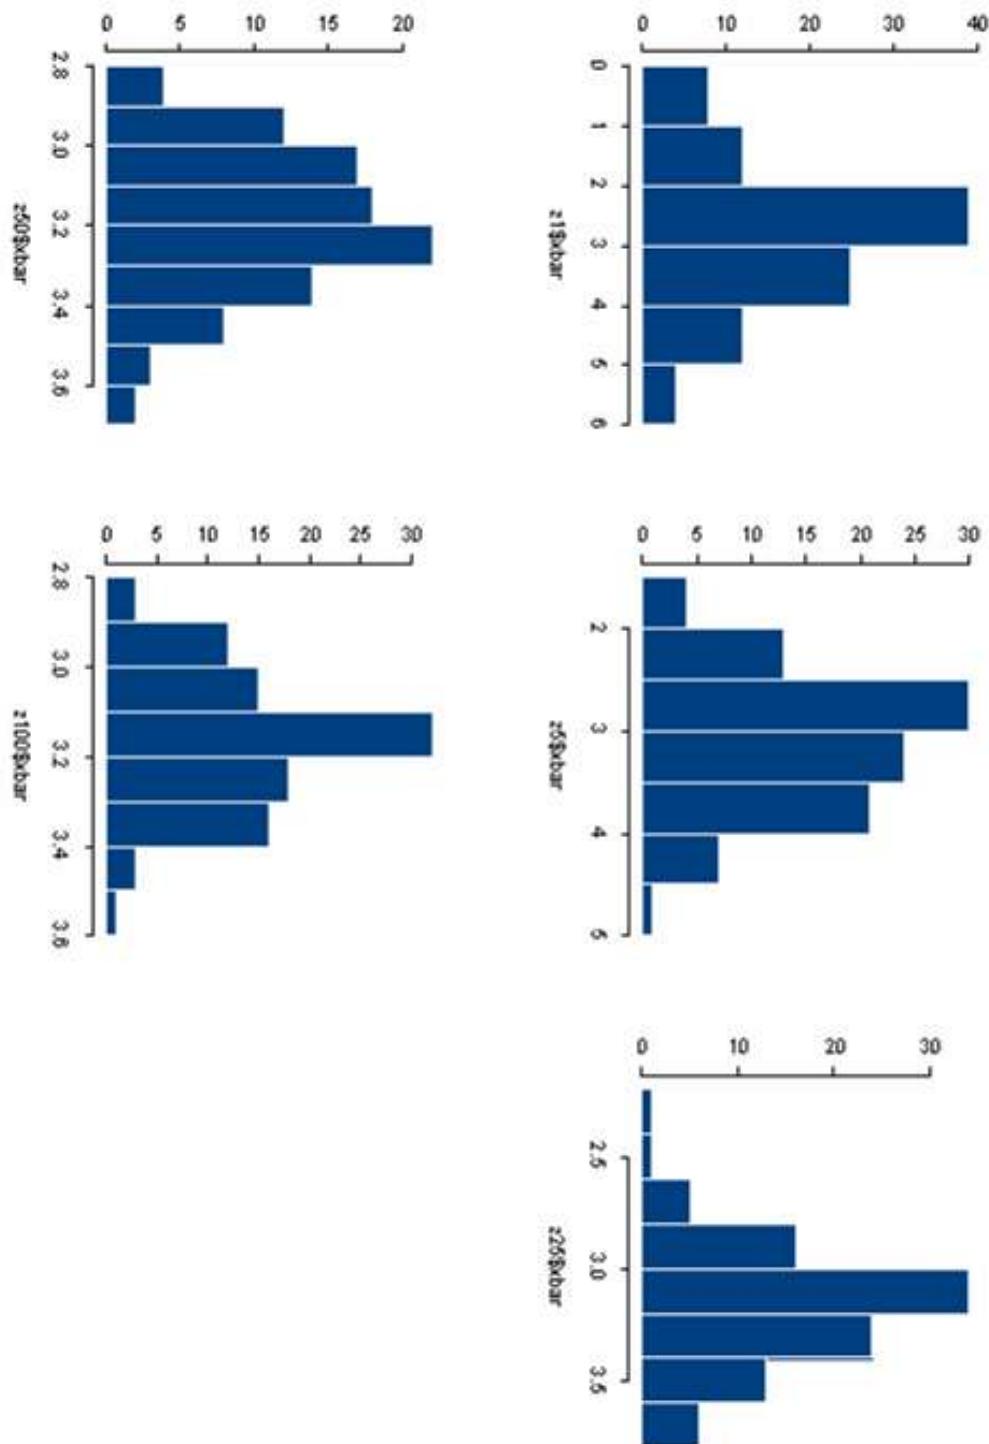
Distribution	Sample Size	\bar{X}		Normal	
		mean	S.D.	mean	S.D.
Poisson	1	2.805	1.806	3.000	1.732
	5	3.011	0.827	3.000	0.775
	25	2.973	0.325	3.000	0.346
	50	2.994	0.250	3.000	0.245
	100	3.007	0.150	3.000	0.173

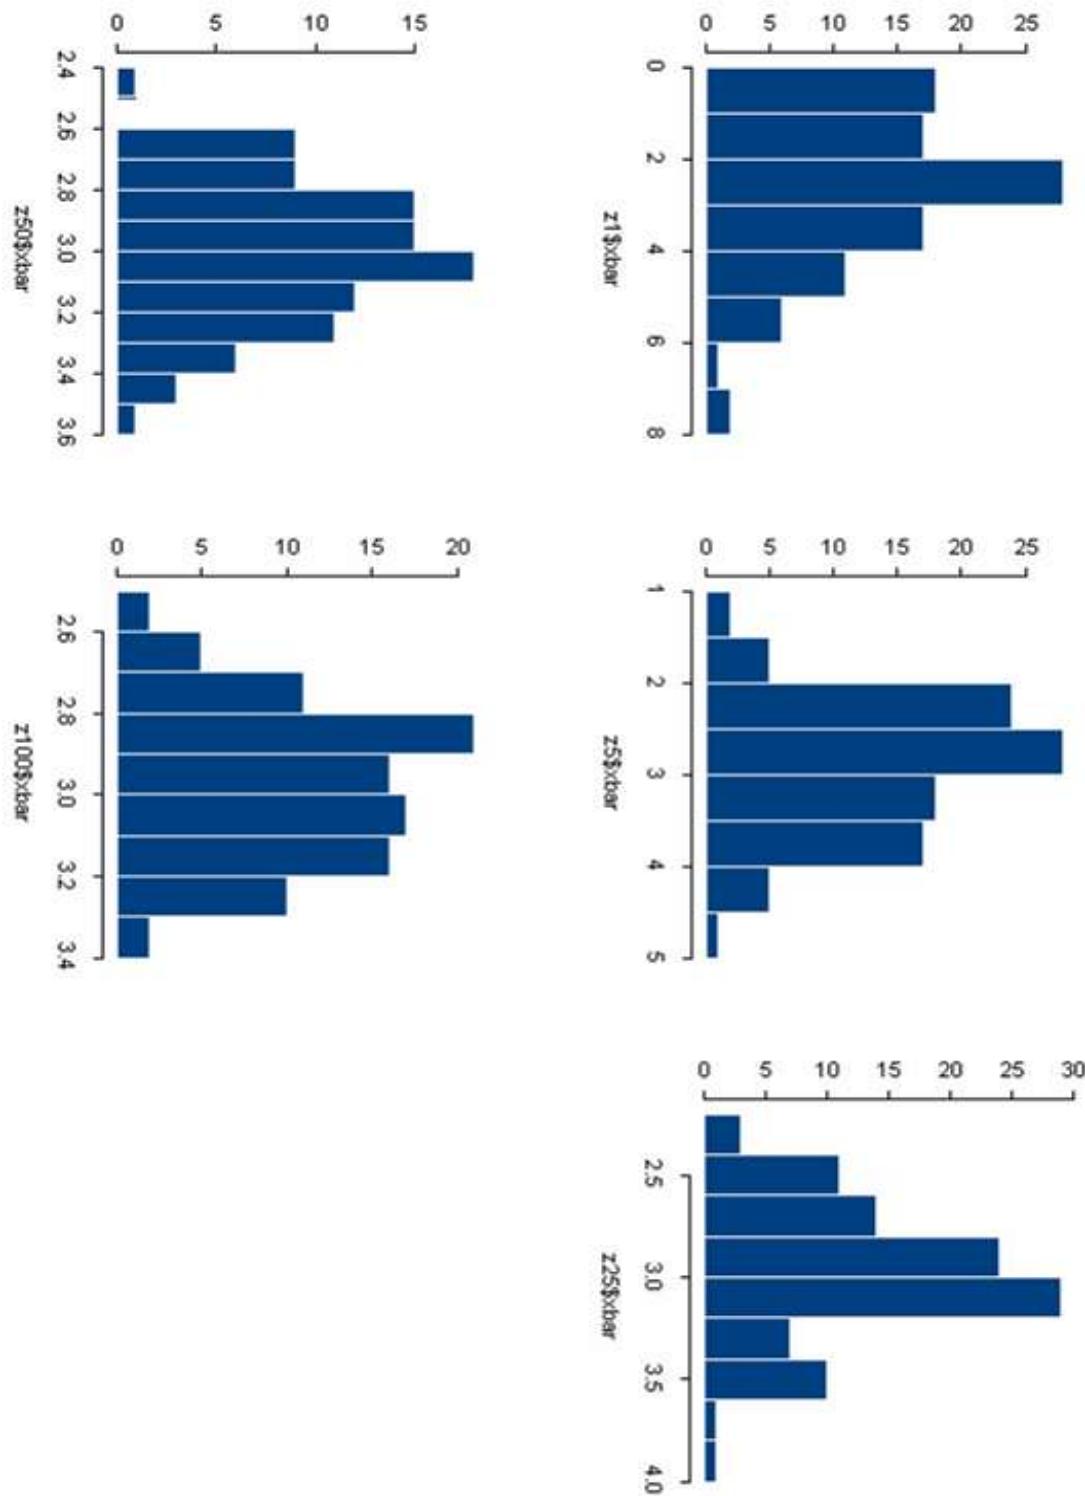
نلاحظ من الجدول (٨) بأنه كلما كبر حجم العينة $n \geq 30$ كلما اقترب الوسط الحسابي والانحراف المعياري (التقريبي) للإعداد العشوائية المحسوبة (Normal) .



المدرج التكراري لتوزيع \bar{X} في الجدول (٥)

المدرج التكراري لتوزيع \bar{X} في الجدول (٦)

المدرج التكراري لتوزيع \bar{X} في الجدول (7)



الدرج التكراري للتوزيع \bar{X} في الجدول (٨)

- ٢- نلاحظ من الدرج التكراري في الجدول (٦) المستخرج من البرنامج المذكور اعلاه ان توزيع المعاينة لـ \bar{X} للتوزيع الطبيعي كما يمكن ان تؤول الى التوزيع الاحتمالي الطبيعي عندما يكون حجم العينة كبير ($n \geq 30$) .
- ٣- نلاحظ من الدرج التكراري في الجدول (٧) المستخرج من البرنامج المذكور اعلاه ان توزيع المعاينة لـ \bar{X} للتوزيع شائي الحدين يمكن ان

- ١- نلاحظ من الدرج التكراري في الجدول (٥) المستخرج من البرنامج المذكور اعلاه ان توزيع المعاينة لـ \bar{X} للتوزيع الطبيعي يمكن ان تؤول الى التوزيع الاحتمالي الطبيعي عندما يكون حجم العينة كبير ($n \geq 30$) .

- ٢- ان العينات التي يكون حجمها اكبر من 30 مشاهدة ($n \geq 30$) ،
فإن توزيع متوسط العينات يقترب بشكل معقول من التوزيع الطبيعي .
التقريب يكون افضل كلما كبر حجم العينة .
- ٣- اذا كان المجتمع الاصلی يتبع التوزيع الطبيعي ، فإن متوسط العينة
سوف يتوزع طبيعياً لاي حجم عينة n .
- ٤- نوصي باستخدام العوائل الاساسية لاجاد التوزيعات الاحتمالية الاولية
المختلفة عند استخدام احصاء بيرز .

تؤول الى التوزيع الاحتمالي الطبيعي عندما يكون حجم العينة كبير
 $(n \geq 30)$.

٤- نلاحظ من المدرج التكراري في الجدول (٨) المستخرج من البرنامج
المذكور اعلاه ان توزيع المعاينة \bar{X} لتوزيع بواسون يمكن ان تؤول الى
التوزيع الاحتمالي الطبيعي عندما يكون حجم العينة كبير ($n \geq 30$) .

الاستنتاجات والتوصيات :

- ١- ان نظرية الغاية المركزية تمكنا من معرفة توزيع المعاينة \bar{X} حتى
في حالة عدم معرفة توزيع المتغير الاصلی .

المصادر

- 1- الناصر ، عبد المجيد حمزة و رشيد ، ظافر حسين (١٩٨٨) . " الاستدلال الاحصائي ." .
- 2- Barndorff-Nielsen, O. (1982), " Exponential Families " , in Encyclopedia of Statistical Sciences , eds. Kotz, S. and Johnson, N.L., John Wiley and Sons, NY, 587-596.
- 3- Casella, G., and Berger, R.L. (2002), " Statistical Inference " , Duxbury Press, 2nd ed., Belmont, CA.
- 4- Cox, D.R., and Hinkley, D.V. (1974), " Theoretical Statistics " , Chapman & Hall, London.
- 5- Johanson, S. (1979), " Introduction to the Theory of Regular Exponential Families" , Institute of Mathematical Statistics, University of Copenhagen, Copenhagen, Denmark.
- 6- Joshi, V.M. (1976),"On the Attainment of the Cramér-Rao Lower Bound, The Annals of Statistics, 4, 998-1002.
- 7- Le Cam, L. (1986), "The Central Limit Theorem around 1935 " , Statistical Science 1(1): 78-96.
- 8- Lehmann, E.L. (1983), " Theory of Point Estimation " , 1st ed., John Wiley and Sons, NY.
- 9- Lehmann, E.L. (1986), " Testing Statistical Hypotheses " , 2nd ed., John Wiley and Sons, NY.
- 10- Lehmann, E.L. (1999), " Elements of Large-Sample Theory " , Springer-Verlag, NY.
- 11- Olive, D.J. (2005), " Using Exponential Families in an Inference Course " Department of Mathematics , Southern Illinois University, USA.
- 12- Olive, D.J. (2006), " A Course in Statistical Theory " Department of Mathematics, Southern Illinois University, USA.
- 13- Schervish, M.J. (1995), " Theory of Statistics", Springer -Verlag, NY.
- 14- Wackerly, D., Mendenhall, W., and Scheaffer, R.(2002), " Mathematical Statistics with Applications " , 6th ed., Duxbury, 2002.
- 15- Wijsman, R.A. (1973), " On the Attainment of the Cramér-Rao Lower Bound, The Annals of Statistics, 1, 538-542.

Simulation Study for Central Limit Theorem for Exponential Families

(Received 27 / 10 / 2008 , Accepted 12 / 4 / 2009)

Abstract

This paper shows that under regularity conditions and if Y_1, \dots, Y_n are iid from a k -parameter regular exponential family with complete sufficient statistic T_n with $E(T_n) = \mu_T$, then $\sqrt{n}(T_n - \mu_T) \sim N_k(0, I(\eta))$ where $I(\eta)$ is the information matrix of the natural parameterization of the family. And also we can use the delta method in finding the Expectation and Variance for the complex function . In this paper, I generate random numbers for 2 continuous distributions and 2 discrete distributions which belong to the Exponential Family, the result of Simulation appears that the Central Limit Theorem has a good approximation for the Normal distribution .