

برنامج تمهيدي ماجستير الإحصاء التطبيقي

مادة الاحصاء الرياضي

أستاذ المادة: أ.م. د/ آمال السيد عبد الغني مبارك

الفصل السابع

طرق التقدير الاحصائية:

عمل الطالبات:

- يارا السيد تقي الدين.
- سارة غريب العدل.
- تسنيم السيد عطية.

7-2 GENERAL CONCEPTS OF POINT ESTIMATION

7-2.1 Unbiased Estimators

2-7 المفاهيم العامة لتقدير النقاط:

2.1-7 المقدرات الغير متحيزة:

يجب أن يكون المقدر "قريباً" إلى حد ما من القيمة الحقيقية للمعلمة غير المعروفة. نقول بشكل عام إن $\hat{\theta}$ مقدر غير متحيز إذا كانت القيمة المتوقعة لـ $\hat{\theta}$ تساوي θ . وهذا يعادل القول بأن متوسط التوزيع الاحتمالي لـ $\hat{\theta}$ (أو متوسط توزيع العينات $\hat{\theta}$) يساوي θ .

Definition

مقدر النقاط $\hat{\theta}$ هو مقدر غير متحيز للمعلمة θ إذا كان:

$$E(\hat{\theta}) = \theta \quad (7-1)$$

إذا كان المقدر متحيز ، فإن الفرق

$$E(\hat{\theta}) - \theta \quad (7-2)$$

يسمى مقدار التحيز.

عندما يكون المقدر غير متحيز ، يكون الانحياز صفراً ؛ $E(\hat{\theta}) - \theta = 0$.

EXAMPLE 7-1

افتراض أن X متغير عشوائي بمتوسط μ وتباين σ^2 . افترض ان X_1, X_2, \dots, X_n عينة عشوائية حجمها n من المجتمع ممثلة بـ X . وضح أن متوسط العينة \bar{X} وتباين العينة S^2 هما مقدرين غير متحيزين لـ μ ، و σ^2 على التوالي. ضع في اعتبارك ان متوسط العينة هو مقدر غير متحيز لمتوسط المجتمع μ . $E(\bar{X}) = \mu$. الآن فكر في تباين العينة. نحن لدينا

$$\begin{aligned} E(S^2) &= E \left[\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} \right] = \frac{1}{n-1} E \sum_{i=1}^n (X_i - \bar{X})^2 \\ &= \frac{1}{n-1} E \sum_{i=1}^n (X_i^2 + \bar{X}^2 - 2\bar{X}X_i) = \frac{1}{n-1} E \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2 \right) \end{aligned}$$

$$= \frac{1}{n-1} \left[\sum_{i=1}^n E(X_i^2) - nE(\bar{X}^2) \right]$$

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

$$E(\bar{X}^2) = \mu^2 + \sigma^2/n,$$

$$E(S^2) = \frac{1}{n-1} \left[\sum_{i=1}^n (\mu^2 + \sigma^2) - n(\mu^2 + \sigma^2/n) \right]$$

$$= \frac{1}{n-1} (n\mu^2 + n\sigma^2 - n\mu^2 - \sigma^2)$$

$$= \sigma^2$$

ولذلك، فإن تباين العينة S^2 هو مقدر غير متحيز لتباين المجتمع σ^2 .

7-2.2 Proof That S is a Biased Estimator of σ (CD Only)

7-2.3 Variance of a Point Estimator

7-2.2 إثبات أن S هو مقدر متحيز لـ σ (CD فقط)

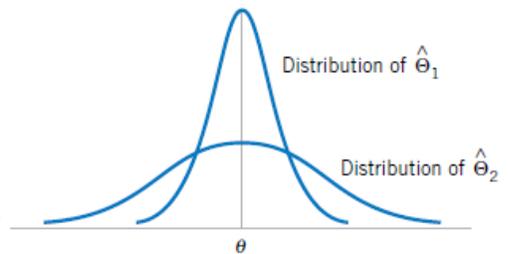
7-2.3 تباين مقدر النقاط:

لنفترض ان $\hat{\theta}_1$ ، و $\hat{\theta}_2$ هم مقدرات غير متحيزة . هذا يشير إلى أن توزيع كل مقدر يتمحور حول القيمة الحقيقية لـ θ . ومع ذلك ، قد يختلف تباين هذه التوزيعات. يوضح الشكل 7-1 الوضع. نظرًا لأن $\hat{\theta}_1$ له تباين أقل من المقدر $\hat{\theta}_2$ ، من المرجح أن $\hat{\theta}_1$ ينتج تقديرًا قريبًا من القيمة الحقيقية θ . من المبادئ المنطقية للتقدير ، عند الاختيار من بين العديد من المقدرات ، اختيار المقدر الذي يحتوي على الحد الأدنى من التباين.

Definition

إذا أخذنا بعين الاعتبار جميع المقدرات غير المتحيزة ، فإن المقدر الذي لديه أصغر تباين يُطلق عليه المقدر الأدنى غير المتحيز للتغير (MVUE).

Figure 7-1 The sampling distributions of two unbiased estimators $\hat{\theta}_1$ and $\hat{\theta}_2$.



Standard Error: Reporting a Point Estimate 2.4-7

2.4-7 الخطأ المعياري: الإبلاغ عن تقدير نقطة:

عندما يتم الإبلاغ عن القيمة العددية أو تقدير النقطة للمعلمة ، فمن المستحسن عادة إعطاء فكرة عن دقة التقدير. مقياس الدقة المستخدم عادة هو الخطأ المعياري للمُقَدَّر الذي تم استخدامه.

Definition

الخطأ المعياري للمُقَدَّر $\hat{\theta}$ هو انحرافه المعياري بواسطة $\sigma_{\hat{\theta}} = \sqrt{V(\hat{\theta})}$. إذا تضمن الخطأ المعياري معلمات غير معروفة يمكن تقديرها ، فإن استبدال هذه القيم $\sigma_{\hat{\theta}}$ ينتج خطأ معيارياً تقديرياً ، يُشار إليه بـ $\hat{\sigma}_{\hat{\theta}}$.

في بعض الأحيان يتم الإشارة إلى الخطأ المعياري المقدر بواسطة $s_{\hat{\theta}}$ أو $se(\hat{\theta})$. لنفترض أننا نأخذ عينات من توزيع طبيعي بمتوسط μ وتباين σ^2 . الآن التوزيع طبيعي لـ \bar{X} مع المتوسط μ والتباين σ^2/n ، وبالتالي فإن الخطأ المعياري لـ \bar{X} هو

$$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

إذا لم نعرف σ ولكن استبدلنا نموذج الانحراف المعياري S في المعادلة أعلاه ، فسيكون الخطأ المعياري المقدر لـ \bar{X} هو

$$\hat{\sigma}_{\bar{X}} = \frac{S}{\sqrt{n}}$$

7-3 METHODS OF POINT ESTIMATION

3-7 طرق تقدير النقاط:

لا تقدم تعريفات عدم التحيز والخصائص الأخرى للمُقَدَّرَات أي توجيهات حول كيفية الحصول على مُقَدَّرَات جيدة. في هذا القسم ، نناقش طريقتين للحصول على مقدرات النقاط: طريقة العزوم وطريقة الاحتمالية القصوى. تكون تقديرات الاحتمالية القصوى مفضلة بشكل عام على مقيمي العزوم لأن لها خصائص كفاءة أفضل. ومع ذلك ، في بعض الأحيان يكون من السهل أحياناً حساب المقدرات الفورية. كلتا الطريقتين يمكن أن تنتج مقدرات نقطية غير متحيزة.

7-3.1 Method of Moments

طريقة العزوم:

الفكرة العامة وراء طريقة العزوم هي مساواة عزوم المجتمع ، والتي يتم تعريفها من حيث القيم المتوقعة ، بعزوم العينة المقابلة. ستكون عزوم المجتمع دوال لمعلومات غير معروفة. ثم يتم حل هذه المعادلات للحصول على مقدرات المعلومات غير المعروفة.

Definition

لنكن X_1, X_2, \dots, X_n عينة عشوائية من توزيع الاحتمال $f(x)$ ، حيث يمكن أن تكون $f(x)$ دالة كثافة احتمالية منفصلة أو دالة كثافة احتمالية مستمرة.

k th هي عزوم المجتمع (أو عزوم التوزيع) وهي $E(X^k)$ ، $k = 1, 2, \dots$ ، عزوم العينة k th المقابلة هي $(1/n) \sum_{i=1}^n X_i^k, k = 1, 2, \dots$

للتوضيح ، أول عزوم للمجتمع هو $E(X) = \mu$ ، وعزم العينة الأولى هو $(1/n) \sum_{i=1}^n X_i = \bar{X}$. وهكذا ، من خلال مساواة عزوم العينة والمجتمع ، نجد أن $\hat{\mu} = \bar{X}$. وهذا يعني أن متوسط العينة هو العزم المقدر لمتوسط المجتمع . في الحالة العامة ، ستكون عزوم المجتمع دوال لمعلومات التوزيع غير المعروفة ، على سبيل المثال ، $\theta_1, \theta_2, \dots, \theta_m$.

EXAMPLE 7-3

لنفترض أن X_1, X_2, \dots, X_n عينة عشوائية من توزيع أسي مع معلمة λ . الآن هناك معلمة واحدة فقط لتقديرها ، لذا يجب أن نساوي $E(X)$ بـ \bar{X} . بالنسبة إلى التوزيع الأسي $E(X) = 1/\lambda$ ، لذلك $E(X) = \bar{X}$ ينتج عن ذلك $1/\lambda = \bar{X}$ ، العزم المقدر $\hat{\lambda} = 1/\bar{X}$.

7-3.2 Method of Maximum Likelihood

طريقة الامكان الاعظم:

واحدة من أفضل الطرق للحصول على مقدر النقاط للمعلمة هي طريقة الامكان الاعظم. تم تطوير هذه التقنية في عشرينيات القرن الماضي. كما يوحي الاسم ، سيكون المقدر هو قيمة المعلمة التي تزيد من دالة الاحتمال.

Definition

افترض أن X متغير عشوائي بتوزيع احتمالي $f(x; \theta)$ ، حيث θ معلمة واحدة غير معروفة. افترض x_1, x_2, \dots, x_n تكون القيم الملاحظة في عينة عشوائية من الحجم n . ثم تكون دالة احتمالية العينة

$$L(\theta) = f(x_1; \theta) \cdot f(x_2; \theta) \cdot \dots \cdot f(x_n; \theta) \quad (7-5)$$

لاحظ أن دالة الاحتمالية هي الآن دالة للمعلمة غير المعروفة θ . الحد الأقصى لتقدير الاحتمالية ل θ هو قيمة θ التي تزيد من دالة الاحتمالية $L(\theta)$.

في حالة المتغير العشوائي المنفصل ، يكون تفسير دالة الاحتمال واضحًا. دالة الاحتمالية للعينة $L(\theta)$ هي الاحتمال فقط

$$P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n)$$

EXAMPLE 7-6

افتراض X متغيرًا عشوائيًا لـ Bernoulli. دالة الكتلة الاحتمالية هي

$$f(x; p) = \begin{cases} p^x(1-p)^{1-x}, & x = 0, 1 \\ 0, & \text{otherwise} \end{cases}$$

حيث p هي المعلمة المراد تقديرها. دالة الاحتمالية لعينة عشوائية من الحجم n هي

$$\begin{aligned} L(p) &= p^{x_1}(1-p)^{1-x_1} p^{x_2}(1-p)^{1-x_2} \dots p^{x_n}(1-p)^{1-x_n} \\ &= \prod_{i=1}^n p^{x_i}(1-p)^{1-x_i} = p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \end{aligned}$$

نلاحظ أنه إذا زاد \hat{p} من $L(p)$ إلى أقصى حد ، فإن \hat{p} يزيد أيضًا من $\ln L(p)$ وبالتالي

$$\ln L(p) = \left(\sum_{i=1}^n x_i \right) \ln p + \left(n - \sum_{i=1}^n x_i \right) \ln(1-p)$$

$$\frac{d \ln L(p)}{dp} = \frac{\sum_{i=1}^n x_i}{p} - \frac{\left(n - \sum_{i=1}^n x_i \right)}{1-p}$$

يساوي ذلك صفرًا ويحل عوائد p وبالتالي $\hat{p} = (1/n) \sum_{i=1}^n x_i$ ، فإن الحد الأقصى لمقدر الاحتمالية لـ p هو

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$$

7-3.3 Bayesian Estimation of Parameters (CD Only)

يستخدم هذا الكتاب طرق الاستدلال الإحصائي على أساس المعلومات الواردة في بيانات العينة. في الواقع ، تفسر هذه الطرق الاحتمالات على أنها ترددات نسبية. في بعض الأحيان نسمي الاحتمالات التي يتم تفسيرها بهذه الطريقة الاحتمالات الموضوعية. هناك نهج آخر للاستدلال الإحصائي ، يسمى نهج بايزي ، يجمع بين معلومات العينة مع

معلومات أخرى قد تكون متاحة قبل جمع العينة. في هذا القسم نوضح بإيجاز كيف يمكن استخدام هذا النهج في تقدير المعلمات.

افترض أن المتغير العشوائي X لديه توزيع احتمالي يكون دالة لمعلمة واحدة θ . سنكتب هذا التوزيع الاحتمالي حيث يشير هذا التدوين إلى أن الشكل الدقيق لتوزيع $f(x|\theta)$ مشروط بالقيمة المخصصة له θ . يتألف النهج الكلاسيكي للتقدير من أخذ عينة عشوائية من الحجم n من هذا التوزيع ثم استبدال قيم العينة x_i في المُقدِّر لـ θ . كان من الممكن تطوير هذا المُقدِّر باستخدام نهج الاحتمالية القصوى ، على سبيل المثال.

لنفترض أن لدينا بعض المعلومات الإضافية حول θ يمكننا تلخيص تلك المعلومات في شكل توزيع احتمالي لـ θ ، على سبيل المثال ، $f(\theta)$ غالبًا ما يطلق على هذا التوزيع الاحتمالي التوزيع القبلي لـ θ ، ونفترض أن متوسط التوزيع القبلي هو μ_0 وأن التباين هو σ_0^2 . هذا مفهوم جديد للغاية فيما يتعلق ببقية هذا الكتاب لأننا الآن ننظر إلى المعلمة θ كمتغير عشوائي. غالبًا ما تسمى الاحتمالات المرتبطة بالتوزيع القبلي بالاحتمالات الذاتية ، لأنها تعكس عادة درجة اعتقاد المحلل فيما يتعلق بالقيمة الحقيقية لـ θ . يستخدم نهج بايزي للتقدير التوزيع القبلي للعينة $f(\theta)$ ، والتوزيع الاحتمالي المشترك للعينة ، على سبيل المثال $f(x_1, x_2, \dots, x_n | \theta)$ لإيجاد توزيع بعدي لـ θ ، على سبيل المثال $f(\theta | x_1, x_2, \dots, x_n)$ ، يحتوي هذا التوزيع البعدي على معلومات من العينة والتوزيع القبلي لـ θ . بمعنى ما ، فإنه يعبر عن درجة اعتقادنا فيما يتعلق بالقيمة الحقيقية θ بعد ملاحظة بيانات العينة. من السهل من الناحية المفاهيمية العثور على التوزيع الخلفي. التوزيع الاحتمالي المشترك للعينة X_1, X_2, \dots, X_n والمعلمة θ (تذكر أن θ متغير عشوائي) هو

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

والتوزيع الهامشي لـ X_1, X_2, \dots, X_n هو

$$f(x_1, x_2, \dots, x_n) = \begin{cases} \sum_{\theta} f(x_1, x_2, \dots, x_n, \theta), & \theta \text{ discrete} \\ \int_{-\infty}^{\infty} f(x_1, x_2, \dots, x_n, \theta) d\theta, & \theta \text{ continuous} \end{cases}$$

لذلك ، التوزيع المطلوب هو

$$f(\theta | x_1, x_2, \dots, x_n) = \frac{f(x_1, x_2, \dots, x_n, \theta)}{f(x_1, x_2, \dots, x_n)}$$

نحدد مقدر بايز θ بالقيمة $\tilde{\theta}$ التي تتوافق مع متوسط التوزيع البعدي $f(\theta | x_1, x_2, \dots, x_n)$.

في بعض الأحيان ، يمكن تحديد متوسط التوزيع البعدي لـ θ بسهولة. كدالة $f(\theta | x_1, \dots, x_n)$ ، هي دالة كثافة احتمالية و x_1, \dots, x_n هي مجرد ثوابت. لأن θ تدخل $f(\theta | x_1, \dots, x_n)$ فقط من خلال $f(x_1, \dots, x_n, \theta)$ ما إذا تم الاعتراف كدالة لـ θ . كدالة احتمالية معروفة ، يمكن استنتاج الوسط البعدي θ من التوزيع المعروف جيدًا بدون تكامل أو حتى حساب $f(x_1, \dots, x_n)$.

EXAMPLE S7-2

افترض X_1, X_2, \dots, X_n تكون عينة عشوائية من التوزيع الطبيعي مع المتوسط μ والتباين σ^2 ، حيث يكون μ غير معروف و σ^2 معروف. افترض أن التوزيع القبلي توزيع طبيعي مع متوسط μ_0 والتباين σ_0^2 ؛ هذا هو

$$f(\mu) = \frac{1}{\sqrt{2\pi\sigma_0}} e^{-(\mu - \mu_0)^2/(2\sigma_0^2)} = \frac{1}{\sqrt{2\pi\sigma_0^2}} e^{-(\mu^2 - 2\mu_0\mu + \mu_0^2)/(2\sigma_0^2)}$$

التوزيع الاحتمالي المشترك للعينة هو

$$\begin{aligned} f(x_1, x_2, \dots, x_n | \mu) &= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-(1/2\sigma^2)\sum_{i=1}^n (x_i - \mu)^2} \\ &= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-(1/2\sigma^2)(\sum x_i^2 - 2\mu\sum x_i + n\mu^2)} \end{aligned}$$

وبالتالي ، فإن التوزيع الاحتمالي المشترك للعينة μ هو

$$\begin{aligned} f(x_1, x_2, \dots, x_n, \mu) &= \frac{1}{(2\pi\sigma^2)^{n/2} \sqrt{2\pi\sigma_0^2}} e^{-(1/2)[(1/\sigma_0^2 + n/\sigma^2)\mu^2 - (2\mu_0/\sigma_0^2 + 2\sum x_i/\sigma^2)\mu + \sum x_i^2/\sigma^2 + \mu_0^2/\sigma_0^2]} \\ &= e^{-(1/2)\left[\left(\frac{1}{\sigma_0^2} + \frac{1}{\sigma^2/n}\right)\mu^2 - 2\left(\frac{\mu_0}{\sigma_0^2} + \frac{\bar{x}}{\sigma^2/n}\right)\mu\right]} h_1(x_1, \dots, x_n, \sigma^2, \mu_0, \sigma_0^2) \end{aligned}$$

عند استكمال المربع في الأس

$$f(x_1, x_2, \dots, x_n, \mu) = e^{-(1/2)\left(\frac{1}{\sigma_0^2} + \frac{1}{\sigma^2/n}\right)\left[\mu^2 - \left(\frac{(\sigma^2/n)\mu_0}{\sigma_0^2 + \sigma^2/n} + \frac{\bar{x}\sigma_0^2}{\sigma_0^2 + \sigma^2/n}\right)\mu\right]^2} h_2(x_1, \dots, x_n, \sigma^2, \mu_0, \sigma_0^2)$$

حيث $h_2(x_1, \dots, x_n, \sigma^2, \mu_0, \sigma_0^2)$ هي دالة للقيم المرصودة $\sigma^2, \mu_0,$ and σ_0^2 ، الآن ، لأن $f(x_1, \dots, x_n)$ لا تعتمد على μ :

$$f(\mu | x_1, \dots, x_n) = e^{-\frac{1}{2} \left(\frac{1}{\sigma_0^2} + \frac{1}{\sigma^2/n} \right) \left[\mu^2 - \frac{(\sigma^2/n)\mu_0 + \sigma_0^2 \bar{x}}{\sigma_0^2 + \sigma^2/n} \right]} h_3(x_1, \dots, x_n, \sigma^2, \mu_0, \sigma_0^2)$$

يتم التعرف على ذلك كدالة كثافة احتمالية عادية ذات متوسط بعدي

$$\frac{(\sigma^2/n)\mu_0 + \sigma_0^2 \bar{x}}{\sigma_0^2 + \sigma^2/n}$$

والتباين البعدي

$$\left(\frac{1}{\sigma_0^2} + \frac{1}{\sigma^2/n} \right)^{-1} = \frac{\sigma_0^2(\sigma^2/n)}{\sigma_0^2 + \sigma^2/n}$$

وبالتالي ، فإن تقدير Bayes هو μ متوسط مرجح قدره μ_0 and \bar{x} . لأغراض المقارنة ، لاحظ أن الحد الأقصى لتقدير الاحتمالية لـ μ is $\hat{\mu} = \bar{x}$.