





نظرية التقدير



المحتويات

تمهيد

1. النموذج الإحصائي الاحتمالي ومهام الإحصاء الرياضي 1
2. المصطلحات والرموز 5
3. رموز بعض النماذج الإحصائية الأساسية 10

الفصل الأول: مبرهنات النهاية

- 1.1 مقدمة 13
- 2.1 تقارب متتاليات متغيرات عشوائية 14
- 3.1 متباينة تشيبيشيف 17
- 4.1 قانون الأعداد الكبيرة الضعيف 21
 - 1.4.1 صيغة تشيبيشيف لقانون الأعداد الكبيرة الضعيف 22
 - 2.4.1 صيغة بيرنولي لقانون الأعداد الكبيرة الضعيف 24
 - 3.4.1 صيغة بواسون لقانون الأعداد الكبيرة الضعيف 25
 - 4.4.1 صيغة ماركوف لقانون الأعداد الكبيرة الضعيف 26
- 5.1 قانون الأعداد الكبيرة القوي 27
- 6.1 مبرهنات النهاية المركزية 28
 - 1.6.1 مبرهنة النهاية المركزية بصيغة ليابونوف 29
 - 2.6.1 مبرهنة النهاية المركزية بصيغة موافر ولابلاس 33
- تمارين 34

الفصل الثاني: بعض النماذج الإحصائية الخاصة

- 1.2 مقدمة 37
- 2.2 بعض النماذج الإحصائية المنقطعة الخاصة 38

| | | |
|----|---|-------|
| 38 | نموذج بيرنولي | 1.2.2 |
| 39 | نموذج ذي الحدين | 2.2.2 |
| 40 | نموذج بواسون | 3.2.2 |
| 41 | النموذج فوق الهندسي | 4.2.2 |
| 42 | نموذج ذي الحدين السالب | 5.2.2 |
| 43 | النموذج المتعدد الحدود | 6.2.2 |
| | بعض النماذج الإحصائية المستمرة الخاصة | 3.2 |
| 44 | النموذج المنتظم | 1.3.2 |
| 45 | النموذج الطبيعي العام | 2.3.2 |
| 48 | النموذج الطبيعي الثنائي العام | 3.3.2 |
| 50 | النموذج الطبيعي المتعدد العام | 4.3.2 |
| 51 | نموذج جاما | 5.3.2 |
| 57 | نموذج χ^2 | 6.3.2 |
| 63 | نموذج β | 7.3.2 |
| 65 | نموذج F | 8.3.2 |
| 67 | نموذج t | 9.3.2 |

الفصل الثالث: المعاينة وتوزيعات المعاينة

| | | |
|----|---|-------|
| 71 | مقدمة | 1.3 |
| 71 | الاستدلال الإحصائي | 2.3 |
| 74 | العينة العشوائية وتوزيعها | 3.3 |
| 75 | التوزيع التجريبي | 4.3 |
| 77 | دالة التوزيع التجريبي | 1.4.3 |
| 80 | التمثيل البياني للتوزيعات التجريبية | 2.4.3 |
| 82 | الإحصاء وعزوم العينة | 5.3 |
| 85 | متوسط وتباين متوسط العينة | 6.3 |

| | | |
|-----|---|--------|
| 86 | متوسط وتباين وتباين العينة | 7.3 |
| 89 | توزيعات المعاينة لمجموع ومتوسط العينة | 8.3 |
| 89 | طريقة التكرار | 1.8.3 |
| 90 | طريقة الدالة المميزة | 2.8.3 |
| 93 | توزيعات المعاينة لمجموع ومتوسط عينة في بعض الحالات الخاصة | 3.8.3 |
| 96 | توزيعات المعاينة لصيغ تربيعية معينة في عينات من توزيع طبيعي | 9.3 |
| 97 | الصيغ الخطية والتربيعية في متغيرات عشوائية طبيعية | 1.9.3 |
| 100 | توزيعات المعاينة لصيغ تربيعية في متغيرات عشوائية طبيعية | 2.9.3 |
| 106 | الإحصاءات المرتبة | 10.3 |
| 107 | التوزيع الاحتمالي الهامشي لإحصاء مرتب | 1.10.3 |
| 110 | التوزيع المشترك لإحصائين مرتبين | 2.10.3 |
| 115 | توزيع دوال في الإحصاءات المرتبة | 11.3 |
| 117 | توزيع وسيط العينة | 1.11.3 |
| 119 | توزيع مدى ونصف مدى العينة | 2.11.3 |
| 121 | توزيع المعاينة لـ $F^*(x)$ | 12.3 |
| 123 | المشمولات أو المغطيات | 13.3 |
| 126 | المعاينة في حالة عينات كبيرة | 14.3 |
| 127 | تقارب عزوم العينة بالاحتمال | 1.14.3 |
| 130 | التوزيعات التقريبية للعزوم الابتدائية للعينة | 2.14.3 |
| 132 | التوزيع التقريبي لـ $F_n^*(x)$ | 3.14.3 |
| 138 | التوزيع المقارب لوسيط العينة | 4.14.3 |
| 140 | تمارين | |

الفصل الرابع: الإحصاءات الكافية والمعلومات في العينة

| | | |
|-----|-------------------|-----|
| 147 | مقدمة | 1.4 |
| 149 | الإحصاءات الكافية | 2.4 |

| | | |
|-----|---|-----|
| 169 | توزيع إحصاء بشرط معرفة إحصاء كافي | 3.4 |
| 171 | عائلة التوزيعات الأسية والإحصاءات الكافية | 4.4 |
| 176 | الكفاية والتمام | 5.4 |
| 179 | دالة المعقولة | 6.4 |
| 184 | معلومات فيشر | 7.4 |
| 193 | تمارين | |

الفصل الخامس: خواص مقدرات النقطة

| | | |
|-----|---|-----|
| 197 | مقدمة | 1.5 |
| 198 | التقدير الإحصائي بنقطة | 2.5 |
| 202 | متوسط مربع الخطأ | 3.5 |
| 203 | المقدرات غير المتحيزة | 4.5 |
| 214 | المقدرات المتسقة | 5.5 |
| 221 | المقدر الأكفأ | 6.5 |
| 231 | معايير كفاءة المقدرات المبنية على متباينة كرامر وراو وتعميماتها | 7.5 |
| 231 | 1.7.5 متباينة كرامر وراو والمقدر الأكفأ | |
| 245 | 2.7.5 عائلة النماذج الأسية والمقدر الأكفأ | |
| 249 | 3.7.5 متباينة بختشاري والمقدر الأكفأ | |
| 252 | 4.7.5 معيار الكفاءة في حالة معلمة متعددة الأبعاد | |
| 259 | 8.5 الكفاية، التمام والمقدرات الأكفأ | |
| 260 | 1.8.5 الكفاية والمقدرات الأكفأ | |
| 267 | تمارين | |

الفصل السادس: طرق إيجاد المقدرات النقطية

| | | |
|-----|--|-----|
| 271 | مقدمة | 1.6 |
| 271 | طريقة المعقولة العظمى | 2.6 |
| 291 | 1.2.6 طريقة التراكم لحساب تقدير المعقولة العظمى بالتقريب | |

| | | |
|-----|--|-------|
| 293 | الخواص التقاربية لمقدر المعقولة العظمى | 2.2.6 |
| 303 | طريقة العزوم | 3.6 |
| 308 | طرق أخرى | 4.6 |
| 308 | طريقة χ^2 الصغرى | 1.4.6 |
| 313 | طريقة المسافة الصغرى | 2.4.6 |
| 315 | مقدر بتمان لمعلمة الموضوع والمقياس | 3.4.6 |
| 322 | تمارين | |

الفصل السابع: التقدير بفترة

| | | |
|-----|--|-------|
| 327 | مقدمة | 1.7 |
| 328 | فترات الثقة | 2.7 |
| 330 | طريقة الكمية المحورية | 3.7 |
| 334 | بناء فترات الثقة باستخدام كمية محورية في حال المعاينة من توزيع طبيعي | 4.7 |
| 335 | فترة الثقة لمتوسط نموذج طبيعي I | 1.4.7 |
| 337 | فترة الثقة لتباين النموذج الطبيعي II | 2.4.7 |
| 342 | فترة الثقة للمتوسط والتباين في النموذج الطبيعي العام | 3.4.7 |
| 347 | فترة الثقة للفرق بين متوسطي نموذجين طبيعيين | 4.4.7 |
| 349 | فترة الثقة للفرق $(\mu_2 - \mu_1)$ في حالة المعاينة من توزيع طبيعي ثنائي | 5.4.7 |
| 350 | فترة الثقة للنسبة بين تبايني نموذجين طبيعيين | 6.4.7 |
| 351 | طرق إيجاد كمية محورية | 5.7 |
| 363 | طريقة الإحصاء T | 6.7 |
| 364 | حالة T متغير مستمر | 1.6.7 |
| 375 | حالة T متغير منقطع | 2.6.7 |
| 380 | فترات الثقة عندما يكون حجم العينة كبيرا | 7.7 |
| 387 | مناطق الثقة من أجل معلمة متعددة الأبعاد | 8.7 |
| 391 | تمارين | |

الفصل الثامن: طرق تقدير بيز

| | | | |
|-----|-------|-------------------------------|-----|
| 395 | | مقدمة | 1.8 |
| 396 | | التوزيع القبلي والبعدي | 2.8 |
| 403 | | التوزيعات القبلية المرافقة | 3.8 |
| 409 | | التوزيعات القبلية غير المعلمة | 4.8 |
| 413 | | حالة عدة معالم | 5.8 |
| 417 | | تقدير بيز بنقطة | 6.8 |
| 424 | | تقدير بيز بفترة | 7.8 |
| 430 | | تمارين | |
| 433 | | المراجع | |
| 435 | | الملحق | |

مُقَدِّمَةٌ

يعزى تقدم العلوم للتجريب. حيث ينجز الباحث تجربته الخاصة، فيحصل على بعض المعلومات، ويتوصل بناءً عليها إلى نتائج تتجاوز عادة مواد وعمليات التجربة الخاصة بحيث تشمل كل التجارب المشاهدة. أي يقوم بتطبيق منهج الاستدلال الاستقرائي للحصول على معرفة جديدة من الجزء حول الكل.

إن منهج الاستدلال الاستقرائي لا يعطي تعميمات مؤكدة أو حتمية، لكن يمكن قياس درجة الثقة بها فيما إذا ضمنت التجربة الخاصة وفق أسس ومبادئ علمية معينة. إن تصميم التجربة، ومن ثم القيام باستدلالات (تعميمات) بناءً على نتائجها يعد من المسائل الأساسية في الإحصاء الرياضي. وعندئذٍ نكون أمام تطبيق منهج الاستدلال الاستقرائي الإحصائي أو باختصار الاستدلال الإحصائي.

يعالج الاستدلال الإحصائي موضوعين هامين، هما:

1. نظرية التقدير.

2. نظرية اختبار الفرضيات.

وهذا الكتاب هو الجزء الأول من كتاب الاستدلال الإحصائي من جزئين، والذي يهدف إلى تقديم مفاهيم وقواعد ومبرهنات نظرية التقدير بشكل متدرج مترابط وشامل بحيث يمكن الطلاب والباحثين - ليس فقط - من استيعاب الأسس الرياضية لهذه النظرية بل من ترجمتها إلى الواقع العملي، وذلك في مختلف الأبحاث التطبيقية التي يمكن أن تعترضهم.

ولتحقيق الهدف، وزعت موضوعات هذا الكتاب على ثمانية فصول، يتقدمها تمهيد يبين مدلول النموذج الإحصائي ومهام الإحصاء الرياضي بالإضافة إلى إيضاح بعض المصطلحات ومدلولات بعض الرموز التي سترد في الفصول المختلفة. وتعتبر الفصول الثلاث الأولى كمقدمة لا بد منها لدراسة نظريتي التقدير واختبار الفرضيات.

يتناول الفصل الأول مبرهنات النهاية الأساسية، وذلك بعرض موجز لتقارب متتاليات متغيرات عشوائية، بالإضافة إلى بعض الصيغ الأساسية لقانون الأعداد الكبيرة والنهاية المركزية على هيئة مبرهنات.

يقدم الفصل الثاني النماذج الإحصائية الأكثر استخداماً في التطبيقات الإحصائية مرفقة ببعض الخصائص المميزة ومجالات تطبيقها.

يعالج الفصل الثالث أساسيات المعاينة وتوزيعات المعاينة التي لا بد منها لدراسة نظرية التقدير، حيث تم التركيز على المعاينة العشوائية البسيطة لاعتبارها تشكل الأساس لمختلف المعاينات. هذا بالإضافة إلى دراسة بعض الصيغ الخطية والتربيعية الهامة في عناصر العينة وتوزيعاتها الاحتمالية. كما يستعرض إلى جانب ذلك، أهم نتائج نظرية المعاينة للإحصاءات المرتبة والمعاينة في حالة عينة كبيرة الحجم.

يتعرض الفصل الرابع للمعلومات المتوفرة في العينة العشوائية وكيفية تكييفها في إحصاء واحد أو عدد محدود جداً من الإحصاءات حيث التعامل معها أسهل بكثير من التعامل مع العينة نفسها. وفي هذا الإطار أعطى الإحصاء الكافي والكافي التام أهمية خاصة.

يناقش الفصل الخامس مفهوم التقدير بنقطة وبفترة لمعلمة أو معالم توزيع المجتمع الذي سحبت منه العينة العشوائية، هذا بالإضافة إلى الصفات التي نرغب توفرها في المقدّر بنقطة، وتم التركيز على المقدّرات غير المتحيزة ومعايير الكفاءة لها.

يعرض الفصل السادس الطرق المختلفة لإيجاد المقدّرات النقطية للمعلمة أو المعالم غير المعلومة لتوزيع المجتمع بناءً على معطيات عينة عشوائية. وأعطيت أهمية خاصة لطريقة العقلية العظمى لاعتبارها أهم وأكثر الطرق استخداماً في الإحصاء لتقدير المعالم لما يتمتع به من خواص وخواص مقاربة.

ويناقش الفصل السابع طرق التقدير بفترة للمعالم غير المعلومة لتوزيع المجتمع الذي سحبت منه العينة العشوائية. وأعطيت الأهمية لبناء فترات الثقة في حالة المعاينة من مجتمع طبيعي.

يتناول الفصل الثامن، والأخير، طرق تقدير يميز بنقطة وبفترة للمعالم غير المعلومة في صيغة توزيع المجتمع الذي سحبت منه عينة عشوائية، والتي ينظر إليها كقيم لتغيرات عشوائية.

إضافة إلى ما سبق، يعالج الكتاب، باهتمام خاص، أمثلة كثيرة معروضة بطريقة موسعة بغية إعطاء القارئ غير المتألف مع تقنيات نظرية التقدير تمثيلاً محسوساً للأسس الرياضية لهذه النظرية ودليلاً للتطبيق على حالات من الواقع، كما يشتمل أيضاً على عدد لا بأس به من التمارين غير المحلولة.

ونرجو أن يكون في الأسلوب الذي قدمت به المادة والنهج الذي استخدم في عرض الأمثلة الكثيرة والمتنوعة ما يمكن القارئ من اكتساب المعرفة بنظرية التقدير، ولعل في تقديم المصطلحات باللغتين العربية والإنجليزية ضمن سياق النص ما ييسر للقارئ فهم المادة ومتابعة المراجع والبحوث الأجنبية التي لا غنى عنها، وخاصةً أن لبساً يحدث أحياناً في بعض المؤلفات عند اختيار المصطلح العلمي العربي المناسب لما يقابله من المصطلحات الإنجليزية.

أخيراً، أود أن أعبر عن شكري الجزيل لكل الذين ساعدوني بصفة أو بأخرى على إخراج هذا الكتاب، وأخص بالذكر الأخ عبدالرحمن الفيتوري الذي لم يدخر جهداً في تنسيق وإخراج الكتاب.

والله من وراء القصد، فهو نعم المولى ونعم النصير

أ. د. عبدالحفيظ مصطفى

مصراتة في 1999/3/22

تمهيد

1. النموذج الإحصائي الاحتمالي ومهام الإحصاء الرياضي

يفترض عند دراسة نظرية الاحتمالات، أن احتمالات الحوادث الأساسية معلومة. وانطلاقاً من هذه الفرضيات يبنى النموذج الاحتمالي أو الرياضي (Ω, \mathcal{A}, P) للتجربة المفروضة، حيث Ω فضاء الحوادث الأولية، \mathcal{A} صف من الفئات الجزئية (الحوادث) لـ Ω والتي تحقق شروط σ -الجبر، P القياس الاحتمالي المعرف على الحوادث $A \in \mathcal{A}$. وعلى أساس هذا النموذج يتم حساب احتمالات الحوادث الأخرى (غير الأساسية) المختلفة.

ومعرفة النموذج الاحتمالي (Ω, \mathcal{A}, P) ، يمكننا بناء النموذج الاحتمالي $(\Omega_\xi, \mathcal{A}_\xi, P_\xi)$ الذي يولده المتغير العشوائي ξ ، الذي يصف التجربة المفروضة. هكذا يبناء النموذج الرياضي للتجربة المفروضة، الموصوفة بالمتغير العشوائي ξ نكون قد افترضنا معرفة توزيعه الاحتمالي، أي معرفة بنية المجتمع المدروس. وبناءً على ذلك تتم دراسة كيفية حساب احتمالات الحوادث التي يمكن أن تقع نتيجة التجربة المفروضة، بالإضافة إلى حساب المميزات العددية المختلفة للمتغير العشوائي ξ . لنوضح ما سبق بمثال يتعلق بمتغير عشوائي ξ خاضع لتوزيع ذي الحدين.

لتكن E تجربة احتمالية تمثل بإلقاء قطعة نقود معدنية متناظرة (متجانسة) n مرة، تحت نفس الشروط. يبرهن في نظرية الاحتمالات، بافتراض قطعة النقود متناظرة والتكرارات مستقلة، بأن تكرار ظهور الصورة (المتغير العشوائي ξ) يخضع لتوزيع ذي الحدين $B(n, P)$ ، حيث $P = 0.5$. وعلى أساس هذه الافتراضات

يتم تشكيل النموذج الرياضي $(\Omega_\xi, \mathcal{A}_\xi, P_\xi)$ ، حيث $\Omega_\xi = \{1, 2, \dots, n\}$ و \mathcal{A}_ξ مجموعة الفئات الجزئية لـ Ω_ξ والتي تحقق شروط σ -الجبر، أما القياس الاحتمالي P_ξ فيعرف بالعلاقة التالية:

$$P_\xi = P(\xi = m) = C_n^m p^m q^{n-m} ; p + q = 1 , m = 0, 1, \dots, n$$

$$C_n^m = \binom{n}{m} = \frac{n!}{m!(n-m)!}$$

وباستخدام هذا النموذج، يمكننا حل المسائل التالية، التي تعتبر أساسية في نظرية الاحتمالات:

1. حساب احتمال ظهور الصورة m مرة بنتيجة التجربة E (إلقاء قطعة نقود معدنية متناظرة n مرة تحت نفس الشروط).

2. حساب احتمال ظهور الصورة أكثر من m_1 مرة وأقل من m_2 مرة بنتيجة التجربة E ، حيث $m_1 < m_2$.

3. حساب $P\left(\left|\frac{m}{n} - p\right| < \varepsilon\right)$ ، حيث $\frac{m}{n}$ التكرار النسبي لظهور الصورة، p احتمال ظهور الصورة في كل تكرار، و ε عدد حقيقي موجب.

4. إيجاد المميزات (الخواص) العددية للمتغير العشوائي ξ ، وحل مسائل أخرى متعلقة بحساب احتمالات الحوادث المركبة.

هكذا، تدرس نظرية الاحتمالات احتمالات الحوادث التي يمكن أن تقع بنتيجة التجربة، عند تحقق جملة من الشروط (فمثلاً، عند تحقق الشرطين: قطعة النقود متناظرة، والتكرارات مستقلة). وعندها نعتبر الحوادث الأساسية (في حالة متغير عشوائي منقطع، تؤخذ الحوادث الأولية كحوادث أساسية) معلومة مسبقاً (قبل إجراء التجربة)، وباستخدام طرق نظرية الاحتمالات يتم حساب احتمالات الحوادث المطلوبة.

لكن، نادراً ما تكون بنية المجتمع معلومة، وبالتالي عند إجراء التجربة، لا نعلم

بالضرورة، هل جملة الشروط المفروضة محققة. فمثلاً، هل قطعة النقود متناظرة تماماً؟، هل التكرارات مستقلة فعلاً؟.

هكذا، عند دراسة تجربة مفروضة، قلما يكون الاحتمال P معلوماً تماماً، وغالباً يمكن فقط معرفة أن الاحتمال P عنصر في عائلة معينة من الاحتمالات \mathcal{P} وهذه العائلة يمكن أن تشتمل على كل الاحتمالات، التي يمكن تعريفها على \mathcal{A} (الحالة غير معينة تماماً). وفي حالات أخرى يمكن تمثيله بعائلة أصغر من الاحتمالات المعطاة في هذه أو تلك الصيغة الواضحة (الحالة، عند توفر معلومات محددة مسبقاً). وبشكل عام إن \mathcal{P} عبارة عن عائلة الاحتمالات P المقترحة في الحالة المعينة (من أجل وصف التجربة المفروضة). إذا كانت العائلة \mathcal{P} معينة، فيقال إننا نملك نموذج إحصائي احتمالي (أو اختصاراً نموذج إحصائي)، ويفهم منه الثلاثي (Ω, \mathcal{A}, P) أو $(\Omega_{\xi}, \mathcal{A}_{\xi}, P_{\xi})$ ، حيث $P \in \mathcal{P}$ و $P_{\xi} \in \mathcal{P}_{\xi}$.

فمثلاً، في تجربة إلقاء قطعة نقود معدنية n مرة، نبحث نفس الشروط، من الواضح أن احتمال ظهور الصورة في الرمية الواحدة غير معلوم مسبقاً، والذي نرمز له بـ θ ، وعندئذٍ يمكننا القول فقط بأن $\theta \in \Theta = [0,1]$ ، وبالتالي عائلة الاحتمالات المقترحة \mathcal{P} تأخذ الشكل:

$$\mathcal{P} = \{P_{\theta}; \theta \in \Theta\}$$

حيث:

$$P_{\theta}(m) = C_n^m \theta^m (1 - \theta)^{n-m} \quad ; \quad m = 0, 1, \dots, n$$

وبناءً على النتائج العددية الملاحظة x_1, x_2, \dots, x_n (في نظرية الاحتمالات لا يطلب إجراء التجربة فعلياً)، يمكن حل المسائل التالية، التي تعتبر أساسية في الإحصاء الرياضي:

1. اختبار الفرضية (testing hypotheses): إن تكرار ظهور الصورة θ له توزيع ذي الحدين بالمعلمتين المعيتين p, n ، أي أن الفرضية الصفريّة

هذه المسألة في الإحصاء الرياضي تدعى باختبار الفرضية الخاصة بنموذج التوزيع الاحتمالي، ومنها بدالة التوزيع $F(x)$ وتدعى مثل هذه المسألة باختبار الفرضية اللامعلمية (nonparametric).

2. اختبار الفرضية: أن قطعة النقود المعدنية متناظرة، أي أن الفرضية الصفرية خاصة بمعلمة التوزيع $H_0: \theta = 0.5$ ، وتدعى هذه المسألة باختبار الفرضية الخاصة بمعلمة توزيع المتغير العشوائي ξ ، أو اختصاراً الفرضية المعلمية (parametric).

3. بناءً على نتائج التجربة المحققة تقدير الاحتمال المجهول θ (احتمال ظهور الصورة)، أي إيجاد قيمة تقريبية للمعلمة θ في التوزيع الثنائي $B(n, \theta)$ ، وهذه القيمة التقريبية يمكن إيجادها بشكل عدد، الذي يدعى بالتقدير النقطي، (التقدير بنقطة). وإما بشكل فترة (θ_1, θ_2) التي تغطي الاحتمال المجهول θ لظهور الصورة باحتمال كبير، وتدعى هذه المسألة في الإحصاء الرياضي بإيجاد التقديرات بنقطة وفترة للمعلمة غير المعلومة في النموذج الإحصائي المقترح على الترتيب.

بالإضافة إلى المسائل الواردة أعلاه للإحصاء الرياضي، هناك مسائل أخرى عديدة تواجه الباحث. فمثلاً، هل قطعة النقود ألقيت بنزاهة؟ هل التكرارات مستقلة؟.

مما سبق نخلص إلى القول بأن الإحصاء الرياضي يُقِيم بنية النموذج الإحصائي المقترح لدراسة وتحليل التجربة الاحتمالية: اختبار صحة اختيار نموذج التوزيع المقترح (ثنائي، بواسون، طبيعي، ... الخ)، تقدير معالم التوزيع المقترح (بعد التأكد من صحة اختيار النموذج)، اختبار الفرضيات الخاصة بمعالم التوزيع المقترح، وذلك كله يتم بناءً على النتائج الملاحظة للتجربة المفروضة. وإجراء ذلك التقييم لبنية النموذج الإحصائي يجب معرفة كيفية إجراء وتخطيط (تصميم) التجربة، كيفية وصف نتائجها، كيفية تحليل النتائج التجريبية والتنبؤ بنتائج التجربة عند معرفة جملة من الشروط.

إن المسائل الواردة أعلاه (تخطيط، وصف، تحليل وتنبؤ) تعتبر المسائل الأساسية في الإحصاء الرياضي، وفي كتابنا هذا سوف نطلق من اعتبار أن التجربة الاحتمالية أجريت ويطلب وصف نتائجها وتحليلها للوصول إلى التنبؤات واتخاذ القرارات.

هكذا، النموذج الإحصائي يصف تلك الحالات، التي توجد في النموذج الاحتمالي للتجربة المدروسة، عدم تعيين في الاحتمال P ، ومهمة الإحصاء الرياضي تكمن في تقليص عدم التعيين هذا باستخدام المعلومات التي يتم الحصول عليها بملاحظة النتائج التجريبية (البيانات الإحصائية).

وبشكل محدد يعالج الإحصاء الرياضي المسائل التي تعتبر معاكسة لمسائل نظرية الاحتمالات، فهو يستكشف بنية النموذج الإحصائي بناءً على نتائج الملاحظات، وفي هذا الكتاب ينظر إلى أكثر المسائل الإحصائية أساسية والطرق العامة لحلها.

إن نشوء وتطور الإحصاء الرياضي، كبقية فروع الرياضيات، ارتبط بمتطلبات التطبيق، وفي وقتنا الحاضر طرقة تستخدم بشكل واسع في مختلف الفروع التقنية، ويلعب دوراً هاماً في الأبحاث الاقتصادية، الزراعية، البيولوجية، الطب، العلوم الفيزيائية، الجغرافيا، علم النفس والأبحاث الاجتماعية، وغيرها، التي كان ينظر إليها سابقاً على أنها أكثر العلوم بعداً عن الرياضيات.

2. المصطلحات والرموز

تمثل المعطيات الإحصائية الأولية، في أغلب الحالات، نتائج ملاحظة فئة منتبهة من المتغيرات العشوائية $X = (X_1, X_2, \dots, X_n)$ ، التي تصف التجربة المدروسة. وفي مثل هذه الحالة يقال عادة بأن التجربة تتألف من n تكراراً، ونتيجة التكرار i توصف بالمتغير العشوائي X_i ; $i = 1, 2, \dots, n$ ، وتدعى فئة المتغيرات العشوائية الملاحظة بالعينة (sample)، والمتغيرات العشوائية X_i ; $i = 1, 2, \dots, n$ بعناصر أو مركبات العينة وعددها n بحجم العينة (sample size). ونرمز لقيم X بـ:

$$x = (x_1, x_2, \dots, x_n)$$

كما ونرمز بـ $x(k)$ للقيمة ذات الترتيب k (من حيث الكبر) ضمن القيم x_1, \dots, x_n .

لتكن $G = \{x\}$ مجموعة القيم الممكنة للمتغير العشوائي X . تدعى الفئة G في الإحصاء الرياضي بفضاء العينة (*sample space*)، وعندئذ يعرف من G الصف \mathcal{A} من الفئات الجزئية التي تشكل σ -الجسرا، ويمكن أن يكون فضاء العينة G مساوياً لـ R^n أو جزءاً منه (في حالة X متغير عشوائي مستمر)، وإما أن يتألف من عدد منتهي أو غير منتهي قابل للعد من النقاط في R^n (في حالة X متغير عشوائي منقطع). وفي هذه الحالة يفهم النموذج الإحصائي على أنه الثنائي (G, \mathcal{P}) ، حيث \mathcal{P} عائلة التوزيعات المحتملة (المقترحة) للمتغير العشوائي X المعرفة على G . وكما نعلم من نظرية الاحتمالات بأن التوزيع الاحتمالي لأي متغير عشوائي يتعين تماماً بدالة توزيعه، لهذا عادة يعطى النموذج الإحصائي بدلالة عائلة دوال التوزيع المقترحة للعينة X ، أي بالثنائي (G, \mathcal{F}) ، حيث \mathcal{F} عائلة دوال التوزيع، التي تنتمي إليها دالة التوزيع المجهولة:

$$F_X = P(X_1 < x_1, \dots, X_n < x_n) \quad ; \quad -\infty < x_1 < \dots < x_n < \infty$$

$$X = (X_1, X_2, \dots, X_n) \text{ للعينة}$$

يفترض غالباً أن المركبات $X_i, i = 1, 2, \dots, n$ مستقلة ولها توزيع واحد وهو توزيع متغير عشوائي ما ξ ، وهذه الحالة توافق التجربة، التي تتألف من الملاحظات المتكررة والمستقلة على متغير عشوائي ξ ، أي أن:

$$F_i = F_{X_i}(x_i) = F_\xi(x_i) \quad ; \quad i = 1, 2, \dots, n$$

و

$$F_X(x) = F_\xi(x_1) \dots F_\xi(x_n)$$

وعندئذ يقال بأن العينة $X = (X_1, X_2, \dots, X_n)$ مأخوذة من توزيع المتغير العشوائي ξ ، وتدعى فئة القيم الممكنة للمتغير العشوائي ξ ذو التوزيع $F_\xi(x)$

مجتمع الصفة المدروسة أو المجتمع ذو التوزيع $F_{\xi}(x)$ و X بالعينة المأخوذة من هذا المجتمع. سنرمز لتوزيع المتغير العشوائي ξ بـ $L(\xi)$ ، وبالتالي يمكن أن نكتب " X عينة من $L(\xi)$ " .

سنقتصر في هذا الكتاب، وللأهمية الخاصة، على دراسة مثل تلك النماذج، على الرغم من أنه في مسائل عدة شرط الاستقلالية والتوزيع الواحد للمركبات X_i ; $i = 1, 2, \dots, n$ غير محقق. ونرمز للنموذج الإحصائي الموافق للملاحظات المتكررة المستقلة باختصار $\mathcal{F} = \{F_{\xi}\}$ ، أي بالإشارة فقط إلى صف دوال التوزيع المحتملة للمتغير العشوائي الملاحظ ξ ، وعندما لا يوجد التباس يمكن إسقاط الدليل ξ ونكتب $\mathcal{F} = \{F\}$. وإذا كانت دوال التوزيع $F_{\xi} \in \mathcal{F}$ معرفة بدلالة معلمة θ فئة قيمها الممكنة Θ ، فمثل هذا النموذج نرمز له بـ $\mathcal{F} = \{F(x, \theta) ; \theta \in \Theta\}$ ، ويدعى بالنموذج المعلمي. ويقال في هذه الحالة إن نوع توزيع المتغير العشوائي الملاحظ ξ معلوم، ويمكن أن يكون أحد التوزيعات الاحتمالية الشهيرة (ثنائي، بواسون، طبيعي، الخ)، لكنه يعتمد على المعلمة θ غير المعلومة، التي يتبع لها التوزيع، ويمكن أن تكون المعلمة θ سلمية (عددية) أو متجهة، وتدعى فئة قيمها الممكنة Θ بفضاء المعلمة (parametric space). فمثلاً، لنفترض أن $L(\xi)$ توزيع طبيعي بتباين معلوم σ^2 ومتوسط مجهول θ ، أي أن $L(\xi) \in N(\theta, \sigma^2)$ ، عندها النموذج الإحصائي يكتب:

$$\mathcal{F} = \{F(x, \theta) ; \theta \in \Theta = (-\infty, +\infty)\}$$

أي أن فضاء المعلمة يمثل بمحور الأعداد الحقيقية، وصيغة كثافة التوزيع الموافقة لـ ξ تكون:

$$f(x, \theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\theta)^2}{2\sigma^2}} ; \quad -\infty < x < +\infty$$


وإذا كان التباين مجهولاً أيضاً: فإن النموذج الإحصائي يأخذ الشكل:

$$F = \{F(x, \theta) ; \theta = (\theta_1, \theta_2) \in \Theta\}$$

حيث:

$$\Theta = \{\theta = (\theta_1, \theta_2) ; -\infty < \theta_1 < +\infty, 0 < \theta_2 < \infty\}$$

وتمثل بالمنطقة المظلمة على الشكل (1).



شكل (1)

وصيغة كثافة التوزيع الاحتمالي الموافقة:

$$f(x, \theta) = \frac{1}{\theta_2 \sqrt{2\pi}} e^{-\frac{(x-\theta)^2}{2\theta_2^2}} ; -\infty < x < \infty$$

يدعى النموذج $F = \{F_\xi\}$ بالمستمر (المنقطع)، إذا كانت كل عناصر العائلة F من الدوال المستمرة (المنقطعة).

وفيما يلي سنستخدم رمزاً موحداً $f(x; \theta) = f_\xi(\theta)$ (في حالة النماذج الإحصائية المعلمية $F(x, \theta)$) للدلالة على صيغة كثافة التوزيع الاحتمالي للمتغير العشوائي ξ في حالة النموذج المستمر، وللدلالة على صيغة دالة الاحتمال $P_0(\xi = x)$ للمتغير العشوائي ξ في حالة نموذج منقطع.

لنورد المثال التالي الخاص بنموذج معلمي منقطع:

لنفترض أن $\mathcal{L}(\xi)$ ينتمي إلى عائلة توزيعات بواسون، عندها يأخذ النموذج الإحصائي الشكل:

$$\mathcal{F} = \{F(x, \theta) ; \theta \in \Theta = (0, \infty)\}$$

حيث $F(x, \theta)$ يتعين بناءً على الاحتمالات:

$$f(x, \theta) = P(\xi = x) = \frac{\theta^x}{x!} e^{-\theta} ; \quad x = 0, 1, 2, \dots$$

إن توزيع الاحتمالات على فضاء العينة G الموافق للمعلمة θ (في حالة نموذج معلمي) نرسم له P_θ ، وبشكل مشابه نضيف الدليل θ إلى رمز التوقع والتباين... الخ، وهذا يعني أن المقدار الموافق يحسب للتوزيع P_θ . فمثلاً: $E_\theta T(X)$ و $\text{var}_\theta(T(X)) = V_\theta T(X)$ يرمزان على الترتيب لتوقع وتباين الدالة $T(X)$ في العينة X ، في حالة كون دالة توزيع العينة $F(x, \theta)$ ، وعندئذٍ لوحدة الرمز نستخدم الكتابة المختصرة بدلالة تكامل ستيلنج:

$$E_\theta T(X) = \int T(x) dF_X(x, \theta)$$

وهنا يفهم التكامل على أنه تكامل ذو n بعد على كامل فضاء العينة G ، والذي في حالة نموذج مستمر يحسب كتكامل ريمان العادي:

$$\int \dots \int T(x_1, \dots, x_n) f(x_1, \theta) \dots f(x_n, \theta) dx_1 \dots dx_n$$

وفي حالة نموذج منقطع يحسب كمجموع:

$$\sum_{x_1} \dots \sum_{x_n} T(x_1, \dots, x_n) f(x_1, \theta) \dots f(x_n, \theta)$$

نحتاج في مسائل عدة، بحث متتالية من المتغيرات العشوائية $\{\eta_n\}$ المتقاربة من نهاية محددة η (متغير عشوائي أو ثابت)، عندما $n \rightarrow \infty$ ، وفي عرضنا القادم

ستعرض لنوعين من التقارب: التقارب بالاحتمال، والتقارب بالتوزيع، ونشير إلى أن المتتالية $\{\eta_n\}$ تدعى متقاربة بالاحتمال من η إذا حققت الشرط التالي:

$$\lim_{n \rightarrow \infty} P(|\eta_n - \eta| > \varepsilon) = 0 \quad ; \quad \varepsilon > 0$$

ونكتب ذلك باختصار:

$$\eta_n \xrightarrow{P} \eta$$

وفهم التقارب بالتوزيع أو اختصاراً $\mathcal{L}(\eta_n) \rightarrow \mathcal{L}(\eta)$ على أنه تقارب دوال التوزيع الموافقة في كل نقطة باستمرار من دالة النهاية، عندما $n \rightarrow \infty$. أما بقية الرموز والمفاهيم فستعرض في سياق النص.

3. رموز بعض النماذج الإحصائية الأساسية

إن التوزيعات التي نصادفها غالباً في نظرية الاحتمالات لها تسميات ورموز عامة. فمثلاً، التوزيع الطبيعي بمتوسط معلوم μ وتباين معلوم σ^2 يرمز له بالرمز $N(\mu, \sigma^2)$. توزيع ذي الحدين الموافق لـ n و P يرمز له بـ $B(n, P)$ ، توزيع بواسون بمتوسط λ يرمز له بـ $\Pi(\lambda)$... الخ. لهذا إذا كان نوع توزيع المتغير العشوائي الملاحظ ξ معلوم (طبيعي، ثنائي، بواسون، ... الخ)، فإن النموذج الإحصائي الموافق يحمل أيضاً ذلك الاسم. فمثلاً: يقال نموذج طبيعي، نموذج ذي الحدين، نموذج بواسون، ... الخ.

يتضمن الجدول (1) أكثر النماذج الإحصائية استخداماً في التطبيقات (الدالة f تساوي الصفر من أجل قيم x غير الواردة في الجدول 1). فمثلاً، $\mathcal{L}(\xi) \in N(\theta_1, \theta_2^2)$ تعني أن النموذج معطى بفئة دوال الكثافة الطبيعية المحتملة $\{f(x; \theta) ; \theta \in \Theta\}$ ، حيث $f(x; \theta)$ كثافة التوزيع الطبيعي و θ المعلمة المجهولة من فضاء المعلمة Θ . ويبين الجدول التالي أهم النماذج الإحصائية.

جدول (1)

بعض النماذج الإحصائية الأساسية

| اسم النموذج | رمز النموذج | دالة الكثافة الاحتمالية أو دالة الاحتمال $f(x, \theta)$ | فضاء المعلمة θ |
|----------------|---------------------------|--|---|
| I الطبيعي | $N(\theta, \sigma^2)$ | $\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\theta}{\sigma}\right)^2}$; $-\infty < x < +\infty$ | $\{\theta : -\infty < \theta < +\infty\}$ |
| II الطبيعي | $N(\mu, \theta^2)$ | $\frac{1}{\theta\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\theta}\right)^2}$; $-\infty < x < +\infty$ | $\{\theta : 0 < \theta < +\infty\}$ |
| الطبيعي العام | $N(\theta_1, \theta_2^2)$ | $\frac{1}{\theta_2\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\theta_1}{\theta_2}\right)^2}$; $-\infty < x < +\infty$ | $\left\{ \begin{array}{l} \theta = (\theta_1, \theta_2), -\infty < \theta_1 < +\infty \\ , 0 < \theta_2 < +\infty \end{array} \right\}$ |
| جاما | $\Gamma(\alpha, \theta)$ | $\frac{x^{\alpha-1} e^{-x/\theta}}{\Gamma(\alpha)\theta^\alpha}$, $x > 0$ | $\{\theta : 0 < \theta < +\infty\}$ |
| I المنتظم | $R(0, \theta)$ | $\frac{1}{\theta}$, $0 \leq x \leq \theta$ | $\{\theta : 0 < \theta < +\infty\}$ |
| المنتظم العام | $R(\theta_1, \theta_2)$ | $\frac{1}{\theta_2 - \theta_1}$, $\theta_1 \leq x \leq \theta_2$ | $\{\theta = (\theta_1, \theta_2), -\infty < \theta_1 < \theta_2 < +\infty\}$ |
| كوشي | $K(\theta)$ | $\frac{1}{\pi} \frac{1}{1+(x-\theta)^2}$, $-\infty < x < +\infty$ | $\{\theta : -\infty < \theta < +\infty\}$ |
| ذو الحددين | $B(n, \theta)$ | $C_n^x \theta^x (1-\theta)^{n-x}$, $x = 0, 1, \dots, n$ | $\{\theta : 0 < \theta < 1\}$ |
| البواسوني | $\Pi(\theta)$ | $\frac{\theta^x}{x!} e^{-\theta}$, $x = 0, 1, \dots$ | $\{\theta : 0 < \theta < +\infty\}$ |
| الثنائي السالب | $\bar{B}(r, \theta)$ | $C_{r+x-1}^r \theta^x (1-\theta)^x$, $x = 0, 1, 2, \dots$ | $\{\theta : 0 < \theta < 1\}$ |
| كاي مربع | χ_v^2 | $\frac{1}{2^{v/2} \Gamma(v/2)} x^{v/2-1} e^{-x/2}$; $x > 0$ | $\{v; v = 1, 2, \dots\}$ |

تابع جدول (1)

| اسم النموذج | رمز النموذج | دالة الكثافة الاحتمالي أو دالة الاحتمال $f(x, \theta)$ | فضاء المعلمة θ |
|-------------|----------------|--|--|
| بيتا | $Be(v_1, v_2)$ | $\frac{1}{\beta(v_1, v_2)} x^{v_1-1} (1-x)^{v_2-1}; 0 < x < 1$ | $\{(v_1, v_2); v_1, v_2 > 0\}$ |
| إف | F | $\frac{1}{\beta\left(\frac{v_1}{2}, \frac{v_2}{2}\right)} x^{\frac{v_1}{2}-1} (1-x)^{\frac{v_2}{2}-1}; 0 < x < 1$ | $\{(v_1, v_2); v_1, v_2 = 1, 2, \dots\}$ |
| ت | $S(v)$ | $\frac{\Gamma\left(\frac{v+1}{2}\right)}{\sqrt{2\pi v}} \left(1 + \frac{t^2}{v}\right)^{-\frac{v+1}{2}}; -\infty < t < \infty$ | $\{v; v = 1, 2, \dots\}$ |

هنا ولاحقاً، عندما نكتب $N(\theta, \sigma^2)$ ، نعني بذلك توزيع طبيعي بمتوسط مجهول وتباين معلوم، وكذلك نعني بالرمز $N(\mu, \theta^2)$ توزيع طبيعي بمتوسط معلوم وتباين مجهول. وبعبارة أخرى فالرمزين μ ، σ^2 ثوابت معينة، طالما لم نشر إلى خلاف ذلك.

وأخيراً لا بد لنا من الإشارة إلى أن هناك بعض الحالات الخاصة للنماذج الواردة في الجدول رقم (1) تحمل تسميات خاصة، فمثلاً النموذج $B(1, \theta)$ يدعى بنموذج برنولي، والنموذج $\bar{B}(1, \theta)$ بالهندسي، ... الخ.

مبرهنتات النهاية

1.1 مقدمة

تدرس نظرية الاحتمالات القوانين التي تظهر عند تكرار التجارب الاحتمالية مرات عديدة تحت نفس الشروط. وتسمح دراسة مثل هذه القوانين بالتنبؤ بنتائج تلك التجارب، وعندما يكون عدد التكرارات كبيراً بكفاية، فإن بعض مميزات المتغيرات والحوادث العشوائية تصبح تقريباً غير عشوائية، ويقال عادة في مثل هذه الحالة أن المميزات تتمتع بصفة الاستقرار (invariant). فمثلاً، التكرار النسبي يتمتع بهذه الصفة، أي إذا كانت شروط التجربة ثابتة أو ثابتة تقريباً، فإن التكرار النسبي يتأرجح حول قيمة ثابتة. وبعبارة أخرى، عندما تكون $n \rightarrow \infty$ ، فإن التكرار النسبي يفقد صفة العشوائية، وكذلك الوسط الحسابي لنتائج التكرارات $\bar{X} = \frac{1}{n} \sum X_i$ يتمتع أيضاً بصفة الاستقرار عندما تكون n كبيرة.

يتطلب صف هام من المسائل في الإحصاء الرياضي، تعيين نهاية دوال معينة في n متغير عشوائي، وكذلك نهاية توزيعاتها عندما $n \rightarrow \infty$ ، وبعبارة أخرى، إذا كان $X = (X_1, \dots, X_n)$ متغير عشوائي ذو n بعد و $g_n(X)$ دالة ما، التي تعتبر أيضاً متغير عشوائي، ويتطلب تعيين نهاية $g_n(X)$ ونهاية توزيعها (التوزيع المقارب لها) عندما $n \rightarrow \infty$. إن مجموعة المبرهنتات التي تعطي الحل لمثل هذه المسائل تدعى بمبرهنتات النهاية (limit theorems). وهذه المبرهنتات تصنف إلى نوعين:

1. قانون الأعداد الكبيرة: وهي مجموعة مبرهنات النهاية، التي تعين نهاية متوسط متغيرات عشوائية، عند شروط معينة، وهذه تندرج تحت اسم "قانون الأعداد الكبيرة (law of large numbers)".

2. مبرهنات النهاية المركزية: وهي مجموعة مبرهنات النهاية التي تعين نهاية توزيعات دوال في متغيرات عشوائية، تحت شروط معينة، وتندرج تحت اسم "مبرهنات النهاية المركزية (central limit theorems)".

يهدف هذا الفصل إلى تقديم بعض الصيغ الأساسية لقانون الأعداد الكبيرة على هيئة مبرهنات، بالإضافة إلى مبرهنات أساسية في النهاية المركزية.

سنعرض في البداية، وبصورة موجزة لتقارب متتاليات متغيرات عشوائية.

2.1 تقارب متتاليات متغيرات عشوائية

CONVERGENCE OF SEQUENCES OF RANDOM VARIABLES

لتكن $X_1, X_2, \dots, X_n, \dots$ متتالية متغيرات عشوائية نرمز لها بـ $\{X_{(n)}\}$ ، المعرفة على الفضاء الاحتمالي (Ω, \mathcal{A}, P) . بما أن المتغيرات العشوائية المشكلة لهذه المتتالية عبارة عن دوال في الحوادث الأولية $w \in \Omega$ ، باختيار $w_0 \in \Omega$ نحصل على المتتالية العددية $\{X_n(w_0)\}$ ، التي يمكن أن تكون متقاربة أو متباعدة.

تعريف 1.2.1

نقول عن متتالية المتغيرات العشوائية $\{X_n\}$ إنها متقاربة عند الحادث الأولي $w_0 \in \Omega$ إذا كانت المتتالية العددية $\{X_n(w_0)\}$ متقاربة.

تعريف 2.2.1

نقول إن متتالية المتغيرات العشوائية $\{X_n\}$ متقاربة عند الحادث $A \subset \Omega$ ، إذا كانت هذه المتتالية متقاربة عند كل حادث أولي $w \in A$.

تعريف 3.2.1

يقال عن متتالية المتغيرات العشوائية $\{X_n\}$ إنها متقاربة من المتغير العشوائي X عند الحادث A ، إذا تحقق الشرط الآتي:

$$\lim_{n \rightarrow \infty} X_n(w) = X(w) \quad ; \quad \forall w \in A \quad (1.2.1)$$

مثال 1.2.1

لتكن متتالية المتغيرات العشوائية $\{X_n\}$ ، حيث $X_n(w) = w^n$; $n = 1, 2, \dots$ المعرفة على الفضاء $\Omega = [-1, 1]$.

بما أن:

$$X(w) = \lim_{n \rightarrow \infty} X_n(w) = \lim_{n \rightarrow \infty} w^n = \begin{cases} 1 & ; \quad w = 1 \\ 0 & ; \quad 0 \leq w < 1 \end{cases}$$

وغير معرف عندما $-1 < w < 0$ ، فإن متتالية المتغيرات العشوائية $\{X_{(n)}\}$ تتقارب من $X = 1$ عندما $w = 1$ وتتقارب من $X = 0$ عند الحادث $A = [0, 1]$.

وبصورة خاصة، إذا كان $A = \Omega$ فيقال بأن متتالية المتغيرات العشوائية $\{X_n\}$ متقاربة من X باحتمال يساوي الواحد أو تقارب تقارباً شبه أكيد (almost certain convergence).

تعريف 4.2.1: التقارب شبه الأكيد Almost Certain Convergence

نقول عن متتالية المتغيرات العشوائية $\{X_n\}$ إنها متقاربة من X باحتمال يساوي الواحد (تقارب شبه أكيد)، إذا تحقق الشرط الآتي:

$$P\left(\left\{w \in \Omega ; \lim_{n \rightarrow \infty} X_n(w) = X(w)\right\}\right) = 1 \quad (2.2.1)$$

ويرمز لهذا التقارب بـ:

$$P(X_n \not\rightarrow X) = 0 \quad \text{أو} \quad P(X_n \longrightarrow X) = 1$$

أو في بعض الأدبيات الإحصائية بـ $X_n \xrightarrow{CP} X$

تعريف 5.2.1: التقارب بالاحتمال Convergence in Probability

نقول عن متتالية من المتغيرات العشوائية $\{X_n\}$ بأنها متقاربة بالاحتمال من المتغير العشوائي (أو غير العشوائي) X ، إذا تحققت الشرط:

$$\lim_{n \rightarrow \infty} P(|X_n - X| \leq \varepsilon) = 1 \quad ; \quad \varepsilon > 0 \quad (3.2.1)$$

ويرمز للتقارب بالاحتمال عادة بـ:

$$X_n \xrightarrow{P} X$$

نلاحظ عندما $X_n \xrightarrow{P} X$ ، فهذا يعني أن المتتالية $\{X_n\}$ قد تكون متقاربة من X عندما تقع بعض الحوادث الأولية، وقد تكون غير متقاربة عند وقوع بعض الحوادث الأولية الأخرى المرتبطة بالتجربة نفسها، فتقارب هذه المتتالية إذن هو حادث مرتبط بالتجربة المفروضة، وأن وقوع هذا الحادث يكافئ وقوع جميع الحوادث $\{|X_n - X| \leq \varepsilon\}$ باستثناء عدد منته منها وذلك مهما يكن العدد الموجب ε . وبناءً على ذلك، وتعريف التقارب في التحليل الرياضي، نجد أن هنالك اختلافاً بين التقارب بالاحتمال والتقارب العادي، ويتمثل هذا الاختلاف بما يلي:

إذا كانت $\{X_n\}$ متقاربة، بمفهوم التحليل الرياضي، من X عندما $n \rightarrow \infty$ ، فهذا يعني بدءاً من قيمة معينة $n_0 \in N$:

$$|X_n - X| \leq \varepsilon \quad ; \quad n > n_0 \quad (4.2.1)$$

أما إذا كانت المتتالية $\{X_n\}$ متقاربة بالاحتمال من X عندما $n \rightarrow \infty$ ، فإنه من أجل بعض القيم لـ n يمكن أن تكون المتباينة $|X_n - X| \leq \varepsilon$ غير محققة.

1.2.1 ملاحظة

إذا كانت متتالية المتغيرات العشوائية $\{X_n\}$ متقاربة من X باحتمال يساوي الواحد، فهي بالضرورة متقاربة بالاحتمال من X . ويمكن إثبات ذلك بسهولة، ونتركه للقارئ كتمرين.


6.2.1 تعريف

نقول عن متتالية دوال توزيع $\{F_n(x) = P(X < x)\}$ إنها متقاربة بالتوزيع (convergence in distribution) من الدالة $F(x)$ ، إذا تحقق الشرط:

$$\lim_{n \rightarrow \infty} F_n(x) = F(x) \quad ; \quad \forall x \in R \quad (5.2.1)$$

حيث إن $F(x)$ دالة مستمرة عند النقطة x . وكمثال على التقارب بالتوزيع نذكر تقارب توزيع ذي الحدين $B(n, P)$ من التوزيع الطبيعي $N(np, npq)$.

نلاحظ مما سبق أن هناك علاقة بين أنواع التقارب (التقارب بالاحتمال، التقارب باحتمال يساوي الواحد، التقارب بالتوزيع)، وهذه العلاقة ممثلة بالشكل (1.2.1).



شكل (1.1.1)

3.1 متباينة تشيبيشيف Tchebichev Inequality

سنتطرق في هذا البند لمتباينة شهيرة تملك قيمة تطبيقية محدودة، لكنها ذات قيمة نظرية كبيرة لأنها تستخدم أساساً لإثبات مجموعة من المبرهنت المتتمية لقانون الأعداد الكبيرة. وهذه المتباينة تدعى بـ "متباينة تشيبيشيف".

مبرهنة 1.3.1

إذا كان X متغير عشوائي حقيقي و $g(X)$ دالة حقيقة غير سالبة، فإن:

$$P(g(X) \geq k) \leq \frac{E[g(X)]}{k} \quad ; \quad k > 0 \quad (1.3.1)$$

الإثبات

لنفترض X متغير عشوائي مستمر دالة كثافته $f(x)$ ، عندئذ:

$$\begin{aligned} E[g(X)] &= \int_{-\infty}^{+\infty} g(x)f_x(x)dx = \int_{\{x:g(x) \geq k\}} g(x)f_x(x)dx + \int_{\{x:g(x) < k\}} g(x)f_x(x)dx \\ &\geq \int_{\{x:g(x) \geq k\}} g(x)f_x(x)dx \geq \int_{\{x:g(x) \geq k\}} kf_x(x)dx = kP(g(X) \geq k) \end{aligned}$$

وبالقسمة على k نجد:

$$P(g(X) \geq k) \leq \frac{E[g(X)]}{k}$$

وهو المطلوب.

وبشكل مشابه يمكن الإثبات في حالة X متغير عشوائي منقطع، وذلك باستبدال التكامل بالمجموع.

متباينة تشيبيشيف

إذا كان X متغيراً عشوائياً بمتوسط $EX = \mu$ وتباين منتهي $\text{var } X = \sigma^2$ ، فإن:

$$P(|X - \mu| \geq \varepsilon) = P((X - \mu)^2 \geq \varepsilon^2) \leq \frac{\sigma^2}{\varepsilon^2} \quad ; \quad \varepsilon > 0 \quad (2.3.1)$$

الإثبات

بوضع $g(X) = (X - \mu)^2$ و $k = \varepsilon^2$ في العلاقة (1.3.1) نحصل على العلاقة (2.3.1)

بما أن:

$$\Omega_X = \{|X - \mu| \geq \varepsilon\} \cup \{|X - \mu| < \varepsilon\}$$

والحدثان $\{|X - \mu| \geq \varepsilon\}$ و $\{|X - \mu| < \varepsilon\}$ متنافيان، فإن:

$$P(\Omega_X) = P(\{|X - \mu| \geq \varepsilon\}) + P(\{|X - \mu| < \varepsilon\}) = 1$$

ومنه:

$$P(\{|X - \mu| < \varepsilon\}) = 1 - P(\{|X - \mu| \geq \varepsilon\}) \geq 1 - \frac{\sigma^2}{\varepsilon^2} \quad (3.3.1)$$

وهي صيغة مكافئة لـ (2.3.1).

بوضع $\varepsilon = r\sigma$ حيث $r > 0$ ، في العلاقة (3.3.1) نجد:

$$P(\{|X - \mu| < r\sigma\}) = P(\mu - r\sigma < X < \mu + r\sigma) \geq 1 - \frac{1}{r^2}$$

أي أن احتمال أن يأخذ المتغير العشوائي قيمة في الفترة $(\mu - r\sigma, \mu + r\sigma)$ لا يقل عن $1 - \frac{1}{r^2}$ ، فمثلاً، عندما $r = \frac{1}{2}$:

$$P(\mu - 2\sigma < X < \mu + 2\sigma) \geq \frac{3}{4}$$

وهذا يعني من أجل متغير عشوائي X ، تباينه منتهي، فإن $\frac{3}{4}$ قيمه الممكنة على الأقل تقع في إطار إنحرافين معيارين عن متوسطه.

هكذا نجد أن متباينة تشيبيشيف تطبق على أي متغير عشوائي X شريطة أن يكون تباينه منتهي، ولا نحتاج لمعرفة توزيع X . وهذه المتباينة لا تعطي طريقة عملية لتقدير الاحتمالات، لأن الفرق بين طرفي المتباينة (3.3.1) عادة كبير. وعندما $r \leq 1$ أي $\left(\frac{1}{r} \geq 1\right)$ ، فإن المتباينة (3.3.1) لا تفيدنا شيئاً.

مثال 1.3.1

لتكن لدينا شحنة كبيرة من بضاعة مصنعة، نسبة العطب فيها p ، ونريد تعيين n ، بحيث إذا أخذنا عينة عشوائية (X_1, X_2, \dots, X_n) حجمها n أو أكثر من هذه البضاعة كنا واثقين باحتمال لا يقل عن 0.95 بأن نسبة العطب في العينة يختلف عن P بأقل من 0.1.

لنرمز بـ X_i ; $i = 1, 2, \dots, n$ لنتيجة السحب رقم i عند تشكيل العينة العشوائية، حيث $X_i = 0$ إذا كانت الوحدة المسحوبة سليمة، و $X_i = 1$ إذا كانت معطوبة. ولتكن $X = \sum_1^n X_i$ عدد الوحدات المعطوبة في العينة العشوائية المؤلفة من n وحدة. ويصبح المطلوب تعيين n بحيث:

$$P\left(\left|\frac{X}{n} - p\right| < 0.1\right) \geq 0.95 \quad ; \quad EX = p$$

$$P\left(\left|\frac{X}{n} - p\right| < 0.1\right) = P(|X - np| < 0.1n) \Rightarrow$$

$$P(|X - np| \geq 0.1n) \leq 1 - 0.95 = 0.05 \quad \dots (1)$$

وحسب متباينة تشيبيشيف:

$$P(|X - np| \geq 0.1n) \leq \frac{\text{var } X}{(0.1n)^2} = \frac{npq}{(0.1n)^2} \leq \frac{n/4}{(0.1n)^2} = \frac{25}{n} \quad \dots (2)$$

لأن: $pq \leq \frac{1}{4}$ ، ومقارنة (1)، (2) نجد:

$$\frac{25}{n} \leq 0.05 \Rightarrow n \geq 500$$

مثال 3.3.1

لتكن لدينا تجربة عشوائية، احتمال ظهور الحادث A يساوي $\frac{1}{2}$ ، أثبت أن

عدد مرات ظهور الحادث A في 1000 تكراراً مستقلاً للتجربة المفروضة يقع بين 400 و 600 باحتمال لا يقل عن 0.97.

لنرمز بـ X لعدد مرات ظهور الحادث A في n تكراراً مستقلاً للتجربة المفروضة.

بما أن $n = 1000$, $\text{var } X = npq = 250$ و $EX = np = 500$ ، فحسب

متباينة تشيبيشيف:

$$P(|X - EX| < \varepsilon) \geq 1 - \frac{\text{var } X}{\varepsilon^2}$$

$$P(|X - 500| < 100) \geq 1 - \frac{250}{(100)^2} = 0.975$$

وهو المطلوب.

4.1 قانون الأعداد الكبيرة الضعيف

THE WEAK LAW OF LARGE NUMBERS

إن مجموعة المفاهيم المتعلقة بالتقارب بالإضافة إلى متباينة تشيبيشيف الواردة أعلاه، تمكن من إيضاح محتوى قانون الأعداد الكبيرة.

يصوغ قانون الأعداد الكبيرة العلاقة بين المميزات النظرية والتجريبية للتجارب العشوائية. وهذا القانون له صيغ مختلفة تتجلى بمجموعة من المبرهنات (تشيبيشيف، برنولي، بواسون، ...).

تعريف 1.4.1: قانون الأعداد الكبيرة الضعيف

نقول عن متتالية من المتغيرات العشوائية $\{X_n\}$ إنها تخضع لقانون الأعداد الكبيرة الضعيف إذا حققت الشرط:

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{n} \sum_{i=1}^n EX_i\right| < \varepsilon\right) = 1 \quad ; \quad \varepsilon > 0 \quad (1.4.1)$$

1.4.1 صيغة تشيبيشيف لقانون الأعداد الكبيرة الضعيف

Tchebichev Theorem **مبرهنة 1.4.1: مبرهنة تشيبيشيف**

إذا كانت متتالية المتغيرات العشوائية $X_1, X_2, \dots, X_n, \dots$ مستقلة متنى متنى،
و ذات تباينات $\text{var } X_i = \sigma_i^2$; $i = 1, 2, \dots$ منتهية ومحدودة بعدد ثابت c ، فإن:

$$\lim_{n \rightarrow \infty} P \left(\left| \frac{1}{n} \sum_1^n X_i - \frac{1}{n} \sum_1^n EX_i \right| < \varepsilon \right) = 1 \quad ; \quad \varepsilon > 0 \quad (2.4.1)$$

الإثبات

حسب الفرض، المتغيرات X_i ; $i = 1, 2, \dots, n$ مستقلة وبالتالي:

$$\begin{aligned} \text{var} \left(\frac{1}{n} \sum_1^n X_i \right) &= \frac{1}{n^2} \sum_1^n \text{var } X_i = \frac{1}{n^2} \sum_1^n \sigma_i^2 \\ &\leq \frac{nc}{n^2} = \frac{c}{n} \end{aligned}$$

وبناءً على متباينة تشيبيشيف (العلاقة 3.3.1)

$$P \left(\left| \frac{1}{n} \sum_1^n X_i - \frac{1}{n} \sum_1^n EX_i \right| < \varepsilon \right) \geq 1 - \left[\frac{\text{var} \left(\frac{1}{n} \sum_1^n X_i \right)}{\varepsilon^2} \right] \geq 1 - \frac{c}{n\varepsilon^2}$$

وبأخذ نهاية الطرفين، عندما $n \rightarrow \infty$ ، نجد:

$$\lim_{n \rightarrow \infty} P \left\{ \left| \frac{1}{n} \sum_1^n X_i - \frac{1}{n} \sum_1^n EX_i \right| < \varepsilon \right\} \geq 1$$

وبما أن الاحتمال لا يمكن أن يتجاوز الواحد، فنحصل على العلاقة المطلوبة.

ونحصل بالانتقال إلى الحادث المعاكس على صيغة أخرى مكافئة لـ (2.4.1):

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_1^n X_i - \frac{1}{n} \sum_1^n EX_i\right| \geq \varepsilon\right) = 0 \quad ; \quad \varepsilon > 0 \quad (3.4.1)$$

نلاحظ أن المتوسط $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ عبارة عن متغير عشوائي، بينما $\frac{1}{n} \sum_1^n EX_i$ مقدار ثابت.

وكحالة خاصة، إذا كان $EX_i = \mu$; $i = 1, 2, \dots$ فإن (2.4.1) تكتب:

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_1^n X_i - \mu\right| < \varepsilon\right) = 1 \quad ; \quad \varepsilon > 0 \quad (4.4.1)$$

وهي تعطي الأساس لتقدير المتوسط الحسابي لمجتمع. فمثلاً، لنفترض إجراء عملية قياس لمقدار فيزيائي α . بتكرار عملية القياس n مرة بشكل مستقل، تحت نفس الشروط، يحصل الملاحظ على النتائج x_1, \dots, x_n غير المتطابقة تماماً، عندها يؤخذ المتوسط الحسابي للقيم الملاحظة كتقريب لـ α .

مثال 1.4.1

إذا كانت X_1, X_2, \dots, X_n القياسات المستقلة لمقدار فيزيائي α ، وكانت:

$$S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \alpha)^2$$

هل يمكن اعتبار:

$$S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \alpha)^2$$

قيمة تقريبية لتباين أخطاء جهاز القياس وليكن σ^2 ؟

يمكن اعتبار S_n^2 قيمة تقريبية لـ σ^2 ، إذا كان:

$$\lim_{n \rightarrow \infty} P(|S_n^2 - \sigma^2| < \varepsilon) = 1 \quad ; \quad \varepsilon > 0 \quad \dots (1)$$

بما أن المتغيرات العشوائية X_1, X_2, \dots, X_n مستقلة ولها نفس التوزيع (حسب الفرض)، فإن المتغيرات العشوائية $Y_i = (X_i - a)^2$ ، $i = 1, \dots, n$ مستقلة ولها توزيع واحد.

$$EY_i = E(X_i - a)^2 = EX_i^2 - 2aEX_i + a^2 ; i = 1, \dots, n$$

$$= \sigma^2 + \mu^2 - 2a\mu + a^2 = \sigma^2 + (\mu - a)^2$$

حيث إن:

$$\mu = EX_i$$

ولكي تتحقق المساواة $EY_i = \sigma^2$ يجب أن يكون $\mu = a$ ، وهذا يعني عدم وجود أخطاء نظامية، وبالتالي حسب المبرهنة (2.4.1) فالعلاقة (1) محققة.

تبين مبرهنة تشيبيشيف أن المتوسط الحسابي لعدد كبير من المتغيرات العشوائية المستقلة ذات تباينات منتهية ومحدودة بعدد ثابت يفقد صفة العشوائية، أي يقترب بالاحتمال من مقدار ثابت.

2.4.1 صيغة برنولي لقانون الأعداد الكبيرة الضعيف

Bernoulli's Theorem

مبرهنة 2.4.1: مبرهنة برنولي

إذا كان X متغيراً عشوائياً يساوي عدد مرات ظهور حادث A في n تكراراً مستقلاً لتجربة عشوائية و p احتمال ظهور الحادث A في كل تكرار، فإن:

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{X}{n} - p\right| < \varepsilon\right) = 1 ; \quad \varepsilon > 0 \quad (5.4.1)$$

الإثبات

يمكن اعتبار X متغير عشوائي مؤلف من مجموع n متغيراً عشوائياً.

$$X = \sum_{i=1}^n X_i$$

حيث X_i متغير عشوائي يساوي عدد مرات وقوع الحادث A في التكرار i ، أي يفترض القيمتين 0,1 باحتمال p و $q = 1 - p$ على الترتيب.
بما أن:

$$EX_i = p \quad , \quad \text{var } X_i = pq \leq \frac{1}{4} \quad ; \quad i = 1, \dots, n$$

فبتطبيق مبرهنة (1.4.1) نجد:

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{n} \sum_{i=1}^n EX_i\right| < \varepsilon\right) = \lim_{n \rightarrow \infty} P\left(\left|\frac{X}{n} - p\right| < \varepsilon\right) = 1$$

وهو المطلوب.

عندما تكون n كبيرة بكفاية، فإن التكرار النسبي $W(A) = \frac{X}{n}$ يكون قريباً جداً من القيمة p (يفقد صفة العشوائية). وتكمن الأهمية التطبيقية لقانون الأعداد الكبيرة الضعيف بصيغة برنولي في أنه يعتبر أساس الطريقة الإحصائية لتقدير الاحتمالات.

تجدر الإشارة، إلى أن مبرهنة برنولي أهم صيغة، وأسبق تاريخياً، لقانون الأعداد الكبيرة، وهي تصوغ العلاقة بين التكرار النسبي لوقوع حادث واحتماله. وبرهانها كان صعباً، إلى أن جاء العالم تشيبيشيف وقدم الإثبات الوارد أعلاه.

3.4.1 صيغة بواسون لقانون الأعداد الكبيرة الضعيف

Poisson's Theorem

مبرهنة 3.4.1: مبرهنة بواسون

إذا كان في متتالية من التكرارات المستقلة، احتمال وقوع حادث A في التكرار رقم i يساوي P_i ، فإن:

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{X}{n} - \frac{1}{n} \sum_{i=1}^n P_i\right| < \varepsilon\right) = 1 \quad ; \quad \varepsilon > 0 \quad (6.4.1)$$

حيث إن X عدد مرات ظهور الحادث A في التكرارات الـ n الأولى.

الإثبات

لدينا:

$$X = \sum_1^n X_i \quad , \quad EX_i = P_i \quad , \quad \text{var } X_i = p_i q_i \leq \frac{1}{4}$$

حيث X_i ; $i = 1, 2, \dots$ عدد مرات ظهور الحادث A في التكرار رقم i .

بتطبيق مبرهنة تشيبيشيف (1.4.1) نحصل على المطلوب

4.4.1 صيغة ماركوف لقانون الأعداد الكبيرة الضعيف

Markov's Theorem

مبرهنة 4.4.1: مبرهنة ماركوف

إذا كانت متتالية المتغيرات العشوائية $\{X_n\}$ ، وكان:

$$\lim_{n \rightarrow \infty} \text{var} \left(\frac{1}{n} \sum_1^n X_i \right) = 0$$

فإن:

$$\lim_{n \rightarrow \infty} P \left(\left| \frac{1}{n} \sum_1^n X_i - \frac{1}{n} \sum_1^n EX_i \right| < \varepsilon \right) = 1 \quad ; \quad \varepsilon > 0 \quad (7.4.1)$$

يمكن إثبات صحة هذه المبرهنة بسهولة بتطبيق مبرهنة تشيبيشيف. وكحالة

خاصة، إذا كانت المتغيرات العشوائية $X_1, X_2, \dots, X_n, \dots$ مستقلة متنى متنى،

فإن شرط ماركوف يكتب على الصورة:

$$\lim_{n \rightarrow \infty} \left(\frac{1}{n^2} \sum_{i=1}^n \text{var } X_i \right) = 0$$

نلاحظ أن مبرهنة تشيبيشيف (1.4.1) حالة خاصة من مبرهنة ماركوف.

5.1 قانون الأعداد الكبيرة القوي

THE STRONG LAW OF LARGE NUMBERS

رأينا في البند (4.1) أن قانون الأعداد الكبيرة الضعيف، تحت شروط معينة، يبين أن متوسط متتالية المتغيرات العشوائية المستقلة تتقارب بالاحتمال من متوسط القيم المتوقعة لها. والسؤال الذي يطرح نفسه الآن: هل يمكن تقديم عبارة احتمالية حول متتالية المتوسطات $\left\{ \bar{X}_n ; \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i, n = 1, 2, \dots \right\}$ والجواب يعطى بقانون الأعداد الكبيرة القوي.

تعريف 1.5.1

نقول عن متتالية المتغيرات العشوائية $\{X_n\}$ بأنها تخضع لقانون الأعداد الكبيرة القوي إذا كان مهما يكن $\varepsilon > 0$ و $\delta > 0$ يمكن إيجاد عدد صحيح موجب n_0 بحيث يتحقق الشرط:

$$P\left(\left|\bar{X}_n - \sum_{i=1}^n EX_i\right| < \varepsilon ; n = n_0, n_0 + 1, \dots, n_0 + k\right) \geq 1 - \delta \quad (1.5.1)$$

من أجل كل قيم $n \geq n_0$ وكل قيم k .

Kalmagorov Inequality

متباينة كالمغوروف

إذا كانت X_1, X_2, \dots, X_n متغيرات عشوائية مستقلة وذات تباينات منتهية

فإن: $EX_i = \mu_i ; i = 1, \dots, n$ و $\sum_{i=1}^n \sigma_i^2 = c_n$ ولنفترض $\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2$

$$P\left(\left|\sum_{i=1}^n (X_i - \mu_i)\right| < \varepsilon\right) \geq 1 - \frac{c_n}{\varepsilon^2} ; \quad \varepsilon > 0 \quad (2.5.1)$$

مبرهنة 1.5.1: مبرهنة كالماغوروف Kalmagorov Theorem

إذا كانت متتالية المتغيرات العشوائية $\{X_n\}$ مستقلة متنى متنى وتحقق الشرط:

$$\sum_{i=1}^{\infty} \frac{\sigma_i^2}{i^2} < +\infty \quad (3.5.1)$$

فإنها تخضع لقانون الأعداد الكبيرة القوي.

وبناءً على ذلك، إذا كانت متتالية المتغيرات العشوائية $\{X_n\}$ مستقلة متنى متنى وذات تباينات محدودة بعدد ثابت c ، فإنها تخضع لقانون الأعداد الكبيرة القوي.

إحدى النتائج الهامة المتعلقة بقانون الأعداد الكبيرة القوي توصل إليها العالم كالماغوروف وهي:

”إذا كانت $\{X_n\}$ متتالية من المتغيرات العشوائية المستقلة متنى متنى ولها نفس التوزيع، فإن الشرط اللازم والكافي لكي تخضع هذه المتتالية لقانون الأعداد الكبيرة القوي يتمثل في وجود القيمة المتوقعة $\mu = EX_i$ “.

6.1 مبرهنات النهاية المركزية CENTRAL LIMIT THEOREMS

تطرقنا في البندين السابقين لمسائل تقارب بعض المتغيرات العشوائية إلى نهاية معينة، بغض النظر عن توزيعاتها الاحتمالية. ورأينا أن المعرفة المطلوبة للمتغيرات العشوائية موضوع الدراسة لا تتعدى قيمها المتوقعة وتبايناتها.

توجد مجموعة أخرى من المبرهنات في نظرية الاحتمالات تخص التوزيع الاحتمالي الذي ينتهي إليه توزيع المتغير العشوائي $Y_n = \sum_{i=1}^n X_i$ ، عندما $n \rightarrow \infty$.

وهذه المجموعة من المبرهنات هامة جداً في الإحصاء، وتحمل اسماً عاماً "مبرهنات النهاية المركزية"، وهي تبين الشروط العامة المفروضة على المتغيرات العشوائية X_1, \dots, X_n لكي يؤول مجموعها Y_n إلى التوزيع الطبيعي عندما $n \rightarrow \infty$.

لتكن $\{X_n\}$ متتالية من المتغيرات العشوائية المستقلة، ولنرمز بـ $EX_i = m_i$ ، $\text{var} X_i = \sigma_i^2$ ؛ $i = 1, 2, \dots$ على الترتيب، وكذلك بـ $EX_n = m_n = \sum_{i=1}^n m_i$ ، $\text{var} Y_n = \sigma_{Y_n}^2 = \sum_{i=1}^n \sigma_i^2$ للمتوقعة والتباين لـ Y_n . وعندئذ يمكن التعبير عن المحتوى العام لمبرهنات النهاية المركزية كالآتي:

بغض النظر عن توزيعات المتغيرات العشوائية X_1, \dots, X_n فإن توزيع مجموعها Y_n ، تحت شروط معينة مفروضة على المتغيرات العشوائية X_i ، ينتهي إلى التوزيع الطبيعي $N(m_{Y_n}, \sigma_{Y_n}^2)$ عندما $n \rightarrow \infty$.

1.6.1 مبرهنة النهاية المركزية بصيغة ليابونوف

Liapounov Central Limit Theorem

إذا كانت $\{X_n\}$ متتالية من المتغيرات العشوائية تحقق الشروط الآتية:

1. القيم المتوقعة $EX_i = m_i$ ، $i = 1, 2, \dots$ موجودة.
2. التباينات $\text{var} X_i = \sigma_i^2$ ؛ $i = 1, 2, \dots$ موجودة.
3. العزوم المركزية المطلقة من المرتبة الثالثة $E(|X_i - m_i|^3)$ موجودة.

$$\lim_{n \rightarrow \infty} \frac{\sum_{i=1}^n E(|X_i - m_i|^3)}{\left(\sum_{i=1}^n \sigma_i^2\right)^{3/2}} = 0 \quad (1.6.1)$$

فإن توزيع المجموع $Y_n = \sum_{i=1}^n X_i$ ينتهي إلى التوزيع الطبيعي $N(m_{Y_n}, \sigma_{Y_n}^2)$ عندما $n \rightarrow \infty$. وهذا يعني عندما تكون n كبيرة بكفاية فإن التوزيع التقريبي لـ Y_n هو $N(m_{Y_n}, \sigma_{Y_n}^2)$.
 نلاحظ من شرط ليابونوف (1.6.1) أن:

$$\lim_{n \rightarrow \infty} \frac{\sigma_i^2}{\sum_{i=1}^n \sigma_i^2} = 0 \quad (2.6.1)$$

وهذا يعني أن تبين كل متغير عشوائي X_i يدخل في تشكيل المتغير العشوائي $Y_n = \sum_{i=1}^n X_i$ يمثل نسبة صغيرة من تبين Y_n . وبعبارة أخرى، بغض النظر عن اختلاف تباينات المتغيرات العشوائية X_i ، فإن هذه التباينات يجب أن لا تختلف عن بعضها بشكل كبير، من حيث تأثيرها على تبين المتغير العشوائي Y_n ، وعندئذٍ يقال: لا يسود في المجموع Y_n أي متغير من المتغيرات العشوائية X_i .

وإذا رمزنا بـ $Z_n = \frac{Y_n - m_{Y_n}}{\sigma_{Y_n}}$ ، فإن Z_n يخضع تقريباً للتوزيع الطبيعي المعياري، عندما تكون n كبيرة.

إثبات مبرهنة ليابونوف معقد، ولا مجال لذكره هنا، لذا سنقبل هذه المبرهنة دون إثبات. وسنكتفي بإثباتها في حالة خاصة كافية من أجل معظم القضايا التي نحتاجها، بالإضافة إلى أنها كافية لمعظم التطبيقات الإحصائية.

إذا كانت $\{X_n\}$ متتالية من المتغيرات العشوائية المستقلة محققة للشروط الآتية:

1. تخضع لتوزيع احتمالي واحد.
2. القيم المتوقعة $EX_i = m$ ، $i = 1, 2, \dots$ موجودة.
3. التباينات $\text{var } X_i = \sigma^2$ ، $i = 1, 2, \dots$ موجودة.

فإن توزيع المتغير العشوائي:

$$Z_n = \frac{Y_n - nm}{\sigma\sqrt{n}} \quad ; \quad Y_n = \sum_{i=1}^n X_i$$

ينتهي إلى التوزيع الطبيعي المعياري $N(0,1)$ عندما $n \rightarrow \infty$.

الإثبات

بما أن المتغيرات العشوائية X_i ; $i = 1, 2, \dots$ مستقلة (حسب الفرض) فإن المتغيرات العشوائية $(X_i - m_i)$; $i = 1, 2, \dots$ مستقلة بدورها أيضاً.

لنرمز بـ $\varphi_i(t)$; $i = 1, 2, \dots$ للدالة المميزة للمتغير العشوائي $(X_i - m_i)$ ، وبـ $\varphi_n(t)$ للدالة المميزة للمتغير العشوائية Z_n ، ولتكن $F_n(x)$ دالة توزيع Z_n .

بناءً على خواص الدالة المميزة، فإن الدالة المميزة للمتغير العشوائي $\frac{X_i - m_i}{\sigma\sqrt{n}}$ ولنرمز لها بـ $\varphi_i^*(t)$

$$\varphi_i^*(t) = \varphi_i\left(\frac{t}{\sigma\sqrt{n}}\right) \quad ; \quad i = 1, 2, \dots$$

ومن ثم:

$$\varphi_n(t) = \left[\varphi_i\left(\frac{t}{\sigma\sqrt{n}}\right) \right]^n$$

وحيث إن العزمين المركزيين الأول والثاني هما 0 و σ^2 على الترتيب، فإن:

$$\varphi_i(t) = 1 - \frac{1}{2}\sigma^2 t^2 + o(t^2)$$

وباستبدال t بـ $\frac{t}{\sigma\sqrt{n}}$ نجد:

$$\varphi_i\left(\frac{t}{\sigma/\sqrt{n}}\right) = 1 - \frac{t^2}{2n} + \frac{R(n,t)}{n}$$

حيث إن $\lim_{n \rightarrow \infty} R(n,t) = 0$ وذلك من أجل t ثابتة. وبالتالي:

$$\varphi_n(t) = \left[1 - \frac{t^2}{2n} + \frac{R(n,t)}{n}\right]^n$$

وبأخذ نهاية الطرفين، عندما $n \rightarrow \infty$ نجد:

$$\lim_{n \rightarrow \infty} \varphi_n(t) = e^{-\frac{1}{2}t^2}$$

وهذه ما هي إلا الدالة المميزة للتوزيع الطبيعي المعياري $N(0,1)$ ، أي أن:

$$\lim_{n \rightarrow \infty} F_n(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{1}{2}z^2} dz = \Phi(z)$$

وهذا يعني عندما تكون n كبيرة فإن:

$$F_n(z) \approx \Phi(z); \quad -\infty < z < +\infty$$

ومن ثم فإن التوزيع التقريبي لـ $Y_n = \sum_{i=1}^n X_i$ عندما تكون n كبيرة، هو التوزيع الطبيعي $N(n\mu, n\sigma^2)$.

فمثلاً، عند قياس مقدار فيزيائي ما a ، نتائج القياس تمثل متغيراً عشوائياً X_i ، وبتكرار قياس المقدار a ، تحت نفس الشروط، نحصل على متتالية $\{X_n\}$ من المتغيرات العشوائية المستقلة. إذا كانت القياسات لا تتضمن أخطاء نظامية، فإن القيمة المتوقعة لـ X_i هي عبارة عن القيمة الحقيقية لقياس المقدار a ، أي أن $EX_i = a$. وعندئذ تبين أن المتغيرات X_i تصف دقة القياسات، وبما أننا لا نميز بين القياسات (لا نعتبر أي قياس هو الأساس)، فإن شروط ميرهنه.

النهاية المركزية محققة، لذا فالوسط الحسابي للقياسات المأخوذة للمقدار a هو متغير عشوائي، وتوزيعه يقترب من التوزيع الطبيعي بازدياد عدد القياسات.

2.6.1 مبرهنة النهاية المركزية بصيغة موافر ولابلاس

أشرنا عند دراسة مبرهنة لياونوف إلى أن المتغيرات العشوائية $X_i ; i = 1, \dots, n$ ، الداخلة في تشكيل المجموع $Y_n = \sum_{i=1}^n X_i$ ، تخضع لتوزيع احتمالي واحد، لكن لم نحدد نوع التوزيع (طبيعي، ذي الحدين، بواسون، ...)، أي يمكن أن تخضع لأي توزيع احتمالي. إذا افترضنا أنها تتبع توزيع برنولي بمعلمة p ، فما هو التوزيع المقارب للمجموع $Y_n = \sum_{i=1}^n X_i$ ، وبعبارة أخرى ما هو التوزيع المقارب لتوزيع ذي الحدين؟ هذا ما تجيب عليه مبرهنة موافر ولابلاس.

مبرهنة موافر ولابلاس

Laplace-Moiver Theorem

إذا كانت متتالية المتغيرات العشوائية $\{X_n\}$ مستقلة ولكل منها توزيع برنولي $B(1, p)$ ، فإن توزيع المجموع $Y_n = \sum_{i=1}^n X_i$ يتقارب من التوزيع الطبيعي $N(np, npq)$ بازدياد n ، أي أن:

$$\lim_{n \rightarrow \infty} B(n, p) = N(np, npq)$$

الإثبات

كما نعلم

$$P(X_i = x_i) = p^{x_i} q^{1-x_i} ; x_i = 0, 1 , q = 1 - p ; 0 \leq p \leq 1$$

$$EX_i = \sum_{i=0}^1 x_i p^{x_i} q^{1-x_i} = p$$

$$\text{var } X_i = EX_i^2 - (EX_i)^2 = pq + p^2 - p^2 = pq \leq \frac{1}{4} ; i = 1, 2, \dots$$

أي أن شروط مبرهنة لياونوف (في صيغتها المبسطة) محققة، ومن ثم توزيع

$Y_n = \sum_{i=1}^n X_i$ ينتهي إلى التوزيع الطبيعي $N(np, npq)$.

لكن Y_n يتبع توزيع ذي الحدين $B(n, p)$ ، وبالتالي:

$$\lim_{n \rightarrow \infty} B(n, p) = N(np, npq)$$

وعندما تكون n كبيرة فإن:

$$B(n, p) \approx N(np, npq)$$

تمارين

1. كم مرة يجب رمي قطعة نقود متجانسة حتى يكون:

$$P\left(0.4 < \frac{m}{n} < 0.6\right) \geq 0.90$$

2. يرغب باحث علمي تقدير متوسط مجتمع مستخدماً عينة عشوائية حجمها كاف للقول بأن احتمال ألا يتجاوز الفرق بين متوسط العينة ومتوسط المجتمع 25% من الانحراف المعياري هو 0.59، فما هو حجم العينة المطلوب؟

3. X متغير عشوائي توقعه الرياضي $EX = 1$ والانحراف المعياري $\sigma = 0.2$ ، قدر الحد الأدنى لاحتمالات الحوادث:

$$A = \{0.5 \leq X < 1.5\} \quad , \quad B = \{0.75 \leq X < 1.35\} \quad , \quad C = \{X < 2\}$$

4. X متغير عشوائي يساوي عدد الأيام المشمسة من السنة في منطقة معينة. إذا علمت بأن $EX = 100$ يوم و $\sigma = 20$ يوم، قدر احتمال كل من الحادثين:

$$A = \{X \geq 150\} \quad , \quad B = \{X \geq 200\}$$

5. كم مرة يجب رمي قطعة نقود متجانسة للحصول على تكرار نسبي لظهور الصورة يقع في المجال $[0.4, 0.6]$ ، وذلك باحتمال لا يقل عن 0.975 ؟
6. في استفتاء للرأي العام حول قضية ما، نريد أن يكون حجم العينة بحيث يكون الاحتمال 1% فقط أن نحصل على نسبة تأييد للقضية المطروحة على الاستفتاء أقل من 50% ، في حين أن حقيقة هذه النسبة 52% ، فكم يجب أن يكون حجم العينة؟
7. هل يمكن تطبيق قانون الأعداد الكبيرة على متتالية المتغيرات العشوائية المستقلة مثنى مثنى X_1, X_2, \dots في كل من الحالات الآتية:
- a) $P(X_k = \pm 2^k) = 2^{-(2k+1)}$ ، $P(X_k = 0) = 1 - 2^{-2k}$
- b) $P(X_k = \pm ak) = \frac{1}{2k^2}$ ، $P(X_k = 0) = 1 - \frac{1}{k^2}$
- c) $P(X_k = \pm 2^k) = \frac{1}{2^k}$ ، $P(X_k = 0) = 1 - \frac{1}{2^{2k-1}}$
- d) $P(X_k = a) = \frac{k}{2k+1}$ ، $P(X_k = -a) = \frac{k+1}{2k+1}$
8. في إحدى المدارس الابتدائية، يجب استقبال 200 طفل وطفلة في السنة الأولى، أو وجد احتمال أن يكون من بينهم 100 طفلة إذا علمت بأن احتمال ولادة ذكر يساوي 0.515 .
9. ليكن لدينا 625 تكراراً مستقلاً لتجربة مفروضة، إذا علمت بأن احتمال ظهور الحادث A في كل تكرار ثابت ويساوي 0.8 ، فأوجد احتمال أن يكون انحراف التكرار النسبي لظهور الحادث A عن احتمالها الثابت، بالقيمة المطلقة، لا يزيد عن 0.06 .
10. نسبة العطب في إنتاج صناعي 61% ، سحبت عينة عشوائية بحجم

$n = 1100$ ، فما هو احتمال أن تحتوي هذه العينة على 17 وحدة معطوبة على الأكثر؟

11 . نعلم أن دواءً معيناً فعال في 80٪ من الحالات التي يستخدم فيها للعلاج، وقد وُجد أن نوعاً جديداً من هذا الدواء أثبت فعالية في 85 من الحالات المائة الأولى التي استخدم فيها، هل يمكن القول أن هذا الدواء الجديد أفضل من القديم؟

12 . لتكن X_1, X_2, \dots متتالية من المتغيرات العشوائية ذات توقعات رياضية متساوية وتباينات محدودة، إذا علمت بأن التغاير المشترك $C_{ij} = E[(X_i - m_i)(X_j - m_j)]$ سالب فهل يمكن تطبيق قانون الأعداد الكبيرة على هذه المتتالية؟

13 . عين الدالة المميزة للمتغير العشوائي:

$$Y_n = \frac{\sum_{k=1}^n (X_k - EX_k)}{\sqrt{\sum_{k=1}^n VX_k}}$$

ثم أوجد نهايتها عندما $n \rightarrow \infty$ ، إذا علمت بأن المتغيرات العشوائية X_1, X_2, \dots مستقلة ولها توزيع احتمالي واحد:

$$P(X_k = m) = \frac{\lambda^m}{m!} e^{-\lambda} \quad ; \quad x = 0, 1, \dots$$

14 . احتمال ظهور الحادث A في كل تكرار لتجربة مفروضة 0.25، فما هو احتمال ظهور الحادث A عند 300 تكرار لتجربة المفروضة:

1. 75 مرة؟

2. أكثر من 85 وأقل من 100 مرة؟

بعض النماذج الإحصائية الخاصة

1.2 مقدمة

يهدف صف هام من المسائل في الإحصاء الرياضي إلى إيجاد توزيعات متغيرات عشوائية تصف مجتمعات مختلفة. وإحدى المسائل المركزية: دراسة مجتمعات أشكال توزيعاتها معلومة، أي أن صيغ دوال التوزيع $F(x;\theta)$ أو دوال الكثافة (دوال الاحتمال في حالة المنقطع) $f(x;\theta)$ معلومة، لكنها تعتمد على معلمة غير معلومة θ (وحيدة البعد أو متعددة الأبعاد)، وبمعرفة القيمة الحقيقية (أو التقريبية) لـ θ يتعين تماماً (أو تقريباً) توزيع المجتمع. ويعني هذا أن لدينا عائلة من التوزيعات الاحتمالية المختلفة فيما بينها قيمة المعلمة θ ، وتوزيع مجتمع الصفة المدروسة هو أحد هذه التوزيعات الاحتمالية (عضو في هذه العائلة).

يدعى التوزيع الاحتمالي الذي يعتمد على معلمة غير معلومة θ بالتوزيع الاحتمالي الإحصائي أو اختصاراً بالنموذج الإحصائي (statistical model).

ويهدف هذا الفصل إلى تقديم النماذج الإحصائية الأكثر استخداماً في الإحصاء الرياضي والتي لها تسميات ورموز عامة. فمثلاً، نموذج ذي الحدين، ويرمز له بـ $B(n,\theta)$. هذا بالإضافة إلى تقديم بعض الخصائص لكل نموذج إحصائي كالتوسط، التباين، الدالة المميزة ...

نميز بين نوعين من النماذج الإحصائية: المنقطعة والمستمرة، وذلك حسب طبيعة المتغير العشوائي X الذي يصف خاصية من خواص المجتمع قيد الدراسة.

2.2 بعض النماذج الإحصائية المنقطعة الخاصة

SOME SPECIAL STATISTICAL DISCRETE MODELS

نقدم في هذا البند أهم النماذج الإحصائية المنقطعة في الإحصاء الرياضي، ونرفق كل نموذج ببعض خواصه المميزة ومجالات تطبيقه.

1.2.2 نموذج بيرنولي Bernoulli Model

يقال عن متغير عشوائي ξ إنه يخضع لنموذج بيرنولي، إذا كانت صيغة دالة كثافته من الشكل:

$$f(x; \theta) = \theta^x (1 - \theta)^{1-x} ; \quad x = 0, 1 ; \quad 0 \leq \theta \leq 1 \quad (1.2.2)$$

حيث إن θ غير معلومة، ويمكن أن تأخذ أية قيمة في الفترة $[0, 1]$. وعندئذٍ عائلة توزيعات بيرنولي:

$$\{f(x; \theta) ; 0 \leq \theta \leq 1\}$$

ويرمز عادة لنموذج بيرنولي بـ $B(1, \theta)$. وعندئذٍ نكتب $\mathcal{L}(\xi) \in B(1, \theta)$ وتقرأ أن توزيع ξ هو أحد توزيعات $B(1, \theta)$ ، أو ξ يخضع لنموذج بيرنولي بمعلمة غير معلومة θ . نلاحظ عند كل قيمة معينة لـ θ نحصل على توزيع احتمالي (توزيعاً بيرنولياً معيناً تماماً). وإذا علمنا القيمة الحقيقية أو التقريبية لـ θ الموافقة لتوزيع ξ ولتكن θ_0 عندئذٍ نكتب $\mathcal{L}(\xi) = B(1, \theta_0)$.

إذا رمزنا للقيمة المتوقعة والتباين والدالة المميزة للنموذج $B(1, \theta)$ بـ $E_0 \xi$ ، $V_0 \xi$ و $\varphi(t; \theta)$ على الترتيب، فإن:

$$E_0 \xi = \theta \quad , \quad V_0 \xi = \theta(1 - \theta) \quad ; \quad \varphi(t; \theta) = [1 + \theta(e^t - 1)] \quad (2.2.2)$$

$$\begin{aligned}\varphi(t; \theta) &= E_{\theta} e^{it\xi} = \sum_{x=0}^1 e^{itx} \theta^x (1-\theta)^{1-x} \\ &= [1 + \theta(e^{it} - 1)] = [(1-\theta) + \theta e^{it}]\end{aligned}$$

وكما نعلم من نظرية الاحتمالات:

$$\begin{aligned}E_{\theta} \xi &= \frac{1}{i} \frac{\partial \varphi(t; \theta)}{\partial t} \Big|_{t=0} = \frac{1}{i} i \theta e^{it} \Big|_{t=0} = \theta \\ E_{\theta} \xi^2 &= \frac{1}{i^2} \frac{\partial^2 \varphi(t; \theta)}{\partial t^2} \Big|_{t=0} = \frac{1}{i^2} i^2 \theta e^{it} \Big|_{t=0} = \theta \\ V_{\theta} \xi &= E_{\theta} \xi^2 - (E_{\theta} \xi)^2 = \theta - \theta^2 = \theta(1-\theta)\end{aligned}$$

يستخدم هذا النموذج إذا كنا أمام تجربة أو محاولة عشوائية لها ناتجان فقط هما ظهور الحدث A أو عدم ظهوره (ظهور \bar{A})، وأن θ احتمال ظهور الحدث A ، ويكون $\xi(A) = 1$ ، $\xi(\bar{A}) = 0$. ومثل هذه المحاولة تدعى بمحاولة بيرنولي (Bernoulli trial)، ويدعى هذا النموذج أحياناً بنموذج ذي الحدين النقطي.

Binomial Model

2.2.2 نموذج ذي الحدين

يقال عن متغير عشوائي ξ إنه يخضع لنموذج ذي الحدين إذا كانت صيغة دالة احتمالته كالاتي:

$$f(x; n, \theta) = C_n^x \theta^x (1-\theta)^{n-x} ; \quad x = 0, 1, \dots, n ; \quad 0 \leq \theta \leq 1 \quad (3.2.2)$$

ويرمز عادة لهذا النموذج بـ $B(n, \theta)$ ، وهو يعتمد على معلمتين n, θ غير معلومتين بشكل عام، وغالباً تكون n معلومة.

ويستخدم هذا النموذج إذا كان ξ متغير عشوائي يصف نتائج n تكراراً مستقلاً لمحاولة بيرنولي (n تكراراً مستقلاً لتجربة مفروضة ذات ناتجين A و \bar{A}

وا احتمال ظهور الحادث A ثابت في كل تكرار ويساوي θ . أي أن نموذج بيرنولي حالة خاصة من نموذج ذي الحدين (موافق لـ $n = 1$).

$$E_{\theta}\xi = n\theta \quad ; \quad V_{\theta}\xi = n\theta(1-\theta) \quad ; \quad \varphi(t;n,\theta) = [(1-\theta) + \theta e^{it}]^n \quad (4.2.2)$$

الإثبات

$$\begin{aligned} \varphi(t;n,\theta) &= E_{\theta}e^{it\xi} = \sum_{x=0}^n C_n^x e^{itx} \theta^x (1-\theta)^{n-x} \\ &= [(1-\theta) + \theta e^{it}]^n \end{aligned}$$

$$E_{\theta}\xi = \frac{1}{i} \frac{\partial \varphi(t;n,\theta)}{\partial t} \Big|_{t=0} = n\theta$$

$$E_{\theta}\xi^2 = \frac{1}{i^2} \frac{\partial^2 \varphi(t;n,\theta)}{\partial t^2} \Big|_{t=0} = n\theta[(1-\theta) + n\theta]$$

$$V_{\theta}\xi = E_{\theta}\xi^2 - (E_{\theta}\xi)^2 = n\theta(1-\theta)$$

ولأهمية نموذج ذي الحدين في التطبيقات الإحصائية، ولتسهيل استخدامه، أعدت له جداول خاصة حسب قيم n و θ تعطي مباشرة احتمالات القيم الممكنة لـ ξ [الملحق جدول (1)].

Possion Model

3.2.2 نموذج بواسون

يقال عن توزيع متغير عشوائي ξ إنه يخضع لنموذج بواسون، إذا كانت صيغة دالة احتمالته:

$$f(x;\theta) = \frac{\theta^x}{x!} e^{-\theta} \quad ; \quad x = 0,1,\dots, \quad \theta > 0$$

ويرمز عادة لهذا النموذج بـ $\Pi(\theta)$ وهو يعتمد على معلمة مجهولة θ ، وعندئذ نكتب $\mathcal{L}(\xi) \in \Pi(\theta)$.

إن الدالة المميزة لـ $\Pi(\theta)$

$$\varphi(t; \theta) = \sum_{x=0}^{\infty} e^{itx} \frac{\theta^x}{x!} e^{-\theta} = e^{-\theta(1-e^{it})} \quad (6.2.2)$$

ومنها:

$$E_{\theta} \xi = \frac{1}{i} \frac{\partial \varphi(t, \theta)}{\partial t} \Big|_{t=0} = \theta \quad (7.2.2)$$

$$V_{\theta} \xi = E_{\theta} \xi^2 - (E_{\theta} \xi)^2 = \frac{1}{i^2} \frac{\partial^2 \varphi(t, \theta)}{\partial t^2} \Big|_{t=0} - \theta^2 = \theta^2 + \theta - \theta^2 = \theta$$

نلاحظ أن:

$$E_{\theta} \xi = V_{\theta} \xi = \theta \quad (8.2.2)$$

وهذه صفة مميزة لنموذج بواسون.

يدعى نموذج بواسون بنموذج الحوادث النادرة، حيث يصف الكثير من الظواهر التي تحدث في واحدة الزمن أو الفضاء. هذا بالإضافة إلى أن نموذج ذي الحدين ينتهي ضمن شروط معينة (عندما $n \rightarrow \infty$ و $\theta \rightarrow 0$ و $n\theta = c$ حيث c ثابت) إلى نموذج بواسون $\Pi(n\theta)$ ، وبالتالي عندما تكون n كبيرة و θ صغيرة، بحيث تكون $n\theta$ ثابتة أو ثابتة تقريباً، فيمكن تقريب نموذج ذي الحدين $B(n, \theta)$ بنموذج بواسون $\Pi(n\theta)$. ولتسهيل عملية استخدامه في التطبيقات الكثيرة أعدت له جداول خاصة [الملحق جدول (2)].

4.2.2 النموذج فوق الهندسي *The Hypergeometric Model*

يقال عن متغير عشوائي ξ أن توزيعه ينتمي لعائلة التوزيعات فوق الهندسية إذا كانت دالة احتمالته معرفة كالاتي:

$$f(x; N, k, n) = \frac{C_k^x C_{N-k}^{n-x}}{C_N^n} \quad ; \quad x = 0, 1, \dots, n \quad (9.2.2)$$

حيث إن n ، k ، N أعداد صحيحة موجبة و $n \leq k \leq N$. ويرمز لهذا النموذج عادة بـ $H(N, k, n)$ وهو يعتمد على ثلاث معالم n ، k ، N ، أي أن $\theta = (N, k, n)$ ، وأن:

$$E_{\theta} \xi = n \frac{k}{N} \quad , \quad V_{\theta} \xi = n \frac{k}{N} \frac{N-k}{N} \frac{N-n}{N-1} \quad (10.2.2)$$

نترك إثبات ذلك للقارئ على سبيل المثال.

يستخدم هذا النموذج عندما نكون أمام حالة من النوع الآتي:

ليكن ξ متغيراً عشوائياً يساوي عدد الوحدات المعطوبة في عينة بحجم n مشكلة بطريقة المعاينة بدون إرجاع (without replacement) من صندوق يحتوي على N وحدة منتوج منها k وحدة معطوبة. عندئذٍ ξ يتبع التوزيع فوق الهندسي.

5.2.2 نموذج ذي الحدين السالب

Negative Binomial Distribution

يقال عن متغير عشوائي ξ أن توزيعه عضو في عائلة توزيعات ذي الحدين السالب إذا كانت صيغة دالته الاحتمالية كالآتي:

$$f(x; r, \theta) = C_{r+x-1}^x \theta^r (1-\theta)^x \quad ; \quad x = 0, 1, 2, \dots \quad (11.2.2)$$

حيث: $0 \leq \theta \leq 1$ و r عدد صحيح موجب، ونرمز لهذا النموذج بـ $\bar{B}(r, \theta)$.

يستخدم هذا النموذج في الحالة التي نكون فيها أمام تكرار لتجربة بيرنولي (محاولة بيرنولي) تحت نفس الشروط حتى الحصول على r نجاحاً. فيكون ξ عندئذٍ يساوي عدد مرات الفشل حتى الحصول على r نجاحاً، أي أن $r + \xi$ يساوي عدد التكرارات اللازمة حتى الحصول على r نجاحاً، وهنالك ظواهر عديدة في الحياة العملية تخضع لمثل هذا التوزيع.

ويمكن إثبات أن:

$$E_{\theta}\xi = \frac{r(1-\theta)}{\theta} , \quad V_{\theta}\xi = \frac{r(1-\theta)}{\theta^2} , \quad \varphi(t;r,\theta) = \theta^r [1 - (1-\theta)e^{it}]^{-r} \quad (12.2.2)$$

كحالة خاصة، عندما $r = 1$ ، فنموذج ذي الحدين السالب يؤدي إلى نموذج يدعى بالنموذج الهندسي (geometric distribution) أو نموذج باسكال (Pascal) ويمكن إثبات أن توزيع مجموع متغيرات عشوائية مستقلة ولكل منها نفس التوزيع الهندسي عبارة عن توزيع ذي الحدين السالب.

6.2.2 النموذج المتعدد الحدود *The Multinomial Model*

لنفترض لدينا تجربة أو محاولة تنتهي إلى واحدة فقط من الحوادث المتنافية C_1, \dots, C_k ، ولتكن احتمالاتها الموافقة على الترتيب $\theta_1, \theta_2, \dots, \theta_k$ ، حيث $\sum_1^k \theta_i = 1$ و $\theta_i > 0$ ؛ $i = 1, \dots, k$. لنفترض الآن أننا كررنا التجربة أو المحاولة n مرة بشكل مستقل، وكان $\xi = (X_1, \dots, X_k)$ متغير عشوائي ذي k بعدد يصف عدد مرات ظهور الحوادث C_1, \dots, C_k ضمن n تكراراً مستقلاً للتجربة المفروضة، وهذا يعني أن X_1 يساوي عدد مرات ظهور الحادث C_1 ، X_2 عدد مرات ظهور الحادث C_2 ، وهكذا X_k عدد مرات ظهور الحادث C_k ، بحيث أن $\sum_1^k X_i = n$. عندئذٍ المتغير العشوائي ξ يخضع لنموذج يدعى بالنموذج المتعدد الحدود، ودالة احتمالته من الشكل:

$$f(x; \theta_1, \dots, \theta_k) = \frac{n!}{x_1! \dots x_k!} \theta_1^{x_1} \dots \theta_k^{x_k} \quad (13.2.2)$$

حيث إن $x = (x_1, \dots, x_k)$ ويرمز لهذا النموذج عادة بـ $M(n; \theta_1, \dots, \theta_k)$.

إن الدالة المميزة للتوزيع $M(n; \theta_1, \dots, \theta_k)$ هي:

$$\varphi(t_1, \dots, t_k; \theta_1, \dots, \theta_k) = (\theta_1 e^{it_1} + \dots + \theta_k e^{it_k})^n \quad (14.2.2)$$

ومن ثم:

$$E_{\theta}X_i = n\theta_i \quad , \quad V_{\theta}X_i = n\theta_i(1 - \theta_i) \quad (15.2.2)$$

$$\text{cov}_{\theta}(X_i, X_j) = -n\theta_i\theta_j$$

حيث إن: $\theta = (\theta_1, \dots, \theta_k)$

3.2 بعض النماذج الإحصائية المستمرة الخاصة

SOME SPECIAL CONTINUOUS STATISTICAL MODELS

يهدف هذا البند إلى تقديم بعض أهم النماذج الإحصائية المستمرة في الإحصاء الرياضي مرفقة ببعض خواصها.

1.3.2 النموذج المنتظم *The Uniform Rectangular Model*

إذا كان ξ متغير عشوائي مستمر كثافة توزيعه من الشكل:

$$f(x; \theta_1, \theta_2) = \begin{cases} \frac{1}{\theta_2 - \theta_1} & ; \quad \theta_1 \leq x \leq \theta_2 \\ 0 & ; \quad x < \theta_1 \text{ أو } x > \theta_2 \end{cases} \quad (1.3.2)$$

حيث إن $\theta_1 < \theta_2$ معلمتين غير معلومتين، فيقال إن توزيع ξ عضو في عائلة التوزيعات المنتظمة (أو المستطيلة)، التي تختلف عن بعضها بقيمة أحد المعلمتين $\theta_1 > \theta_2$ أو الاثنتين معاً. ويرمز لهذا النموذج عادة بـ $R(\theta_1, \theta_2)$ ، وهو يعتمد على المعلمتين θ_1, θ_2 غير المعلومتين. ونكتب $\mathcal{L}(\xi) \in R(\theta_1, \theta_2)$. وفي حالات عدة تكون $\theta_1 = 0$ فنحصل على النموذج $R(0, \theta_2)$.

إن دالة توزيع النموذج $R(\theta_1, \theta_2)$ هي:

$$F(x; \theta_1, \theta_2) = \begin{cases} 0 & ; \quad x \leq \theta_1 \\ \frac{x - \theta_1}{\theta_2 - \theta_1} & ; \quad \theta_1 < x \leq \theta_2 \\ 1 & ; \quad x > \theta_2 \end{cases} \quad (2.3.2)$$

كما أن:

$$E_{\theta}\xi = \frac{\theta_1 + \theta_2}{2}, \quad V_{\theta}\xi = \frac{(\theta_2 - \theta_1)^2}{12} \quad (3.3.2)$$

$$\varphi(t, \theta) = \frac{e^{i\theta_2 t} - e^{i\theta_1 t}}{i(\theta_2 - \theta_1)t}; \quad \theta = (\theta_1, \theta_2)$$

يعتبر النموذج $R(\theta_1, \theta_2)$ من أبسط النماذج الإحصائية المستمرة، لكنه مفيد جداً في الإحصاء الرياضي، وتبدو فائدته بشكل خاص بما يلي:

إذا كان X متغيراً عشوائياً مستمراً دالة توزيعه $F(x)$ ، فإن المتغير العشوائي $Y = F(X)$ يتبع التوزيع المنتظم $R(0,1)$. وهذه الحقيقة يمكن إثباتها على النحو التالي.

بما أن:

$$H(y) = P(F(X) < y) = \begin{cases} 0 & ; y \leq 0 \\ y & ; 0 < y \leq 1 \\ 1 & ; y > 1 \end{cases}$$

وهذا يعني أن الدالة $H(y)$ [قارن بالعلاقة (2.3.2)]، حيث: $\theta_1 = 0, \theta_2 = 1$ ما هي إلا دالة التوزيع المنتظم $R(0,1)$ ، وهو المطلوب. ونلاحظ بسهولة أن متوسط وتباين المتغير العشوائي $Y = F(X)$ هما:

$$EY = \frac{1}{2}, \quad VY = \frac{1}{12}$$

2.3.2 النموذج الطبيعي العام *The General Normal Model*

يعتبر من أهم النماذج المستمرة، حيث إن توزيعات أو نهايات توزيعات العديد من الظواهر إن لم نقل أغليبتها تنتمي لعائلة التوزيعات الطبيعية بالإضافة إلى

أن غالبية الطرق والأساليب في الإحصاء الرياضي تعتمد على التوزيعات الطبيعية، وهذا ما يبدو بوضوح في الموضوعات اللاحقة.

يقال عن توزيع متغير عشوائي ξ إنه عضو في عائلة التوزيعات الطبيعية إذا كانت دالة توزيعه من الشكل:

$$f(x; \theta_1, \theta_2) = \frac{1}{\theta_2 \sqrt{2\pi}} e^{-\frac{1}{2}(x-\theta_1)^2/\theta_2^2} ; \quad -\infty < x < +\infty \quad (4.3.2)$$

حيث إن θ_1, θ_2^2 معلمتين غير معلومتين. تدعى هذه العائلة من التوزيعات الطبيعية التي تتميز عن بعضها بقيمة إحدى المعلمتين θ_1, θ_2^2 (أو الاثنتين معا) بعائلة التوزيعات الطبيعية العامة، يرمز للنموذج (4.3.2) بـ $N(\theta_1, \theta_2^2)$ ويدعى بالنموذج الطبيعي العام، وهو يعتمد على معلمتين مجهولتين.

ومن الواضح بإجراء التحويل $Z = \frac{\xi - \theta_1}{\theta_2}$ نحصل على التوزيع الطبيعي المعياري $N(0,1)$ (توزيع معين تماماً).

إن الدالة المميزة للنموذج $N(\theta_1, \theta_2^2)$ هي:

$$\varphi(t; \theta_1, \theta_2^2) = e^{i\theta_1 t - \frac{1}{2}\theta_2^2 t^2} \quad (5.3.2)$$

وباستخدام طريقة الاشتقاق نجد متوسط وتباين $N(\theta_1, \theta_2^2)$

$$E_\theta \xi = \frac{1}{i} \frac{\partial \varphi(t; \theta_1, \theta_2)}{\partial t} \Big|_{t=0} = \theta_1 \quad (6.3.2)$$

$$V_\theta \xi = \frac{1}{i^2} \frac{\partial^2 \varphi(t; \theta_1, \theta_2)}{\partial t^2} \Big|_{t=0} = \theta_2^2$$

إذا رمزنا بـ $\theta = (\theta_1, \theta_2^2)$. فإن النموذج الطبيعي العام يعتمد على معلمة متجه (معلمة ذات بعدين).

مبرهنة 1.3.2

إذا كان X_1, X_2 متغيرين عشوائيين مستقلين، وكان X_1 يتبع $N(\mu_1, \sigma_1^2)$ و X_2 يتبع $N(\mu_2, \sigma_2^2)$ ، فإن $\eta = c_1 X_1 + c_2 X_2$ ، حيث c_1, c_2 ثابتان حقيقيان (ليس كلاهما صفرًا)، يتبع التوزيع الطبيعي:

$$N\left(\sum_{i=1}^2 c_i \mu_i, \sum_{i=1}^2 c_i^2 \sigma_i^2\right)$$

الإثبات

إذا رمزنا بـ $\varphi(t)$ للدالة المميزة للمتغير العشوائي η و بـ $\varphi_i(t)$ ؛ $i = 1, 2$ للدالة المميزة لـ X_i ، فإن:

$$\varphi(t) = \varphi_1(c_1 t) \varphi_2(c_2 t) \quad (7.3.2)$$

لأن X_1 و X_2 مستقلان (حسب الفرض)، وحسب العلاقة (5.3.2) نجد:

$$\varphi_i(c_i t) = e^{i c_i \mu_i t - \frac{1}{2} c_i^2 \sigma_i^2 t^2} ; \quad i = 1, 2$$

ومن ثم:

$$\varphi(t) = e^{i(c_1 \mu_1 + c_2 \mu_2)t - \frac{1}{2}(c_1^2 \sigma_1^2 + c_2^2 \sigma_2^2)t^2} \quad (8.3.2)$$

وهذه ما هي إلا الدالة المميزة للتوزيع الطبيعي $N\left(\sum_{i=1}^2 c_i \mu_i, \sum_{i=1}^2 c_i^2 \sigma_i^2\right)$ وهو المطلوب.

يمكن تعميم تلك الخاصة على n من المتغيرات العشوائية المستقلة X_1, \dots, X_n حيث:

$$\mathcal{L}(X_i) = N(\mu_i, \sigma_i^2) ; \quad i = 1, 2, \dots, n$$

عندئذ توزيع المتغير العشوائي $\eta = \sum_{i=1}^n c_i X_i$ هو:

$$N\left(\sum_{i=1}^n c_i \mu_i, \sum_{i=1}^n c_i^2 \sigma_i^2\right)$$

كحالة خاصة، إذا كانت المعلمة θ_2^2 معلومة ولنرمز لها بـ σ^2 ، بينما θ_1 غير معلومة، فنحصل على النموذج الطبيعي $N(\theta, \sigma^2)$ ، ولتمييز سنطلق عليه اسم النموذج الطبيعي *I*. وبشكل مشابه، إذا كانت المعلمة θ_1 معلومة ولنرمز لها بـ μ ، بينما θ_2^2 غير معلومة، فنحصل على النموذج الطبيعي $N(\mu, \theta^2)$ ونطلق عليه اسم النموذج الطبيعي *II*.

3.3.2 النموذج الطبيعي الثنائي العام

The General Bivariate Normal Model

تطرقنا في الفقرة السابقة للنموذج الطبيعي للمتغيرات العشوائية وحيدة البعد، وللأهمية الاستثنائية لهذا النموذج في الإحصاء، من المفيد دراسة النموذج الطبيعي المتعدد. وقبل ذلك نرى الفائدة في دراسة النموذج الطبيعي الثنائي بشيءٍ من التفصيل.

يقال إن المتغير العشوائي ذو البعدين $Y = (X_1, X_2)$ يتبع النموذج الطبيعي الثنائي العام، إذا كانت صيغة دالة كثافته من الشكل:

$$f(x_1, x_2; \mu, \Sigma) = \frac{\sqrt{|\Sigma^{-1}|}}{2\pi} e^{-\frac{1}{2}Q(x_1, x_2)} ; \quad (x_1, x_2) \in R^2 \quad (9.3.2)$$

حيث إن:

$$Q = \sigma^{11}(x_1 - \mu_1)^2 + 2\sigma^{12}(x_1 - \mu_1)(x_2 - \mu_2) + \sigma^{22}(x_2 - \mu_2)^2 \quad (10.3.2)$$

و

$$\Sigma = \|\sigma_{ij}\| \quad ; \quad \sigma_{ij} = \text{cov}(X_i, X_j) \quad , \quad i, j = 1, 2$$

مصفوفة التباين (covariance matrix)، $\Sigma^{-1} = \|\sigma^{ij}\|$ معكوس المصفوفة Σ ، $|\Sigma^{-1}|$ محددة المصفوفة Σ^{-1} وأن:

$$\mu = (\mu_1, \mu_2) \quad ; \quad EX_i = \mu_i \quad ; \quad i = 1, 2$$

نلاحظ بسهولة أن المصفوفة Σ محددة موجبة (أي أن $|\Sigma| \neq 0$)، ومن ثم فالصيغة التوزيعية Q محددة موجبة.

وإذا رمزنا بـ ρ لمعامل الارتباط بين X_1 و X_2 ، يمكن كتابة العلاقة (9.3.2) على النحو الآتي:

$$f(x_1, x_2; \mu, \Sigma) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho}} e^{-\frac{1}{2}Q(x_1, x_2)} ; (x_1, x_2) \in R^2 \quad (11.3.2)$$

حيث أن:

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

$$\sigma_i^2 = \text{var } X_i ; i = 1, 2$$

ونرمز للنموذج الطبيعي الثنائي العام بـ $N(\mu, \Sigma)$ حيث إن μ و Σ غير معلومتين.

إن الدالة المميزة للنموذج $N(\mu, \Sigma)$ هي:

$$\phi(t_1, t_2) = \exp \left[i(\mu_1 t_1 + \mu_2 t_2) - \frac{1}{2}(\sigma_{11}t_1^2 + \sigma_{22}t_2^2 + 2\sigma_{12}t_1 t_2) \right] \quad (12.3.2)$$

مبرهنة 2.3.2

إذا كان (X_1, X_2) متغيراً عشوائياً يتبع النموذج الطبيعي الثنائي العام $N(\mu, \Sigma)$ ، فإن المتغير العشوائي $\eta = c_1 X_1 + c_2 X_2$ يتبع النموذج:

$$N \left(\sum_{i=1}^2 c_i \mu_i, \sum_{i,j=1}^2 \sigma_{ij} c_i c_j \right)$$

ويمكن إثبات صحة هذه المبرهنة بسهولة اعتماداً على العلاقة (12.3.2) وخواص الدالة المميزة.

لندرس الآن المتغير العشوائي الشرطي $X_2|X_1$ ، حيث (X_1, X_2) يتبع النموذج الثنائي $N(\mu, \Sigma)$.

إن النموذج الهامشي لـ X_1 :

$$f_1(x_1; \mu, \Sigma) = \int_{-\infty}^{+\infty} f(x; \mu, \Sigma) dx_2$$

$$= \frac{1}{\sigma_1 \sqrt{2\pi}} e^{-\frac{1}{2}(x_1 - \mu_1)^2 / \sigma_1^2} \quad ; \quad x_1 \in R$$

حيث إن: $\sigma_1^2 = \sigma_{11}$ ، وباستخدام العلاقة (10.3.2) نجد:

$$f(x_2 | x_1; \mu, \Sigma) = \frac{f(x_1, x_2)}{f_1(x_1)} = \frac{1}{\sigma_2 \sqrt{2\pi(1-\rho^2)}} e^{-\frac{1}{2}Q(x_1, x_2) + \frac{1}{2}(x_1 - \mu_1)^2 / \sigma_1^2} \quad (13.3.2)$$

وبإجراء بعض الإصلاحات الجبرية نجد:

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

. (14.3.2)

أي أن $(X_2 | X_1)$ يتبع النموذج الطبيعي:

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

وهذا يعني:

$$E(X_2 | X_1) = \mu_2 + \rho \frac{\sigma_2}{\sigma_1} (x_1 - \mu_1) \quad , \quad \text{var}(X_2 | X_1) = \sigma_2^2 (1 - \rho^2) \quad (15.3.2)$$

وهي عبارة عن معادلة خط المخدر X_2 على X_1 . وبشكل مشابه نجد توزيع $X_1 | X_2$.

4.3.2 النموذج الطبيعي المتعدد العام

The General k-Negative Normal Model

إن النموذج الطبيعي ذي $k > 2$ بعدد وخواصه عبارة عن تعميم مباشر لحالة $k = 2$ ، الواردة في الفقرة السابقة.

دالة كثافة النموذج الطبيعي المتعدد العام (ذي k بعد)

$$f(x_1, \dots, x_k; \mu, \Sigma) = \frac{\sqrt{|\Sigma^{-1}|}}{(2\pi)^{k/2}} e^{-\frac{1}{2}Q(x_1, \dots, x_k)} ; (x_1, \dots, x_k) \in R^k \quad (16.3.2)$$

حيث إن:

$$\mu = (\mu_1, \dots, \mu_k) , \quad Q(x_1, \dots, x_k) = \sum_{i,j=1}^k \sigma^{ij} (x_i - \mu_i)(x_j - \mu_j) \quad (17.3.2)$$

$$\Sigma^{-1} = \|\sigma^{ij}\| \text{ و } \Sigma = \|\sigma_{ij}\| ; i, j = 1, \dots, k \text{ مصفوفة المعكوس}$$

نفترض أن Σ محددة موجبة ($|\sigma_{ij}| \neq 0$).

إذا رمزنا بـ μ لمتجه القيم المتوقعة (μ_1, \dots, μ_k) ، فنرمز للنموذج الطبيعي المتعدد العام بـ $N(\mu, \Sigma)$ ودالته المميزة تكون:

$$\varphi(t_1, \dots, t_k; \mu, \Sigma) = \exp \left[i \sum_{i=1}^k \mu_i t_i - \frac{1}{2} \sum_{i,j=1}^k \sigma_{ij} t_i t_j \right] \quad (18.3.2)$$

مبرهنة 3.3.2

إذا كان (X_1, \dots, X_k) متغيراً عشوائياً يتبع النموذج الطبيعي المتعدد $N(\mu, \Sigma)$ ، فإن المتغير العشوائي $\eta = c_1 X_1 + \dots + c_k X_k$ يتبع النموذج الطبيعي العام:

$$N \left(\sum_{i=1}^k c_i \mu_i , \sum_{i,j=1}^k \sigma_{ij} c_i c_j \right)$$

يمكن الإثبات بالاعتماد على الدالة المميزة وخواصها.

Gamma Model

5.3.2 نموذج جاما

تدعى الدالة $\Gamma(\alpha)$ المعرفة كالتالي:

$$\Gamma(\alpha) = \int_0^{\infty} x^{\alpha-1} e^{-x} dx ; x > 0 , \alpha > 0 \quad (19.3.2)$$

بدالة جاما (gamma function) أو بتكامل آيلر من النوع الثاني.

تحقق دالة جاما $\Gamma(\alpha)$ الخواص الآتية:

$$\Gamma(1) = \Gamma(2) = 1 \quad .1$$

وهذه تنتج مباشرة من العلاقة (19.3.2) بإعطاء $\alpha = 1, 2$.

$$\Gamma(\alpha) = (\alpha - 1)\Gamma(\alpha - 1) \quad .2$$

يمكن إثبات صحة هذه الخاصية باستخدام العلاقة (19.3.2) وتطبيق التكامل بالتجزئة:


$$\begin{aligned} \Gamma(\alpha) &= \int_0^{\infty} x^{\alpha-1} e^{-x} dx = \left(-x^{\alpha-1} e^{-x} \Big|_0^{\infty} + (\alpha - 1) \int_0^{\infty} x^{\alpha-2} e^{-x} dx \right) \\ &= (\alpha - 1)\Gamma(\alpha - 1) \end{aligned}$$

وكحالة خاصة، إذا كان α عدد صحيح، فإن:

$$\Gamma(\alpha) = (\alpha - 1)!$$

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi} \quad .3$$

ويمكن تمثيل الدالة $\Gamma(\alpha)$ بيانياً كما هو مبين على الشكل (1.3.2).



شكل 1.3.2


يمكن من الدالة $\Gamma(\alpha)$ تعريف نموذج له دور هام في الإحصاء، يدعى بنموذج جاما (gamma model) نرمز له بـ $\Gamma(\alpha, \beta)$ وهو يعتمد على معلمتين α, β غير معلومتين.

يقال عن توزيع متغير عشوائي X إنه عضو في عائلة التوزيعات الجماوية إذا كانت صيغة دالة كثافته من الشكل:

$$f(x; \alpha, \beta) = \begin{cases} \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} & ; x > 0 \\ 0 & ; x \leq 0 \end{cases} \quad (20.3.2)$$

حيث إن $\Gamma(\alpha)$ دالة جاما المعرفة بالعلاقة (19.3.2) و $\alpha > 0, \beta > 0$. ونرمز لنموذج Γ بـ $\Gamma(\alpha, \beta)$.

نلاحظ أن نموذج جاما يتعلق بالمعلمتين α, β ، ويبين الشكل (2.3.2) منحنيات توزيعات جاما الموافقة لبعض القيم الخاصة لـ α, β .



شكل (2.3.2)

الدالة المميزة للنموذج $\Gamma(\alpha, \beta)$ هي:

$$\varphi(t; \alpha, \beta) = (1 - i\beta t)^{-\alpha} \quad (21.3.2)$$

الإثبات

$$\begin{aligned} \varphi(t; \alpha, \beta) &= Ee^{it\xi} = \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^\infty e^{itx} x^{\alpha-1} e^{-x/\beta} dx \\ &= \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^\infty x^{\alpha-1} e^{-\left(\frac{1}{\beta} - it\right)x} dx \end{aligned}$$

وبإجراء التحويل $y = \left(\frac{1}{\beta} - it\right)x$ نجد:

$$\varphi(t; \alpha, \beta) = \frac{1}{\beta^\alpha \Gamma(\alpha)} \frac{1}{(1/\beta - it)^\alpha} \int_0^\infty y^{\alpha-1} e^{-y} dy$$

$$\varphi(t; \alpha, \beta) = (1 - i\beta t)^{-\alpha}$$

وهو المطلوب.

العزم الابتدائي من المرتبة r لنموذج جاما (20.3.2)

$$E_\theta \xi^r = \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^\infty x^{r+\alpha-1} e^{-x/\beta} dx \quad ; \quad \theta = (\alpha, \beta)$$

وبوضع $y = \frac{x}{\beta}$ نجد:

$$E_\theta \xi^r = \frac{\beta^\alpha}{\Gamma(\alpha)} \int_0^\infty y^{r+\alpha-1} e^{-y} dy = \frac{\beta^r \Gamma(\alpha + r)}{\Gamma(\alpha)} \quad ; \quad \theta = (\alpha, \beta) \quad (22.3.2)$$

وبإعطاء $r = 1, 2$ نحصل على:

$$E_\theta \xi = \alpha\beta \quad , \quad E_\theta \xi^2 = \alpha(\alpha + 1)\beta^2 \quad , \quad \text{var}_\theta \xi = E_\theta \xi^2 - (E_\theta \xi)^2 = \alpha\beta^2 \quad (23.3.2)$$

ويمكن الوصول إلى نفس النتيجة باستخدام الدالة المميزة $\varphi(t; \alpha, \beta)$ وتطبيق العلاقة:

$$E_{\theta} \xi^r = \frac{1}{i^r} \frac{\partial^r \varphi(t; \alpha, \beta)}{\partial t^r} \Big|_{t=0}$$

نلاحظ من العلاقتين (20.3.2) و (21.3.2) أن المعلمة β تلعب دور المقياس، بحيث إنه إذا كان $\mathcal{L}(\xi) \in \Gamma(\alpha, 1)$ فإن $\mathcal{L}(\beta\xi) \in \Gamma(\alpha, \beta)$. وبناءً على هذه الخاصة، لدراسة المميزات العددية لنموذج جاما يكفي دراستها من أجل قيم معينة لـ β . فمثلاً عند $\beta = 1$ أو $\beta = 2$ ، والقيمة الثانية أكثر فائدة، لأن النموذج $\Gamma(\alpha, 2)$ يلعب دوراً هاماً في الإحصاء ويدعى بنموذج كاي مربع.

وهناك حالة خاصة من نموذج جاما تلعب دوراً هاماً في الإحصاء، وهي الحالة الموافقة لـ $\alpha = 1, \beta = \theta$ ، وتدعى بالنموذج الأسّي (exponential model) ونرمز له بـ $\Gamma(1, \theta)$. أي أن:

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} e^{-x/\theta} & ; x > 0 \\ 0 & ; x \leq 0 \end{cases} \quad (24.3.2)$$

ودالته المميزة:

$$\varphi(t; \theta) = (1 - i\theta t)^{-1} = \frac{1}{(1 - i\theta t)} \quad (25.3.2)$$

وإذا كان $\mathcal{L}(\xi) \in \Gamma(1, \theta)$ ، فإن:

$$E_{\theta} \xi^r = \frac{\theta^r \Gamma(1+r)}{\Gamma(1)} = \theta^r \Gamma(r+1) \quad (26.3.2)$$

وبإعطاء $r = 1, 2$ نجد:

$$E_{\theta}\xi = \theta \quad , \quad E_{\theta}\xi^2 = 2\theta^2 \quad , \quad \text{var}\xi = \theta^2$$

مبرهنة 4.3.2

إذا كانت X_1, \dots, X_n متغيرات عشوائية مستقلة من توزيع $\mathcal{L}(\xi) \in \Gamma(1, \theta)$ ، فإن المتغير العشوائي $\sum_{j=1}^n X_j = Y$ يخضع لتوزيع $\Gamma(n, \theta)$.

يمكن إثبات ذلك باستخدام الدالة المميزة على النحو الآتي:

$$\varphi_Y(t, \theta) = \prod_{j=1}^n \varphi_{X_j}(t, \theta) = (1 - i\theta t)^{-n}$$

وبالمقارنة مع العلاقة (21.3.2) نجد أن $\varphi_Y(t)$ ما هي إلا الدالة المميزة للنموذج $\Gamma(n, \theta)$ ، حيث $\alpha = n$ ، $\beta = \theta$. وحسب العلاقة (23.3.2)، فإن:

$$E_{\theta}Y = n\theta \quad , \quad E_{\theta}Y^2 = n(n+1)\theta^2 \quad , \quad V_{\theta}Y = n\theta^2 \quad (28.3.2)$$

$$E_{\theta}\left(\frac{1}{Y}\right) = \frac{1}{\theta^n \Gamma(n)} \int_0^{\infty} \frac{1}{y} y^{n-1} e^{-y/\theta} dy = \frac{1}{\theta^n \Gamma(n)} \int_0^{\infty} y^{n-2} e^{-y/\theta} dy$$

وبوضع $z = \frac{y}{\theta}$ نجد:

$$E_{\theta}\left(\frac{1}{Y}\right) = \frac{\theta^{n-1}}{\theta^n \Gamma(n)} \int_0^{\infty} z^{n-2} e^{-z} dz = \frac{1}{\theta \Gamma(n)} \Gamma(n-1) = \frac{1}{n-1} \frac{1}{\theta} \quad (27.3.2)$$

وهناك صيغة أخرى مكافئة للنموذج الأسّي نرمز لها بـ $\Gamma\left(1, \frac{1}{\theta}\right)$:

$$f(x; \theta) = \begin{cases} \theta e^{-\theta x} & ; \quad x > 0 \\ 0 & ; \quad x \leq 0 \end{cases}$$

وعندئذٍ تبقى كل النتائج أعلاه صحيحة على أن نستبدل θ بـ $\frac{1}{\theta}$.

مبرهنة 5.3.2

إذا كان X متغيراً عشوائياً له التوزيع المنتظم $R(0,1)$ ، فإن توزيع المتغير العشوائي $Y = -\ln X$ له توزيع جاما $\Gamma(1,1)$.

نترك إثبات صحة هذه المبرهنة كتمرين للقارئ.

للمنموذج $\Gamma(\alpha, \beta)$ دورٌ هامٌ عند حل المسائل الإحصائية المتعلقة بصيغ تريعية في متغيرات عشوائية لها توزيعات طبيعية.

6.3.2 نموذج كاي مربع (نموذج χ^2) Chi-Square Model

نميز ضمن عائلة التوزيعات الجماوية عائلة أصغر تدعى بعائلة توزيعات χ^2 .


نقول عن توزيع متغير عشوائي χ^2 إنه عضو في عائلة توزيعات χ^2 إذا كانت صيغة دالة كثافته الاحتمالية من الشكل:

$$f(x;v) = \frac{1}{2^{v/2} \Gamma(v/2)} x^{v/2-1} e^{-\frac{1}{2}x} ; \quad x > 0 \quad (29.3.2)$$

و يرمز لنموذج χ^2 بـ χ_v^2 (أو $\chi_{(v)}^2$)، الذي يعتمد على معلمة غير معلومة v تدعى بدرجات الحرية، وهو حالة خاصة من نموذج $\Gamma(\alpha, \beta)$ الموافق لـ $\alpha = \frac{v}{2}$ و

$$\beta = 2 \text{، أي أن } \chi_v^2 = \Gamma\left(\frac{v}{2}, 2\right)$$

هكذا، فإن نموذج χ_v^2 يشتمل على معلمة غير معلومة واحدة v ويبين الشكل (4.3.2) منحني توزيع χ^2 الموافق بعض درجات حرية مختلفة.




شكل (4.3.2)

دالة توزيع χ^2 تأخذ الشكل:


$$F(x; v) = P_v(\xi < x) = \begin{cases} \frac{1}{2^{v/2} \Gamma(v/2)} \int_0^x x^{v/2-1} e^{-x/2} dx & ; x > 0 \\ 0 & ; x \leq 0 \end{cases} \quad (30.3.2)$$

ويرمز عادة للمتغير العشوائي الذي توزيعه يخضع للنموذج χ_v^2 بـ χ^2 .

ويبين الشكل (5.3.2) منحنى دالة توزيع χ^2 الموافق لدرجات حرية مختلفة.



شكل (6.3.2) توزيع χ_v^2



شكل (5.3.2) دالة توزيع χ_v^2

تستخدم غالباً في التطبيقات القيمة الحرجة لتوزيع χ_v^2 والتي نرمز لها بـ $\chi_{p,v}^2$. القيمة الحرجة $\chi_{p,v}^2$ الموافقة لاحتمال مفروض p هي عبارة عن قيمة المتغير العشوائي χ^2 التي تحقق الشرط الآتي:

$$P(\chi^2 > \chi_{p,v}^2) = \int_{\chi_{p,v}^2}^{\infty} f(\chi^2) d\chi^2 = p$$

ومن وجهة نظر هندسية، إيجاد القيمة الحرجة $\chi_{p,v}^2$ يتمثل في اختيار قيمة لـ χ^2 بحيث تكون مساحة المنطقة المخططة على الشكل (6.3.2) مساوية لـ p . ويتضمن الجدول (11) في الملحق قيم $\chi_{p,v}^2$ الموافقة لدرجات حرية $v \leq 35$ واحتمل P .

بوضع $\alpha = \frac{v}{2}$ و $\beta = 2$ في العلاقة (21.3.2) نحصل على الدالة المميزة للنموذج χ_v^2 ، أي أن:

$$\varphi(t, v) = (1 - 2it)^{-\frac{v}{2}} \quad (31.3.2)$$

وأيضاً بوضع $\beta = 2$ وإعطاء $r = 1, 2$ في العلاقة (22.3.2) نجد:

$$E_v \chi^2 = 2\alpha = v \quad , \quad V_v \chi^2 = 4\alpha = 2v \quad (32.3.2)$$

مبرهنة 6.3.2

إذا كانت المتغيرات العشوائية ξ_1, \dots, ξ_n مستقلة و $\mathcal{L}(\xi_i) \in \chi_{v_i}^2$; $i = 1, \dots, n$ ، فإن $\xi = \sum_{i=1}^n \xi_i$ حيث $\mathcal{L}(\xi) \in \chi_v^2$ ، $v = \sum_{i=1}^n v_i$.

الإثبات

بناءً على خاصية الدالة المميزة:

$$\varphi_{\xi}(t) = \varphi_{\sum_{i=1}^n \xi_i}(t) = \prod_{i=1}^n \varphi_{\xi_i}(t, v_i) = \prod_{i=1}^n (1 - 2it)^{-\frac{v_i}{2}} = (1 - 2it)^{-\frac{1}{2} \sum_{i=1}^n v_i} = (1 - 2it)^{-\frac{v}{2}}$$

أي أن:

$$\mathcal{L}(\xi) \in \chi_v^2 \quad ; \quad v = \sum_{i=1}^n v_i$$

وهو المطلوب.

إذا كان $\mathcal{L}(\eta_i^2) = \chi_{(1)}^2$; $i = \overline{1, n}$ فإن:

$$E\eta_i^2 = 1 \quad , \quad V\eta_i^2 = 2$$

وحسب مبرهنة النهاية المركزية، عندما $n \rightarrow \infty$ ، نجد:

$$\mathcal{L}(\eta^*) = N(n, 2n) \quad ; \quad \eta^* = \sum_{i=1}^n \eta_i^2$$

وعلى ذلك:

$$\mathcal{L}\left(\frac{\eta^* - n}{\sqrt{2n}}\right) = N(0, 1)$$

وهذا يعني عندما تكون n كبيرة ($n \geq 30$) يمكن استخدام التوزيع الطبيعي $N(n, 2n)$ كتقريب جيد للتوزيع $\chi_{(n)}^2$. وبالتالي عندما $n \geq 30$ يمكن استخدام العلاقة:

$$P(\chi^2 < x) \approx \Phi\left(\frac{x - n}{\sqrt{2n}}\right)$$

لحساب $P(\chi^2 < x)$ ، أو لإيجاد القيم الحرجة الموافقة لـ n درجة حرية واحتمال معطى p ، ويمكن استخدام الصيغة التقريبية:

$$P(\chi^2 < x) \approx \Phi(\sqrt{2x} - \sqrt{2n - 1})$$

عندما تكون n و x كبيرتين. لذا لا يشتمل الملحق جدول (11) على قيم $v > 35$.

مبرهنة 7.3.2

إذا كان $\mathcal{L}(\eta) = N(0,1)$ ، فإن $\mathcal{L}(\eta^2) = \chi_1^2$ ، أي أن توزيع مربع المتغير العشوائي η الخاضع للتوزيع الطبيعي المعياري هو χ^2 بدرجة حرية واحدة.

الإثبات

يمكن إثبات ذلك على النحو الآتي:

$$\varphi_{\eta^2}(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{iuz} e^{-\frac{1}{2}z^2} dz = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}(1-2it)z^2} dz$$

وبإجراء التحويل $u = (1-2it)^{\frac{1}{2}} z$ نجد:

$$\varphi_{\eta^2}(t) = \frac{1}{\sqrt{2\pi}} \frac{1}{(1-2it)^{1/2}} \int_{-\infty}^{+\infty} e^{-\frac{1}{2}u^2} du = (1-2it)^{-\frac{1}{2}}$$

وهذه ما هي إلا الدالة المميزة للتوزيع χ_1^2 .

نتيجة

بناءً على المبرهنتين (6.3.2) و (7.3.2) نجد: إذا كانت المتغيرات العشوائية η_1, \dots, η_n مستقلة ولكل منها توزيع طبيعي معياري $N(0,1)$ ، فإن:

$$\mathcal{L}\left(\sum_{i=1}^n \eta_i^2\right) = \chi_n^2$$

لأن: $\mathcal{L}(\eta_i^2) = \chi_1^2$; $i = 1, \dots, n$.

هكذا، إذا كان $\mathcal{L}(\eta^*) = \chi_n^2$ ، فإن المتغير العشوائي η^* يمكن كتابته على الشكل: $\eta^* = \sum_{i=1}^n \eta_i^2$ ، حيث المتغيرات العشوائية η_i^2 ; $i = 1, \dots, n$ مستقلة و $\mathcal{L}(\eta_i^2) = \chi_{(1)}^2$; $i = 1, \dots, n$. ومصطلح "درجات الحرية" مرتبط أساساً بهذا التصور.

مبرهنة 8.3.2

إذا كان X_1^2 و X_2^2 متغيرين عشوائيين مستقلين، حيث X_1^2 يتبع توزيع $\chi_{v_1}^2$ و $X_2^2 + X_1^2$ يتبع توزيع χ_v^2 ($v > v_1$)، فإن X_2^2 يخضع أيضاً لتوزيع χ^2 بـ $v_2 = v - v_1$ درجة حرية.

يمكن إثبات هذه الخاصة بسهولة باستخدام العلاقة (31.3.2).

سنحتاج لاحقاً إلى إحدى التعميمات الهامة لتوزيع χ^2 . لتكن η_1, \dots, η_n متغيرات عشوائية مستقلة و $\mathcal{L}(\eta_i) = N(\mu_i, 1)$ ، وبالتالي فإن:

$$\mathcal{L}\left(\sum_{i=1}^n (\eta_i - \mu_i)^2\right) = \chi_n^2$$

ونحتاج أحياناً لمعرفة توزيع مجموع مربعات المتغيرات العشوائية η_i . ويدعى التوزيع الاحتمالي للمتغير العشوائي $\eta^* = \sum_1^n \eta_i^2$ بتوزيع χ^2 اللامركزي بـ n درجة حرية بالمعلمة $\lambda^2 = \sum_{i=1}^n \mu_i^2$ ونرمز له بـ $\chi_{n,\lambda}^2$ (أو $\chi_{(n,\lambda)}^2$). أي أن:

$$\mathcal{L}\left(\sum_1^n \eta_i^2\right) = \chi_{(n,\lambda)}^2$$

ودالة كثافة هذا التوزيع:

$$f_n(\chi^2, \lambda^2) = \frac{(\chi^2)^{\frac{n}{2}-1} e^{-(\chi^2+\lambda^2)/2}}{2^{\frac{n}{2}}} \sum_{j=0}^{\infty} \frac{(\chi^2 \lambda^2)^j}{j! 2^{2j} \Gamma(n/2 + j)} \quad (33.3.2)$$

ونلاحظ بسهولة أن:

$$E_\lambda\left(\sum_1^n \eta_i^2\right) = n + \lambda^2 \quad , \quad V_\lambda\left(\sum_1^n \eta_i^2\right) = 2(n + 2\lambda^2)$$

وعندما $\lambda = 0$ فإن توزيع $\chi_{n,\lambda}^2$ اللامركزي يؤول إلى توزيع χ_n^2 المركزي (العادي).

Beta Model

7.3.2 نموذج بيتا (نموذج β)

يقال عن توزيع متغير عشوائي مستمر X إنه عضو في عائلة توزيعات β ، إذا كانت صيغة كثافة توزيعه الاحتمالية من الشكل:

$$f(x; v_1, v_2) = \frac{\Gamma(v_1 + v_2)}{\Gamma(v_1)\Gamma(v_2)} x^{v_1-1}(1-x)^{v_2-1} ; \quad 0 < x < 1 \quad (34.3.2)$$

حيث إن v_1, v_2 أعداد حقيقية موجبة، ويرمز لهذا النموذج عادة بـ $Be(v_1, v_2)$ ، وهو يعتمد على معلمتين غير معلومتين v_1 و v_2 .

دالة توزيع $Be(v_1, v_2)$ ، ونرمز لها بـ $I_x(v_1, v_2)$. وتدعى بدالة بيتا غير التامة (الناقصة):

$$I_x(v_1, v_2) = \frac{\Gamma(v_1 + v_2)}{\Gamma(v_1)\Gamma(v_2)} \int_0^x x^{v_1-1}(1-x)^{v_2-1} dx ; \quad 0 < x < 1 \quad (35.3.2)$$

وهناك جداول خاصة تعطي قيم $I_x(v_1, v_2)$ من أجل $x = 0.01, \dots, 1$ و $v_1, v_2 = 0.05, \dots, 50$ ويدعى المقدار $\frac{\Gamma(v_1)\Gamma(v_2)}{\Gamma(v_1 + v_2)}$ بدالة بيتا (beta function) ونرمز لها بـ $\beta(v_1, v_2)$. ومن خواص دالة الكثافة نجد أن:

$$\beta(v_1, v_2) = \frac{\Gamma(v_1)\Gamma(v_2)}{\Gamma(v_1 + v_2)} = \int_0^1 x^{v_1-1}(1-x)^{v_2-1} dx \quad (36.3.2)$$

العزم الابتدائي من المرتبة r للتوزيع (34.3.2)

$$E_{\theta} \xi^r = \frac{1}{\beta(v_1, v_2)} \int_0^1 x^{v_1+r-1}(1-x)^{v_2-1} dx ; \quad \theta = (v_1, v_2)$$

وبناءً على العلاقة (36.3.2) نجد:

$$E_{\theta} \xi = \frac{\Gamma(v_1 + v_2)}{\Gamma(v_1)\Gamma(v_2)} \frac{\Gamma(v_1 + r)\Gamma(v_2)}{\Gamma(v_1 + v_2 + r)} = \frac{\Gamma(v_1 + v_2)\Gamma(v_1 + r)}{\Gamma(v_1 + v_2 + r)\Gamma(v_1)} \quad (37.3.2)$$

ومن ثم:

$$E_{\theta}\xi = \frac{\Gamma(v_1 + v_2)\Gamma(v_1 + r)}{\Gamma(v_1 + v_2 + r)\Gamma(v_1)} = \frac{v_1}{v_1 + v_2} \quad (38.3.2)$$

$$V_{\theta}\xi = E_{\theta}\xi^2 - (E_{\theta}\xi)^2 = \frac{v_1 v_2}{(v_1 + v_2)^2 (v_1 + v_2 + 1)}$$

مبرهنة 8.3.2

إذا كان X_1, X_2 متغيرين عشوائيين مستقلين لهما توزيع $\Gamma(v_2, 1)$ و $\Gamma(v_1, 1)$ على الترتيب، فإن المتغير العشوائي

$$U = \frac{X_1}{X_1 + X_2}$$

له توزيع بيتا $Be(v_1, v_2)$.

الإثبات

دالة كثافة المتغير العشوائي (X_1, X_2)

$$\frac{1}{\Gamma(v_1)\Gamma(v_2)} x_1^{v_1-1} x_2^{v_2-1} e^{-x_1-x_2}$$

وبالانتقال إلى المتغيرين Z, U ، حيث إن:

$$u = \frac{x_1}{x_1 + x_2}, \quad z = x_2$$

نجد:

$$\frac{1}{\Gamma(v_1)\Gamma(v_2)} u^{v_1-1} z^{v_1+v_2-1} (1-u)^{-(v_1+1)} e^{-z/(1-u)} du dz$$

وبإجراء التكامل بالنسبة لـ z من 0 إلى ∞ نجد:

$$f(u; v_1, v_2) = \frac{\Gamma(v_1 + v_2)}{\Gamma(v_1)\Gamma(v_2)} u^{v_1-1} (1-u)^{v_2-1} \quad ; \quad 0 < u < 1$$

وهو عبارة عن توزيع $Be(v_1, v_2)$.

F Model

8.3.2 نموذج F

هناك نموذج آخر يلعب دوراً هاماً يتعلق بالمعينة من مجتمع طبيعي، يدعى نموذج F (نموذج فيشر)، الذي يستنتج من نموذج β على النحو الآتي:

بإستبدال v_1, v_2 بـ $\frac{v_1}{2}, \frac{v_2}{2}$ على الترتيب في نموذج بيتا (34.3.2) نجد:

$$f(x; v_1, v_2) = \begin{cases} kx^{\frac{v_1}{2}-1} (1-x)^{\frac{v_2}{2}-1} & ; \quad 0 < x < 1 \\ 0 & ; \quad x \leq 0 \text{ or } x \geq 1 \end{cases} \quad (39.3.2)$$

حيث إن $k = \Gamma\left(\frac{v_1 + v_2}{2}\right) / \Gamma\left(\frac{v_1}{2}\right)\Gamma\left(\frac{v_2}{2}\right)$

لنبحث الآن عن النموذج الإحصائي الاحتمالي للمتغير $Y = \frac{v_2 \xi}{v_1(1-\xi)}$ حيث إن ξ يخضع للنموذج (39.3.2).

نلاحظ أن:

$$\xi = \frac{v_1 Y}{v_2 + v_1 Y} \Rightarrow \frac{dx}{dy} = \frac{v_1 v_2}{(v_2 + v_1 y)^2}$$

وبما أن:

$$g(y; v_1, v_2) = f(x; v_1, v_2) \left| \frac{dx}{dy} \right|$$


فإن:

$$g(y) = g(y; v_1, v_2) = \frac{\Gamma\left(\frac{v_1 + v_2}{2}\right)}{\Gamma\left(\frac{v_1}{2}\right)\Gamma\left(\frac{v_2}{2}\right)} \left(\frac{v_1}{v_2}\right)^{\frac{v_1}{2}} y^{\frac{v_1}{2}-1} \left(1 + \frac{v_1}{v_2} y\right)^{-\frac{v_1+v_2}{2}} \quad ; \quad y > 0 \quad (40.3.2)$$

يدعى النموذج المعرف بدالة الكثافة الاحتمالية (40.3.2) بنموذج F بـ v_1 و v_2 درجة حرية ونرمز له بـ F_{v_1, v_2} . ونظراً لأهمية هذا النموذج أعدت له جداول خاصة. والجدول (12) في الملحق يتضمن قيم F_{α, v_1, v_2} ، حيث إن:

$$\int_{F_{\alpha, v_1, v_2}}^{\infty} g(y) dy = \alpha$$

وذلك من أجل $\alpha = 0.01$ و $\alpha = 0.05$ والقيم المختلفة لـ v_2, v_1 . والشكل (7.3.2) يبين منحنى نموذج F والقيمة الحرجة F_{α, v_1, v_2} .



شكل (7.3.2)

مبرهنة 9.3.2

إذا كان X_1, X_2 متغيرين عشوائيين مستقلين لكل منهما توزيع χ^2 بـ v_1, v_2 درجة حرية على الترتيب، فإن:

$$Y = \frac{X_1 / v_1}{X_2 / v_2}$$

له توزيع F بـ v_2, v_1 درجة حرية. نترك إثبات صحة ذلك للقارئ على سبيل المثال.

نتيجة:

إذا كان X متغيراً عشوائياً يخضع لتوزيع F بـ m و n درجة حرية، فإن المتغير العشوائي $Y = 1/X$ يخضع بدوره لتوزيع F ، لكن بـ n و m درجة حرية. وبناءً على هذه النتيجة فإن:

$$F_{1-\alpha;n,m} = \frac{1}{F_{\alpha;m,n}} = F_{\alpha;m,n}^{-1}$$

لأن:

$$\alpha = P(X > F_{\alpha;m,n}) = P\left(Y < \frac{1}{F_{\alpha;m,n}}\right) = 1 - P\left(Y > \frac{1}{F_{\alpha;m,n}}\right)$$

$$1 - \alpha = P\left(Y > \frac{1}{F_{\alpha;m,n}}\right) \Rightarrow F_{1-\alpha;n,m} = \frac{1}{F_{\alpha;m,n}}$$

t-Model

9.3.2 نموذج t

لتوزيع t دوراً هاماً عند إيجاد تقديرات معالم نموذج مقترح لمتغير عشوائي ملاحظ ξ . وحسب تعريف نموذج t بـ v درجة حرية، ونرمز له بـ $S(v)$ هو عبارة عن نموذج المتغير العشوائي:

$$t = \frac{\xi}{\sqrt{\eta/v}} \quad (41.3.2)$$

حيث إن المتغيرين العشوائيين ξ و η مستقلان و $\mathcal{L}(\xi) = N(0,1)$ و $\mathcal{L}(\eta) \in \chi_v^2$.

يمكن إيجاد دالة الكثافة $s_v(x)$ للنموذج $S(v)$ باستخدام الطريقة العامة لحساب كثافة توزيع حاصل قسمة متغيرين عشوائيين مستقلين. إن دالة الكثافة المشتركة لـ ξ و η تعطى كما يلي:

$$f(x, y) = f_\xi(x) \cdot f_\eta(y) = \begin{cases} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \frac{1}{\Gamma(v/2)2^{v/2}} y^{\frac{v}{2}-1} e^{-\frac{y}{2}} ; & -\infty < x < +\infty, y > 0 \\ 0 & ; y \leq 0 \end{cases}$$

ومنها دالة الكثافة المشتركة لـ t و η :

$$g(t,y) = f(t, \sqrt{y/v}, y) \left| \frac{dx}{dt} \right| = \begin{cases} \frac{1}{\sqrt{2\pi v} \Gamma(v/2) 2^{v/2}} y^{\frac{v-1}{2}} e^{-\frac{y}{2} \left(1 + \frac{t^2}{v}\right)} ; & -\infty < x < +\infty, y > 0 \\ 0 & ; y \leq 0 \end{cases}$$

حيث إن $t = \frac{x}{\sqrt{y/v}}$ و $\frac{dx}{dt} = \sqrt{y/v}$ (بافتراض y ثابت).

بإجراء تكامل الدالة $g(t,y)$ بالنسبة لـ y ، وبافتراض $z = \frac{y}{2} \left(1 + \frac{t^2}{v}\right)$ نجد:

$$S_v(t) = \frac{\Gamma\left(\frac{v+1}{2}\right)}{\sqrt{2\pi v} \Gamma\left(\frac{v}{2}\right)} \left(1 + \frac{t^2}{v}\right)^{-\frac{v+1}{2}} ; \quad -\infty < t < +\infty \quad (42.3.2)$$

وهذه هي دالة كثافة نموذج t بـ v درجة حرية. وكان أول من حصل على هذا النموذج هو غوسيت (W. S. Gosset)، الذي نشر بحثه تحت اسم مستعار "ستيودنت Student"، لذا يدعى هذا النموذج أيضاً بنموذج ستيودنت.

يدل الرمز v في الصيغة (42.3.2) على عدد درجات الحرية للمتغير العشوائي η في العلاقة (41.3.2).


ولأهمية نموذج t أعدت له جداول خاصة تعطي القيم الحرجة $t_{\alpha,v}$ ، حيث إن:

$$\int_{t_{\alpha,v}}^{\infty} s_v(t) dt = \alpha$$

ويبدو بوضوح α و $t_{\alpha,v}$ على الشكل (8.3.2)، ويتضمن الجدول (10) في الملحق على قيم $t_{\alpha,v}$ من أجل:

$$\alpha = 0.005, 0.01, 0.025, 0.05, 0.10$$

$$v = 1, 2, \dots, 29$$



شكل (8.3.2)

لا تشتمل جداول t على قيم $t_{\alpha, v}$ السالبة (أي عندما $\alpha > 0.50$) لأن نموذج t متناظر بالنسبة لـ $t = 0$ ، وبالتالي $t_{1-\alpha, v} = -t_{\alpha, v}$. وعندما تكون $v \geq 30$ يستخدم التوزيع الطبيعي المعياري $N(0,1)$ كتقريب جيد لتوزيع t .

يمكن إثبات أن القيمة المتوقعة والتباين للمتغير العشوائي t يساويان على الترتيب.

$$E_v t = 0 \quad , \quad V_v t = \text{var } t = \frac{v}{v-2} \quad , \quad v > 2$$

نلاحظ من الصيغة (42.3.2) أن نموذج t يعتمد على معلمة واحدة فقط هي عدد درجات الحرية v . وعندما $v = 1$ يؤول نموذج t إلى توزيع كوشي، الذي يعرف بدالة الكثافة:

$$f(t) = \frac{1}{\sqrt{2\pi}(1+t^2)} \quad ; \quad -\infty < t < \infty$$


وعندما $v \rightarrow \infty$ ، فإن:

$$\left(1 + \frac{t^2}{v}\right)^{-\frac{v+1}{2}} \longrightarrow e^{-\frac{t^2}{2}} \quad , \quad \frac{\Gamma\left(\frac{v+1}{2}\right)}{\Gamma\left(\frac{v}{2}\right)\sqrt{\pi v}} \longrightarrow \frac{1}{\sqrt{2\pi}}$$

وهذا يعني أن متتالية كثافات الاحتمال f_n للمتغيرات العشوائية التي لها نموذج t تتقارب إلى التوزيع الطبيعي المعياري:

$$S_v(t) \longrightarrow N(0,1)$$

بازدياد عدد درجات الحرية v بدون حدود. ويبين الشكل (9.3.2) منحنى توزيع t عند درجات حرية v مختلفة. ونلاحظ بوضوح أنه بازدياد عدد درجات الحرية v فإن منحنى توزيع t يقرب أكثر فأكثر من منحنى التوزيع الطبيعي المعياري. وإذا كانت درجة الحرية v صغيرة، فإن احتمالات الانحرافات الكبيرة إلى حد ما أكبر بالمقارنة مع التوزيع الطبيعي المعياري، وعندما $t > 2$ فإن منحنى توزيع t يتوضع فوق المنحنى الطبيعي المعياري.



شكل (9.3.2): توزيع t

نلاحظ مما سبق أن هنالك نوعين من النماذج: النماذج الاحتمالية (التوزيع الاحتمالي معين تماماً، أي لدينا توزيع واحد)، والنماذج الاحتمالية الإحصائية (نوع التوزيع الاحتمالي معلوم لكنه يعتمد على معلومة غير معلومة).

المعينة وتوزيعات المعينة

1.3 مقدمة

لن نعمل في هذا الفصل إلى بحث كامل لنظرية المعينة، بل سنقتصر على ما هو لازم وضروري لدراسة نظرية التقدير . لذا سنتعرض فقط للحالات التي توافق نموذجاً للملاحظات متكررة ومستقلة على متغير عشوائي حقيقي X ، ونقدم بعض المفاهيم الأساسية في نظرية المعينة كالاستدلال الإحصائي، العينة العشوائية، التوزيع التجريبي، عزوم العينة، الإحصاءات المرتبة... الخ. ومن ثم نبحث في توزيعات المعينة لبعض الصيغ الخطية والتوزيعية في متغيرات العينة، بالإضافة إلى دراسة موجزة للإحصاءات المرتبة وتوزيعاتها الاحتمالية، حيث إن هذه الأخيرة مهمة جداً عند دراسة الاستدلال الإحصائي اللامعلمي، وأخيراً، دراسة تقارب بعض مميزات العينة وتوزيعات المعينة في حالة عينات كبيرة.

2.3 الاستدلال الإحصائي STATISTICAL INFERENCE

يعزى دائماً تقدم العلوم للتجريب، وإذا أنجز الباحث تجربة وتحصل على بعض المعلومات، وبناءً على هذه المعلومات توصل إلى نتائج معينة، وهذه النتائج عادة تتجاوز مواد وعمليات التجربة الخاصة. وبعبارة أخرى، يستطيع الباحث التعميم من التجربة الخاصة إلى صف كل التجارب المشابهة.

يدعى هذا النوع من التمديد من الخاص إلى العام بـ "الاستدلال الاستقرائي inductive inference"، ويعتبر إحدى طرق الوصول إلى معرفة جديدة.

لا تعطي طريقة الاستدلال الاستقرائي تعميمات مؤكدة، لكن يمكن قياس درجة الشك (أو درجة الثقة) بتلك التعميمات فيما إذا أنجزت التجربة وفق مبادئ معينة. وإحدى مهام الإحصاء تتمثل في تقديم الأساليب لإجراء استدلالات استقرائية وقياس درجة الثقة في كل استدلال وذلك بعبارة احتمالية.

وتجدر الإشارة هنا إلى نوع آخر من الاستدلال، الذي يدعى "الاستدلال الاستنتاجي deductive inference"، في حين أن النتائج التي نتوصل إليها بواسطة الاستدلال الاستقرائي احتمالية، إلا أن النتائج التي نتوصل إليها بواسطة الاستدلال الاستنتاجي قطعية (مؤكدة).

ولإيضاح الاستدلال الاستنتاجي، لنفترض لدينا العبارتين الآتيتين:

1. إحدى الزوايا الداخلية في كل مثلث قائم تساوي 90 درجة.
2. المثلث A قائم.

إذا قبلنا بالعبارتين السابقتين فنصل قطعاً إلى النتيجة:

3. إحدى الزوايا الداخلية في المثلث A تساوي 90 درجة.

تدعى العبارة (1) بالمقدمة الكبرى، والعبارة (2) بالمقدمة الصغرى، بينما العبارة (3) فتدعى بالنتيجة.

نلاحظ أن طريقة الاستدلال الاستنتاجي هي انتقال من العام إلى الخاص، أي عكس الاستدلال الاستقرائي، بالإضافة إلى أنها تعطي نتائج مؤكدة.

بالرغم من أن الاستدلال الاستنتاجي مهم جداً، وخاصة في الرياضيات، للوصول إلى معارف جديدة، إلا أن الكثير من المعارف الجديدة في مختلف الميادين يتم الوصول إليها باتباع طريقة الاستدلال الاستقرائي.

لنوضح الآن الاستدلال الاستقرائي بمثال بسيط. لنفترض لدينا صندوق تخزين يحتوي على 10 مليون بذرة ورد، ونعلم أن كل بذرة تنتج وردة بيضاء أو حمراء

فيما لو زرعت. ونريد معرفة ما يلي: كم عدد (أو نسبة) البذور ضمن الـ 10 مليون بذرة التي ستنتج ورود بيضاء؟ الطريقة الوحيدة التي تمكننا الإجابة على هذا السؤال وبدقة تامة هي زراعة كل البذور الـ 10 مليون وملاحظة عدد الورود البيضاء. لكن هذه الطريقة غير عملية لأننا نريد بيع البذور، وحتى إذا لم نرد بيع البذور، فنرغب في الإجابة على هذا السؤال بأقل تكلفة وجهد ممكنين وأحياناً في أسرع وقت. طبعاً، بدون زراعة كل البذور، ومن ثم ملاحظة عدد الورود البيضاء لا يمكننا بشكل مؤكد معرفة عدد البذور في صندوق التخزين التي ستنتج بذوراً بيضاء.

الطريقة المنطقية الأخرى هي: نستطيع زراعة جزء من البذور، وعلى أساس ألوان الورود الناتجة نحصل على إفادة (تقدير) حول عدد البذور ضمن الـ 10 مليون بذرة التي سوف تنتج وروداً بيضاء. وهذه إجابة غير مؤكدة عن عدد البذور التي ستنتج وروداً بيضاء، لكن يمكن صياغة عبارة احتمالية (درجة الثقة) بالإجابة فيما إذا كان ذلك الجزء من البذور مأخوذاً بطريقة معينة.

هكذا، فالاستدلال الاستقرائي: نأخذ جزءاً من الـ 10 مليون بذرة، نزرعها، نلاحظ عدد الورود البيضاء، وعلى أساسها نقدر عدد البذور التي ستنتج وروداً بيضاء ضمن الـ 10 مليون بذرة. أي من معرفة ألوان جزء نعمم على الكل (10 مليون بذرة) وهذا التعميم غير مؤكد. وإذا كان هذا الجزء من الكل مأخوذاً بطريقة علمية (محققة لشروط معينة)، وهذا ما سنتطرق إليه لاحقاً، فيمكننا قياس درجة الثقة في التعميم باستخدام نظرية الاحتمالات، وعندئذٍ يطلق على الاستدلال الاستقرائي بـ "الاستدلال الإحصائي statistical inference".

يعالج الاستدلال الإحصائي مسألتين هامتين هما:

1. التقدير.
2. اختبار الفرضيات.

3.3 العينة العشوائية وتوزيعها

RANDOM SAMPLE AND ITS DISTRIBUTION

ليكن ξ متغيراً عشوائياً وحيد البعد (one-dimensional) دالة توزيعه $F(x)$ معرفة على R (فئة الأعداد الحقيقية)، ولنرمز لتوزيع ξ بشكل عام بـ $\mathcal{L}(\xi)$. تعرف العينة العشوائية بحجم n مأخوذة من مجتمع دالة توزيعه $F(x)$ على أنها متغير عشوائي ذي n بعد $X = (X_1, \dots, X_n)$ دالة توزيعه:

$$F_X(x) = F_X(x_1, \dots, x_n) = \prod_{i=1}^n F(x_i) \quad (1.3.3)$$

معرفة على R^n .

نلاحظ من هذا التعريف أن العناصر أو المركبات X_1, \dots, X_n للعينة العشوائية مستقلة ولكل منها نفس التوزيع، وهو توزيع المجتمع الذي سحبت منه، أي $F(x)$. ومن أجل الاختصار نقول عادة أن X عينة عشوائية بحجم n من $F(x)$ (أو من $\mathcal{L}(\xi)$). وبملاحظة أن العينة بحجم n من $F(x)$ عبارة عن مثال بسيط للعمليات العشوائية المنتهية، لذا تدعى أحياناً بالعينة العشوائية البسيطة (simple random sample) أو بالمعانيمة العشوائية البسيطة (simple random sampling)، وفيما يلي حيث نذكر كلمة عينة نقصد بها عينة عشوائية.

إذا كان المتغير العشوائي ξ من النوع المنقطع (المنقطع) دالة احتمالته $f(x)$ ، فإن دالة احتمال ودالة توزيع العينة X

$$f_X(x) = f_X(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i) \quad (2.3.3)$$

$$F_X(x) = \prod_{i=1}^n \left(\sum_{x_{ij} < x_i} f(x_{ij}) \right)$$

حيث إن x_{ij} القيم الممكنة للمركبة X_i ; $i = 1, \dots, n$; $j = 1, 2, \dots$.

وإذا كان المتغير ξ من النوع المستمر (المتصل)، فإن دالة كثافة ودالة توزيع العينة X :

$$f_X(x) = f(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

$$F_X(x) = \prod_{i=1}^n \left(\int_{-\infty}^{x_i} f(x) dx \right) \quad (3.3.3)$$

وهذا بناءً على مفهوم استقلال المتغيرات العشوائية في نظرية الاحتمالات.

بعد ملاحظة العينة $X = (X_1, \dots, X_n)$ ، تكون القيم الفعلية لـ X_1, \dots, X_n معلومة، أي لدينا عينة عشوائية مسحوبة فعلاً من المجتمع $F(x)$ ، نرمز لها عادة بـ $x = (x_1, \dots, x_n)$ وتدعى بالعينة العشوائية الملاحظة (المشكلة فعلاً).

ملاحظة 1.3.3

إن تعريفنا للمعينة العشوائية يقتصر على المعينة من مجتمع غير منتهى أو منتهى لكن السحب مع الإعادة، لأن المركبات X_i ; $i = 1, \dots, n$ مستقلة.

4.3 التوزيع التجريبي EXPERIMENTAL DISTRIBUTION

إن مسألة استدلال التوزيع الاحتمالي للمتغير العشوائي الملاحظ ξ [توزيع المجتمع $\mathcal{L}(\xi)$] أو بعض خصائصه، في حالة كون $\mathcal{L}(\xi)$ غير معلوم، تتطلب في حالات عدة تبويب المعطيات الإحصائية التي تقدمها عينة عشوائية ملاحظة $x = (x_1, \dots, x_n)$ من هذا المجتمع.

إذا كان المتغير العشوائي ξ من النوع المنقطع وحجم العينة n صغيراً، فنأخذ القيم المختلفة في العينة الملاحظة x ونرتبها تصاعدياً ومن ثم نعين التكرارات النسبية الموافقة لها، فمثلاً، إذا كان القيم الملاحظة x_i ; $i = 1, \dots, n$ تشتمل على $k \leq n$ قيمة مختلفة ولنرمز لها بـ z_j ; $j = 1, \dots, k$ ، حيث $z_1 < z_2 < \dots < z_k$ ، وكانت التكرارات النسبية الموافقة لها، فنُدعى فئة النتائج $\frac{n_j}{n}$; $j = 1, \dots, k$

بالتوزيع التجريبي للمتغير العشوائي الملاحظ ξ الموافق للعينة $x = (x_1, \dots, x_n)$ ، حيث إن $\sum_{j=1}^k \frac{n_j}{n} = 1$. وللتمييز نستخدم أحياناً مصطلح التوزيع النظري ξ للدلالة على التوزيع الاحتمالي له (توزيع المجتمع) ويتم عرض التوزيع التجريبي ξ جدولياً، كالجدول (1.4.3).

جدول (1.4.3): التوزيع التجريبي للمتغير العشوائي المنقطع ξ

| القيم الملاحظة المختلفة z_j | z_1 | z_2 | | z_k |
|--|-----------------|-----------------|--|-----------------|
| التكرارات النسبية الموافقة $\frac{n_j}{n}$ | $\frac{n_1}{n}$ | $\frac{n_2}{n}$ | | $\frac{n_k}{n}$ |

أما إذا كنا ندرس متغيراً عشوائياً مستمراً ξ ، أو كان منقطعاً لكن حجم العينة n كبير، فإن ترويب المعطيات الإحصائية يتطلب تقسيم المدى $r = x_{(n)} - x_{(1)}$ إلى k من الفئات الجزئية غير المتقاطعة، وتبسط الحسابات إلى حد كبير إذا كانت الفئات متساوية المدى $\frac{r}{k} \approx 1$ ، وهذا ما سوف نعتمده دوماً. وبعدها يتم حساب التكرارات النسبية الموافقة لتلك الفئات n_j/n . ونشير هنا إلى أن عدد الفئات k اختياري وعادة لا يقل عن 5 ولا يزيد عن 20، ويعتمد هذا الاختيار على طبيعة الظاهرة أو الخاصة المدروسة، بحيث يمكن اعتبار عناصر الفئة متجانسة بالنسبة للصفة المدروسة ξ . ونحصل بالنتيجة على التوزيع التجريبي للمتغير العشوائي الملاحظ ξ ، كما هو مبين في الجدول (2.4.3).

جدول (2.4.3): التوزيع التجريبي للمتغير العشوائي ξ

| الفئات $(c_{j-1}, c_j]$ | $(c_0, c_1]$ | $(c_1, c_2]$ | ... | $(c_{k-1}, c_k]$ |
|--------------------------------|-----------------|-----------------|-----|------------------|
| التكرار النسبي $\frac{n_j}{n}$ | $\frac{n_1}{n}$ | $\frac{n_2}{n}$ | | $\frac{n_k}{n}$ |

$$\sum_{j=1}^k \frac{n_j}{n} = 1 \quad \text{و } j = 1, 2, \dots, k \quad \text{حيث } [c_{j-1}, c_j] \text{ الفئة رقم } j$$

يعتبر التكرار النسبي $\frac{n_j}{n}$ للحادث $B_j = (c_{j-1}, c_j]$ متغيراً عشوائياً (لأنه يتغير بشكل عام من عينة ملحوظة لأخرى) بقيمة متوقعة تساوي احتمال هذا الحادث، أي أن:

$$E\left(\frac{n_j}{n}\right) = P(c_{j-1} < \xi \leq c_j) = P(B_j) = p_j \quad (1.4.3)$$

لأن المتغير العشوائي $Y = n_j$ يتبع توزيع ذي الحدين $B(n, p_j)$.

وكما نعلم من قانون الأعداد الكبيرة [مبرهنة بيرنولي (2.3.1)] أنه إذا كررت التجربة المفروضة n مرة تحت نفس الشروط، فإن التكرار النسبي لظهور الحادث B_j ينتهي إلى احتمال هذا الحادث، وذلك عندما $n \rightarrow \infty$ ، أي أن:

$$\lim_{n \rightarrow \infty} \frac{n_j}{n} = p_j$$

وهذا يعني، بملاحظة الجدولين (1.4.3) و (2.4.3)، أن السطر الثاني في كليهما يحتوي على القيم التقديرية للاحتمالات p_j ; $j = 1, 2, \dots, k$. أي أن:

$$\frac{n_j}{n} \approx p_j \quad ; \quad j = 1, \dots, k$$

1.4.3 دالة التوزيع التجريبي

Experimental Distribution Function

لنفترض من أجل أي عدد حقيقي x فالمتغير Z_i معرف على النحو الآتي:

$$Z_i = \begin{cases} 1 & ; \quad x_i < x \\ 0 & ; \quad x_i \geq x \end{cases}, \quad i = 1, 2, \dots, n \quad (2.4.3)$$

وعليه $Z = \sum_{i=1}^n Z_i$ متغير عشوائي يمثل عدد عناصر العينة الملاحظة $x = (x_1, \dots, x_n)$ الأصغر من x .

إذا رمزنا بـ $F_n^*(x) = \frac{Z}{n}$ ، فتدعى الدالة $F_n^*(x)$ بدالة التوزيع التجريبي لـ ξ (experimental distribution function)، الموافقة للعينة الملاحظة x . وللتمييز نسمي دالة التوزيع $F(x)$ للمتغير العشوائي ξ بدالة التوزيع النظري (توزيع المجتمع). وفي حالات عدة حيث لا يوجد التباس نسقط الدليل n ، أي نرمز بـ $F^*(x)$ لدالة التوزيع التجريبي لـ ξ .

مثال 1.4.3

إذا كان التوزيع التجريبي للمتغير العشوائي ξ معطى بالجدول (3.4.3). فأوجد دالة التوزيع التجريبي $F^*(x)$.


جدول (3.4.3): التوزيع التجريبي لـ ξ

| | | | |
|--------------------------------|------|------|------|
| القيم الملاحظة لـ ξ | 2 | 3 | 5 |
| $\frac{n_i}{n}$ التكرار النسبي | 0.75 | 0.20 | 0.05 |

من تعريف دالة التوزيع التجريبي $F_n^*(x) = \frac{Z}{n}$ ، نجد أن:

$$F_n^*(x) = \begin{cases} 0 & ; x \leq 2 \\ 0.75 & ; 2 < x \leq 3 \\ 0.95 & ; 3 < x \leq 5 \\ 1 & ; x > 5 \end{cases}$$

والتمثيل البياني لدالة التوزيع التجريبي $F_n^*(x)$ يبينه الشكل (1.4.3).




شكل (1.4.3)

إذا كانت عناصر المتجه x مختلفة فإن دالة التوزيع التجريبي $F_n^*(x)$ تعطى كما يلي:

$$F_n^*(x) = \begin{cases} 0 & ; x \leq x_{(1)} \\ k/n & ; x_{(k)} < x \leq x_{(k+1)} \quad , \quad k = 1, 2, \dots, n-1 \\ 1 & ; x > x_{(n)} \end{cases}$$

وهذا يعني، في هذه الحالة، أن قيم القفزات متساوية وتساوي $1/n$.
والتمثيل البياني لـ $F_n^*(x)$ يأخذ الشكل (2.4.3).



شكل (2.4.3)

وفي الحالة العامة يمكن كتابة دالة التوزيع التجريبي $F_n^*(x)$ على النحو الآتي:

$$F_n^*(x) = \frac{1}{n} \sum_{k=1}^n e(x - x_{(k)}) \quad (3.4.3)$$

حيث $e(x)$ ما هي إلا دالة الواحدية للقفزات (دالة خوفسيد):

$$e(x) = \begin{cases} 0 & ; \quad x \leq 0 \\ 1 & ; \quad x > 0 \end{cases}$$

وفي العلاقة (3.4.3) يبدو بوضوح ارتباط $F_n^*(x)$ بالعينة x .

إن لدالة التوزيع التجريبي دوراً هاماً وأساسياً في الإحصاء الرياضي، وتكمن أهميتها الخاصة بأنه بازياد عدد الملاحظات للمتغير العشوائي X تقرب دالة التوزيع التجريبي $F_n^*(x)$ من دالة التوزيع النظري $F(x)$. وهذا ما سنراه لاحقاً.

2.4.3 التمثيل البياني للتوزيعات التجريبية

نلاحظ مما سبق أن التوزيع التجريبي يعتبر طريقة مفيدة لتمثيل المعطيات الإحصائية (معطيات العينة الملاحظة) والتي يمكننا من استدلال بعض النتائج عن التوزيع الاحتمالي للمتغير العشوائي الملاحظ X عندما يكون مجهولاً بشكل كامل أو جزئي. هذا وتوجد طرق أخرى لتمثيل المعطيات الإحصائية، وإحدى هذه الطرق تتمثل في بناء المدرج والمضلع للتوزيع التجريبي X . ويستخدم مضلع التوزيع التجريبي عندما يكون المتغير العشوائي الملاحظ X مستمراً أو منقطعاً، أما مدرج التوزيع التجريبي فيقتصر استخدامه على حالة كون المتغير العشوائي الملاحظ X مستمراً، أو أن العينة العشوائية X ذات حجم كبير (المعطيات الإحصائية مبوبة حسب الفئات).

لنوضح كيفية بناء مدرج ومضلع توزيع تجريبي لمتغير عشوائي X من خلال المثال التالي.

مثال 2.4.3

لتكن لدينا نتائج دراسة متانة 200 نموذج من البيتون المسلح، كما هي واردة في الجدول التالي:


جدول 4.4.3:

| التكرار النسبي $\frac{n_j}{n}$ | بجالاتئة (ميجا باسكال) |
|--------------------------------|------------------------|
| 0.05 | 20-19 |
| 0.13 | 21-20 |
| 0.28 | 22-21 |
| 0.32 | 23-22 |
| 0.15 | 24-23 |
| 0.07 | 25-24 |

المطلوب بناء مدرج ومضلع التوزيع التجريبي المعطى.

لبناء المدرج التكراري لهذا التوزيع التجريبي نرسم محورين متعامدين، يمثل المحور الأفقي الفترات الجزئية والمحور الشاقولي التكرارات النسبية. ثم نحدد الفترات الجزئية للقيم الملاحظة والتكرارات النسبية الموافقة على المحول الأفقي والشاقولي على الترتيب، وبعد ذلك نقيم مستطيلات على تلك الفترات الجزئية بارتفاعات تساوي التكرارات النسبية الموافقة، فنحصل بالنتيجة على المدرج التكراري المبين بالشكل (3.4.3).

لرسم مضلع التوزيع التجريبي، نحدد منتصفات الأضلاع العليا للمستطيلات المبنية على الشكل (3.4.3)، ثم نصل بينها على الترتيب بخطوط مستقيمة فنحصل على المطلوب. ولإغلاق المضلع نضيف فئة قبل الفئة الأولى وأخرى بعد الفئة الأخيرة بحيث يكون التكرار النسبي لكل منها صفراً، فنحصل على المضلع المبين على الشكل (3.4.3).



شكل (3.4.3)

يستخدم مدرج ومضلع التوزيع التجريبي لاستدلال نوع نموذج التوزيع لـ ξ .
 فمثلاً، النموذج المبين على الشكل (3.4.3) يذكرنا بالنموذج الطبيعي العام، لهذا
 يمكن افتراض أن نوع توزيع المتغير العشوائي الملاحظ ξ هو طبيعي، هكذا، يمكن
 اعتبار الشكل البياني للتوزيع التجريبي لمتغير عشوائي ξ كمناظر إحصائي لشكل
 التوزيع النظري له.

5.3 الإحصاء وعزم العينة

STATISTIC AND SAMPLE MOMENT

إن تشكيل العينة العشوائية ليس هدفاً بحد ذاته، بل الهدف هو الوصول إلى
 استدلالات حول المجتمع الذي سحبت منه، وهذه الاستدلالات قد تكون حول
 توزيع المجتمع أو حول بعض أو كل مميزاته العددية (معالمه). لهذا في نظرية المعاينة لا
 نكتفي بمعرفة التوزيع التجريبي أو التوزيع الاحتمالي للعينة العشوائية، بل نهتم
 بمعرفة دالة أو أكثر في المتغيرات العشوائية المكونة للعينة، حيث تستخدم للقيام

باستدلالات حول معالم المجتمع. ومن أهم تلك الدوال ما تدعى بعزوم العينة (sample moments). سنعرف أولاً الإحصاء أو الإحصاءة (statistic).

تعريف 1.5.3: الإحصاء Statistic

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $L(\xi)$ ، فإن أي دالة في العينة فقط $T = T(X)$ تدعى "إحصاء".

نلاحظ من هذا التعريف أن الإحصاء $T = T(X)$ لا يحتوي على أي معلمة مجهولة، كما أنه يعتبر متغيراً عشوائياً لأن قيمته، بشكل عام، تتغير من عينة ملاحظة لأخرى، وبالتالي له توزيع احتمالي يدعى بتوزيع المعينة (sampling distribution) للإحصاء T .

فمثلاً، إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $L(\xi) \in N(\theta_1, \theta_2^2)$ ، حيث θ_1, θ_2 معلمتين مجهولتين، فإن الدالة $X_1 - \theta_1$ وكذلك الدالة $\sum_1^n X_i / \theta_2$ ليست إحصاء (لأن كليهما ليس دالة في العينة فقط، بل يحتويان معلمة مجهولة)، لكن $\sum_1^n X_i$ ، $\frac{X_1 + X_2}{4}$ و $\sum_1^n \ln X_i$ إحصاءات.

إحدى المسائل الأساسية في الإحصاء هي إيجاد الإحصاءات المناسبة لتقدير معالم المجتمع.

سنعرف فيما يلي ونناقش بعض الإحصاءات الهامة وهي عزوم العينة.

تعريف 2.5.3: عزوم العينة Sample moments

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع المتغير العشوائي الملاحظ ξ ولنرمز له بـ $f(x)$. عندئذ فالعزم الابتدائي (حول 0) للعينة X من المرتبة r نرمز له بـ $A_r = A_r(X)$ ، ويعرف كالآتي:

$$A_r(X) = \frac{1}{n} \sum_{i=1}^n X_i^r ; r = 1, 2, \dots \quad (1.5.3)$$

وكحالة خاصة، عندما $r = 1$ ، نحصل على متوسط العينة، ويرمز له عادة بـ \bar{X} أو \bar{X}_n ، أي أن:

$$A_1(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2.5.3)$$

وبشكل مشابه، العزم المركزي (حول \bar{X}) للعينة من المرتبة r ، نرمز له بـ $M_r = M_r(X)$ ، ويعرف كالتالي:

$$M_r(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^r ; \quad r = 1, 2, \dots \quad (3.5.3)$$

وكحالة خاصة، عندما $r = 2$ ، نحصل على تباين العينة، ويرمز له عادة بـ $S^2 = S^2(X)$ أو $S_n^2 = S_n^2(X)$ ؛ أي أن:

$$M_2(X) = S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (4.5.3)$$

وكما نعلم من نظرية الاحتمالات، إذا رمزنا بـ α_r و μ_r للعزم الابتدائي والمركزي من المرتبة r للمتغير العشوائي ξ (العزوم النظرية) على الترتيب، فإن:

$$\alpha_r = E\xi^r ; \quad r = 1, 2, \dots \quad (5.5.3)$$

$$\mu_r = E(\xi - \mu)^r ; \quad r = 1, 2, \dots , \quad \mu = \alpha_1$$

وأن هنالك علاقة بينهما وهي:

$$\mu_r = \sum_{j=0}^r (-1)^j C_r^j \mu^j \alpha_{r-j} \quad (6.5.3)$$

وأن العلاقة (6.5.3) موجودة أيضاً بين العزوم الابتدائية والعزوم المركزية للعينة:

$$M_r = \sum_{j=0}^r (-1)^j C_r^j \bar{X}^j A_{r-j} ; \quad C_r^j = \frac{r!}{j!(r-j)!} \quad (7.5.3)$$

وبإعطاء $r = 2, 3, 4$ نجد:

$$S^2 = A_2 - \bar{X}^2 , \quad M_3 = A_3 - 3\bar{X}A_2 + 2\bar{X}^3 \quad (8.5.3)$$

$$M_4 = A_4 - 4\bar{X}A_3 + 6A_2\bar{X}^2 - 3\bar{X}^4$$

6.3 متوسط وتباين متوسط العينة

MEAN AND VARIANCE OF SAMPLE MEAN

نفترض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $f(x)$ بمتوسط μ وتباين σ^2 ، ونريد تعيين القيمة المتوقعة والتباين لمتوسط العينة \bar{X} .

لدينا حسب التعريف (العلاقة 2.5.3):

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} (X_1 + \dots + X_n)$$

بأخذ القيمة المتوقعة للطرفين، نجد:

$$E\bar{X} = \frac{1}{n} (EX_1 + \dots + EX_n)$$

لكن X_1, \dots, X_n متغيرات عشوائية مستقلة ولكل منها التوزيع $f(x)$ ، إذن:

$$EX_1 = EX_2 = \dots = EX_n = \mu$$

وبالتالي:

$$E\bar{X} = \mu$$

$$(1.6.3)$$

إيجاد $\text{var } \bar{X}$:

بما أن:

$$\text{var } \bar{X} = E(\bar{X} - E\bar{X})^2 = E(\bar{X} - \mu)^2$$

و

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

فإن:

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

$$(2.6.3)$$

$$= \frac{1}{n^2} \sum_{i=1}^n E(X_i - \mu)^2 + \frac{1}{n^2} \sum_{i \neq j} E[(X_i - \mu)(X_j - \mu)]$$

لكن حسب تعريف العينة العشوائية، فالمتغيرات X_i ; $i = 1, 2, \dots, n$ مستقلة ولها نفس التوزيع، إذن:

$$\begin{aligned} E(X_i - \mu)^2 &= \sigma^2 \quad ; \quad i = 1, \dots, n \\ \text{cov}(X_i, X_j) &= E[(X_i - \mu)(X_j - \mu)] = 0 \quad ; \quad i \neq j \end{aligned} \quad (3.6.3)$$

وبالتعويض في (2.6.3)، نجد:

$$\text{var } \bar{X} = V\bar{X} = \frac{\sigma^2}{n} \quad (4.6.3)$$

7.3 متوسط وتباين وتباين العينة

MEAN AND VARIANCE OF SAMPLE VARIANCE

لنتأمل الآن تباين العينة، المعرف بالعلاقة (4.5.3):

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

بأخذ القيمة المتوقعة والاستفادة من (3.6.3)، نجد:

$$ES^2 = \frac{n-1}{n} \sigma^2 \quad (1.7.3)$$

إيجاد $\text{var } S^2$:

كما نعلم:

$$\text{var } S^2 = ES^4 - (ES^2)^2$$

ولحساب ES^4 نضع $Y_i = X_i - \mu$ في عبارة S^2 ثم نربعها، فنجد:

$$S^2 = \frac{n-1}{n^2} \sum_{i=1}^n Y_i^2 - \frac{1}{n^2} \sum_{i \neq j} Y_i Y_j$$

$$S^4 = \frac{(n-1)^2}{n^4} \left(\sum_{i=1}^n Y_i^2 \right)^2 + \frac{1}{n^4} \left(\sum_{i \neq j} Y_i Y_j \right)^2 - \frac{2(n-1)}{n^4} \sum_{i=1}^n Y_i^2 \sum_{i \neq j} Y_i Y_j$$

وبما أن $EX_i = \mu = 0$ ، $EY_i = EX_i - \mu = 0$ ، فبأخذ توقع S^4 نجد:

$$\begin{aligned} ES^4 &= \frac{(n-1)^2}{n^4} \sum_{i=1}^n EY_i^4 + \frac{(n-1)^2}{n^4} \sum_{i \neq j} EY_i^2 EY_j^2 + \frac{2}{n^4} \sum_{i \neq j} EY_i^2 EY_j^2 \\ &= \frac{(n-1)^2}{n^3} \mu_4 + \frac{(n-1)^2 + 2}{n^3} (n-1) \mu_2^2 \end{aligned}$$

وبالتالي:

$$\begin{aligned} \text{var } S^4 &= ES^4 - (ES^2)^2 \\ &= \frac{(n-1)^2}{n^3} \mu_4 + \frac{(n-1)^2 + 2}{n^3} (n-1) \mu_2^2 - \frac{(n-1)^2}{n^2} \mu_2^2 \\ &= \frac{(n-1)^2}{n^3} \left(\mu_4 - \frac{n-3}{n-1} \mu_2^2 \right) \quad ; \quad \mu_2 = \sigma^2 \end{aligned} \quad (2.7.3)$$

يمكن تلخيص ما سبق على النحو الآتي:

إذا كانت $X = (X_1, \dots, X_n)$ عينة من توزيع $f(x)$ بمتوسط μ وتباين σ^2 ، فإن متوسط وتباين متوسط العينة \bar{X} هما:

$$E\bar{X} = \mu \quad , \quad \text{var } \bar{X} = \frac{\sigma^2}{n}$$

بالإضافة إلى ذلك، إذا كان العزم المركزي من المرتبة الرابعة لتوزيع المجتمع منتهى، عندئذٍ تباين العينة S^2 له متوسط وتباين هما:

$$ES^2 = \frac{n-1}{n} \sigma^2$$

$$\text{var } S^2 = \frac{(n-1)^2}{n^3} \left(\mu_4 - \frac{n-3}{n-1} \sigma^4 \right)$$

ملاحظة

يستخدم عادة في التطبيقات الإحصائية تباين العينة المعدل S^{*2} .

$$S^{*2}(X) = \frac{n}{n-1} S^2(X) \quad (3.7.3)$$

وبالتالي:

$$ES^{*2} = E\left(\frac{n}{n-1} S^2\right) = \frac{n}{n-1} ES^2 = \sigma^2 \quad (4.7.3)$$

$$\text{var } S^{*2} = \text{var}\left(\frac{n}{n-1} S^2\right) = \left(\frac{n}{n-1}\right)^2 \text{var } S^2$$

$$= \frac{1}{n} \left(\mu_4 - \frac{n-3}{n-1} \sigma^4 \right) \quad (5.7.3)$$

ومرر استخدام S^{*2} في التطبيقات الإحصائية هو أن $ES^{*2} = \sigma^2$ ، وهذا يعني S^{*2} مقلد غير متحيز للتباين، وتجاوزاً يدعى S^{*2} بتباين العينة $X = (X_1, \dots, X_n)$.

8.3 توزيعات المعينة لجمع ومتوسط عينة

SAMPLING DISTRIBUTIONS OF SAMPLE SUM AND MEAN

سنحتاج في موضوعات قادمة لمعرفة توزيع مجموع ومتوسط عينة عشوائية، ولإيجاد ذلك هناك طريقتان سنتطرق إليها في الفقرتين التاليتين.

1.8.3 طريقة التكرار

لدراسة طريقة التكرار لإيجاد توزيع مجموع ومتوسط عينة، وللتبسيط نفترض أولاً أن العينة بحجم $n = 2$ ، إذا رمزنا بـ $G_2(z)$ لدالة توزيع المجموع $Z = X_1 + X_2$ ، فإن:

$$G_2(z) = P(X_1 + X_2 < z) = \int_D d(F(x_1)F(x_2))$$

حيث إن $D = \{(x_1, x_2) \in R^2 ; x_1 + x_2 < z\}$ ، وبما أن X_1, X_2 متغيرين عشوائيين مستقلين، يمكننا كتابة:

$$\begin{aligned} G_2(z) &= \int_D d(F(x_1)F(x_2)) = \int_{-\infty}^{+\infty} \left[\int_{-\infty}^{z-x_1} dF(x_2) \right] dF(x_1) \\ &= \int_{-\infty}^{+\infty} F(z - x_1) dF(x_1) \end{aligned} \quad (1.8.3)$$

ويمكن تعميم ذلك على مجموع عينة حجمها $n > 2$ فنجد:

$$G_n(z) = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{z-(x_1+\dots+x_{n-3})} \int_{-\infty}^{z-(x_1+\dots+x_{n-2})} F(z - x_1 - \dots - x_{n-1}) dF(x_{n-1}) dF(x_{n-2}) \dots dF(x_1) \quad \dots \quad (2.8.3)$$

وإذا رمزنا بـ $H_n(\bar{x})$ لدالة توزيع متوسط العينة \bar{X} ، فإن:

$$H_n(\bar{x}) \equiv G_n(n\bar{x})$$

هكذا، إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $F(x)$ ، فإن دالة توزيع مجموع العينة $Z = \sum_{i=1}^n X_i$ تعطى بالعلاقة (2.8.3)، ودالة توزيع متوسط العينة \bar{X} بالعلاقة:

$$H_n(\bar{x}) \equiv G_n(n\bar{x}) \quad (3.8.3)$$

نلاحظ أن هذه الطريقة صعبة وتتطلب إجراءات متتالية من التكميلات. في بعض الحالات، وخاصة عندما يكون الإحصاء الذي نرغب في معرفة توزيعه الاحتمالي عبارة عن دالة خطية في متغيرات عشوائية مستقلة، يمكن دائماً الحصول على التوزيع باستخدام طريقة سهلة تدعى بطريقة الدالة المميزة.

2.8.3 طريقة الدالة المميزة

تعتبر طريقة الدالة المميزة طريقة بسيطة ومفيدة لتعيين توزيع المعاينة للمجاميع والمتوسطات في حالات عدة.

في البداية سنذكر بتعريف الدالة المميزة، ومن ثم نقدم بعض خواصها الأساسية بصورة مبرهنات بدون إثبات، حيث إن إثباتها بسيط نتركه للقارئ.

تعريف 1.8.3: الدالة المميزة The Characteristic Function

ليكن ξ متغير عشوائي حقيقي دالة توزيعه $F(x; \theta)$. تدعى الدالة $\varphi(t; \theta)$ المعرفة كالاتي:

$$\varphi(t; \theta) = E_{\theta}(e^{it\xi}) = \int_{-\infty}^{+\infty} e^{itx} dF(x; \theta) \quad (4.8.3)$$

بالدالة المميزة للنموذج $F(x; \theta)$ أو الدالة المميزة لـ ξ بالعلمة θ ، حيث إن $i = \sqrt{-1}$ و t عدد حقيقي.

وبشكل مشابه، بفرض $\eta = (X_1, \dots, X_n)$ متغير عشوائي ذي n بعد، دالة توزيعه

فإن الدالة المميزة $F(x_1, \dots, x_n; \theta)$ للمتغير العشوائي $\varphi(t_1, \dots, t_n; \theta)$ تعرف كالآتي:

$$\begin{aligned} \varphi_h(t_1, \dots, t_n; \theta) &= E_\theta \left[\exp \left(i \sum_{j=1}^n t_j X_j \right) \right] \\ &= \int_{R^n} \exp \left(i \sum_{j=1}^n t_j X_j \right) dF(x_1, \dots, x_n; \theta) \end{aligned} \quad (5.8.3)$$

مبرهنة 1.8.3

إذا كان X_1, X_2 متغيرين عشوائيين دالتي توزيعهما $F_1(x), F_2(x)$ على الترتيب، وكانت $\varphi_1(t), \varphi_2(t)$ الدالتين المميزتين لـ X_1, X_2 على الترتيب، فإن الشرط اللازم والكافي لتساوي التوزيعين $F_1(x), F_2(x)$ ، أي $F_1(x) \equiv F_2(x)$ هو تساوي دالتيهما المميزتين $\varphi_1(t) \equiv \varphi_2(t)$.

هذا التوافق الأحادي (تقابل واحد لواحد) بين دوال التوزيع والدوال المميزة له أهمية كبيرة في نظرية الاحتمالات والإحصاء الرياضي، حيث يعطي الأساس لإيجاد التوزيعات الاحتمالية والنماذج الإحصائية لمتغيرات عشوائية من خلال دوالها المميزة.

مبرهنة 2.8.3

إذا كانت Y دالة خطية في k متغير عشوائي مستقل X_1, \dots, X_k معرفة كالآتي:

$$Y = \sum_{j=1}^k c_j X_j$$

وكانت $\varphi(t)$ الدالة المميزة لـ Y و $\varphi_i(t_i)$ ؛ $i = 1, \dots, k$ الدالة المميزة للمتغير العشوائي X_i ، فإن:

$$\varphi(t) = \prod_{j=1}^k \varphi_j(c_j t_j) \quad (6.8.3)$$

مبرهنة 3.8.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $F(x; \theta)$ ، وكانت $\varphi(t; \theta)$ الدالة المميزة للتوزيع $F(x; \theta)$ ، فإن الدالة المميزة لمجموع العينة $Z = X_1 + \dots + X_n$

$$\varphi_Z(t; \theta) = [\varphi(t; \theta)]^n \quad (7.8.3)$$

والدالة المميزة لمتوسط العينة \bar{X} :

$$\varphi_{\bar{X}}(t; \theta) = \left[\varphi\left(\frac{t}{n}; \theta\right) \right]^n \quad (8.8.3)$$

مبرهنة 4.8.3

بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $F(x; \theta)$ دالته المميزة $\varphi(t; \theta)$. عندئذٍ إذا كان:

$$[\varphi(t; \theta)]^n = \varphi(t; n\theta)$$

فإن توزيع مجموع العينة Z ومتوسط العينة \bar{X} هو من الشكل $F(z; n\theta)$ و $F(n\bar{x}; n\theta)$ على الترتيب.

مبرهنة 5.8.3

إذا كان العزم الابتدائي من المرتبة r للمتغير العشوائي X موجوداً، فإن:

$$\varphi(t) = 1 + \sum_{j=1}^r \frac{(it)^j}{j!} \alpha_j + o(t^r)$$

حيث إن:

$$\lim_{t \rightarrow \infty} \frac{o(t^r)}{t^r} = 0$$

3.8.3 توزيعات المعينة لمجموع ومتوسط عينة في بعض الحالات الخاصة

يمكننا الآن باستخدام الدالة المميزة وبعض خواصها الأساسية معرفة توزيع المعينة لمجموع ومتوسط عينة في بعض الحالات الخاصة والمهمة، التي سنحتاجها في فصول لاحقة.

1. إذا كانت العينة العشوائية $X = (X_1, \dots, X_n)$ من توزيع بيرنولي $B(1, \theta)$ ، فإن توزيع المعينة للمجموع $Z = \sum_{i=1}^n X_i$ هو توزيع ذي الحدين $B(n, \theta)$. إن الدالة المميزة للتوزيع $B(1, \theta)$ هي:

$$\varphi(t) = [(1 - \theta) + \theta e^{it}]$$

وحسب المبرهنة (3.8.3) [العلاقة (7.8.3)]، فإن الدالة المميزة لـ

$$Z = \sum_{i=1}^n X_i$$

$$\varphi_Z(t) = [(1 - \theta) + \theta e^{it}]^n \quad (9.8.3)$$

وهذه ما هي إلا الدالة المميزة للتوزيع $B(n, \theta)$ ، أي أن توزيع Z هو $B(n, \theta)$.

وحسب المبرهنة (3.8.3) [العلاقة (8.8.3)] فالدالة المميزة لـ \bar{X} هي:

$$\varphi_{\bar{X}}(t; \theta) = \varphi_Z\left(\frac{t}{n}; \theta\right) = \left[(1 - \theta) + \theta e^{\frac{it}{n}}\right]^n \quad (10.8.3)$$

وهذه أيضاً الدالة المميزة لنموذج ذي الحدين $B(n, \theta)$ ، أي أن توزيع المعينة لـ \bar{X} هو توزيع ذي الحدين $B(n, \theta)$.

2. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بواسون $\Pi(\theta)$ ،

فإن توزيع المعاينة لـ $Z = \sum_{i=1}^n X_i$ هو نموذج بواسون $\Pi(n\theta)$.

إن الدالة المميزة للنموذج $\Pi(\theta)$ هي:

$$\varphi(t; \theta) = e^{-\theta(1-e^t)}$$

ومنها حسب المبرهنة (3.8.3) [العلاقة (7.8.3)] فالدالة المميزة لـ Z هي:

$$\varphi_Z(t; \theta) = e^{-n\theta(1-e^t)} \quad (11.8.3)$$

وهذه ما هي إلا الدالة المميزة لنموذج بواسون $\Pi(n\theta)$. ومن ثم توزيع المعاينة لـ \bar{X} هو أيضاً نموذج بواسون بمتوسط $n\theta$.

3. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من نموذج طبيعي عام

$N(\theta_1, \theta_2^2)$ ، فإن توزيع المعاينة لـ $Z = \sum_{i=1}^n X_i$ هو $N(n\theta_1, n\theta_2^2)$ ،

وتوزيع المعاينة لـ \bar{X} يكون $N(\theta_1, \theta_2^2/n)$.

إن الدالة المميزة للتوزيع $N(\theta_1, \theta_2^2)$ هي:

$$\varphi(t; \theta) = e^{i\theta_1 t - \frac{1}{2}\theta_2^2 t^2} ; \quad \theta = (\theta_1, \theta_2^2)$$

ومن ثم فالدالة المميزة لـ Z هي:

$$\varphi_Z(t; \theta) = [\varphi(t; \theta)]^n = e^{i(n\theta_1)t - \frac{1}{2}(n\theta_2^2)t^2} \quad (12.8.3)$$

وهذه الأخيرة ما هي إلا الدالة المميزة للنموذج $N(n\theta_1, n\theta_2^2)$ ، ومن ثم

فهو توزيع المعاينة لـ Z . وللحصول على الدالة المميزة لـ \bar{X} نستبدل t بـ $\frac{t}{n}$

في $\varphi_Z(t; \theta)$:

$$\varphi_{\bar{X}}(t; \theta) = \varphi_Z\left(\frac{t}{n}; \theta\right) = e^{i\theta_1 t - \frac{1}{2}\left(\frac{\theta_2^2}{n}\right)t^2} \quad (13.8.3)$$

وهذه الدالة المميزة للنموذج $N(\theta_1, \theta_2^2/n)$ ، أي أن توزيع المعانة لـ \bar{X} هو من الشكل $N(\theta_1, \theta_2^2/n)$.

4. إذا كانت (Y_1, \dots, Y_n) ، حيث $(Y_i = (X_{1i}, \dots, X_{ki}))$ ؛ $i = 1, 2, \dots, n$ عينة عشوائية من توزيع طبيعي ذي k بعد

$$N(\mu, \Sigma) ; \mu = (\mu_1, \dots, \mu_k) , \Sigma = \|\sigma_{ij}\| ; i, j = 1, \dots, k$$

فإن توزيع المعانة لمتجه المجاميع (Z_1, \dots, Z_k) ؛ $Z_r = \sum_{i=1}^n X_{ri}$ ، $r = 1, 2, \dots, k$ هو التوزيع الطبيعي $N(n\mu, n\Sigma)$ ، وتوزيع المعانة لمتجه المتوسطات $N\left(\mu, \frac{1}{n}\Sigma\right)$ يكون $(\bar{X}_1, \dots, \bar{X}_n)$ ؛ $\bar{X}_r = \frac{1}{n} \sum_{i=1}^n X_{ri}$.

الإثبات هنا، مشابه للحالة (3)، ولذا نترك ذلك للقارئ على سبيل المثال.

5. إذا كانت (X_1, \dots, X_n) عينة عشوائية من توزيع $\Gamma(\alpha, 1)$ ، فإن توزيع المعانة لـ $Z = \sum_{i=1}^n X_i$ هو توزيع جاما $\Gamma(n\alpha, 1)$.

الدالة المميزة لنموذج $\Gamma(\alpha, 1)$ هي:

$$\varphi(t; \alpha) = (1 - it)^{-\alpha}$$

ومن ثم فالدالة المميزة لـ Z هي:

$$\varphi_Z(t; \alpha) = (1 - it)^{-n\alpha} \quad (14.8.3)$$

وهي الدالة المميزة لتوزيع $\Gamma(n\alpha, 1)$. وللحصول على الدالة المميزة لمتوسط المعانة \bar{X} ، نستبدل t بـ $\frac{t}{n}$ في عبارة $\varphi_Z(t; \alpha)$ ، فنجد:

$$\varphi_{\bar{X}}(t; \alpha) = \varphi_Z\left(\frac{t}{n}; \alpha\right) = \left(1 - i \frac{1}{n}t\right)^{-n\alpha} \quad (15.8.3)$$

وهي عبارة عن الدالة المميزة لتوزيع جاما $\Gamma(n\alpha, 1/n)$.

6. إذا كانت $(X_{11}, \dots, X_{1n_1}), \dots, (X_{k1}, \dots, X_{kn_k})$ عبارة عن k عينة مستقلة من التوزيعات الطبيعية $N(\theta_{11}, \theta_{21}^2), N(\theta_{12}, \theta_{22}^2), \dots, N(\theta_{1k}, \theta_{2k}^2)$ على الترتيب، وكان $\bar{X}_1, \dots, \bar{X}_n$ متوسطات هذه العينات على الترتيب، و c_1, \dots, c_k ثوابت (ليست كلها أصفاراً)، فعندئذٍ توزيع المعاينة لـ:

$$Y = c_1 \bar{X}_1 + \dots + c_k \bar{X}_k$$

هو التوزيع الطبيعي:

$$N\left(\sum_{i=1}^k c_i \theta_{1i}, \sum_{i=1}^k \frac{c_i^2 \theta_{2i}^2}{n_i}\right)$$

باستخدام الدوال المميزة نحصل على المطلوب مباشرة.

نلاحظ، بوضع $c_1 = 1, c_2 = -1, c_3 = \dots = c_k = 0$ نحصل على النتيجة التالية:

توزيع المعاينة للفرق $\bar{X}_1 - \bar{X}_2$ بين متوسطي عيّنتين مستقلتين $(X_{11}, \dots, X_{1n_1}), (X_{21}, \dots, X_{2n_2})$ مأخوذتين من توزيعين طبيعيين $N(\theta_{11}, \theta_{21}^2)$ و $N(\theta_{12}, \theta_{22}^2)$ على الترتيب هو التوزيع الطبيعي:

$$N\left((\theta_{11} - \theta_{12}), \frac{\theta_{21}^2}{n_1} + \frac{\theta_{22}^2}{n_2}\right)$$

9.3 توزيعات المعاينة لصيغ تربيعية معينة في عينات من توزيع طبيعي

بمنا في الفقرة السابقة (3.8.3) توزيعات المعاينة الأساسية لمجاميع ومتوسطات عينات عشوائية، وبشكل خاص لمجاميع ومتوسطات عينات عشوائية (صيغ خطية في عناصر العينة) من توزيعات طبيعية (الحالات 3، 4، 6). سنعالج في هذا البند

توزيعات المعانة لمجموع مربعات (صيغ تربيعية) في عناصر العينة العشوائية كالتباين و صيغ تربيعية أخرى للعينات من توزيع طبيعي ووحيد البعد.

سنعرض في البداية بعض التعاريف والمبرهنات الضرورية لدراسة الصيغ التربيعية في متغيرات عشوائية طبيعية وتوزيعات المعانة لها.

1.9.3 الصيغ الخطية والتربيعية في متغيرات عشوائية طبيعية

Linear A Quadratic Forms in Normal Random Variables

نفترض أن $X = (X_1, \dots, X_n)$ متغيراً عشوائياً ذا n بعد، و $A = \|a_{ij}\|_1^n$ مصفوفة حقيقية متناظرة من المرتبة $n \times n$. يدعى المقدار $G = X'AX$ بالشكل التربيعي في المتغيرات X_i ; $i = 1, \dots, n$ ، وعندئذٍ تدعى A بمصفوفة الشكل التربيعي، وإذا كانت المصفوفة A محددة موجبة ($|A| \neq 0$)، فإن الشكل التربيعي G محدد موجب. نلاحظ أن:

$$G = X'AX = \sum_{i=1}^n \sum_{j=1}^n a_{ij} X_i X_j \quad (1.9.3)$$

و X' منقول X .

ويدعى المقدار $t_k = \sum_{i=1}^n b_{ki} X_i$ بالشكل الخطي في المتغيرات X_i ، حيث b_{ki} أعداد ثابتة. وإذا كان لدينا m شكل خطي t_k ; $k = 1, \dots, m$ ، فيمكننا كتابته بصيغة المصفوفات على النحو $t = BX$ ، حيث $B = \|b_{ki}\|$ مصفوفة مستطيلة من المرتبة $m \times n$. وفيما يلي سنرمز بـ O للمصفوفة الصفرية (zero matrix or null matrix) وبـ E_n للمصفوفة المحايدة أو الواحديّة (identity) والدليل n يشير إلى مرتبة المصفوفة.

مبرهنة 1.9.3

بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(0,1)$ ، ولدينا الشكل التربيعي $G = X'AX$ و m صيغة خطية $t = BX$. عندئذٍ إذا كان

$BA = O$ ، فإن المتغيرين G و t_k ; $k = 1, \dots, m$ مستقلان.

الإثبات

عما أن A مصفوفة حقيقة متناظرة، فهي قابلة التقاطر تعامدياً (orthogonally diagonalizable)، أي يمكن إيجاد مصفوفة متعامدة U (orthogonal matrix) ($U^t U = E_n$)، بحيث إن $U^t A U = D$ مصفوفة قطرية عناصرها λ_i ; $i = 1, \dots, n$ عبارة عن القيم الذاتية للمصفوفة A (حلول المعادلة المميزة $|A - \lambda E_n| = 0$). وتعتبر الأعمدة u_j للمصفوفة $U = \|u_1 u_2 \dots u_n\|$ المتجهات الذاتية للمصفوفة A الموافقة للقيم الذاتية $\lambda_1, \dots, \lambda_n$ على الترتيب، أي أن:

$$A u_j = \lambda_j u_j \quad ; \quad j = 1, \dots, n$$

يفهم في لغة المصفوفات المتجه كمصفوفة عمود و U^t أو U^t منقول المصفوفة U .

لتكن r رتبة المصفوفة A ($\text{rank } A$) و $\lambda_1, \dots, \lambda_r$ القيم الذاتية لها المختلفة عن الصفر، وبما أن $U^t A U = D$ ، فيمكن كتابة:

$$A = U D U^t = \sum_{j=1}^r \lambda_j u_j u_j^t \quad (2.9.3)$$

وحسب الفرض:

$$B A = O \Rightarrow \sum_{j=1}^r \lambda_j (B u_j) u_j^t = O$$

وبضرب طرفي المساواة الأخيرة من اليمين بالمتجه u_s ، وباعتبار أن المتجهات u_j متعامدة (لأن المصفوفة U متعامدة)، أي أن $u_j^t u_s = 0$; $j \neq s$ نجد:

$$B u_s = O \quad ; \quad s = 1, 2, \dots, r \quad (3.9.3)$$

لنأخذ الآن المتجه العشوائي $(t_1, \dots, t_m, u_1^t X, \dots, u_r^t X)$. يخضع هذا المتجه للتوزيع الطبيعي ذي $m+r$ بعد، لأن مركباته (متغيرات عشوائية) عبارة عن

أشكال خطية في المتجه الطبيعي X .

يمكن بناءً على العلاقة (2.9.3) كتابة:

$$G = X'AX = \sum_{j=1}^r \lambda_j (X'u_j)(u_j'X) = \sum_{j=1}^r \lambda_j (u_j'X)^2 \quad (4.9.3)$$

وبالتالي، نصل إلى المطلوب، إذا أمكن إثبات أن المتغيرات العشوائية $t_1, \dots, t_m, u_1'X, \dots, u_r'X$ غير مرتبطة، وذلك لأنها خاضعة لتوزيعات طبيعية، أي يكفي إثبات أن:

$$\text{cov}(t_i, u_j'X) = 0 \quad ; \quad i = 1, \dots, m \quad , \quad j = 1, \dots, r$$

وهذا يعني أن $t_i, u_j'X$ مستقلان.

لإثبات ذلك، لنرمز بـ b_i' ، $i = 1, \dots, m$ لأسطر المصفوفة B ، وحسب العلاقة (23.3.2)، نجد:

$$\begin{aligned} \text{cov}(t_i, u_j'X) &= \text{cov}(b_i'X, u_j'X) \\ &= E(b_i'Xu_j'X) - E(b_i'X)E(u_j'X) \\ &= E(b_i'Xu_j'X) = b_i'E(XX')u_j \\ &= b_i'E_n u_j = b_i'u_j = 0 \end{aligned}$$

حيث إن $E(b_i'X) = E(u_j'X) = 0$ ، لأن توزيع X_i هو $N(0,1)$ ، و $b_i'u_j = 0$ لأن $Bu_j = 0$ ؛ $j = 1, \dots, r$ [العلاقة (3.9.3)]. وهو المطلوب.

لنرى الآن الشكلين الستريعيين:

$$G_1 = X'AX \quad , \quad G_2 = X'BX$$

حيث كل من A و B مصفوفة حقيقة متناظرة من المرتبة n .

مبرهنة 2.4.3

إذا كان $AB = BA = O$ ، فإن المتغيرين العشوائيين G_2 و G_1 مستقلان.

الإثبات

لنفترض من أجل المصفوفة A العلاقة (2.9.3) صحيحة. ويمكننا كتابة المصفوفة B على النحو الآتي:

$$B = \sum_{j=1}^S v_j \mathbf{v}_j \mathbf{v}_j' \quad , \quad S = \text{Rank} B$$

وحسب الفرض $AB = O$ ، إذن:

$$AB = \sum_{i=1}^r \sum_{j=1}^S \lambda_i v_j u_i (u_i' \mathbf{v}_j) \mathbf{v}_j' = O$$

وبضرب هذه المساواة من اليسار بـ u_i' ومن اليمين بـ \mathbf{v}_j ، نجد:

$$u_i' \mathbf{v}_j = 0 \quad , \quad i = 1, \dots, r \quad , \quad j = 1, \dots, s$$

وهذا يعني أن المتجهات u_i متعامدة مع المتجهات \mathbf{v}_j . من هنا، كما أشرنا سابقاً، فالتغيرات العشوائية $u_i' X$ و $\mathbf{v}_j' X$ غير مرتبطة. وبما أن توزيعها المشترك طبيعي فإنها مستقلة. وبالتالي، بما أن:

$$G_1 = \sum_{i=1}^r \lambda_i (u_i' X)^2 \quad , \quad G_2 = \sum_{j=1}^S \lambda_j (\mathbf{v}_j' X)^2$$

فإن المتغيرين G_2, G_1 مستقلان.

2.9.3 توزيعات المعاينة لصيغ تربيعية في متغيرات عشوائية طبيعية

لنرمز بـ $\text{tr}A$ لأثر المصفوفة المربعة A (مجموع عناصرها القطرية).

مبرهنة 3.9.3

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(0,1)$ ، $G = X'AX$ و $r \leq n$ رتبة المصفوفة A . إذا كانت $A^2 = A$ (مصفوفة متساوية القوى)، فإن $\mathcal{L}(G) = \chi_{(r)}^2$; $r = \text{tr}A$.

الإثبات

لنفترض من أجل A العلاقة (2.9.3) صحيحة، عندها من خاصية التناظر ومتساوية القوى نجد أن $\lambda_1 = \lambda_2 = \dots = \lambda_r = 1$ ، وبناءً على العلاقة (4.9.3) نجد:

$$G = \sum_{k=1}^r (u_k' X)^2$$

وبما أن المتجهات u_k متعامدة ومستقلة، فإن المتغيرات العشوائية $u_k' X$ ، $k = 1, \dots, r$ مستقلة ولكل منها التوزيع الطبيعي $N(0,1)$. وبالتالي، بناءً على المبرهتين (6.3.2) و (7.3.2) لتوزيع χ^2 فإن $\chi^2_{(r)} = L(G)$ ، وأن:

$$t_r A = t_r (U^2 U D) = t_r D = \lambda_1 + \dots + \lambda_r = r$$

مبرهنة 4.9.3

إذا كان المتجه $Y = (Y_1, \dots, Y_n)$ خاضعاً للتوزيع $N(\mu, \Sigma)$ ، فإن الشكل التربيعي $G = (Y - \mu)' \Sigma (Y - \mu)$ يخضع لتوزيع $\chi^2_{(n)}$. حيث إن Σ مصفوفة التغاير و μ مصفوفة القيم المتوقعة لـ Y_i ؛ $i = 1, \dots, n$.

الإثبات

بما أن Σ مصفوفة حقيقية ومتناظرة، فهي قابلة للتقاطر. وبالتالي يمكن إيجاد المصفوفة U التي تحول المصفوفة Σ إلى شكل قطري $U' \Sigma U = D$. وبما أن العناصر القطرية λ_i للمصفوفة D موجبة، فإن المصفوفة $D^{-1/2}$ عبارة عن المصفوفة القطرية بالعناصر $\lambda_i^{-1/2}$. لنبحث الآن عن توزيع المتجه $Z = D^{-1/2} U' (Y - \mu)$.

بما أن $L(Y) = N(\mu, \Sigma)$ ، وبأخذ $V = LY$ ، حيث L مصفوفة التحويل الخطي، فإن $L(V) = N(L\mu, L\Sigma L')$ ، وبالتالي:

$$\mathcal{L}(Z) = N(O, E_n)$$

لكن $Y - \mu = UD^{1/2}Z$ ، إذن:

$$G = ZD^{-1/2}U'\Sigma^{-1}UD^{1/2}Z = Z'E_nZ = Z'Z$$

وبناءً على المبرهنتين (6.3.2) و (7.3.2) لتوزيع χ^2 ، نجد:

$$\mathcal{L}(G) = \chi^2_{(n)}$$

مبرهنة 5.9.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(\mu, \sigma^2)$ وكان $S^2(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ متوسط وتباين العينة X على الترتيب، فإنهما مستقلان وتوزيع المتغير العشوائي $\frac{nS^2}{\sigma^2}$ هو $\chi^2_{(n-1)}$.

الإثبات

بما أن (حسب الفرض):

$$\mathcal{L}(X_i) = N(\mu, \sigma^2) \quad , \quad i = 1, 2, \dots, n$$

فإن:

$$\mathcal{L}\left(Y_i = \frac{X_i - \mu}{\sigma}\right) = N(0, 1) \quad , \quad i = 1, 2, \dots, n$$

أي أن $Y = (Y_1, \dots, Y_n)$ عينة عشوائية من التوزيع $N(0, 1)$. ونلاحظ أن:

$$\bar{Y} = \frac{\bar{X} - \mu}{\sigma} \quad , \quad S^2(Y) = \frac{S^2(X)}{\sigma^2}$$

ولإثبات استقلال المتغيرين $S^2(X), \bar{X}$ يكفي إثبات استقلال المتغيرين $S^2(Y), \bar{Y}$.

لنأخذ مصفوفة السطر $b' = \left[\frac{1}{n} \dots \frac{1}{n} \right]$ من المرتبة $1 \times n$ ، عندئذ المصفوفة $B = \|b \dots b\|$ من المرتبة n حقيقة ومتناظرة.

نلاحظ $\bar{Y} = b'Y$ و $nS^2(Y) = (Y - BY)'(Y - BY)$ وبالتالي يمكننا أن نكتب $nS^2(Y) = Y'AY$ حيث إن $A = E_n - B$ مصفوفة متساوية القوى.

بما أن $BA = O$ فإن $b'A = b' - b'B = b' - b' = O$ وحسب المبرهنة (1.9.3) فإن المتغيرين $S^2(Y), \bar{Y}$ مستقلان، وبالتالي $S^2(X), \bar{X}$ مستقلان.

من الواضح أن توزيع $\sqrt{n} \bar{Y} = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ هو $N(0,1)$. وبما أن:

$$\begin{aligned} \frac{nS^2(X)}{\sigma^2} &= \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{\sigma^2} \sum_{i=1}^n \left[(X_i - \mu) - (\bar{X} - \mu) \right]^2 \\ &= \sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2 - \left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right)^2 \end{aligned}$$

وحسب المبرهنتين (6.3.2) و (7.3.2) لتوزيع χ^2 فإن:

$$\begin{aligned} \mathcal{L} \left(\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} \right)^2 \right) &= \chi_{(n)}^2 \\ \mathcal{L} \left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right)^2 &= \chi_{(1)}^2 \end{aligned}$$

وبالتالي، بناءً على المبرهنة (8.3.2) لتوزيع χ^2 نجد:

$$\mathcal{L} \left(\frac{nS^2(X)}{\sigma^2} \right) = \chi_{(n-1)}^2$$

مبرهنة 6.9.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(\mu, \sigma^2)$ وكان S^2, \bar{X} متوسط وتباين العينة X على الترتيب، فإن:

$$\mathcal{L}\left(\frac{\bar{X} - \mu}{S/\sqrt{n-1}}\right) = S_{(n-1)}$$

أي أن المتغير العشوائي $\frac{\bar{X} - \mu}{S/\sqrt{n-1}}$ يخضع لتوزيع t بـ $n-1$ درجة حرية.

الإثبات

لنفترض في العلاقة (41.3.2) أن:

$$\xi = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}, \quad \eta = \frac{nS^2(X)}{\sigma^2}$$

وعلى ذلك:

$$\frac{\bar{X} - \mu}{S/\sqrt{n-1}} = \frac{\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}}{\sqrt{\frac{nS^2}{\sigma^2}/(n-1)}} = \frac{\xi}{\sqrt{\frac{\eta}{(n-1)}}}$$

وبما أن:

$$\mathcal{L}\left(\xi = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}\right) = N(0,1)$$

$$\mathcal{L}\left(\eta = \frac{nS^2}{S/\sqrt{n}}\right) = \chi_{(n-1)}^2$$

إذن حسب تعريف توزيع t ، فإن:

$$\mathcal{L}\left(\frac{nS^2}{S/\sqrt{n}}\right) = S_{(n-1)}$$

مبرهنة 7.9.3

إذا كانت $Y = (Y_1, \dots, Y_n)$ و $X = (X_1, \dots, X_m)$ عينتين عشوائيتين مستقلتين من التوزيع $N(\mu, \sigma^2)$ ، وكان $S^2(X), \bar{X}$ و $S^2(Y), \bar{Y}$ متوسط وتباين كل منهما على الترتيب، فإن المتغير العشوائي:

$$t = \sqrt{\frac{mn(m+n-2)}{m+n}} \frac{\bar{X} - \bar{Y}}{\sqrt{mS^2(X) + nS^2(Y)}} \quad (5.9.3)$$

يخضع لتوزيع t بـ $(m+n-2)$ درجة حرية.

الإثبات

يمكن كتابة المتغير العشوائي t على النحو الآتي:

$$t = \frac{[(\bar{X} - \bar{Y})/\sigma] \sqrt{\frac{mn}{m+n}}}{\sqrt{\frac{mS^2(X) + nS^2(Y)}{\sigma^2} / (m+n-2)}}$$

حيث إن:

$$E(\bar{X} - \bar{Y}) = 0 \quad , \quad \text{var}(\bar{X} - \bar{Y}) = \frac{m+n}{mn} \sigma^2$$

بما أن:

$$\mathcal{L}\left(\frac{mS^2(X)}{\sigma^2}\right) = \chi_{(m-1)}^2 \quad , \quad \mathcal{L}\left(\frac{nS^2(Y)}{\sigma^2}\right) = \chi_{(n-1)}^2$$

فحسب الخاصة (2) لتوزيع χ^2 نجد:

$$\mathcal{L}\left(\frac{mS^2(X) + nS^2(Y)}{\sigma^2}\right) = \chi_{(m+n-2)}^2$$

وبسهولة يمكن إثبات أن:

$$\mathcal{L}\left(\frac{\bar{X} - \bar{Y}}{\sigma} \sqrt{\frac{mn}{m+n}}\right) = N(0,1)$$

وبالتالي، بناءً على تعريف توزيع t (41.3.2) نجد أن توزيع المتغير العشوائي t المعرف بالعلاقة (5.9.3) هو $S(m+n-2)$ ، أي أن:

$$\mathcal{L}\left(\frac{\left[\frac{(\bar{X} - \bar{Y})/\sigma}{\sqrt{\frac{mS^2(X) + nS^2(Y)}{\sigma^2}}}\right] \sqrt{\frac{mn}{m+n}}}{(m+n-2)}\right) = S(m+n-2)$$

وبشكل مشابه، يمكن إثبات أن المتغير العشوائي:

$$t = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{mS^2(X) + nS^2(Y)}{m+n}}} \sqrt{\frac{mn(m+n-2)}{m+n}}$$

يخضع لتوزيع t بـ $(m+n-2)$ درجة حرية، حيث إن $X = (X_1, \dots, X_m)$ من التوزيع $N(\mu_1, \sigma^2)$ و $Y = (Y_1, \dots, Y_n)$ من التوزيع $N(\mu_2, \sigma^2)$.

10.3 الإحصاءات المرتبة THE ORDER STATISTICS

تلعب نظرية المعاينة للإحصاءات المرتبة دوراً هاماً في مسائل مختلفة للاستدلال الإحصائي، التي سنتطرق إليها فيما بعد. لذا سنبحث في هذا البند بعض أهم نتائج نظرية المعاينة للإحصاءات المرتبة.

نفترض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر $F(x)$ و $x = (x_1, \dots, x_n)$ قيمة ملاحظة لـ X . إن القيم الملاحظة x_1, \dots, x_n يمكن ترتيبها تصاعدياً حسب قيمها (من الأصغر إلى الأكبر) ولنرمز لها بـ $x_{(1)}, \dots, x_{(n)}$ ، حيث إن:

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)} \quad (1.10.3)$$

ولنرمز بـ $X_{(k)}$ للمتغير العشوائي الذي يأخذ القيمة $x_{(k)}$; $k = 1, \dots, n$ عند أي ملاحظة x للعينة X ، وبذلك نعرف من العينة X متتالية جديدة من المتغيرات العشوائية $X_{(1)}, X_{(2)}, \dots, X_{(n)}$ ، حيث إن:

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)} \quad (2.10.3)$$

تدعى المتغيرات الجديدة $X_{(k)}$; $k = 1, \dots, n$ بالإحصاءات المرتبة للعينة، ويدعى المتغير $X_{(k)}$ بالإحصاء ذو الترتيب k ، ومن ثم تدعى $(X_{(1)}, \dots, X_{(k)})$ بالعينة المرتبة. كما تدعى المتسلسلة المعرفة بالعلاقة (2.10.3) بالمتسلسلة المتغيرة (variable sery) للعينة X . وهذا يعني أن المتسلسلة المتغيرة لـ X ما هي إلا عينة عناصرها مرتبة تصاعدياً حسب قيمها. ومن أجل ملاحظة x لـ X ، فإن المتسلسلة المعرفة بالعلاقة (2.10.3) تأخذ شكل المتسلسلة العددية المعرفة بالعلاقة (1.10.3). وهذه الأخيرة تعتبر الشكل الأولي لتمثيل المعطيات الإحصائية (العينة الملاحظة).

1.10.3 التوزيع الاحتمالي الهامشي لإحصاء مرتب

The Marginal Probability distribution of An Individual Order Statistic

نقدم في هذه الفقرة التوزيعات الاحتمالية الهامشية للإحصاءات المرتبة $X_{(k)}$; $k = 1, \dots, n$ لعينة عشوائية X مأخوذة من توزيع مستمر $F(x)$.

مبرهنة 1.10.3

إذا كانت $X = (X_{(1)}, \dots, X_{(n)})$ عينة عشوائية من توزيع مستمر $L(\xi)$ دالة كثافته الاحتمالية $f(x)$ ودالة توزيعه هي:

$$F(x) = P(\xi < x)$$

وكانت $Y_1 = X_{(1)}, \dots, Y_n = X_{(n)}$ الإحصاءات المرتبة للعينة X ، فإن التوزيع الاحتمالي للإحصاء المرتب $Y_i = X_{(i)}$ يعطى بدالة الكثافة:

$$h_i(y) = h(y) = \frac{n!}{(i-1)!(n-i)!} f(y)[F(y)]^{i-1}[1-F(y)]^{n-i} \quad (3.10.3)$$

الإثبات

حسب تعريف دالة الكثافة في نظرية الاحتمالات:

$$h(y) = \lim_{\Delta y \rightarrow 0} \frac{H(y + \Delta y) - H(y)}{\Delta y} = \lim_{\Delta y \rightarrow 0} \frac{P(y \leq Y_i < y + \Delta y)}{\Delta y}$$

حيث $h(y)$ و $H(y)$ دالة الكثافة الاحتمالية ودالة التوزيع للمتغير العشوائي Y_i على الترتيب.

إن تحقق الحادث $y \leq Y_i < y + \Delta y$ يعني أن $(i-1)$ من المركبات $X_i ; i = 1, \dots, n$ للينة X أقل من y ومركبة واحدة تنتمي للفترة $[y, y + \Delta y)$ وأن $(n-i)$ مركبة من X أكبر أو تساوي $y + \Delta y$. وباستخدام التوزيع المتعدد الحدود نجد:

$$\begin{aligned} P(y \leq Y_i < y + \Delta y) &= \\ &= \frac{n!}{(i-1)!!(n-i)!} [F(y)]^{i-1} [F(y + \Delta y) - F(y)] [1 - F(y + \Delta y)]^{n-i} \end{aligned}$$

وبتقسيم الطرفين على Δy ، وبأخذ النهاية عندما $\Delta y \rightarrow 0$ ، نجد:

$$\begin{aligned} \lim_{\Delta y \rightarrow 0} \frac{P(y \leq Y_i < y + \Delta y)}{\Delta y} &= \\ &= \frac{n!}{(i-1)!!(n-i)!} [F(y)]^{i-1} [1 - F(y)]^{n-i} \lim_{\Delta y \rightarrow 0} \frac{F(y + \Delta y) - F(y)}{\Delta y} \end{aligned}$$

وبالتالي:

$$h_i(y) = \frac{n!}{(i-1)!!(n-i)!} f(y)[F(y)]^{i-1}[1-F(y)]^{n-i}$$

وهو المطلوب.

بوضع $i = 1$ في العلاقة (3.10.3) نحصل على دالة الكثافة الاحتمالية لتوزيع
 $: Y_1 = X_{(1)}$

$$h_1(y) = \frac{n!}{(n-1)!} f(y)[1-F(y)]^{n-1} = nf(y)[1-F(y)]^{n-1} \quad (4.10.3)$$

وبوضع $i = n$ نحصل على دالة كثافة توزيع $: Y_n = X_{(n)}$

$$h_n(y) = nf(y)[F(y)]^{n-1} \quad (5.10.3)$$

وبشكل مشابه نحصل على توزيع بقية الإحصاءات المرتبة.

مثال 1.10.3

بفرض $X_i = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع المنتظم $R(0,1)$ ، أوجد
 توزيع كل من $Y_1 = X_{(1)}$ ، $Y_n = X_{(n)}$

بما أن دالة كثافة ودالة توزيع $R(0,1)$ هي على الترتيب:

$$f(x) = \begin{cases} 1 & ; \quad 0 \leq x \leq 1 \\ 0 & ; \quad x < 0 \text{ or } x > 1 \end{cases}$$

$$F(x) = \begin{cases} 0 & ; \quad x \leq 0 \\ x & ; \quad 0 < x \leq 1 \\ 1 & ; \quad x > 1 \end{cases}$$

فحسب العلاقة (3.10.3) نجد دالة كثافة توزيع $Y_i = X_{(i)}$

$$h_i(y) = \frac{n!}{(i-1)!(n-i)!} y^{i-1} (1-y)^{n-i} \quad ; \quad 0 < y \leq 1$$

بوضع $i = 1$ نحصل على توزيع $Y_1 = X_{(1)}$

$$h_1(y) = n(1-y)^{n-1} \quad ; \quad 0 < y \leq 1$$

وبوضع $i = n$ نحصل على توزيع $Y_n = X_{(n)}$

$$h_n(y) = ny^{n-1} \quad ; \quad 0 < y \leq 1$$

مثال 2.10.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع أسّي:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0, \theta > 0$$

فأوجد توزيع كل من $Y_2 = X_{(2)}$ و $Y_{n-1} = X_{(n-1)}$

بما أن دالة التوزيع الأسّي:

$$F(x; \theta) = \begin{cases} 0 & ; x \leq 0 \\ 1 - e^{-\theta x} & ; x > 0 \end{cases}$$

فبالتعويض في العلاقة (3.10.3) نجد توزيع $Y_i = X_{(i)}$

$$h_i(y) = \frac{n!}{(i-1)!(n-i)!} \theta e^{-(n+1-i)\theta x} (1 - e^{-\theta x})^{i-1} \quad ; \quad x > 0$$

بوضع $i = 2, n-1$ نحصل على توزيع Y_2 و Y_{n-1} على الترتيب.

$$h_2(y) = n(n-1)\theta e^{-(n-1)\theta x} (1 - e^{-\theta x}) \quad ; \quad x > 0$$

$$h_{n-1}(y) = n(n-1)\theta e^{-2\theta x} (1 - e^{-\theta x})^{n-2} \quad ; \quad x > 0$$

2.10.3 التوزيع المشترك لإحصائين مرتبين

The Joint Distribution of Two Order Statistics

مبرهنة 2.10.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع دالة كثافته الاحتمالية $f(x)$ ودالة توزيعه $F(x)$ ، فإن دالة الكثافة الاحتمالية المشتركة للإحصائين

المرتبين $Y_i = X_{(i)}, Y_j = X_{(j)}$; $1 \leq i < j \leq n$ هي:

$$h_{Y_i Y_j}(x, y) = h_{ij}(x, y) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} f(x)f(y)[F(x)]^{i-1}[F(y)-F(x)]^{j-i-1}[1-F(y)]^{n-j}$$

(6.10.3)

الإثبات

نعلم أن:

$$h_{ij}(x, y) = \lim_{\substack{\Delta x \rightarrow 0 \\ \Delta y \rightarrow 0}} \frac{P(x \leq Y_i < x + \Delta x, y \leq Y_j < y + \Delta y)}{\Delta x \Delta y}$$

وتحقق الحادث $(x \leq Y_i < x + \Delta x, y \leq Y_j < y + \Delta y)$ يعني تحقق الحوادث:

$$Y_k < x \quad ; \quad k \leq i-1$$

$$x \leq Y_k < x + \Delta x \quad ; \quad k = i$$

$$x + \Delta x \leq Y_k < y \quad ; \quad i < k \leq j-1$$

$$y \leq Y_k < y + \Delta y \quad ; \quad k = j$$

$$Y_k \geq y + \Delta y \quad ; \quad k > j$$

نلاحظ أننا أمام n تكرار مستقل لتجربة مفروضة، فضاء الحوادث الأولية الموافق لها مجزأ إلى خمس حوادث متنافية متنى متنى، وهي الواردة أعلاه، وأن احتمالات هذه الحوادث على الترتيب:

$$P_1 = F(x)$$

$$P_2 = F(x + \Delta x) - F(x)$$

$$P_3 = F(y) - F(x + \Delta x)$$

$$P_4 = F(y + \Delta y) - F(y)$$

$$P_5 = 1 - F(y + \Delta y)$$

ومن ثم احتمال ظهور الحادث الأول $(i-1)$ مرة، الحادث الثاني مرة واحدة، الحادث الثالث $(j-i-1)$ مرة، الحادث الرابع مرة واحدة والحادث الخامس $(n-j)$ مرة ضمن الـ n تكرار مستقل للتجربة المفروضة يعطى بقانون التوزيع المتعدد الحدود:

$$P(x \leq Y_i < x + \Delta x, y \leq Y_j < y + \Delta y) = \\ = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} [F(x)]^{i-1} [F(x + \Delta x) - F(x)] \\ \times [F(y) - F(x + \Delta x)]^{j-i-1} [F(y + \Delta y) - F(y)] [1 - F(y + \Delta y)]^{n-j}$$

بتقسيم الطرفين على $\Delta x \Delta y$ ، وأخذ النهاية عندما $\Delta x \rightarrow 0, \Delta y \rightarrow 0$ نحصل على دالة الكثافة المشتركة $h_{ij}(x, y)$ المعرفة بالعلاقة (6.10.3).

بوضع $n = j, i = 1$ في العلاقة (6.10.3) نحصل على دالة الكثافة الاحتمالية المشتركة للإحصائين المرتبين $Y_1 = X_{(1)}, Y_n = X_{(n)}$

$$h_{1n}(x, y) = n(n-1)f(x)f(y)[F(y) - F(x)]^{n-2}; \quad x < y \quad (7.10.3)$$

مثال 3.10.3

بفرض $X = (X_1, \dots, X_n)$ عينة من التوزيع المنتظم $R(0,1)$ ، أوجد التوزيع المشترك للإحصائين $Y_1 = X_{(1)}, Y_n = X_{(n)}$

حيث أن:

$$f(x) = 1; \quad 0 \leq x \leq 1$$

$$F(x) = x; \quad 0 < x \leq 1$$

وبالتعويض في العلاقة (6.10.3):

$$h_{ij}(x, y) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} x^{i-1} (y-x)^{j-i-1} (1-y)^{n-j}; \quad 0 < x < y \leq 1$$

وبإعطاء $i = 1, j = n$ نحصل على كثافة التوزيع الاحتمالي لـ (Y_1, Y_n)

$$h_{1n}(x, y) = n(n-1)(y-x)^{n-2} \quad ; \quad 0 < x < y \leq 1$$

ويمكن الحصول على نفس النتيجة بالتطبيق في العلاقة (7.10.3).

مثال 4.10.3

بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه:

$$f(x) = \frac{1}{2} e^{-\frac{x}{2}} \quad ; \quad x > 0$$

أوجد التوزيع المشترك للإحصائين $Y_1 = X_{(1)}, Y_n = X_{(n)}$

بما أن:

$$F(x) = \frac{1}{2} \int_0^x e^{-\frac{x}{2}} dx = 1 - e^{-\frac{x}{2}} \quad ; \quad x > 0$$

فحسب العلاقة (7.10.3)

$$h_{1n}(x, y) = \frac{n(n-1)}{4} e^{-(x+y)/2} \left[(1 - e^{-y/2}) - (1 - e^{-x/2}) \right]^{n-2} \quad ; \quad 0 < x < y$$

مبرهنة 3.10.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه $f(x)$ ودالة توزيعه $F(x)$ ، وكانت Y_1, \dots, Y_n الإحصاءات المرتبة للعينة X ، فإن دالة الكثافة المشتركة لها هي:

$$h(y_1, \dots, y_n) = n! \prod_{i=1}^n f(y_i) \quad ; \quad y_1 < y_2 < \dots < y_n \quad (8.10.3)$$

الإثبات

نعلم أن:

$$h(y_1, y_2, \dots, y_n) = \lim_{\Delta y_i \rightarrow 0} \frac{1}{\prod_{i=1}^n \Delta y_i} P(y_1 \leq Y_1 < y_1 + \Delta y_1, \dots, y_n \leq Y_n < y_n + \Delta y_n)$$

وتحقق الحادث $(y_1 \leq Y_1 < y_1 + \Delta y_1, \dots, y_n \leq Y_n < y_n + \Delta y_n)$ يعني تحقيق الحوادث $(y_i \leq Y_i < y_i + \Delta y_i)$; $i = 1, \dots, n$ المتنافية متشى متشى في آن واحد، حيث توجد ملاحظة واحدة من العينة X في كل فترة $(y_i \leq Y_i < y_i + \Delta y_i)$ باحتمال $F(y_i + \Delta y_i) - F(y_i)$ وحسب قانون التوزيع المتعدد الحدود:

$$P(y_1 \leq Y_1 < y_1 + \Delta y_1, \dots, y_n \leq Y_n < y_n + \Delta y_n) = n! \prod_{i=1}^n [F(y_i + \Delta y_i) - F(y_i)]$$

وبتقسيم الطرفين على $\prod_{i=1}^n \Delta y_i$ وجعل $\Delta y_i \rightarrow 0$ نجد:

$$\begin{aligned} h(y_1, \dots, y_n) &= n! \prod_{i=1}^n \lim_{\Delta y_i \rightarrow 0} \frac{F(y_i + \Delta y_i) - F(y_i)}{\Delta y_i} = \\ &= n! \prod_{i=1}^n f(y_i) \quad ; \quad y_1 < y_2 < \dots < y_n \end{aligned}$$

وهو المطلوب.

فمثلاً، إذا كانت لدينا معطيات المثال (4.10.3)، نجد:

$$h(y_1, \dots, y_n) = \left(\frac{1}{2}\right)^n n! e^{-\frac{1}{2} \sum_1^n y_i} \quad ; \quad 0 < y_1 < y_2 < \dots < y_n$$

وإذا كانت لدينا معطيات المثال (3.10.3)، فإن:

$$h(y_1, \dots, y_n) = n! \quad ; \quad 0 < y_1 < y_2 < \dots < y_n \leq 1$$

ملاحظة 1.10.3

يوجد فرق بين توزيع العينة العشوائية $X = (X_1, \dots, X_n)$ وتوزيع العينة العشوائية

المرتبة $Y = (Y_1, \dots, Y_n)$; $Y_i = X_{(i)}$, $i = 1, \dots, n$ ، فمثلاً، في حالة المعينة من توزيع $R(0,1)$ ، فإن:

$$f(x_1, \dots, x_n) = \prod_{i=1}^n f(x_i) = 1 \quad ; \quad 0 \leq x_i \leq 1, \quad i = 1, \dots, n$$

بينما:

$$h(y_1, \dots, y_n) = n! \quad ; \quad 0 < y_1 < y_2 < \dots < y_n \leq 1$$

وفي حالة المعينة من توزيع $\Gamma(1,2)$ فإن:

$$f(x_1, \dots, x_n) = \left(\frac{1}{2}\right)^n e^{-\frac{1}{2}\sum_{i=1}^n x_i}$$

بينما:

$$h(y_1, \dots, y_n) = \left(\frac{1}{2}\right)^n n! e^{-\frac{1}{2}\sum_{i=1}^n y_i}$$

11.3 توزيع دوال في الإحصاءات المرتبة

DISTRIBUTION OF FUNCTIONS OF ORDER STATISTICS

استخلصنا في الفقرتين السابقتين التوزيعات الهامشية والمشاركة للإحصاء المرتبة ذاتها. وسنبحث في هذه الفقرة توزيع دوال معينة في الإحصاءات المرتبة. إحدى أبسط الدوال في الإحصاءات المرتبة هو المتوسط الحسابي لها:

$$\frac{1}{n} \sum_{i=1}^n Y_i \quad ; \quad Y_i = X_{(i)}$$

وبما أن:

$$\frac{1}{n} \sum_{i=1}^n Y_i = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

فتوزيع المعاينة لمتوسط الإحصاءات المرتبة هو نفسه توزيع المعاينة لمتوسط العينة \bar{X} ، وهذا الأخير تم بحثه في البند 8.3.

سنناقش في الفقرات التالية توزيع وسيط العينة، مدى العينة ونصف مدى العينة. لذا لا بد في البداية من تعريف وسيط، مدى ونصف مدى العينة.

نفترض Y_1, \dots, Y_n الإحصاءات المرتبة لعينة عشوائية X_1, \dots, X_n من توزيع مستمر $F(x)$.

تعريف 1.11.3: وسيط العينة Sample Median

يعرف وسيط العينة \tilde{X} على أنه الإحصاء المرتب الأوسط إذا كانت n فردية ومتوسط الإحصائين المرتبين الأوسطين إذا كانت n زوجية. وإذا رمزنا بـ \tilde{X} لوسيط العينة العشوائية X ، فإن:

$$\tilde{X} = \begin{cases} Y_{m+1} & ; n = 2m + 1 \\ \frac{Y_m + Y_{m+1}}{2} & ; n = 2m \end{cases} \quad (1.11.3)$$

حيث إن m عدد صحيح موجب.

ونعلم من نظرية الاحتمالات أن وسيط المجتمع $F(x)$ ، ولنرمز له بـ $\tilde{\mu}$ ، هو تلك القيمة التي تحقق الشرط:

$$F(\tilde{\mu}) = \frac{1}{2}$$

تعريف 2.11.3: مدى العينة Sample Range

مدى العينة $X = (X_1, \dots, X_n)$ نرمز له بـ R ويعرف على النحو الآتي:

$$R = Y_n - Y_1 = X_{(n)} - X_{(1)} \quad (2.11.3)$$

تعريف 3.11.3: نصف مدى العينة Sample Midrange

نصف مدى العينة $X = (X_1, \dots, X_n)$ نرمز له بـ T ويعرف على النحو التالي:

$$T = \frac{Y_n + Y_1}{2} = \frac{R}{2} + Y_1 \quad (3.11.3)$$

1.11.3 توزيع وسيط العينة Distribution of Sample Median

بما أن وسيط العينة \tilde{X} عبارة عن إحصاء، أي متغير عشوائي فله توزيع احتمالي يدعى بتوزيع المعانة لـ \tilde{X} . ولإيجاد هذا التوزيع نميز حالتين: n فردية، n زوجية.

إذا كان حجم العينة X فردياً، فإن $\tilde{X} = Y_{m+1}$ ، ومن ثم توزيع \tilde{X} هو عبارة عن توزيع الإحصاء المرتب Y_{m+1} ، وهذا الأخير نحصل عليه بوضع $n = 2m + 1$ ، $i = m + 1$ في العلاقة (3.10.3).

$$h(\tilde{x}) = \frac{(2m+1)!}{m!m!} f(\tilde{x}) [F(\tilde{x})]^m [1 - F(\tilde{x})]^m \quad (4.11.3)$$

أما إذا كان حجم العينة X زوجياً $(n = 2m)$ ، فإن $\tilde{X} = \frac{Y_m + Y_{m+1}}{2}$ وعندئذٍ نشق توزيع \tilde{X} على النحو الآتي:

نعين توزيع (Y_m, Y_{m+1}) ، وذلك بوضع $i = m$ ، $j = m + 1$ في العلاقة (6.10.3):

$$h(x, y) = \frac{2m!}{(m-1)!(m-1)!} f(x)f(y) [F(x)]^{m-1} [1 - F(y)]^{m-1}$$

وبإجراء التحويل من (Y_m, Y_{m+1}) إلى (\tilde{X}, Z) ، حيث إن $Z = Y_{m+1}$. وبملاحظة أن المحدد الجاكوبي $J = 2$ نجد:

$$g(\tilde{x}, z) = \frac{2(2m)!}{(m-1)!(m-1)!} f(z)f(2\tilde{x}-z)[F(2\tilde{x}-z)]^{m-1}[1-F(z)]^{m-1}; \tilde{x} \leq z \quad (5.11.3)$$

ومن ثم دالة الكثافة الاحتمالية لوسيط العينة هي:

$$g(\tilde{x}) = \int_{\tilde{x}}^{\infty} g(\tilde{x}, z) dz \quad (6.11.3)$$

مثال 1.11.3

بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x) = 2e^{-2x}; \quad x > 0$$

أوجد توزيع \tilde{X} ، إذا علمت أن حجم العينة فردي $(n = 2m + 1)$.
بما أن:

$$f(x) = 2e^{-2x}; \quad x > 0$$

فإن:

$$F(x) = 1 - e^{-2x}; \quad x > 0$$

وبما أن $n = 2m + 1$ فردي، عندئذٍ توزيع \tilde{X} نحصل عليه باستخدام العلاقة
(4.11.3)

$$\begin{aligned} h(\tilde{x}) &= \frac{(2m+1)!}{m!m!} 2e^{-2\tilde{x}} (1 - e^{-2\tilde{x}})^m (e^{-2\tilde{x}})^m \\ &= \frac{2(2m+1)!}{m!m!} e^{-2(1+m)\tilde{x}} (1 - e^{-2\tilde{x}})^m; \quad \tilde{x} > 0 \end{aligned}$$

فمثلاً، إذا كانت $n = 11$ ، أي $m = 5$:

$$h(\tilde{x}) = \frac{2 \times 11!}{5!5!} e^{-12\tilde{x}} (1 - e^{-2\tilde{x}})^5; \quad \tilde{x} > 0$$

مثال 2.11.3

بفرض Y_1, Y_2, Y_3 الإحصاءات المرتبة لعينة عشوائية $X = (X_1, X_2, X_3)$ من التوزيع المنتظم $R(0,1)$ ، أوجد توزيع الوسيط \tilde{X} واحسب متوسطه وتباينه.
بما أن:

$$f(x) = 1 \quad ; \quad 0 \leq x \leq 1$$

$$F(x) = x \quad ; \quad 0 < x \leq 1$$

فبتطبيق العلاقة (4.11.3)، نجد:

$$g(\tilde{x}) = \frac{3!}{1!1!} \tilde{x}(1-\tilde{x}) = 6\tilde{x}(1-\tilde{x}) \quad ; \quad 0 < \tilde{x} \leq 1$$

$$E\tilde{X} = 6 \int_0^1 \tilde{x}^2(1-\tilde{x})d\tilde{x} = 6 \left(\frac{\tilde{x}^3}{3} - \frac{\tilde{x}^4}{4} \right) \Big|_0^1 = \frac{1}{2}, \quad E\tilde{X}^2 = 6 \int_0^1 \tilde{x}^3(1-\tilde{x})d\tilde{x} = \frac{3}{10}$$

$$\text{var } \tilde{X} = E\tilde{X}^2 - (E\tilde{X})^2 = \frac{3}{10} - \frac{1}{4} = \frac{1}{20}$$

2.11.3 توزيع مدى ونصف مدى العينة

Distribution of Sample Range and Midrange

لاشتقاق توزيع كل من مدى العينة $R = Y_n - Y_1$ ونصف مدى العينة

$$T = \frac{Y_1 + Y_n}{2}, \quad \text{نبحث أولاً عن توزيع } (Y_1, Y_n) \text{ وهو:}$$

$$h_{in}(x, y) = n(n-1)f(x)f(y)[F(y) - F(x)]^{n-2} \quad ; \quad x < y$$

وبالتحويل من (Y_1, Y_n) إلى (R, T) ، حيث إن:

$$\left. \begin{aligned} R &= Y_n - Y_1 \\ T &= \frac{Y_1 + Y_n}{2} \end{aligned} \right\} \Rightarrow \begin{cases} x = \frac{2t - r}{2} \\ y = \frac{2t + r}{2} \end{cases}$$

ومن ثم جاكوبي التحويل:

$$J = \begin{vmatrix} \frac{\partial x}{\partial r} & \frac{\partial x}{\partial t} \\ \frac{\partial y}{\partial r} & \frac{\partial y}{\partial t} \end{vmatrix} = \begin{vmatrix} -\frac{1}{2} & 1 \\ \frac{1}{2} & 1 \end{vmatrix} = -1$$

وبالتالي، فإن دالة الكثافة لـ (R, T)

$$g(r, t) = n(n-1)f\left(t - \frac{r}{2}\right)f\left(t + \frac{r}{2}\right)\left[F\left(t + \frac{r}{2}\right) - F\left(t - \frac{r}{2}\right)\right]^{n-2}; r > 0 \quad (7.11.3)$$

وبناءً على ذلك فدالة الكثافة الاحتمالية للمدى R

$$g(r) = \int_{-\infty}^{+\infty} g(r, t) dt \quad (8.11.3)$$

ودالة الكثافة الاحتمالية لنصف المدى:

$$g(t) = \int_0^{\infty} g(r, t) dr \quad (9.11.3)$$

مثال 3.11.3

بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع المنتظم $R(0,1)$ ، أوجد:

1. التوزيع المشترك للمدى R ونصف المدى T .

2. التوزيع الهامشي للمدى R .

3. التوزيع الهامشي لنصف المدى T .

بما أن:

$$f(x) = 1 \quad ; \quad 0 \leq x \leq 1$$

$$F(x) = x \quad ; \quad 0 < x \leq 1$$

فإن دالة الكثافة المشتركة لـ R و T هي:

$$g(r, t) = n(n-1)r^{n-2} \quad ; \quad 0 < t - \frac{r}{2} < 1$$

$$0 < t + \frac{r}{2} < 1 \quad (10.11.3)$$

ومن ثم دالة الكثافة الهامشية لـ R :

$$g(r) = \int_{\frac{r}{2}}^{1 - \frac{r}{2}} n(n-1)r^{n-2} dt = n(n-1)(1-r)r^{n-2} \quad ; \quad 0 < r < 1 \quad (11.11.3)$$

ودالة الكثافة الهامشية لـ T :

$$g(t) = n(n-1) \int_0^{\min\{2t, 2(1-t)\}} r^{n-2} dr = \begin{cases} n(2t)^{n-1} & ; \quad -1 < t < 0 \\ n[2(1-t)]^{n-1} & ; \quad 0 < t < 1 \end{cases} \quad (12.11.3)$$

والقيمة المتوقعة لـ R

$$ER = \frac{n-1}{n+1}$$

12.3 توزيع المعينة لـ $F^*(x)$ *SAMPLE DISTRIBUTION OF*

نلاحظ من تعريف دالة التوزيع التجريبي $F_n^*(x)$ (البند 5.3) أنها عبارة عن إحصاء، عند كل قيمة حقيقية x ، لكونها دالة في بيانات العينة، أي متغيراً عشوائياً، وبالتالي لها توزيع احتمالي تحدده المبرهنة الآتية.

مبرهنة 1.12.3

لتكن $F_n^*(x)$ دالة التوزيع التجريبي لمتغير عشوائي ξ الموافقة لعينة عشوائية $x = (x_1, \dots, x_n)$ من توزيع $L(\xi)$ ، ولنفترض $F(x)$ دالة التوزيع النظري لـ ξ . عندئذٍ توزيع $F_n^*(x)$ يعطي بالعلاقة الآتية:

$$P\left(F_n^*(x) = \frac{k}{n}\right) = C_n^k [F(x)]^k [1 - F(x)]^{n-k} \quad ; \quad k = 0, 1, \dots, n \quad (1.12.3)$$

الإثبات

نلاحظ بوضوح أن المتغير العشوائي $F_n^*(x)$ يفترض القيم:

$$0, \frac{1}{n}, \frac{2}{n}, \dots, \frac{n-1}{n}, \frac{n}{n} = 1$$

وإذا رمزنا بـ:

$$Z_i = \begin{cases} 1 & ; x_i < x \\ 0 & ; x_i \geq x \end{cases}$$

فإن Z_i متغير عشوائي يتبع توزيع بيرنولي $B(1, F(x))$ ، ومن ثم $Z = \sum_{i=1}^n Z_i$ يتبع توزيع ذي الحدين $B(n, F(x))$ ، حيث أن Z يمثل عدد القيم x_i الأقل من x . ولكن حسب التعريف:

$$F_n^*(x) = \frac{1}{n} \sum_{i=1}^n Z_i$$

وعلى ذلك يكون له نفس توزيع المعاينة لمتوسط عينة عشوائية مأخوذة من توزيع بيرنولي [راجع (1) في الفقرة 3.8.3]، أي أن:

$$P\left(F_n^*(x) = \frac{k}{n}\right) = C_n^k F^k(x) [1 - F(x)]^{n-k} \quad ; \quad k = 0, 1, \dots, n$$

وهو المطلوب.

بما أن:

$$F_n^*(x) = \frac{Z}{n}$$

فإن:

$$E\left[F_n^*(x)\right] = E\left(\frac{Z}{n}\right) = \frac{1}{n} EZ = \frac{1}{n} nF(x) = F(x) \tag{2.12.3}$$

$$\text{var}\left[F_n^*(x)\right] = V\left(\frac{Z}{n}\right) = \frac{1}{n} F(x)[1 - F(x)]$$

COVERAGES

13.3 المشمولات أو المغطيات

لنفترض أن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر $L(\xi)$ دالة كثافته $f(x)$ ودالة توزيعه $F(x)$ ، ولتكن العينة المرتبة الموافقة $Y = (Y_1, \dots, Y_n)$ لـ X .

توجد خاصتان مهمتان للإحصاءات المرتبة، مفيدتان جداً عند دراسة بعض طرق الاستدلال الإحصائي، وهما

1. المساحة المحددة بدالة الكثافة $f(x)$ وأي إحصائين مرتبين مستقلة عن دالة الكثافة هذه.

2. الإحصاءات المرتبة Y_1, \dots, Y_n تقسم (في المتوسط) المساحة تحت منحني التوزيع $f(x)$ إلى $(n+1)$ جزء متساوٍ، ومساحة كل جزء تساوي $1/(n+1)$.

إثبات الخاصة (1)

إذا رمزنا بـ $U_i = F(Y_i)$ ؛ $i = 1, \dots, n$ ، فإن متغير عشوائي يخضع للتوزيع المنتظم $R(0,1)$ [راجع فقرة (1.3.2)]، وبناءً على ذلك $U = (U_1, \dots, U_n)$ عبارة عن الإحصاءات المرتبة لعينة عشوائية مأخوذة من مجتمع يتبع التوزيع المنتظم $R(0,1)$ ، ومن ثم الفرق:

$$Z_{ij} = U_j - U_i = F(Y_j) - F(Y_i) = P(Y_i < \xi < Y_j)$$

عبارة عن المساحة المحددة بمنحني التوزيع $f(x)$ والإحصائين المرتبين Y_i, Y_j ؛ $i < j$ ، ويصبح المطلوب إثبات أن التوزيع الاحتمالي للفرق Z_{ij} لا يعتمد على التوزيع $L(\xi)$.

بناءً على نتائج المثال (3.10.3)، فإن كثافة الاحتمال لـ (U_i, U_j) هي:

$$h(u_i, u_j) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} u_i^{i-1} (u_j - u_i)^{j-i-1} (1-u_j)^{n-j}$$

; $0 < u_i < u_j < 1$

وبالتحويل من المتغير (U_i, U_j) إلى المتغير (U_i, Z_{ij}) ، وملاحظة أن المحدد الجاكوبي $J = 1$ ، نجد:

$$K(u, z) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} u^{i-1} z^{j-i-1} (1-z-u)^{n-j} ; 0 < u < 1$$

; $0 < z+u < 1$

وبإجراء تكامل الدالة $K(u, z)$ بالنسبة لـ u نحصل على دالة الكثافة الاحتمالية لـ Z_{ij} :

$$K(z) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} z^{j-i-1} \int_0^{1-z} u^{i-1} (1-z-u)^{n-j} du$$

ولحساب هذا التكامل نضع $y = \frac{u}{1-z}$

$$K(z) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} z^{j-i-1} (1-z)^{n-j+i} \int_0^1 y^{i-1} (1-y)^{n-j} dy \quad (1.13.3)$$

وبناءً على العلاقة (36.3.2) والخاصة (2) لدالة جاما [راجع الفقرة (5.3.2)]، نجد:

$$\int_0^1 y^{i-1} (1-y)^{n-j} dy = \frac{\Gamma(i)\Gamma(n-j+1)}{\Gamma(n-j+i+1)} = \frac{(i-1)!(n-j)!}{(n-j+i)!}$$

وبالتعويض في (1.13.3) نحصل على دالة كثافة توزيع $Z_{ij} = Z$

$$K(z) = \frac{n!}{(i-1)!(j-i-1)!(n-j)!} \frac{(i-1)!(n-j)!}{(n-j+i)!} z^{j-i-1} (1-z)^{n-j+i}$$

(2.13.3)

$$= \frac{n!}{(j-i-1)!(n-j+i)!} z^{j-i-1} (1-z)^{n-j+i} ; 0 < z < 1$$

وهذه دالة كثافة توزيع $Be(j-i, n-j+i+1)$ ، وهو لا يعتمد على توزيع المجتمع $f(x)$.

إثبات الخاصة (2)

$$\begin{aligned} EZ &= \int_0^1 zK(z)dz = \frac{n!}{(j-i-1)!(n-j+i)!} \int_0^1 z^{j-i}(1-z)^{n-j+i} dz \\ &= \frac{n!}{(j-i-1)!(n-j+i)!} \frac{\Gamma(j-i+1)\Gamma(n-j+i+1)}{\Gamma(n+2)} \\ &= \frac{n!}{(j-i-1)!(n-j+i)!} \frac{(j-i)!(n-j+i)!}{(n+1)n!} = \frac{j-i}{n+1} \\ &\text{وبوضع } j = i+1 \text{ نجد } EZ = \frac{1}{n+1} \text{ وهو المطلوب.} \end{aligned}$$

تعريف 1.13.3: المشمولات أو المغطيات Coverages

تدعى الفترات $(-\infty, X_{(1)}], (X_{(1)}, X_{(2)}], \dots, (X_{(n)}, +\infty)$ بخلايا العينة X ونرمز لها بـ B_1, B_2, \dots, B_{n+1} على الترتيب، كما تدعى الدوال (الإحصاءات):

$$C_1 = F(Y_1) - F(-\infty) = U_1$$


$$C_2 = F(Y_2) - F(Y_1) = U_2 - U_1$$

(3.13.3)

$$C_n = F(Y_n) - F(Y_{n-1}) = U_n - U_{n-1}$$

$$C_{n+1} = F(+\infty) - F(Y_n) = 1 - U_n \quad ; \quad Y_i = X_{(i)} ; i = 1, \dots, n$$

في هذه الخلايا بالمشمولات أو المغطيات (coverages)، حيث إن مجموعها $\sum_{i=1}^{n+1} C_i = 1$ وهذا يعني أن C_i غطاء الخلية B_i حيث $i = 1, \dots, n+1$ ، ويبدو ذلك بوضوح على الشكل (1.13.3).



شكل 1.13.3

بما أن الغطاء C_j ; $j = 1, \dots, n$ متغير عشوائي، فله إذن توزيع احتمالي، وهذا التوزيع يمكن إيجاداه بسهولة بوضع $i = j - 1$, $j = z$ في العلاقة (2.13.3):

$$K_{C_j}(z) = n(1-z)^{n-1} \quad ; \quad 0 < z < 1 \quad (4.13.3)$$

وبناءً على ذلك:

$$E(C_i) = n \int_0^1 z(1-z)^{n-1} dz = n \frac{\Gamma(2)\Gamma(n)}{\Gamma(n+2)} = \frac{1}{n+1}$$

$$E(C_i^2) = n \int_0^1 z^2(1-z)^{n-1} dz = n \frac{\Gamma(3)\Gamma(n)}{\Gamma(n+3)} = \frac{2}{(n+2)(n+1)}$$

$$V(C_i) = E(C_i^2) - [E(C_i)]^2 = \frac{n}{(n+2)(n+1)^2}$$

14.3 المعاينة في حالة عينات كبيرة

SAMPLING FOR LARGE SAMPLES

بحثنا في البنود السابقة من هذا الفصل أساسيات نظرية المعاينة في حالة عينات بحجم محدود n . ولنتأمل الآن النتائج التي يمكن الحصول عليها من نظرية المعاينة عندما نجعل $n \rightarrow \infty$ ، في هذه الحالة لدينا مجتمع دالة توزيعه $F(x)$ وندرس

متتالية من المتغيرات العشوائية X_1, X_2, \dots المستقلة مثنى مثنى، وأي ففة من n من تلك المتغيرات تعتبر عينة عشوائية بحجم n مأخوذة من المجتمع $F(x)$. وسنعمد في هذا البند على ميرهنات النهاية الواردة في الفصل الأول ونتائجها المفيدة لدراسة السلوك التقاربي لميزات العينة وإيجاد التوزيعات التقريبية لدوال مختلفة في العينة، في حالة عينة كبيرة الحجم.

1.14.3 تقارب عزوم العينة بالاحتمال

Convergence of Sample Moments in Probability

أحد أبسط النتائج المتعلقة بعزوم العينة من أجل عينات كبيرة معطاة بالميرهننة الآتية:

مبرهنة 1.14.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $L(\xi)$ ، وكان العزم من المرتبة r لـ ξ موجوداً، فإن العزم من المرتبة r للعينة X يتقارب بالاحتمال من العزم من المرتبة r لـ ξ ، عندما $n \rightarrow \infty$.

الإثبات

لنرمز للعزم الابتدائي من المرتبة r المعروف بالعلاقة (1.5.3) بـ A_{nr} للإشارة إلى علاقة عزم العينة بحجمها n .

كما نعلم:

$$EA_{nr} = \alpha_r$$

$$VA_{nr} = \frac{\alpha_{2r} - \alpha_r^2}{n}$$

وحسب متباينة تشيبشيف (العلاقة 3.2.1)

$$P(|A_{nr} - \alpha_r| \leq \varepsilon) \geq 1 - \frac{\alpha_{2r} - \alpha_r^2}{n\varepsilon^2}$$

وبأخذ نهاية الطرفين، عندما $n \rightarrow \infty$ ، نجد:

$$\lim_{n \rightarrow \infty} P(|A_{nr} - \alpha_r| \leq \varepsilon) = 1$$

لأن الاحتمال لا يتجاوز الواحد والعزم الابتدائي من المرتبة r لـ ξ موجود (حسب الفرض)، وهو المطلوب.

وبشكل مشابه، يمكن الإثبات من أجل العزم المركزي M_{nr} للعينة X على أنه يتقارب بالاحتمال من العزم المركزي μ_r لـ ξ عندما $n \rightarrow \infty$.

تعني المبرهنة (1.14.3) أن عزوم العينة تعتبر قيماً تقريبية جيدة للعزوم النظرية الموافقة لها (إذا كانت هذه الأخيرة موجودة) في حالة عينات كبيرة الحجم.

وكحالة خاصة، عندما $r = 1$ فإن $A_{n1} = \bar{X}$ و $\alpha_1 = \mu$ ، أي أن متوسط العينة متقارب بالاحتمال من متوسط المجتمع μ . وكذلك، عندما $r = 2$ فإن $M_{n2} = S^2$ و $\mu_2 = \sigma^2$ ، أي أن تباين العينة متقارب بالاحتمال من تباين المجتمع σ^2 .

بصورة عامة، تبقى المبرهنة (1.14.3) صحيحة من أجل أي دالة مستمر لعدد منته من الكميات A_{nr} (فمثلاً، M_{nr} دالة مستمرة في A_{n1}, \dots, A_{nr} على شكل كثير حدود من الدرجة r). وهذه تعتبر نتيجة للمبرهنة العامة الآتية حول التقارب بالاحتمال لدالة مستمرة في متغيرات عشوائية.

مبرهنة 2.14.3

لتكن المتغيرات العشوائية $\eta_1(n), \eta_2(n), \dots, \eta_r(n)$ متقاربة بالاحتمال، عندما $n \rightarrow \infty$ ، إلى الثوابت c_1, c_2, \dots, c_r على الترتيب، عندهما من أجل أي دالة مستمرة $\varphi(x_1, x_2, \dots, x_r)$ فالتغير العشوائي:

$$\eta(n) = \varphi(\eta_1(n), \eta_2(n), \dots, \eta_r(n)) \xrightarrow{P} \varphi(c_1, c_2, \dots, c_r)$$

الإثبات

بما أن φ دالة مستمرة، فإنه مهما يكن العدد الحقيقي $\varepsilon > 0$ يمكن إيجاد

عدد حقيقي $\delta = \delta(\varepsilon)$ ، بحيث إن:

$$|\varphi(x_1, x_2, \dots, x_r) - \varphi(c_1, c_2, \dots, c_r)| < \varepsilon$$

من أجل $|x_i - c_i| < \delta$; $i = 1, 2, \dots, r$.

إذا رمزنا بـ $B_i = \{|\eta_i(n) - c_i| < \delta\}$; $i = 1, 2, \dots, r$ ، فإن الحادث $B = B_1 \cap B_2 \cap \dots \cap B_r$ محتوى في الحادث $C = \{|\eta(n) - \varphi(c_1, c_2, \dots, c_r)| < \varepsilon\}$ ومن ثم:

$$P(C) \geq P(B) = 1 - P(\bar{B}) = 1 - P(\bar{B}_1 \cup \bar{B}_2 \cup \dots \cup \bar{B}_r) = 1 - \sum_{i=1}^r P(\bar{B}_i)$$

وبناءً على التقارب بالاحتمال، حسب الفرض، للمتغيرات العشوائية $\eta_i(n)$ فإنه من أجل أي عدد حقيقي δ وأي $\gamma > 0$ يمكن إيجاد عدد طبيعي $n_i = n_i(\gamma)$ ، بحيث إن:

$$P(\bar{B}_i) = P(|\eta_i(n) - c_i| \geq \delta) < \frac{\gamma}{r} \quad ; \quad n \geq n_i, \quad i = 1, \dots, r$$

بأخذ $n_0 = \max(n_1, n_2, \dots, n_r)$ نجد أن المتباينات:

$$P(\bar{B}_i) < \frac{\gamma}{r} \quad ; \quad i = 1, 2, \dots, r$$

محققة في آن واحد عندما $n \geq n_0$ ، وبالتالي:

$$P(|\eta(n) - \varphi(c_1, c_2, \dots, c_r)| < \varepsilon) \geq 1 - \gamma \quad ; \quad n \geq n_0$$

وهو المطلوب.

نشير أيضاً لاستخدام إحصائي آخر للمبرهنة (2.14.3)، عند دراسة خصائص منحني توزيع متغير عشوائي مستمر، حيث نحتاج في الغالب لإيجاد معامل الالتواء γ_1 ومعامل التطاول γ_2 ، المعرفين كما يلي:

$$\gamma_1 = \frac{\mu_3}{\mu_2^{3/2}} \quad , \quad \gamma_2 = \frac{\mu_4}{\mu_2^2} - 3 \quad (1.14.3)$$

وإذا كانت العينة العشوائية $X = (X_1, X_2, \dots, X_n)$ من توزيع مستمر $\mathcal{L}(\xi)$ ، فإن معامل الإلتواء والتطاول للعيبة العشوائية Γ_{n2}, Γ_{n1} يعرفان على النحو الآتي:

$$\Gamma_{n1} = \frac{M_{n3}}{S_n^3}, \quad \Gamma_{n2} = \frac{M_{n4}}{S_n^4} - 3 \quad (2.14.3)$$

وبملاحظة أن Γ_{ni} ، $i = 1, 2$ دالتين مستمرتين، عندما $\mu_2 > 0$ ، في عزوم العينة (راجع العلاقة (8.5.3))، وبالتالي حسب المبرهنة (2.14.3) فإن $\Gamma_{n2} \rightarrow \Gamma_{n1}$ يتقاربان بالاحتمال إلى الميزين النظريين الموافقين لهما γ_2, γ_1 عندما $n \rightarrow \infty$.

2.14.3 التوزيعات التقريبية للعزوم الابتدائية للعيبة

Approximating Distribution of Sample Elementary Moments

نفترض أن العزوم المختلفة من المـرتبة r للمجتمع $\mathcal{L}(\xi)$ موجودة، وهذا ما نتخذه دائماً.

إذا كان توزيع المتغير العشوائي η_n يتقارب بالتوزيع (convergence in distribution) من توزيع المتغير العشوائي η ، عندما $n \rightarrow \infty$ ، فإننا نكتب ذلك:

$$\mathcal{L}(\eta_n) \xrightarrow{n \rightarrow \infty} \mathcal{L}(\eta) \quad \text{أو} \quad \mathcal{L}(\eta_n) \xrightarrow{n \rightarrow \infty} \mathcal{L}(\eta)$$

وفيما يلي، إذا كان المتغير العشوائي η_n يتقارب من التوزيع الطبيعي بالمعلمتين μ_n^*, σ_n^{*2} عندما $n \rightarrow \infty$ ، أي له التوزيع الحدي $N(\mu_n^*, \sigma_n^{*2})$ فنعتبر عن ذلك:

$$\mathcal{L}(\eta_n) \xrightarrow{n \rightarrow \infty} N(\mu_n^*, \sigma_n^{*2})$$

وهذا يعني:

$$\mathcal{L}\left(\frac{\eta_n - \mu_n^*}{\sigma_n^*}\right) \xrightarrow{n \rightarrow \infty} N(0,1)$$

يعطى التوزيع الحدي للزم الابتدائي A_{nr} للعينة بالبرهنة الآتية.

مبرهنة 3.14.3

إذا كان A_{nr} العزم الابتدائي من المرتبة r لعينة عشوائية بحجم n من مجتمع $\mathcal{L}(\xi)$ عزمه الابتدائي α_r موجود (منته)، فإن التوزيع الحدي لـ A_{nr} هو $N\left(\alpha_r, \frac{\alpha_{2r} - \alpha_r^2}{n}\right)$ ، أي أن:

$$\mathcal{L}(A_{nr}) \xrightarrow{n \rightarrow \infty} N\left(\alpha_r, \frac{\alpha_{2r} - \alpha_r^2}{n}\right) \quad (3.14.3)$$

الإثبات

كما نعلم A_{nr} عبارة عن متوسط n من المتغيرات العشوائية X_i^r ، $i = 1, \dots, n$ المستقلة متنى متنى ولها نفس التوزيع، وهو توزيع ξ^r ، إذن، حسب مبرهنة النهاية المركزية، فإن:

$$\mathcal{L}(A_{nr}) \xrightarrow{n \rightarrow \infty} N\left(\alpha_r, \frac{\alpha_{2r} - \alpha_r^2}{n}\right)$$

ومن ثم:

$$\mathcal{L}\left(\frac{A_{nr} - \alpha_r}{\sqrt{(\alpha_{2r} - \alpha_r^2)/n}}\right) \xrightarrow{n \rightarrow \infty} N(0,1) \quad (4.14.3)$$

وهو المطلوب.

وهذا يعني أن A_{nr} يتوزع طبيعياً بالتقارب (asymptotically normally distributed) وفق

$N\left(\alpha_r, \frac{\alpha_{2r} - \alpha_r^2}{n}\right)$ من أجل n كبيرة. ومن ثم $nA_{nr} = \sum_{i=1}^n X_i^r$

يتوزع طبيعياً بالتقارب وفق $N(n\alpha_r, n(\alpha_{2r} - \alpha_r^2))$ من أجل n كبيرة.

وكحالة خاصة، بإعطاء $r = 1$ فإن $A_{n1} = \bar{X}$ ، $nA_{nr} = \sum_{i=1}^n X_i$ ، وبالتالي فإن التوزيع التقريبي لـ \bar{X} ، $\sum_{i=1}^n X_i$ هما على الترتيب $N\left(\mu, \frac{\sigma^2}{n}\right)$ ، $N(n\mu, n\sigma^2)$.

نلاحظ أن المبرهنة (3.14.3) لا تشترط توزيعاً معيناً للمجتمع الذي سحبت منه العينة العشوائية $X = (X_1, \dots, X_n)$ ، وبعبارة أخرى، بغض النظر عن توزيع المجتمع فإن كلاً من المتغيرين العشوائيين A_{nr} و nA_{nr} يتوزع طبيعياً بالتقارب وفق $N\left(\alpha_r, \frac{\alpha_{2r} - \alpha_r^2}{n}\right)$ و $N(n\alpha_r, n(\alpha_{2r} - \alpha_r^2))$ على الترتيب.

نتيجة 1.14.3

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع ذي الحدين $B(n, p)$ ، فإن كلاً من \bar{X} و $\sum_{i=1}^n X_i$ يتوزع طبيعياً بالتقارب وفق $N(n^2 p, n^2 pq)$ و $N(np, pq)$ على الترتيب.

تمكنا المبرهنة (3.14.3) من تقدير (في حالة عينات كبيرة) احتمال إنحراف عزم العينة A_{nr} عن العزم النظري الموافق α_r .

$$P\left(\sqrt{\frac{n}{\alpha_{2r} - \alpha_r^2}} |A_{nr} - \alpha_r| < t\right) \approx \frac{1}{\sqrt{2\pi}} \int_{-t}^t e^{-\frac{1}{2}z^2} dz = 2\Phi(t) - 1 \quad (5.14.3)$$

حيث إن $\Phi(t)$ دالة التوزيع الطبيعي المعياري $N(0,1)$.

3.14.3 التوزيع التقريبي لـ $F_n^*(x)$

رأينا في البند (12.3) أن دالة التوزيع التحريبي $F_n^*(x)$ عبارة عن إحصاء، عند كل قيمة حقيقية معينة x ، وتخضع لتوزيع ذي الحدين $B(n, F(x))$. وعندما تكون n كبيرة (نتيجة 1.14.3) فإن:

$$B(n, F(x)) \approx N\left\{F(x), \frac{1}{n}F(x)[1 - F(x)]\right\} \quad (6.14.3)$$

أي أن:

$$\mathcal{L}\{\sqrt{n}[F_n^*(x) - F(x)]\} \approx N[0, F(x)(1 - F(x))]$$

وإذا كنا نرغب في تقدير $F(x)$ لكل x (بدلاً من قيمة حقيقية معينة x)، فيجب دراسة السلوك التقاربي لـ $F_n^*(x)$ من $F(x)$ لجميع قيم x .

مبرهنة 4.14.3

إذا كانت $F(x)$ و $F_n^*(x)$ دالتي التوزيع التحريبي والنظري للمتغير العشوائي ξ ، فإن:

$$\lim_{n \rightarrow \infty} P(|F_n^*(x) - F(x)| < \varepsilon) = 1 \quad (7.14.3)$$

مهما تكن $-\infty < x < +\infty$ و $\varepsilon > 0$.

الإثبات

بما أن $F_n^*(x)$ عبارة عن التكرار النسبي لظهور الحادث $\{\xi < x\}$ في n تكرار مستقل، واحتمال الظهور في كل تكرار ثابت يساوي $F(x)$ ، فحسب قانون الأعداد الكبيرة الضعيف بصيغة بيرنولي [مبرهنة (2.4.1)]:

$$F_n^*(x) \xrightarrow{P} F(x)$$

أي أن العلاقة (7.14.3) محققة.

وتعني المبرهنة (7.14.3) أن $F_n^*(x)$ يتقارب بالاحتمال وبانتظام في x من $F(x)$ ، عندما $n \rightarrow \infty$ ، ومن ثم عندما تكون n كبيرة فإن:

$$F_n^*(x) \approx F(x)$$

لجميع قيم x .

وبناءً على ذلك يمكن اعتبار $F_n^*(x)$ كمقدّر لـ $F(x)$ ، يتقارب بالاحتمال من $F(x)$ لجميع قيم x .

مبرهنة 5.14.3: مبرهنة كليفيونكو Klevenco Theorem

بناءً على شروط المبرهنة السابقة، فإن:

$$P\left(\lim_{n \rightarrow \infty} \sup_{-\infty < x < \infty} |F_n^*(x) - F(x)| = 0\right) = 1 \quad (8.14.3)$$

وتنص على أنه باحتمال يساوي الواحد فإن $F_n^*(x)$ تتقارب بانتظام في x من $F(x)$ ، وهذا يعني أن $F_n^*(x)$ ، كمقدّر لـ $F(x)$ ، يتقارب من $F(x)$ بانتظام لجميع قيم x وذلك باحتمال يساوي الواحد، وبعبارة أخرى يكون الفرق $|F_n^*(x) - F(x)|$ صغيراً بقدر ما نريد (من أجل كل قيمة لـ x) باحتمال يساوي الواحد، عندما يكون حجم العينة كبيراً.

وإذا رمزنا بـ:

$$D_n = D_n(X) = \sup_{-\infty < x < \infty} |F_n^*(x) - F(x)| \quad (9.14.3)$$

فإن D_n متغير عشوائي منقطع يقيس الانحراف الأعظم للدالة $F_n^*(x)$ عن الدالة $F(x)$ على كامل محور الأعداد الحقيقية، ومن ثم يمكن كتابة العلاقة (8.14.3) على الصورة:

$$P\left(\lim_{n \rightarrow \infty} D_n = 0\right) = 1 \quad (10.14.3)$$

مبرهنة 6.14.3: مبرهنة كالماغوروف Kolmagorov Theorem

إذا كان المتغير العشوائي الملاحظ Z مستمراً، دالة توزيعه $F(x)$ ، فمن أجل أي قيمة حقيقية معينة $z > 0$ تحقق العلاقة الآتية:

$$\lim_{n \rightarrow \infty} P\left(D_n < \frac{z}{\sqrt{n}}\right) = K(z) = 1 - 2 \sum_{j=1}^{\infty} (-1)^{j-1} e^{-2j^2 z^2} \approx 1 - 2e^{-2z^2} \quad (11.14.3)$$

وعندما تكون n كبيرة ($n \geq 20$) فإن:

$$P\left(D_n < \frac{z}{\sqrt{n}}\right) \approx K(z) \approx 1 - 2e^{-2z^2} \quad (12.14.3)$$

أو:

$$P\left(D_n \geq \frac{z}{\sqrt{n}}\right) \approx 2e^{-2z^2}$$

وهذا يعني أنه يمكن استخدام التوزيع $K(z)$ كتقريب جيد لـ $P\left(D_n < \frac{z}{\sqrt{n}}\right)$ في التطبيقات الإحصائية وذلك عندما تكون $n \geq 20$.

تستخدم مبرهنة كالمغوروف لإيجاد الحدين (القيمتين) اللذين تقع بينهما دالة التوزيع $F(x)$ ، عندما تكون هذه الأخيرة غير معلومة، وذلك باحتمال معين $\alpha \in (0,1)$ ، حيث إن:

$$P\left(D_n < \frac{z_\alpha}{\sqrt{n}}\right) = P\left(F_n^*(n) - \frac{z_\alpha}{\sqrt{n}} < F(x) < F_n^*(n) + \frac{z_\alpha}{\sqrt{n}}\right) ; \quad \forall x \in R$$

وعندما تكون $n \geq 20$ فإن z_α تعين من المساواة:

$$K(z) = \alpha$$

هكذا، عندما تكون $n \geq 20$ ، فإن المتباينة:

$$F_n^*(n) - \frac{z_\alpha}{\sqrt{n}} < F(x) < F_n^*(n) + \frac{z_\alpha}{\sqrt{n}} ; \quad \forall x \in R \quad (13.14.3)$$

محققة باحتمال يساوي α تقريباً، لكن $0 \leq F(x) \leq 1$ ، وبالتالي يمكن كتابة المتباينة (13.14.3) على النحو الآتي:

$$\max\left(0, F_n^*(x) - \frac{z_\alpha}{\sqrt{n}}\right) < F(x) < \min\left(1, F_n^*(x) + \frac{z_\alpha}{\sqrt{n}}\right)$$

تكمن أهمية الإحصاء $D_n(X)$ في أن توزيعه مستقل عن توزيع المجتمع الذي سحبت منه العينة X ، أي أن D_n حر التوزيع، ويمكن إثبات ذلك

على النحو الآتي:

إذا رمزنا بـ $u = F(x)$ فإن $x = F^{-1}(u)$ وبالتعويض في (9.14.3)، نجد:

$$D_n = \sup_{0 < u < 1} |F_n^*[F^{-1}(u)] - u|$$

وبالانتقال إلى المتغيرات العشوائية:

$$U_i = F(X_i) \quad ; \quad i = 1, \dots, n$$

$$U_{(1)} \leq U_{(2)} \leq \dots \leq U_{(n)} \quad ; \quad U_{(i)} = F(X_{(i)}) \quad , \quad i = 1, \dots, n$$

الإحصاءات المرتبة للعينة (U_1, \dots, U_n) . وملاحظة أن المتباينة $X_{(i)} \leq x$ مكافئة للمتباينة $U_{(i)} \leq u$ وبالتعويض في العلاقة (3.4.3)، نجد:

$$F_n^*[F^{-1}(u)] = \frac{1}{n} \sum_{i=1}^n e(x - x_{(i)}) = \frac{1}{n} \sum_{i=1}^n e(u - u_i) = \Phi_n^*(u) \quad (14.14.3)$$

يعني هذا أن الدالة $F_n^*(x)$ لا تعتمد على الدالة $F(x)$ ، وكما نعلم أن توزيع $U_i = F(X_i)$ هو التوزيع المنتظم $R(0,1)$ و $\Phi_n^*(u)$ دالة التوزيع التجريبي الموافقة للعينة الملاحظة $u = (u_1, \dots, u_n)$ المأخوذة من التوزيع $R(0,1)$ ، وعلى ذلك فإن $D_n(X)$ يطابق $\sup_{0 \leq u \leq 1} |\Phi_n^*(u) - u|$ ، ومن ثم توزيع D_n مستقل عن $F(x)$ (لا يعتمد على توزيع المجتمع الأساسي). وهذه الخاصة لها أهمية كبيرة، حيث يكفي حساب وجدولة توزيع D_n مرة واحدة من أجل عينات عشوائية مأخوذة من التوزيع $R(0,1)$. بناءً على ذلك وعلى التوزيع المقارب $K(z)$ تم بناء جدول اختبار كالماغوروف، الذي يعطي القيم الحرجة λ الموافقة لكل من الاحتمال α وحجم العينة n ، بحيث:

$$P(D_n \geq \lambda) = \alpha$$

وعندما تكون n كبيرة، فإن:

$$P\left(D_n \geq \frac{z}{\sqrt{n}}\right) \approx 2e^{-2z^2}$$

ومنها:

$$P\left(D_n \geq \frac{z}{\sqrt{n}}\right) = \alpha \Rightarrow \alpha \approx 2e^{-2z^2}$$

وبأخذ لوغاريتم الطرفين، نجد:

$$z_\alpha \approx \sqrt{-\frac{1}{2} \ln \frac{\alpha}{2}}$$

وهذا يعني، عندما تكون n كبيرة فإن الحد الحرج λ_α يعين من الصيغة التقريبية:

$$\lambda_\alpha = \frac{z_\alpha}{\sqrt{n}} \approx \sqrt{-\frac{1}{2} \ln \frac{\alpha}{2}} \quad (15.14.3)$$

بالإضافة إلى ماسبق، فإن خاصية حر التوزيع لـ D_n ، أدت إلى استخدام واسع لهذا الإحصاء في التطبيقات الإحصائية، وخاصة في مجال الاستدلال الإحصائي اللامعلمي.

مبرهنة 7.14.3: مبرهنة سميرنوف Smirnov Theorem

إذا كانت $F_{1n}^*(x)$ ، $F_{2n}^*(x)$ دالتي التوزيع التجريبي للمتغير العشوائي المستمر X الموافقتين لعينتين عشوائيتين بحجم n_1 ، n_2 على الترتيب، والمأخوذتين من توزيع $F(x)$ ، وكان:

$$D_{n_1 n_2} = \sup_{-\infty < x < \infty} |F_{1n_1}^*(x) - F_{2n_1}^*(x)|$$

فإن:

$$\lim_{n_1, n_2 \rightarrow \infty} P\left(\sqrt{n_1 n_2 / (n_1 + n_2)} D_{n_1 n_2} < z\right) = K(z) \quad (26.14.3)$$

من أجل أي عدد حقيقي $z > 0$ ، حيث إن الدالة $K(z)$ معرفة بالعلاقة (12.14.3)، وهذه المبرهنة استخدام هام في اختبار الفرضيات.

4.14.3 التوزيع المقارب لوسيط العينة

Asymptotic Distribution of Sample Median

وجدنا في الفقرة (1.11.3) التوزيع الاحتمالي لوسيط عينة عشوائية $X = (X_1, \dots, X_n)$ مأخوذة من توزيع مستمر $F(x)$. وذلك عندما يكون حجم العينة n صغيراً أو كبيراً. سنبحث في هذه الفقرة عن التوزيع التقريبي لوسيط عينة عشوائية كبيرة الحجم.

كما نعلم، إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر $F(x)$ ، فإن $U_i = F(X_i)$ ؛ $i = 1, \dots, n$ عينة عشوائية من توزيع منتظم $R(0,1)$ ، وإذا كانت $Y_i = X_{(i)}$ ؛ $i = 1, \dots, n$ العينة المرتبة الموافقة لـ X ، فإن $U_{(i)} = F(Y_i)$ ؛ $i = 1, \dots, n$ العينة المرتبة الموافقة لـ (U_1, \dots, U_n) وأن توزيع الإحصاء $U_{(i)}$ هو:

$$h_i(u) = \frac{\Gamma(n+1)}{\Gamma(i)\Gamma(n-i+1)} u^{i-1} (1-u)^{n-i} \quad , \quad 0 < u < 1$$

وقيمته المتوقعة وتباينه:

$$E(U_{(i)}) = \frac{i}{n+1} \quad , \quad V(U_{(i)}) = \frac{i(n-i+1)}{(n+2)(n+1)^2}$$

ومن ثم بافتراض حجم العينة فردي $(n = 2m + 1)$ ، فإن القيمة المتوقعة والتباين لوسيط عينة عشوائية (U_1, \dots, U_n) مسحوبة من توزيع منتظم $R(0,1)$ هما (بوضع $i = m + 1$):

$$E(\tilde{U}) = \frac{1}{2} \quad , \quad V(\tilde{U}) = \frac{1}{4(n+2)} \quad (13.14.3)$$

ومن أجل n كبيرة:

$$V(\tilde{U}) \approx \frac{1}{4n}$$

وبناءً على البرهنة الآتية: إذا كان X متغيراً عشوائياً بمتوسط μ وتباين σ^2 ، وكانت $Y = g(X)$ دالة ما في X ، فيمكن الحصول على $E(Y)$ و $V(Y)$ تقريباً وفق العلاقتين:

$$EY \cong g(\mu) + \frac{1}{2}\sigma^2 g''(\mu) \quad (14.14.3)$$

$$VY \cong \sigma^2 [g'(\mu)]^2$$

يمكن إيجاد قيمة تقريبية لكل من القيمة المتوقعة والتباين للإحصاء Y_i باستخدام العلاقة بين Y_i و $U_{(i)}$ على النحو الآتي:

$$U_{(i)} = F(Y_i) \Rightarrow Y_i = F^{-1}(U_{(i)})$$

ومن ثم:

$$E(Y_i) \approx F^{-1}[EU_{(i)}] = F^{-1}\left(\frac{i}{n+1}\right)$$

$$V(Y_i) \approx \frac{i(n-i+1)}{(n+2)(n+1)^2} \frac{1}{\left\{f\left[F^{-1}\left(\frac{i}{n+1}\right)\right]\right\}^2}$$

وبوضع $i = m+1$ نجد:

$$E\tilde{X} \approx F^{-1}\left(\frac{1}{2}\right) = \tilde{\mu}$$

$$V\tilde{X} \approx \frac{1}{4(n+2)} \frac{1}{\left\{f\left[F^{-1}\left(\frac{1}{2}\right)\right]\right\}^2}$$

$$= \frac{1}{4(n+2)} \frac{1}{f^2(\tilde{\mu})} \approx \frac{1}{4nf^2(\tilde{\mu})}$$

عندما تكون n كبيرة. وهذا يعني أن وسيط العينة تقدير غير متحيز تقريباً لوسيط المجتمع $\tilde{\mu}$.

مبرهنة

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه الاحتمالية $f(x)$ ودالة توزيعه $F(x)$ ، فإن وسيط هذه العينة \tilde{X} يتوزع تقريباً وفق التوزيع الطبيعي، بمتوسط $E\tilde{X} = \tilde{\mu}$ وتباين $V\tilde{X} = \frac{1}{4nf^2(\tilde{\mu})}$ ، عندما تكون n كبيرة. أي أن:

$$\mathcal{L}(\tilde{X}) \approx N\left(\tilde{\mu}, \frac{1}{4nf^2(\tilde{\mu})}\right)$$

ومن ثم:

$$\mathcal{L}\left[2\sqrt{nf}(\tilde{\mu})(\tilde{X} - \tilde{\mu})\right] \approx N(0,1)$$

تمارين

1. إذا كان ξ متغيراً عشوائياً يصف درجات الطلاب في مقرر ما (حيث الدرجة من 100)، وأخذت 18 ملاحظة مستقلة، فكانت على النحو الآتي:
81 ، 57 ، 59 ، 56 ، 72 ، 68 ، 46 ، 54 ، 42 ، 82 ، 87 ، 82 ،
85 ، 82 ، 66 ، 60 ، 82 ، 59
المطلوب:

 1. بناء جدول التوزيع التكراري لدرجات الطلاب.
 2. إيجاد دالة التوزيع التجريبي لـ ξ الموافقة للعينة الملاحظة.
 3. رسم المدرج التكراري للتوزيع التجريبي لدرجات الطلاب.

2. ليكن لدينا التوزيع التجريبي لمتغير عشوائي مستمر كما هو مبين في الجدول

الآتي:

جدول التوزيع التجريبي لـ ξ

| القيم الملاحظة x | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
|------------------------|-----|------|------|------|------|------|------|
| التكرار النسبي n_i/n | 0.5 | 0.10 | 0.15 | 0.30 | 0.20 | 0.15 | 0.05 |

المطلوب:

1. إيجاد دالة التوزيع التجريبي لـ ξ .

2. رسم المدرج والمضلع للتوزيع التجريبي لـ ξ .

3. ما هو نوع توزيع ξ الذي تستقره من شكل المدرج أو المضلع التكراري؟

3. إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع توزيع $f(x, \theta)$ ، فبين أي من الدوال الآتية يمثل إحصاء:

$$T_1 = \sum X_i + \theta, \quad T_2 = \frac{X_1 + X_2}{2}, \quad T_3 = \prod_{i=1}^n \frac{X_i}{\theta^2}$$

$$T_4 = \sum_{i=1}^{n-1} \ln X_i, \quad T_5 = e^{\theta X_i}, \quad T_6 = \frac{X_1 \cdot X_2}{X_n}$$

4. إذا كانت $\mathbf{X} = (X_1, X_2, X_3)$ عينة عشوائية من التوزيع المنتظم $R(0,1)$ ، فأوجد توزيع كل من المتغيرين:

$$\frac{X_1 + X_2}{2}, \quad \bar{X}$$

5. إذا كانت $\mathbf{X} = (X_1, X_2)$ عينة عشوائية من التوزيع $N(0,1)$ ، فأوجد:

$$1. \text{ توزيع } \frac{X_2 - X_1}{\sqrt{2}}$$

2. توزيع $\frac{(X_1 + X_2)^2}{(X_1 - X_2)^2}$

3. توزيع $\frac{(X_1 + X_2)}{\sqrt{(X_1 - X_2)^2}}$

4. توزيع $\frac{X_2^2}{X_1^2}$

6. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(0,1)$ ، أوجد:

1. توزيع $\frac{(\bar{X}_k + \bar{X}_{n-k})}{2}$; $k < n$

2. توزيع $k\bar{X}_k^2 + (n-k)\bar{X}_{n-k}^2$; $k < n$

3. توزيع $\frac{X_1}{X_n}$

7. إذا كانت $X = (X_1, X_2)$ و $Y = (Y_1, Y_2)$ عينتين عشوائيتين مستقلتين

من التوزيع $N(0,1)$ و $N(1,1)$ على الترتيب، فأوجد:

1. توزيع $\bar{X} + \bar{Y}$

2. $(Y_1 - Y_2) / \sqrt{[(X_2 - X_1)^2 + (Y_1 - Y_2)^2]} / 2$

3. $(2\bar{X} - 2)^2 / (X_2 - X_1)^2$

8. لتكن $\mathcal{L}(X_i) = N(i, i^2)$; $i = 1, 2, 3$ و متغيرات عشوائية

مستقلة متنى متنى:

1. أعط مثلاً لإحصاء يتبع توزيع χ^2 بثلاث درجات حرية.

2. أعط مثلاً لإحصاء يتبع توزيع $F_{1,2}$.

3. أعط مثلاً لإحصاء يتبع توزيع $S(2)$.

9. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع المنتظم $R(-2, 2)$ ، فأوجد:

1. توزيع كل من المتغيرين $X_{(1)}$ و $X_{(n)}$.
2. التوزيع المشترك لـ $X_{(1)}$ و $X_{(2)}$.
3. توزيع وسيط العينة \tilde{X} بافتراض أن n عدد فردي.

10. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\mathcal{L}(\xi) \in \Gamma(1, \theta)$ ، فأوجد:

1. التوزيع الاحتمالي لـ $X = (X_1, \dots, X_n)$.
 2. التوزيع الاحتمالي لـ $(X_{(1)}, \dots, X_{(n)})$.
 3. التوزيع الاحتمالي لكل من المتغيرين $X_{(1)}$ و $X_{(n)}$ ثم احسب متوسط وتباين كل منهما.
 4. التوزيع الاحتمالي لكل من المدى $R = X_{(n)} - X_{(1)}$ ونصف المدى T .
11. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $R(-3, 3)$ فأوجد متوسط وتباين كل من المتغيرات الآتية:

$$\frac{X_{(1)} + X_{(3)}}{2} , \quad X_{(n)} - X_{(1)} , \quad X_{(k+1)} ; \quad n = 2k + 1$$

12. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع:

$$f(x) = 2e^{-2(x-3)} ; \quad x \geq 3$$

فأوجد:

1. التوزيع الاحتمالي لـ $X_{(n)} - X_{(1)}$.
2. التوزيع الاحتمالي لوسيط العينة \tilde{X} .

3. التوزيع الاحتمالي لـ $R = X_{(n)} - X_{(1)}$.

13. إذا كانت $X = (X_1, X_2)$ عينة عشوائية من التوزيع الأسّي:

$$f(x) = \frac{1}{2} e^{-\frac{1}{2}x} ; \quad x > 0$$

فأوجد توزيع X_1/X_2 .

14. إذا كانت $X = (X_1, X_2)$ عينة عشوائية من التوزيع المنتظم $R(0,1)$ ،

وكانت $Y = (Y_1, Y_2)$ العينة المرتبة الموافقة لـ X ، فأوجد التوزيع الشرطي لـ

Y_2 بفرض $Y_1 = y_1$.

15. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع المنتظم

Y_1, \dots, Y_n وكانت $R(a - \sqrt{3}b, a + \sqrt{3}b)$ ، حيث a, b ثوابت حقيقية، وكانت

الإحصاءات المرتبة الموافقة لـ X ، فأوجد:

1. متوسط وتباين $Y_2 - Y_1$.

2. متوسط وتباين $\frac{Y_1 + Y_2}{2}$.

3. توزيع وسيط العينة \tilde{X} .

16. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $F(x)$ ، وكانت

العزوم المركزية (حول المتوسط) من المرتبة $2r$ لهذا التوزيع موجودة، فأثبت

أن:

$$VM_{nr} = \frac{1}{n} \left[\mu_{2r} - \mu_r^2 - r(r-1)\mu_2\mu_{r-2} + r\mu_{r-2}(r\mu_2\mu_{r-1}) - 2\mu_{r+1} \right] + 0 \left(\frac{1}{n^2} \right)$$

17. إذا كانت $X = (X_1, \dots, X_{n_1})$ و $Y = (Y_1, \dots, Y_{n_2})$ عينتين عشوائيتين مستقلتين

مأخوذتان من التوزيعين $N(\mu_1, \sigma^2)$ و $N(\mu_2, \sigma^2)$ على الترتيب، فأثبت أن توزيع

$$\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right) \left(\frac{(n_1 - 1)S_1^{*2} + (n_2 - 1)S_2^{*2}}{n_1 + n_2 - 2}\right)}}$$

يتبع توزيع $S(n-2)$ ، حيث إن

$$S_2^{*2} = \frac{1}{n_2 - 1} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2 \quad \text{و} \quad S_1^{*2} = \frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2$$

18. إذا كان لدينا عينة عشوائية X بحجم $(n = 2m + 1)$ من توزيع $R(0,1)$ ، فثبت أن وسيط هذه العينة له توزيع $Be(m + 1, m + 1)$.

19. إذا كانت (X_1, \dots, X_n) عينة عشوائية من توزيع مستمر $F(x)$ ، وكانت $D_n = \sup_x |F_n^*(x) - F(x)|$ ، فأوجد توزيع المتغير العشوائي المنقطع D_n عندما $n = 3$ ، $n = 5$.

20. ليكن ξ متغيراً عشوائياً يتبع التوزيع الأسّي:

$$f(x) = \frac{1}{3} e^{-\frac{x}{3}} ; \quad x > 0$$

سحبت عينة عشوائية بحجم $n = 10$ من هذا التوزيع فكانت على النحو الآتي:

$$1, 3, 5, 0.2, 4, 0.5, 0.6, 2.2, 0.3, 3$$

$$. D_n = \sup_x |F_n^*(x) - F(x)| \text{ أوجد قيمة الإحصاء}$$

21. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر دالة توزيعه:

$$F(x) = 1 - e^{-0.5x} ; \quad x > 0$$

فأوجد دالة الكثافة الاحتمالية للمتغيرات العشوائية الآتية:

1. \tilde{X} ، \bar{X} .

2. $F(Y_j)$ ، $1 - F(Y_j)$.

3. $F(Y_n) - F(Y_1)$ ، $F(Y_2) - F(Y_1)$.

4. $F(Y_n) - F(Y_1) + F(Y_2) - F(Y_1)$.

حيث إن $Y_i = X_{(i)}$; $i = \overline{1, n}$

22. إذا كانت $\bar{X} = (X_1, \dots, X_{10})$ عينة عشوائية من التوزيع $\mathcal{L}(\xi) = N(0,1)$ فأوجد:

1. توزيع $Y_{10} = X_{(10)}$.

2. $P(Y_3 < \xi < Y_4)$ ، حيث إن $Y_i = X_{(i)}$; $i = \overline{1, 10}$.

3. التوقع الرياضي للمتغير العشوائي $Y_1 - Y_{10}$.

23. إذا كانت $\mathbf{X} = (X_1, \dots, X_{10})$ و $\mathbf{Y} = (Y_1, \dots, Y_{25})$ عينتين عشوائيتين مستقلتين من التوزيع الطبيعي $N(150, 28.6)$ ، فعين:

$$E(\bar{X} - \bar{Y}) \quad , \quad \text{var}(\bar{X} - \bar{Y}) \quad , \quad P(|\bar{X} - \bar{Y}| < 4)$$

24. إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0 \quad , \quad \theta > 0$$

فأوجد:

1. التوزيع المقارب لـ \bar{X}_n .

2. التوزيع المقارب لـ \tilde{X}_n .

الإحصاءات الكافية والمعلومات في العينة

1.4 مقدمة

كما نعلم أن المجتمع الإحصائي عبارة عن فئة منتهية أو غير منتهية من المفردات. وغالباً يقتصر الاهتمام على صفة مميزة أو أكثر لمفردات المجتمع الإحصائي، ويعبر عن الصفة المميزة قيد الدراسة بمتغير عشوائي حقيقي ξ . وأن لكل متغير عشوائي ξ توزيع احتمالي، وكل توزيع احتمالي له مميزاته العددية (معامله)، التي تعبر عن الخصائص الجوهرية لهذا التوزيع، ويمكن تعيين تلك المعالم المختلفة بناءً على معرفة التوزيع الاحتمالي وذلك باستخدام قوانين نظرية الاحتمالات. لكن في مسائل الإحصاء عادة توزيع المتغير العشوائي ξ غير معلوم، وفي حالات عدة يمكن معرفة عائلة التوزيعات التي ينتمي إليها التوزيع الاحتمالي لـ ξ ، أي معرفة النموذج الاحتمالي الإحصائي (النموذج الإحصائي) له، وهذا الأخير يعتمد على معلمة θ (وحيدة البعد أو متعددة الأبعاد) غير معلومة. وهدف الإحصائي أن يعرف قيمتها، ومن ثم يتعين توزيع ξ تماماً. ليس من اليسير معرفة القيمة الحقيقية لـ θ الموافقة لتوزيع ξ ، حيث هذا يتطلب معرفة قيمة ξ عند كل مفردات المجتمع الإحصائي، ولأسباب عدة (قد تكون: فساد عناصر المجتمع الإحصائي، تعذر الوصول إلى جميع عناصر المجتمع الإحصائي، التكاليف الباهظة، الجهد الكبير اللازم، ... الخ) يتعذر ذلك. وعندئذ نلجأ إلى أخذ عينة عشوائية $X = (X_1, \dots, X_n)$ من توزيع ξ (حيث كما أشرنا سابقاً تقتصر على المجتمعات

الإحصائية غير المنتهية أو المنتهية لكن المعاينة بالإرجاع)، وبناءً على معطيات العينة العشوائية X نقوم بتقدير القيمة الحقيقية لـ θ . ويتطلب التقدير عادة إيجاد الدالة المناسبة في عناصر العينة (الإحصاء $T = T(X)$) التي تدعى بمقدر θ ، وقيمتها عند عينة مشاهدة $x = (x_1, \dots, x_n)$ تدعى تقديراً للقيمة الحقيقية لـ θ الموافقة لتوزيع ξ . وبعبارة أخرى نبحث عن تكثيف مناسب للمعطيات المتوفرة في العينة X حول المعلمة θ . لهذا نطمح في أن يشتمل الإحصاء $T = T(X)$ على كافة المعلومات المتوفرة في العينة العشوائية X حول المعلمة θ ، أي لا تؤدي عملية التكثيف هذه إلى خسارة في المعلومات (loss of information) المتوفرة في العينة العشوائية X حول المعلمة θ . إذا وجد مثل هذا الإحصاء $T = T(X)$ ، فيدعى بالإحصاء الكافي (sufficient statistic) للمعلمة θ أو التوزيع $f(x; \theta)$ للمتغير العشوائي ξ .

نلاحظ إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع ξ ، فإن كل المعلومات المتوفرة لدينا حول المعلمة θ تقتصر على معطيات هذه العينة، ولذلك عندما نقول إن $T = T(X)$ إحصاء كافي لـ θ ، فهذا يعني أن الإحصاء $T(X)$ امتص أو احتوى على كافة المعلومات المتوفرة في العينة $x = (x_1, \dots, x_n)$ حول المعلمة θ ، وبشكل عام يقال: إن كل المعلومات المتوفرة في العينة العشوائية X حول المعالم المختلفة لـ ξ يمكن تكثيفها بإحصاءات كافية. لكن، بما أن معرفة قيمة θ في $f(x; \theta)$ تعين لنا تماماً التوزيع الاحتمالي الخاص بالمتغير العشوائي الملاحظ ξ ، لذلك سنقتصر البحث عن الإحصاء الكافي المناسب للمعلمة θ دون المعالم الأخرى المختلفة لـ ξ غير الواردة في صيغة التوزيع.

هكذا، يمثل الإحصاء الكافي $T = T(X)$ للمعلمة θ تكثيفاً للمتغيرات العشوائية X_i ; $i = 1, 2, \dots, n$ ، وبالتالي يعطي أسلوباً جيداً لتقديم معطيات العينة العشوائية X ، وخاصة عندما يكون حجم العينة العشوائية X كبيراً. ولذلك من المفيد البحث عن الإحصاء الكافي، الذي يقدم أكبر تكثيف ممكن للمعطيات، وبهذا المعنى يتم الحديث عن الإحصاء الكافي الأصغر (minimal)، حيث

إن المعلمة θ في $f(x; \theta)$ لها غالباً أكثر من إحصاء كافي، وهذا ما سنلاحظه لاحقاً.

2.4 الإحصاءات الكافية SUFFICIENT STATISTICS

تعريف 1.2.4: الإحصاء الكافي The Sufficient Statistic

يدعى الإحصاء $T = T(X)$ بالكافي من أجل التوزيع $f(x; \theta)$ (أو بالإحصاء الكافي من أجل المعلمة θ ، عندما يكون واضحاً عن أي نموذج يدور الحديث) إذا وفقط إذا كان التوزيع الشرطي (المشروط) للعينة العشوائية $X = (X_1, X_2, \dots, X_n)$ بافتراض $T(X) = t$ مستقلاً عن المعلمة θ ، أي إذا رمزنا بـ $f(x|t; \theta)$ لدالة الكثافة الشرطية (دالة الاحتمال الشرطي في حالة المنقطع) للمتغير العشوائي $X = (X_1, X_2, \dots, X_n)$ ، بافتراض $T(X) = t$ ، فإن:

$$f(x|t; \theta) = \frac{f(x; \theta)}{g(t; \theta)} \quad (1.2.4)$$

لا يعتمد على θ ، حيث إن:

$f(x; \theta)$ دالة كثافة أو دالة احتمال العينة العشوائية X .

$g(t; \theta)$ دالة كثافة أو دالة احتمال الإحصاء $T(X)$.

يمكن تفسير التوزيع $f(x|t; \theta)$ كتوزيع X على السطح $T(X) = t$ ، وعندما يكون $T(X)$ إحصاء كافي، فإن هذا التوزيع مستقل (لا يعتمد) عن θ . وهذا يعني أن معرفة أين تقع النقطة العشوائية (X_1, X_2, \dots, X_n) على السطح $T(X) = t$ لا تخبرنا أو تزودنا بأية معلومات إضافية حول المعلمة θ . وبعبارة أخرى، إذا علمنا قيمة الإحصاء الكافي فإننا لسنا بحاجة لقيم العينة العشوائية، لأنها لا تقدم لنا معلومات أكثر عن θ .

مثال 1.2.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من مجتمع يتبع توزيع بواسون بمعلمة θ ، فهل $T(X) = n\bar{X}$ يعتبر إحصاءاً كافياً للمعلمة θ ؟

تتطلب الإجابة على هذا السؤال إثبات أن دالة الاحتمال الشرطية $f(x|t; \theta)$ مستقلة عن θ .

$$\begin{aligned} f(x|t; \theta) &= P_\theta(X = x | t = n\bar{x}; \theta) \\ &= \frac{P_\theta(X = x, T = n\bar{x})}{P_\theta(T = n\bar{x})} = \frac{f(x_1, \dots, x_n; \theta)}{P_\theta(T = n\bar{x})} \end{aligned}$$

لأن $\{X = x\} \subseteq \{T(X) = t\}$

بما أن المتغير العشوائي الملاحظ T يخضع لتوزيع بواسون بالمعلمة θ ، فإن:

$$f(x; \theta) = \frac{\theta^x}{x!} e^{-\theta} \quad ; \quad x = 0, 1, 2, \dots$$

وعليه:

$$f(x_1, x_2, \dots, x_n; \theta) = \prod_{i=1}^n \frac{\theta^{x_i}}{x_i!} e^{-\theta} = \frac{\theta^{\sum x_i}}{\prod_1^n (x_i!)} e^{-n\theta} = \frac{\theta^{n\bar{x}}}{\prod_1^n (x_i!)} e^{-n\theta}$$

وحيث إن $T(X) = n\bar{X} = \sum_1^n X_i$ مجموع n متغير عشوائي مستقل لكل منها نفس توزيع المجتمع الذي سحبت منه العينة العشوائية، فإن T يتبع توزيع بواسون بمعلمة $n\theta$ [راجع الفقرة (3.8.3) علاقة رقم (11.8.3)]:

$$P_\theta(T = n\bar{x}) = \frac{(n\theta)^{n\bar{x}}}{(n\bar{x})!} e^{-n\theta} \quad ; \quad n\bar{x} = 0, 1, 2, \dots$$

وبالتالي:

$$f(x|t; \theta) = \frac{\theta^{n\bar{x}} e^{-n\theta}}{\prod_1^n (x_i!)} \bigg/ \left(\frac{(n\theta)^{n\bar{x}} e^{-n\theta}}{(n\bar{x})!} \right)$$

$$= \frac{(n\bar{x})!}{n^{n\bar{x}} \prod_1^n (x_i!)} = \frac{t!}{n^t \prod_1^n (x_i!)} \quad ; \quad t = n\bar{x}$$

لا يعتمد على θ ، وهذا يعني أن $T = n\bar{X}$ إحصاء كافي لـ θ . ونلاحظ أن التوزيع الشرطي $f(x|t; \theta)$ عبارة عن توزيع كثير الحدود الموافق لـ n ناتج متساوي الإمكانية، أي أن:

$$\theta = (\theta_1, \dots, \theta_n) \quad , \quad \theta_i = \frac{1}{n} \quad , \quad i = 1, 2, \dots, n$$

مثال 2.2.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \sigma^2)$ ، أي عينة عشوائية من مجتمع يتبع توزيعاً طبيعياً معلماً θ ، فهل يمكن اعتبار $T(X) = \bar{X}$ إحصاءً كافياً للمعلمة θ ؟

بما أن المتغير العشوائي X قيد الدراسة يتبع توزيعاً طبيعياً معلماً مجهولة θ ، فإن:

$$f(x, \theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\theta}{\sigma}\right)^2} \quad , \quad -\infty < x < +\infty$$

وعليه:

$$f(x, \theta) = \prod_1^n f(x_i; \theta) = \prod_1^n \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x_i-\theta)^2}{2\sigma^2}}$$

$$= \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp \left[\frac{n(\bar{x} - \theta)^2 + \sum_1^n (x_i - \bar{x})^2}{2\sigma^2} \right]$$

لأن:

$$\sum_1^n (x_i - \theta)^2 = n(\bar{x} - \theta)^2 + \sum_1^n (x_i - \bar{x})^2$$

وكما نعلم، أن متوسط عينة عشوائية مأخوذة من مجتمع طبيعي $N(\theta, \sigma^2)$ يخضع بدوره لتوزيع طبيعي $N(\theta, \sigma^2/n)$ ، أي أن:

$$g(t; \theta) = \left(\frac{\sqrt{n}}{\sigma\sqrt{2\pi}} \right) \exp \left[-\frac{n(\bar{x} - \theta)^2}{2\sigma^2} \right] ; \quad t = \bar{x}$$

لنحسب الآن التوزيع الشرطي $f(x|t; \theta)$:

$$f(x|t; \theta) = \frac{f(x|t; \theta)}{g(t; \theta)} = \frac{1}{\sqrt{n}} \left(\frac{1}{2\pi\sigma^2} \right)^{\frac{n-1}{2}} \exp \left[-\frac{\sum_1^n (x_i - \bar{x})^2}{2\sigma^2} \right]$$

وهذا خالي من المعلمة θ ، وعليه فإن $T(X) = \bar{X}$ إحصاء كافي للمعلمة θ في النموذج $N(\theta, \sigma^2)$.

مثال 3.2.4

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع دالة كثافته الاحتمالية:

$$f(x; \theta) = \theta x^{\theta-1} ; \quad 0 < x < 1$$

فأثبت أن $T(X) = -\sum_{i=1}^n \ln X_i$ إحصاء كافي للمعلمة θ .

بما أن:

$$f(x; \theta) = \prod_{i=1}^n f(x_i; \theta) = \theta^n \prod_{i=1}^n x_i^{\theta-1} = \theta^n \frac{\prod_{i=1}^n x_i^{\theta}}{\prod_{i=1}^n x_i}$$

وإذا كان المتغير العشوائي وحيد البعد X يتبع التوزيع $f(x; \theta)$ ، فإن المتغير العشوائي $Y = -\ln X = \varphi(X)$ يتبع التوزيع:

$$f_Y(y, \theta) = f_X(\varphi^{-1}(y); \theta) \left| \frac{dx}{dy} \right| = \theta e^{-\theta y} \quad ; \quad y > 0$$

وهذا ما هو إلا التوزيع الأسّي $\Gamma\left(1, \frac{1}{\theta}\right)$ ، وبالتالي [مبرهنة (4.3.2)] فإن توزيع المتغير العشوائي $T = -\sum_{i=1}^n \ln X_i$ هو عبارة عن توزيع جاما $\Gamma\left(n, \frac{1}{\theta}\right)$ ، أي أن:

$$\begin{aligned} g(t; \theta) &= \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{-\theta t} \\ &= \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{\theta \ln \prod_1^n x_i} \\ &= \frac{\theta^n}{\Gamma(n)} t^{n-1} \left(\prod_1^n x_i \right)^\theta \\ &= \frac{\theta^n}{\Gamma(n)} t^{n-1} \prod_1^n x_i^\theta \end{aligned}$$

وعلى ذلك فإن:

$$f(x|t; \theta) = \frac{f(x; \theta)}{g(t; \theta)} = \frac{\theta^n \prod_1^n x_i^\theta \Gamma(n)}{\theta^n t^{n-1} \prod_1^n x_i^\theta \left(\prod_1^n x_i \right)} = \frac{\Gamma(n)}{\left(\prod_1^n x_i \right) t^{n-1}} \quad ; \quad t = -\sum_1^n \ln x_i$$

أي أن $f(x|t; \theta)$ لا يعتمد على θ ، وبالتالي فإن $T = -\sum_1^n \ln X_i$ إحصاءاً كافياً للمعلمة θ .

مثال 4.2.4

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع $\mathcal{L}(\xi) \in R(o, \theta)$

فأثبت أن $T = X_{(n)}$ إحصاءً كافياً للمعلمة θ .

بما أن:

$$f(x; \theta) = \frac{1}{\theta} \quad ; \quad 0 < x \leq \theta$$

والتوزيع الاحتمالي للإحصاء المرتب $X_{(n)}$ [راجع العلاقة (3.10.3)] هو:

$$h(t; \theta) = n \frac{t^{n-1}}{\theta^n} \quad ; \quad 0 < t \leq \theta, \quad t = x_{(n)}$$

وعلى ذلك فإن:

$$L(x|t; \theta) = \frac{f(x; \theta)}{h(t; \theta)} = \frac{\frac{1}{\theta^n}}{\frac{nt^{n-1}}{\theta^n}} = \frac{1}{nt^{n-1}}$$

وهذا بخالي من θ ، وبالتالي فإن $T = X_{(n)}$ إحصاءً كافياً للمعلمة θ .

إن الطريقة السابقة التي تعتمد على تعريف الإحصاء الكافي (العلاقة 1.2.4)،
 تمكنا فقط من الإجابة على التساؤل التالي: هل إحصاء ما معطى $T(X)$ كافي أم
 لا؟، وهذه الطريقة شاقة وصعبة في حالات عدة، بالإضافة إلى أنها لا تقدم لنا أي
 إمكانية للحصول على إحصاء كافي.

إذا أردنا التأكد من وجود إحصاء كافي (أو التأكد من إحصاء ما أنه كافي)
 والحصول عليه، فإن المبرهنة الآتية تقدم لنا طريقة سهلة لتحقيق ذلك.

مبرهنة 1.2.4

لتكن $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $f(x; \theta)$.

إن الشرط اللازم والكافي ليكون الإحصاء $T = T(\mathbf{X})$ كافياً من أجل
 المعلمة θ هو إمكانية تحليل دالة كثافة (أو دالة احتمال) العينة العشوائية $f(x; \theta)$
 إلى مضروبين على النحو الآتي:

$$f(x; \theta) = g(t; \theta)h(x) \quad (2.2.4)$$

حيث إن:

$g(t; \theta)$: دالة كثافة (أو دالة احتمال) توزيع الإحصاء $T(X)$ ، وهي تعتمد على θ وعلى العينة X من خلال الدالة $t = T(x)$ فقط.

$h(x)$: دالة غير سالبة لا تعتمد على θ .

تدعى هذه المبرهنة بمبرهنة نيمان وفيشر (Fisher-Neyman theorem) كما تدعى بمبرهنة التحليل إلى مضاريب (factorization theorem).

الإثبات

سنقتصر على إثبات المبرهنة (1.2.4) في أهم حالتين خاصتين: المنقطع والأملس.

نورد فيما يلي الإثبات من أجل نموذج منقطع.

لتكن $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع منقطع $f(x; \theta)$.

لنفترض أن الإحصاء $T(X)$ كافي، ولنبرهن أن العلاقة (2.2.4) صحيحة.

بما أن $T(X)$ إحصاء كافي، فإن الدالة $f(x|t; \theta)$ مستقلة عن θ من أجل أي قيمة t من مجموعة قيم $T(X)$ (حسب تعريف الإحصاء الكافي)، أي يمكننا كتابة الدالة $f(x|t; \theta)$ كدالة في x ولتكن $h(x)$ ، وعندها:

$$\begin{aligned} f(x; \theta) &= P_{\theta}(X = x, T(X) = t) = \\ &= P_{\theta}(T(X) = t)P_{\theta}(X = x|T(X) = t) = g(t; \theta)f(x|t; \theta) = \\ &= g(t; \theta)h(x) \end{aligned}$$

لأن الحادث $\{X = x\} \subseteq \{T(X) = t\}$ ، أي أن العلاقة (2.2.4) محققة.

لنفترض الآن أن العلاقة (2.2.4) محققة، ولنبرهن أن $T(X)$ إحصاء كافي لـ θ . مهما تكن x ، بحيث $T(x) = t$ ، فإن:

$$f(x|t; \theta) = P_\theta(X = x | T(X) = t) = \frac{P_\theta(X = x, T(X) = t)}{P_\theta(T(X) = t)} =$$

$$= \frac{f(x; \theta)}{\sum_{x': T(x')=t} f(x'; \theta)} = \frac{g(t; \theta)h(x)}{\sum_{x': T(x')=t} g(t; \theta)h(x')} = \frac{h(x)}{\sum_{x': T(x')=t} h(x')}$$

أي أن $f(x|t; \theta)$ مستقلة عن θ وذلك مهما تكن x ، بحيث $T(x) = t$. وإذا كانت $T(x) \neq t$ فمن الواضح أن $f(x|t; \theta) = 0$. هكذا، في كل الحالات (مهما تكن x) فإن الاحتمال الشرطي $f(x|t; \theta)$ مستقل عن θ ، وبالتالي الإحصاء $T(X)$ كافي.

إن إثبات المبرهنة (1.2.4) أكثر صعوبة في حالة نموذج مستمر، لذا سنقتصر على إثباتها في حالة خاصة، وذلك عندما تكون الدالة $T(X)$ ملساء في X ، وأن المتغيرات البديلة:

$$Y_1 = T(X) \quad , \quad Y_2 = Y_2(X), \dots, Y_n = Y_n(X)$$

موجودة وقابلة للحل بالنسبة للمتغيرات X_i ; $i = 1, 2, \dots, n$ أي أن المحدد الجاكوبي $J = \left| \frac{\partial X_i}{\partial Y_i} \right| \neq 0$.

بناءً على هذه الشروط، فإن دالة الكثافة الاحتمالية للمتغير العشوائي $Y = (Y_1, Y_2, \dots, Y_n)$ يمكن إيجادها على النحو الآتي:

$$f(y; \theta) = f(x; \theta) |J| \quad ; \quad x_i = \varphi(y_1, y_2, \dots, y_n)$$

وعليه، دالة كثافة توزيع المتغير العشوائي $Y_1 = T(X)$:

$$f_1(y_1; \theta) = \int_{R^{n-1}} f(y; \theta) dy_2 dy_3 \dots dy_n = \int_{R^{n-1}} f(x; \theta) |J| dy_2 dy_3 \dots dy_n$$

وكثافة الاحتمال الشرطي لـ Y بافتراض $T(X) = t$ ، تعطى بالعلاقة:

$$f(y|t; \theta) = \frac{f(y; \theta)}{f_1(t; \theta)} = \frac{f(x; \theta) |J|}{f_1(t; \theta)} \quad ; \quad y_1 = t$$

الإحصاءات الكافية والمعلومات في العينة

بعد هذه الملاحظات التمهيديّة، فإن إثبات المبرهنة (1.2.4) يتم تماماً كما في حالة نموذج منقطع.

لنفترض أن العلاقة (2.2.4) محققة، ولنثبت أن $f(x|t; \theta)$ مستقل عن θ مهما تكن x ، بحيث $T(x) = t$.

$$\begin{aligned} f(y|t; \theta) &= \frac{f(x; \theta)|J|}{f_1(t; \theta)} = \frac{g(t; \theta)h(x)|J|}{\int_{R^{n-1}} f(x; \theta)|J| dy_2 dy_3 \dots dy_n} = \\ &= \frac{g(t; \theta)h(x)|J|}{g(t; \theta) \int_{R^{n-1}} h(x)|J| dy_2 dy_3 \dots dy_n} = \frac{h(x)|J|}{\int_{R^{n-1}} h(x)|J| dy_2 dy_3 \dots dy_n} = h^*(x)|J| \end{aligned}$$

وهذا الأخير لا يعتمد على θ ، أي أن دالة الكثافة الشرطية لـ Y بفرض $Y_1 = T(X)$ مستقلة عن θ ، أي أن $f(x|t; \theta)$ مستقلة عن θ ، وهذا يعني أن $T(X)$ إحصاء كافي للمعلمة θ .

لنفترض الآن أن الإحصاء $T(X)$ كاف لـ θ ، ولنثبت أن العلاقة (2.2.4) محققة.

بما أن:

$$f(x; \theta) = \frac{f(y|t; \theta)f_1(t; \theta)}{|J|} \quad ; \quad T(X) = t$$

وعليه:

$$f(x; \theta) = g(t; \theta)h(x)$$

حيث $g(t; \theta) = f_1(t; \theta)$ و $h(x) = \frac{f(y|t; \theta)}{|J|}$ (لأن $T(X)$ إحصاء كاف لـ θ حسب الفرض).

لنوضح تطبيق المبرهنة (1.2.4)، أي العلاقة (2.2.4)، من خلال بعض الأمثلة.

مثال 5.2.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من مجتمع يتبع توزيع بواسون بالمعلمة θ ، فأوجد إحصاءاً كافياً للمعلمة θ .
بما أن:

$$f(x; \theta) = \frac{\theta^x}{x!} e^{-\theta} \quad ; \quad x = 0, 1, \dots$$

فإن دالة الاحتمال لتوزيع العينة X :

$$f(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n \frac{\theta^{x_i}}{x_i!} e^{-\theta} = \frac{\theta^{\sum_1^n x_i}}{\prod_1^n (x_i!)} e^{-n\theta}$$

وبوضع $t = \sum_{i=1}^n x_i$ و $g(t; \theta) = e^{-n\theta} \theta^{\sum x_i}$ و $h(\mathbf{x}) = 1 / \prod_1^n (x_i!)$ يمكننا كتابة الدالة $f(\mathbf{x}; \theta)$ على النحو الآتي:

$$f(\mathbf{x}; \theta) = g(t; \theta)h(\mathbf{x})$$

أي ان العلاقة (2.2.4) محققة، ومن ثم $T(\mathbf{X}) = \sum_{i=1}^n X_i$ يعتبر إحصاءاً كافياً للمعلمة θ .

مثال 6.2.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع طبيعي $N(\theta, \sigma^2)$ فأوجد إحصاءاً كافياً للمعلمة θ .
حسب الفرض:

$$f(x; \theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\theta}{\sigma}\right)^2}, \quad -\infty < x < \infty$$

وعليه:

$$\begin{aligned} f(\mathbf{x}; \theta) &= \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x_i-\theta)^2}{2\sigma^2}} \\ &= \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2\right] \\ &= \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2\right] \exp\left[-\frac{n}{2\sigma^2} (\bar{x} - \theta)^2\right] \end{aligned}$$

وبوضع:

$$g(t; \theta) = \exp\left[-\frac{n}{2\sigma^2} (t - \theta)^2\right] \quad ; \quad t = \bar{x}$$

$$h(\mathbf{x}) = \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2\right]$$

نجد:

$$f(\mathbf{x}; \theta) = g(t; \theta)h(\mathbf{x})$$

أي أن العلاقة (2.2.4) محققة. وهذا يعني أن $T(\mathbf{X}) = \bar{X}$ إحصاء كافي لـ θ .

مثال 7.2.4

لتكن $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع كثافته:

$$f(x; \theta) = \theta x^{\theta-1} \quad , \quad 0 \leq x \leq 1$$

والمطلوب إيجاد إحصاء كافي للمعلمة θ .

كثافة توزيع العينة \mathbf{X} :

$$f(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n \theta x_i^{\theta-1} = \theta^n \left(\prod_{i=1}^n x_i\right)^{\theta} / \prod_{i=1}^n x_i$$

وبوضع:

$$g(t; \theta) = \theta^n \left(\prod_{i=1}^n x_i \right)^\theta$$

$$h(x) = 1 / \prod_{i=1}^n x_i, \quad t = \prod_{i=1}^n x_i$$

نجد:

$$f(x; \theta) = g(t; \theta)h(x)$$

أي أن العلاقة (2.2.4) محققة، وبالتالي فإن $T(X) = \prod_{i=1}^n X_i$ يكون إحصاءاً

كافياً للمعلمة θ . ولقد رأينا في المثال (3.2.4) أن $T(X) = -\ln \prod_{i=1}^n X_i$ إحصاءاً كافياً أيضاً لـ θ ، فهل هذا يعني أن هنالك تناقض؟.

نلاحظ بالعودة إلى تعريف الإحصاء الكافي والمبرهنة (1.2.4) أننا لم نذكر ما يدل على أن الإحصاء الكافي للمعلمة θ وحيد (unique) أم لا. ويمكننا القول في هذا المجال أن لكل معلمة θ أكثر من إحصاء كافي، وهذا ما تؤكدته المبرهنة التالية.

مبرهنة 2.2.4

إذا كان $T(X)$ إحصاءاً كافياً للمعلمة θ في نموذج $F(x; \theta)$ ، وكانت $U = \psi(T)$ دالة تقابلية (تناظر واحد لواحد) في T ، فإن U أيضاً إحصاء كافي للمعلمة θ والدالة $\psi(\theta)$.

يمكننا إثبات صحة هذه المبرهنة بسهولة وذلك باستبدال المتغير T بالمتغير U في العلاقة (2.2.4)، فنجد:

$$\begin{aligned} f(x; \theta) &= g(t; \theta)h(x) \\ &= g(\psi^{-1}(u); \theta)h(x) \\ &= g^*(u; \theta)h(x) \end{aligned}$$

وبالتالي يكون الإحصاء $U(X)$ إحصاءاً كافياً للمعلمة θ ، وهذا يعني غالباً أنه يوجد أكثر

من إحصاء كافي للمعلمة θ . فمثلاً، إذا كان $T = \sum_{i=1}^n X_i$ إحصاءاً كافياً للمعلمة θ ، فإن $T(X) = \ln \sum_{i=1}^n X_i$ يكون بدوره إحصاءاً كافياً لـ θ و $\tau(\theta) = \ln \theta$. وإذا كان $T(X) = \bar{X}$ إحصاءاً كافياً لـ θ ، فإن $T_1(X) = a\bar{X} + b$ يكون إحصاءاً كافياً لـ θ وللدالة المعلمية $\tau(\theta) = a\theta + b$. نترك إثبات ذلك للقارئ على سبيل المثال.

نلاحظ من خلال الأمثلة السابقة أن البحث اقتصر على إيجاد إحصاء كافي $T(X)$ وحيد البعد لمعلمة θ وحيدة البعد أيضاً، ومن ثم ربما يخلص القارئ إلى الآتي:

1. الإحصاء الكافي لمعلمة وحيدة البعد هو بدوره وحيد البعد.
2. الإحصاء الكافي يقتصر على المعامل وحيدة البعد.

لذا، لا بد من إيضاح عدم صحة ذلك التصور. فمثلاً، إذا كانت المعلمة θ ، التي نرغب في إيجاد إحصاء كافي لها وحيدة البعد، فقد لا نستطيع تلخيص أو تكييف المعلومات المتوفرة في العينة العشوائية $X = (X_1, X_2, \dots, X_n)$ المأخوذة من مجتمع دالة توزيعه $F(x; \theta)$ بإحصاء كافي وحيد البعد (إحصاء واحد) دون فقدان أو خسارة لبعض المعلومات. وبعبارة أخرى قد لا يوجد إحصاء كافي $T(X)$ وحيد البعد للمعلمة θ ، بينما يمكن وجود إحصاء كافي متعدد الأبعاد (مؤلف من مجموعة من الإحصاءات). هذا بالإضافة إلى أننا في تعريف الإحصاء الكافي والمبرهنة (1.2.4) لم نذكر أي شيء عن أبعاد المعلمة θ (وحيدة البعد أم متعددة الأبعاد)، وعليه يمكن تعميم ما سبق على حالة معلمة $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ ذات k بعد.

إذا رمزنا بـ $T(X) = (T_1, T_2, \dots, T_r)$ للإحصاء الكافي للمعلمة $\theta = (\theta_1, \theta_2, \dots, \theta_k)$ فإن $r \leq n$ يمكن أن تكون أصغر أو أكبر أو مساوية لـ k . ويمكن إيضاح ذلك من خلال بعض الأمثلة.

مثال 8.2.4

تعتبر دائماً العينة العشوائية $\mathbf{X} = (X_1, X_2, \dots, X_n)$ ، المأخوذة من مجتمع دالة توزيعه $F(x; \theta)$ ، إحصاءاً كافياً للمعلمة θ (وحيدة البعد أو متعددة الأبعاد) ، وهذا الإحصاء الكافي يدعى بالتافه لأنه لا يقدم أي تكثيف للمعلومات المتوفرة في العينة العشوائية \mathbf{X} حول المعلمة θ .

مثال 9.2.4

إذا كانت $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية من مجتمع دالة توزيعه $F(x; \theta)$ ، والإحصاءات المرتبة الموافقة لها :

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

فيكون الإحصاء $T(\mathbf{X}) = (X_{(1)}, X_{(2)}, \dots, X_{(n)})$ دائماً إحصاءاً كافياً للمعلمة θ (وحيدة البعد أو متعددة الأبعاد) ، وذلك لأن :

$$f(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i, \theta)$$

$$h(t; \theta) = n! \prod_{i=1}^n f(t_i, \theta) \quad , \quad t_1 < t_2 < \dots < t_n$$

ويكون التوزيع الشرطي للعينة \mathbf{X} بمعلومية $T(\mathbf{X}) = t$ هو :

$$f(\mathbf{x}|t; \theta) = \frac{1}{n!} \tag{3.2.4}$$

لا يعتمد على θ ، وهذا بشرط أن \mathbf{x} هي تبديلة للإحصاءات (t_1, t_2, \dots, t_n) وتعني العلاقة (3.2.4) أنه بشرط معرفة القيم المرتبة ، فإن القيمة الوحيدة التي يمكن أن تأخذها العينة \mathbf{X} هي تباديل $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ وحيث إن عدد هذه التباديل هو $n!$ فيكون لكل منها نفس الفرصة وهي $1/n!$.

مثال 10.2.4

بفرض $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع طبيعي $N = (\theta_1, \theta_2^2)$ أوجد إحصاءاً كافياً لـ $\theta = (\theta_1, \theta_2)$.
كما نعلم، دالة كثافة توزيع العينة العشوائية X هي:

$$f(x; \theta) = \prod_{i=1}^n \frac{1}{\theta_2 \sqrt{2\pi}} e^{-\frac{(x_i - \theta_1)^2}{2\theta_2^2}} = \theta_2^{-n} \exp \left[-\frac{\sum_{i=1}^n x_i^2 - 2\theta_1 n\bar{x} + n\theta_1^2}{2\theta_2^2} \right] (2\pi)^{-n/2}$$

وبوضع:

$$t = (t_1, t_2) \quad ; \quad t_1 = T_1(x) = n\bar{x} \quad , \quad t_2 = T_2(x) = \sum_{i=1}^n x_i^2$$

يمكن كتابة الدالة $f(x; \theta)$ على الشكل:

$$f(x; \theta) = g(t; \theta)h(x)$$

حيث:

$$f(t; \theta) = \theta_2^{-n} \exp \left[-\frac{t_2 - 2\theta_1 t_1 + \theta_1^2}{2\theta_2^2} \right]$$

$$h(x) = (2\pi)^{-n/2}$$

وهذا يعني حسب المبرهنة (1.2.4) أن الإحصاء:

$$T = (T_1, T_2) \quad ; \quad T_1(X) = n\bar{X} \quad , \quad T_2(X) = \sum_{i=1}^n X_i^2$$

هو إحصاء كافي للمعلمة $\theta = (\theta_1, \theta_2)$. هنا بالإمكان ضم المضروب $(2\pi)^{-n/2}$ إلى الدالة g ووضع $h(x) = 1$. وبشكل مشابه، يمكن إثبات أن الإحصاء:

$$T = (T_1, T_2) \quad ; \quad T_1(X) = \bar{X} \quad , \quad T_2(X) = \sum_{i=1}^n (X_i - \bar{X})^2$$

هو أيضاً إحصاء كاف للمعلمة $\theta = (\theta_1, \theta_2)$

$$\begin{aligned} f(x; \theta) &= \theta_2^{-n} \exp \left[-\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{2\theta_2^2} - \frac{n(\bar{x} - \theta_1)^2}{2\theta_2^2} \right] (2\pi)^{-n/2} \\ &= \theta_2^{-n} \exp \left[-\frac{t_2}{2\theta_2^2} - \frac{n(t_1 - \theta_1)^2}{2\theta_2^2} \right] (2\pi)^{-n/2} \\ &= g(t; \theta)h(x) \end{aligned}$$

حيث:

$$g(t; \theta) = \theta_2^{-n} \exp \left[-\frac{t_2}{2\theta_2^2} - \frac{n(t_1 - \theta_1)^2}{2\theta_2^2} \right]$$

$$h(x) = (2\pi)^{-n/2}$$

هكذا، من كل المعلومات المتوفرة في العينة العشوائية $X = (X_1, X_2, \dots, X_n)$ حول

المعلمة θ يكفيننا معرفة \bar{X} و $\sum_{i=1}^n X_i^2$.

مثال 11.2.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع منتظم $R(0, \theta)$ ، فالمطلوب

إيجاد إحصاء كاف للمعلمة θ .

كما نعلم كثافة التوزيع المنتظم بالمعلمة θ .

$$f(x; \theta) = \begin{cases} 1/\theta & ; 0 < x \leq \theta \\ 0 & ; x \leq 0 \text{ or } x > \theta \end{cases}$$

وعليه كثافة توزيع العينة العشوائية X :

$$f(x; \theta) = \begin{cases} 1/\theta^n & ; 0 < x_i \leq \theta ; i = 1, 2, \dots, n \\ 0 & ; x_i \leq 0 \text{ or } x_i > \theta \end{cases}$$

إذا رمزنا بـ $x_{(1)} = \min x_i$ و $x_{(n)} = \max x_i$ فيمكننا كتابة دالة الكثافة $f(x; \theta)$ كدالة في θ على النحو الآتي:

$$f(x; \theta) = \begin{cases} 1/\theta^n & , \theta \geq x_{(n)} \\ 0 & , \theta < x_{(n)} \end{cases}$$

أو على الشكل:

$$f(x; \theta) = \frac{e^{(\theta - x_{(n)})}}{\theta^n}$$

حيث $e(x)$ دالة خوفسييد.

وبوضع:

$$h(x) = 1 \quad , \quad g(t; \theta) = \frac{e^{(\theta - x_{(n)})}}{\theta^n} \quad ; \quad T(x) = t = x_{(n)}$$

يمكننا كتابة $f(x; \theta)$ على الصورة:

$$f(x; \theta) = g(t; \theta)h(x)$$

أي أن العلاقة (2.2.4) محققة، وهذا يعني أن الإحصاء المرتب $X_{(n)}$ في العينة X هو إحصاء كافي للمعلمة θ .

وبشكل مشابه، من أجل النموذج المنتظم العام $R(\theta_1, \theta_2)$ يمكن كتابة كثافة توزيع العينة $X = (X_1, X_2, \dots, X_n)$ على الصورة:

$$f(x; \theta) = \frac{e^{(\theta_2 - x_{(n)})} e^{(x_{(1)} - \theta_1)}}{(\theta_2 - \theta_1)^n}$$

$$= g(t; \theta) h(x)$$

حيث: $g(t; \theta) h(x) = \frac{e^{(\theta_2 - x_{(n)})} e^{(x_{(1)} - \theta_1)}}{(\theta_2 - \theta_1)^n}$ ، $h(x) = 1$ ، وهذا

يعني أن الإحصاء $T = (T_1, T_2)$ ؛ $T_1 = X_{(1)}$ ، $T_2 = X_{(n)}$ هو إحصاء كافي للمعلمة $\theta = (\theta_1, \theta_2)$.

مثال 12.2.4

لتكن $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من نموذج $R(a(\theta), b(\theta))$ ، حيث $a(\theta) < b(\theta)$ دالتين مستمرتين في θ .

لايجاد إحصاء كافٍ لـ θ ، بشكل مشابه لما ورد في المثال السابق، نجد:

$$f(x; \theta) = \frac{e^{(x_{(1)} - a(\theta))} e^{(b(\theta) - x_{(n)})}}{(b(\theta) - a(\theta))^n} \quad (4.2.4)$$

$$= g(t; \theta) h(x)$$

حيث إن:

$$h(x) = 1 \quad , \quad g(t; \theta) = \frac{e^{(x_{(1)} - a(\theta))} e^{(b(\theta) - x_{(n)})}}{(b(\theta) - a(\theta))^n} \quad , \quad t = (x_{(1)}, x_{(n)})$$

وهذا يعني حسب المبرهنة (1.2.4) أن الإحصاء $T = (X_{(1)}, X_{(n)})$ إحصاء كافٍ لـ θ .

والسؤال الذي يطرح نفسه الآن: هل يمكن إيجاد إحصاء كافٍ وحيد البعد للمعلمة θ في المسألة المطروحة، أي إحصاء كافٍ أكثر تكثيفاً؟

نلاحظ أن البسط (الصورة) في العلاقة (4.2.4) يساوي الواحد فقط عندما:

$$\{x_{(1)} \geq a(\theta) , b(\theta) \geq x_{(n)}\} \quad (5.2.4)$$

وبفرض أن $\alpha(\theta)$ متزايدة و $b(\theta)$ متناقصة بازدياد θ ، فإن الشرط (5.2.4) يكون مكافئاً للشرط:

$$\{\theta \leq \alpha^{-1}(x_{(1)}), \theta \leq b^{-1}(x_{(n)})\} \Leftrightarrow \{\theta \leq T_1(x) = \min(\alpha^{-1}(x_{(1)}), b^{-1}(x_{(n)}))\}$$

وعليه يمكن كتابة العلاقة (4.2.4) على الشكل:

$$f(x; \theta) = \frac{e^{(T_1(x) - \theta)}}{(b(\theta) - \alpha(\theta))^n}$$

ومن ثم فإن:

$$T_1 = T_1(X) = \min(\alpha^{-1}(X_{(1)}), b^{-1}(X_{(n)}))$$

إحصاء كاف وحيد البعد للمعلمة θ ، وهذا يعني أن $T_1(x)$ أكثر تكثيفاً من الإحصاء الكافي ذو البعدين $T = (X_{(1)}, X_{(2)})$.

وبشكل مشابه، بفرض $\alpha(\theta)$ متناقصة و $b(\theta)$ متزايدة بازدياد θ ، فإن الإحصاء الكافي وحيد البعد يكون $T_2 = T_2(X) = \max(\alpha^{-1}(X_{(n)}), b^{-1}(X_{(1)}))$ ، وهذا أكثر تكثيفاً من $T = (X_{(1)}, X_{(2)})$ ، وتختفي هاتان الحالتان عندما يوجد للنموذج $R(\alpha(\theta), b(\theta))$ إحصاء كافي وحيد البعد.

تجد الإشارة هنا، إلى أن T_1 و T_2 دالتين في الإحصاء الكافي T ، وهذه الحالة لها طبيعة عامة، أي أن الإحصاء الكافي الأصغر (الأكثر تكثيفاً) هو دالة في أي إحصاء كافي آخر للمعلمة θ .

فمن أجل النموذج $R(-\theta, \theta)$ يأخذ الإحصاء الكافي وحيد البعد T_2 الشكل:

$$T_2 = \max(-X_{(1)}, X_{(n)}) = \max(|X_{(1)}|, |X_{(n)}|)$$

ومن أجل النموذج $R(\theta, \theta + 1)$ فإن الإحصاء الكافي وحيد البعد غير موجود.

مثال 13.2.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع كوشي بالمعلمة θ ، فدالة الكثافة:

$$f(x; \theta) = \frac{1}{\pi^n} \prod_{i=1}^n \frac{1}{1 + (x_i - \theta)^2}$$

وهذا لا يمكن كتابته بصورة العلاقة (2.2.4)، ومن ثم لا يمكن إيجاد إحصاء كافٍ للمعلمة θ ، بحجم أقل من n ، أي لا يوجد سوى الإحصاء الكافي التافه $T = X$.

نلاحظ مما سبق إمكانية وجود أكثر من إحصاء كافي لمعلمة θ (وحيدة البعد أو متعددة الأبعاد) في نموذج مفروض، بل يمكن أن تكون كثيرة جداً، فمثلاً بالعودة إلى المثال (9.2.4) نجد أن المعلمة $\theta = (\theta_1, \theta_2)$ لها أكثر من إحصاء كافٍ، منها:

$$T = (T_1, T_2) \quad ; \quad T_1(X) = n\bar{X} \quad , \quad T_2(X) = \sum_{i=1}^n X_i^2$$

$$T = (T_1, T_2) \quad ; \quad T_1(X) = \bar{X} \quad , \quad T_2(X) = \sum_{i=1}^n (X_i - \bar{X})^2$$

بالإضافة إلى الإحصاء التافه $T = X$.

من الواضح أننا نرغب في إيجاد الإحصاء الكافي الأكثر تكتيفاً للمعلومات المتوفرة في العينة العشوائية $X = (X_1, X_2, \dots, X_n)$ حول المعلمة θ في النموذج المفروض $F(x; \theta)$ ، غير أن ذلك غير ممكن دائماً. حيث نجد في حالات عدة أن الإحصاء الكافي الوحيد في نموذج مفروض $F(x; \theta)$ هو الإحصاء التافه. فمثلاً نموذج كوشي والنموذج المنتظم $R(\theta, \theta + 1)$ [راجع المثالين (12.2.4)، (13.2.4)]. يدعى الإحصاء الكافي الأكثر تكتيفاً لمعلمة θ في نموذج $F(x; \theta)$ بالإحصاء الكافي الأصغر (minimum sufficient statistic).

تعريف 3.2.4: الإحصاء الكافي الأصغر

Minimum Sufficient Statistic

إذا كان T_1 و T_2 إحصائين كافيين للمعلمة θ في النموذج $F(x; \theta)$ ، فيقال إن الإحصاء الكافي T_1 يتبع الإحصاء الكافي T_2 عندما تكون T_1 دالة مقيسة في T_2 ، أي أن $T_1 = \varphi(T_2)$. وهذا يعني أن الإحصاء الكافي T_1 أكثر تكثيفاً للمعلومات المتوفرة في العينة X حول المعلمة θ من الإحصاء الكافي T_2 . وإذا كان الإحصاء الكافي T_0 يتبع أي إحصاء كافٍ آخر للمعلمة θ ، فيدعى بالإحصاء الكافي الأصغر أو الأصغري.

هكذا، فالإحصاء الكافي الأصغر هو عبارة عن الإحصاء الكافي الأكثر تكثيفاً على الإطلاق للمعلومات المتوفرة في العينة العشوائية X حول المعلمة θ في النموذج $F(x; \theta)$. وهذا يعني أنه إذا وجد إحصاء كافٍ أصغر T_0 للمعلمة θ ، فإن أي تكثيف أكبر للمعطيات المتوفرة في العينة العشوائية X حول θ ، بالمقارنة مع T_0 ، غير ممكن. وعندها تعتبر المعلومات الأخرى المتوفرة في العينة العشوائية X ، والتي لم يمتصها الإحصاء الكافي T_0 ، ناتجة عن آلية عشوائية مستقلة عن θ (لا تتضمن أية معلومات حول θ).

3.4 توزيع إحصاء بشرط معرفة إحصاء كاف

DISTRIBUTION OF STATISTIC CONDITIONAL ON A SUFFICIENT STATISTIC

رأينا عند إثبات المبرهنة (1.2.4)، وباعتبار $Y_1 = T$ إحصاء كافٍ للمعلمة θ في نموذج $F(x; \theta)$ ، أن:

$$f(y|t, \theta) = \frac{f(y_1, y_2, \dots, y_n; \theta)}{f_1(t; \theta)} = h^*(x) |J| \quad ; \quad y = (y_1, \dots, y_n)$$

أي أن التوزيع المشروط للإحصاءات Y_2, \dots, Y_n بافتراض معلومية $T = t$ لا

يعتمد على θ (مستقل عن θ). وبشكل مشابه، يمكن إثبات أن التوزيع الشرطي لأي مجموعة جزئية من الإحصاءات Y_2, \dots, Y_n ، معلومية T لا يعتمد على θ . وأهمية هذه الخاصية تكمن في أنها تؤخذ أحياناً على أنها تعريف للإحصاء الكافي.

تعريف 1.3.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع $F(x; \theta)$ ، فيقال إن الإحصاء $T = T(X)$ إحصاء كاف للمعلمة θ إذا فقط إذا كان التوزيع الشرطي لأي إحصاء آخر $U = \psi(X)$ بافتراض معرفة $T = t$ مستقل عن θ .

إن هذا التعريف مفيد في معرفة ما إذا كان إحصاءً ما غير كافٍ. فمثلاً، لإثبات أن الإحصاء $U = \psi(X)$ ليس كافياً فإننا نحتاج فقط إلى إيجاد إحصاء آخر $T = T(X)$ يكون توزيعه الشرطي بافتراض معرفة $U = u$ يعتمد على θ (غير مستقل عن θ).

مثال 1.3.4

إذا كانت $X = (X_1, X_2)$ عينة عشوائية من توزيع $N(\theta, 1)$ ، فأثبت أن $U = X_1 - X_2$ إحصاء غير كافي للمعلمة θ .

بما أن:

$$f(x; \theta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\theta)^2}{2}}, \quad -\infty < x < +\infty$$

فإن:

$$\begin{aligned} f(x; \theta) &= f(x_1, x_2; \theta) = f(x_1; \theta) f(x_2; \theta) \\ &= \frac{1}{2\pi} \exp\left[-\frac{(x_1 - \theta)^2 + (x_2 - \theta)^2}{2}\right] \end{aligned}$$

ويمكن التأكد بسهولة من أن $T = X_1 + X_2$ إحصاء كاف للمعلمة θ وتوزيع T هو $N(2\theta, 2)$.

لنعين التوزيع المشترك للمتغيرات:

$$T = X_1 + X_2 \quad , \quad U = X_2 - X_1$$

وذلك باستخدام طريقة التحويلات

$$H(t,u) = f(x_1, x_2; \theta) |J| \quad ; \quad x_1 = \frac{t-u}{2} \quad , \quad x_2 = \frac{t+u}{2} \quad , \quad |J| = \frac{1}{2}$$

$$= \frac{1}{4\pi} \exp \left\{ -\frac{1}{2} \left[\left(\frac{t-u}{2} - \theta \right)^2 + \left(\frac{t+u}{2} - \theta \right)^2 \right] \right\}$$

ولنحسب الآن التوزيع الشرطي للمتغير العشوائي U بمعلومية $T = t$ ولنرمز لذلك بـ $K(u|t)$ ، فنجد:

$$K(t|u) = \frac{H(t,u)}{h(u)} = \frac{\exp \left\{ -\frac{1}{2} \left[\left(\frac{t-u}{2} - \theta \right)^2 + \left(\frac{t+u}{2} - \theta \right)^2 \right] \right\}}{4\pi \exp \left[-\frac{1}{4} u^2 \right]} (\sqrt{4\pi})$$

$$= \frac{1}{\sqrt{4\pi}} e^{-\frac{1}{2}(t-\theta)^2}$$

وهذا الأخير يعتمد على θ ، وعليه حسب التعريف (1.2.4) فإن الإحصاء U إحصاء غير كافٍ للمعلمة θ .

4.4 عائلة التوزيعات الأسية والإحصاءات الكافية

EXPONENTIAL DISTRIBUTION FAMILY AND SUFFICIENT STATISTICS

سننتقل فيما يلي لعائلة من النماذج المعلمية التي تدعى بالأسية، حيث يوجد دائماً مثل هذه النماذج إحصاء كافٍ (غير الإحصاء الكافي التافه)، وهذا الإحصاء الكافي أصغري (minimal).

تعريف 1.4.4

يقال عن نموذج $F(x; \theta)$ إنه أسّي، إذا أمكن كتابة الدالة الموافقة $f(x; \theta)$ على الشكل الآتي؛ بافتراض θ معلمة سلمية:

$$f(x; \theta) = \exp\{A(\theta)B(x) + C(\theta) + D(x)\} \quad (1.4.4)$$

وكثير من النماذج التي تصادفنا في التطبيق تحقق هذه الخاصة، ونذكر من هذه النماذج:

$$N(\theta, \sigma^2), N(\mu, \theta^2), B(n, \theta), \Gamma(\lambda, \theta), \Pi(\theta), \bar{B}(r, \theta)$$

ومن الواضح أن توزيع $K(\theta)$ غير أسّي.

إذا كانت $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية مأخوذة من مجتمع توزيعه الاحتمالي عضو في عائلة النماذج الأسية، فإن:

$$\begin{aligned} f(\mathbf{x}; \theta) &= \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n e^{A(\theta)B(x_i) + C(\theta) + D(x_i)} = e^{A(\theta) \sum_{i=1}^n B(x_i) + nC(\theta) + \sum_{i=1}^n D(x_i)} \\ &= e^{A(\theta) \sum_{i=1}^n B(x_i) + nC(\theta)} e^{\sum_{i=1}^n D(x_i)} = g(t; \theta) h(\mathbf{x}) \quad ; \quad t = \sum_{i=1}^n B(x_i) \end{aligned}$$

حيث إن:

$$g(t; \theta) = e^{A(\theta) \sum_{i=1}^n B(x_i) + nC(\theta)}$$

$$h(\mathbf{x}) = e^{\sum_{i=1}^n D(x_i)}$$

وبالتالي، حسب المبرهنة (1.2.4) فإن الإحصاء $T(\mathbf{X}) = \sum_{i=1}^n B(X_i)$ إحصاء كاف للمعلمة θ ، ويمكن إثبات أنه الإحصاء الكافي الأصغر (minimal).

مثال 1.4.4

إذا كانت كثافة توزيع المتغير العشوائي الملاحظ X :

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0$$

و $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من المجتمع $f(x; \theta)$ ، فأوجد الإحصاء الكافي الأصغر للمعلمة θ .

يمكن كتابة دالة الكثافة $f(x; \theta)$ على النحو الآتي:

$$f(x; \theta) = e^{-\theta x + \ln \theta}$$

وبذلك فهو نموذج أسّي فيه:

$$A(\theta) = -\theta \quad , \quad B(x) = x \quad , \quad C(\theta) = \ln \theta \quad , \quad D(x) = 0$$

وعليه فإن:

$$T(X) = \sum_{i=1}^n B(X_i) = \sum_{i=1}^n X_i$$

إحصاء كاف أصغر للمعلمة θ .

يمكن تعميم مفهوم عائلة النماذج الأسية ذات المعلمة السلمية على العائلة الأسية ذات

العالم متعددة الأبعاد (multi-parameter exponential family)

يقال عن نموذج $f(x; \theta)$ ، حيث $\theta = (\theta_1, \dots, \theta_k)$ إنه أسّي إذا أمكن كتابته

على الصورة:

$$f(x; \theta) = \exp \left[\sum_{j=1}^k A_j(\theta) B_j(x) + C(\theta) + D(x) \right]$$

وعليه:

$$f(x; \theta) = \prod_{i=1}^n f(x_i; \theta) = \exp \left[\sum_{j=1}^k A_j(\theta) \sum_{i=1}^n B_j(x_i) + nC(\theta) + \sum_{i=1}^n D(x_i) \right]$$

وباستخدام المبرهنة (1.2.4) نجد أن الإحصاء:

$$T(X) = (T_1, T_2, \dots, T_k) \quad ; \quad \begin{cases} T_1 = \sum_{i=1}^n B_1(x_i) \\ T_2 = \sum_{i=1}^n B_2(x_i) \\ \vdots \\ T_k = \sum_{i=1}^n B_k(x_i) \end{cases}$$

يعتبر إحصاءاً كافياً للمعلمة $\theta = (\theta_1, \dots, \theta_k)$ وأصغري.

مثال 2.4.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع بيتا بالمعلمة $\theta = (\theta_1, \theta_2)$ ، فأوجد إحصاءاً كافياً للمعلمة θ .

كما نعلم كثافة توزيع بيتا تعطى كما يلي:

$$f(x; \theta) = \frac{1}{\beta(\theta_1, \theta_2)} x^{\theta_1-1} (1-x)^{\theta_2-1}$$

ويمكن كتابتها على النحو الآتي:

$$f(x; \theta) = \exp[-\ln \beta(\theta_1, \theta_2) - \ln x - \ln(1-x) + \theta_1 \ln x + \theta_2 \ln(1-x)]$$

أي نموذج أسّي، وبالمقارنة بالصيغة (2.4.4)، نجد:

$$A_1(\theta) = \theta_1 \quad , \quad A_2(\theta) = \theta_2 \quad , \quad B_1(x) = \ln x \quad , \quad B_2(x) = \ln(1-x)$$

$$C(\theta) = -\ln \beta(\theta_1, \theta_2) \quad , \quad D(x) = -\ln x(1-x)$$

وعليه فإن:

$$T = (T_1, T_2) \quad ; \quad T_1 = \sum_{i=1}^n \ln x_i \quad , \quad T_2 = \sum_{i=1}^n \ln(1-x_i)$$

إحصاء كاف للمعلمة $\theta = (\theta_1, \theta_2)$ وأصغري.

مثال 3.4.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من مجتمع يتبع توزيع $N(\theta_1, \theta_2^2)$ ، فأوجد الإحصاء الكافي الأصغر للمعلمة $\theta = (\theta_1, \theta_2^2)$.
 بما أن النموذج الطبيعي $N(\theta_1, \theta_2^2)$ أسّي، فيمكننا كتابته على النحو الآتي:

$$f(x; \theta) = \frac{1}{\theta_2 \sqrt{2\pi}} e^{-\frac{(x-\theta_1)^2}{2\theta_2^2}}$$

$$= \exp \left[-\frac{1}{2} \ln 2\pi - \frac{1}{2} \left(\ln \theta_2^2 + \frac{\theta_1^2}{\theta_2^2} \right) + \frac{\theta_1}{\theta_2^2} x - \frac{x^2}{2\theta_2^2} \right]$$

وبالمقارنة مع الصيغة الأسية (2.4.4)، نجد:

$$A_1(\theta) = \frac{\theta_1}{\theta_2^2} \quad , \quad A_2(\theta) = -\frac{1}{2\theta_2^2} \quad , \quad B_1(x) = x \quad , \quad B_2(x) = x^2$$

$$C(\theta) = -\frac{1}{2} \left(\ln \theta_2^2 + \frac{\theta_1^2}{\theta_2^2} \right) \quad , \quad D(x) = -\frac{1}{2} \ln 2\pi$$

وعليه فإن:

$$T = (T_1, T_2) \quad ; \quad T_1 = \sum_{i=1}^n B_1(X_i) = \sum_{i=1}^n X_i \quad , \quad T_2 = \sum_{i=1}^n B_2(X_i) = \sum_{i=1}^n X_i^2$$

إحصاء كاف وأصغر للمعلمة $\theta = (\theta_1, \theta_2^2)$.

إن أهمية النموذج الأسّي ليس فقط في وجود إحصاء كاف أصغر له، بل في وجود الإحصاء التام (الكامل) له وسهولة الحصول عليه، ويلعب الإحصاء التام دوراً هاماً في الوصول إلى المقدّرات الأكفأ، كما سنرى ذلك في فصل لاحق.

5.4 الكفاية والتام SUFFICIENCY AND COMPLETENESS

يستخدم مفهوم الكفاية (sufficiency) في أحيان كثيرة مع مفهوم آخر يدعى بالكمال أو التمام (completeness)، لذا لابد من تعريف الإحصاء الكافي التام أو الإحصاء الكافي التام (complete and sufficient statistic).

تعريف 1.5.4

إذا كان $T = T(X)$ إحصاءً كافيًا للنموذج $f(x; \theta)$ ، وكان الإحصاء $\varphi(T)$ يحقق الشرط:

$$E_{\theta} \varphi(T) = 0 \quad ; \quad \forall \theta \in \theta$$

فإن $\varphi(t) = 0$ على كامل مجموعة قيم الإحصاء T ، وهذا يعني أن:

$$P_{\theta}(X \in \{x; \varphi(T) \neq 0\}) = 0 \quad ; \quad \forall \theta \in \theta \quad , \quad t = T(x)$$

يدعى عندئذٍ الإحصاء الكافي T بالتام.

نلاحظ من هذا التعريف أنه إذا كان الإحصاء $T(X)$ تاماً للمعلمة θ فهو أيضاً إحصاء كافٍ، لذا بدلاً من استخدام مصطلح "إحصاء كافٍ وتام" يمكننا اختصاراً القول "إحصاء تام".

مثال 1.5.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \frac{1}{\theta} \quad ; \quad 0 < x < \theta, \quad \theta > 0$$

وعلمت أن $T = \max(X)$ إحصاء كافٍ للمعلمة θ ، فأنبت أن T إحصاء تام.

التوزيع الاحتمالي لـ T :

$$g(t; \theta) = \frac{nt^{n-1}}{\theta^n} \quad ; \quad 0 < t < \theta, \quad \theta > 0$$

وبفرض $\varphi(T)$ إحصاء ما في T ، فإن توقعه الرياضي:

$$\begin{aligned} E_{\theta}[\varphi(T)] &= \int_R \varphi(t)g(t;\theta)dt = \\ &= \int_0^{\theta} \varphi(t) \frac{nt^{n-1}}{\theta^n} dt \end{aligned}$$

إذا كان الشرط $E_{\theta}[\varphi(T)] = 0 ; \forall \theta \in \theta$ محقق، فإن:

$$\int_0^{\theta} \varphi(t) \frac{nt^{n-1}}{\theta^n} dt = 0 ; \forall \theta \in \theta$$

وباشتقاق الطرفين بالنسبة لـ θ ، نجد أن:

$$\varphi(\theta) \frac{n\theta^{n-1}}{\theta^n} = 0 \Rightarrow \varphi(\theta) = 0 ; \forall \theta \in \theta$$

أي أن $\varphi(t) = 0$ مهما تكن t من مجموعة قيم T ، وهذا يعني حسب التعريف (1.5.4) أن T إحصاء تام.

مثال 2.5.4

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بيرنولي $B(1, \theta)$ ، فثبت أن $T(X) = \sum_{i=1}^n X_i$ إحصاء تام.

كما نعلم أن توزيع الإحصاء T هو $B(n, \theta)$ ، أي أن:

$$g(t; \theta) = C_n^t \theta^t (1 - \theta)^{n-t} ; \quad t = 0, 1, \dots, n, \quad 0 < \theta < 1$$

لنفترض أن $\varphi(T)$ دالة ما في T ، ومن ثم فإن:

$$\begin{aligned} E_{\theta} \varphi(T) &= \sum_{t=0}^n \varphi(t) C_n^t \theta^t (1 - \theta)^{n-t} \\ &= (1 - \theta)^n \sum_{t=0}^n \varphi(t) C_n^t \left(\frac{\theta}{1 - \theta} \right)^t \end{aligned}$$

إن كون $E_{\theta} \varphi(T) = 0$ على الفترة $0 < \theta < 1$ يعني أن:

$$\sum_{t=0}^n \varphi(t) C_n^t \left(\frac{\theta}{1-\theta} \right)^t = \sum_{t=0}^n \varphi(t) C_n^t d^t = 0$$

لجميع قيم $d = \frac{\theta}{1-\theta}$ ، وهذه كثيرة حدود في d ولكي تتطابق مع الصفر لابد أن تكون معاملات (أمثال) d^t حيث $t = 0, 1, \dots, n$ مساوية للصفر، أي أن:

$$\varphi(t) C_n^t = 0 \quad ; \quad t = 0, 1, \dots, n$$

وحيث إن $C_n^t \neq 0$ فإن $\varphi(t) = 0$; $t = 0, 1, \dots, n$ وهذا يعني أن $T = \sum_1^n X_i$ إحصاء تام.

مثال 3.5.4

إذا كانت X عينة عشوائية من ملاحظة واحدة من توزيع $N(0, \theta^2)$ ، فأثبت أن $T(X) = X$ إحصاء غير تام.

إن توزيع $T = X$ هو:

$$g(t; \theta) = \frac{1}{\theta\sqrt{2\pi}} e^{-\frac{1}{2\theta^2}t^2} \quad ; \quad -\infty < t < +\infty$$

وبافتراض $\varphi(T)$ دالة ما في T ، فإن:

$$E_{\theta} \varphi(T) = \frac{1}{\theta\sqrt{2\pi}} \int_{-\infty}^{+\infty} \varphi(t) e^{-\frac{1}{2\theta^2}t^2} dt = 0 \quad ; \quad -\infty < t < +\infty$$

وهذا لا يعني أن $\varphi(t)$ مطابق للصفر، وبالتالي فالإحصاء $T = X$ غير تام.

إن التحقق بصورة عامة من تمتع إحصاء كاف ما بخاصة التام يتطلب رياضيات متقدمة باستثناء بعض الحالات الخاصة جداً، والمبرهنة الآتية التي سنقبلها بدون برهان تساعد في الحصول على الإحصاءات التامة في معظم المسائل التطبيقية.

مبرهنة 4.5.4

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع ينتمي لعائلة النماذج الأسية:

$$f(x; \theta) = \exp[A(\theta)B(x) + C(\theta) + D(x)]$$

فإن إحصاء كاف أصغر وتام $T = \sum_{i=1}^n B(X_i)$.

مثال 5.5.4

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta_1, \theta_2^2)$ ، فإن:

$$T = (T_1, T_2) \quad ; \quad T_1 = \sum_{i=1}^n X_i, \quad T_2 = \sum_{i=1}^n X_i^2$$

إحصاء كاف تام.

وكذلك بناءً على نتائج المثال (1.4.4) فإن الإحصاء $T(X) = \sum_1^n X_i$ يعتبر إحصاءً

كافياً وتاماً للمعلمة θ في النموذج $\Gamma\left(1, \frac{1}{\theta}\right)$.

LIKELIHOOD FUNCTION

6.4 دالة العقولية

لنفترض كالعادة $f(x; \theta)$ دالة الكثافة (أو دالة الاحتمال في حالة المنقطع) لتوزيع المتغير العشوائي الملاحظ ξ ، $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من التوزيع $\mathcal{F} \in \mathcal{F}$ و $x = (x_1, x_2, \dots, x_n)$ العينة المشاهدة (نقطة ملاحظة لـ X).

كما نعلم أن توزيع المتغير العشوائي $X = (X_1, X_2, \dots, X_n)$ يرمز له بـ $f(x; \theta) = f(x_1, x_2, \dots, x_n; \theta)$ ، وإذا اعتبرنا هذه الدالة، عند مشاهدة x ، كدالة

في المعلمة θ ، فإنها تدعى بدالة المعقولة (وفي بعض المراجع دالة الأرجحية، أو دالة الإمكان)، ويرمز لها بـ $L = L(x; \theta)$ ، أي أن:

$$L(x; \theta) = f(x_1, x_2, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

وسنعمد فيما يلي مصطلح "دالة المعقولة".

نلاحظ أن الدالة $L(x; \theta)$ هي عبارة عن دالة كثافة (أو دالة احتمال) المتغير العشوائي X وأن $f(x; \theta)$ ، عند قيمة معينة x لـ X ، ينظر إليها كدالة في $\theta \in \Theta$ ، وتدعى عندئذٍ بدالة المعقولة.

نفترض فيما يلي، أن الدالة $L(x; \theta) > 0$ من أجل كل $x \in G$ ومن أجل كل $\theta \in \Theta$ ، وقابلة للاشتقاق بالنسبة لـ θ . إذا كانت المعلمة θ سلمية (وحيدة البعد)، فإن المتغير العشوائي:

$$U(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta} = \sum_{i=1}^n \frac{\partial \ln f(X_i; \theta)}{\partial \theta} \quad (1.6.4)$$

يدعى بدالة مساهمة (أو مساهمة) العينة X ، كما يدعى المقدار:

$$\frac{\partial \ln f(X_i; \theta)}{\partial \theta}$$

بمساهمة الملاحظة رقم i على المتغير العشوائي X الذي يمثل الصفة المدروسة في المجتمع الإحصائي.

ونفترض أيضاً فيما يلي أن:

$$0 < E_{\theta} U^2(X; \theta) < \infty \quad ; \quad \forall \theta \in \Theta$$

ونفهم دالة المساهمة (أو المساهمة)، في حالة معلمة متعددة الأبعاد $\theta = (\theta_1, \theta_2, \dots, \theta_r)$ على أنها متجه عشوائي $U(X; \theta) = (U_1(X; \theta), U_2(X; \theta), \dots, U_r(X; \theta))$ ، حيث:

$$U_i(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta_i} \quad ; \quad i = 1, 2, \dots, r$$

سنحتاج لاحقاً، وأكثر من مرة، للاشتقاق بالنسبة لـ θ لتكاملات دوال معرفة على فضاء العينة G ، وكذلك أيضاً إلى تغيير ترتيب عمليتي التكامل والاشتقاق. تدعى النماذج التي تحقق تلك الشروط بالإضافة إلى شروط أخرى بالنماذج النظامية (regularity moeles)، والشروط الدقيقة، التي تتضمن نظامية النموذج معروفة من التحليل الرياضي وشكلها يتحدد في كل حالة معينة.

لنرى الآن بعض خواص دالة المساهمة $U(X; \theta)$ في حالة نماذج نظامية.

بما أن الدالة $L(x; \theta)$ عبارة عن كثافة (أو دالة احتمال) المتغير العشوائي $X = (X_1, X_2, \dots, X_n)$ ، فإن المطابقة الآتية محققة دوماً بالنسبة لـ θ .

$$\int L(x; \theta) dx \equiv 1 \quad , \quad dx = \prod_{i=1}^n dx_i \quad (2.6.4)$$

(هنا ولاحقاً من أجل النماذج النظامية المنقطعة يستبدل التكامل بالمجموع).

إذا كان النموذج نظامياً، فاشتقاق المطابقة (2.6.4) بالنسبة لـ θ ، نجد:

$$\frac{\partial}{\partial \theta} \int L(x; \theta) dx = \int \frac{\partial L(x; \theta)}{\partial \theta} dx = \int \frac{\partial \ln L(x; \theta)}{\partial \theta} L(x; \theta) dx = E_{\theta} U(X; \theta) = 0$$

لأن:

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = \frac{\partial L(x; \theta)}{\partial \theta} / L(x; \theta)$$

وهذا يعني، من أجل نموذج نظامي، أن التوقع الرياضي (القيمة المتوقعة) لدالة المساهمة يساوي الصفر مهما تكن $\theta \in \Theta$ ، أي أن:

$$E_{\theta} U(X; \theta) = 0 \quad ; \quad \forall \theta \in \Theta \quad (3.6.4)$$

وباشتقاق طرفي المطابقة (3.6.4) بالنسبة لـ θ ، نجد:

$$\int \left[\frac{\partial^2 \ln L(x; \theta)}{\partial \theta^2} L(x; \theta) + \left(\frac{\partial \ln L(x; \theta)}{\partial \theta} \right)^2 L(x; \theta) \right] dx \equiv 0$$

وعلى ذلك، فإن:

$$\int \left(\frac{\partial \ln L(x; \theta)}{\partial \theta} \right)^2 L(x; \theta) dx = - \int \frac{\partial^2 \ln L(x; \theta)}{\partial \theta^2} dx \quad ; \quad \forall \theta \in \theta$$

وهذا يعني:

$$E_{\theta} \left(\frac{\partial \ln L(x; \theta)}{\partial \theta} \right)^2 = -E_{\theta} \left(\frac{\partial^2 \ln L(x; \theta)}{\partial \theta^2} \right)$$

أي:

$$E_{\theta} [U(X; \theta)]^2 = -E_{\theta} \left(\frac{\partial U(X; \theta)}{\partial \theta} \right) \quad ; \quad \forall \theta \in \theta \quad (4.6.4)$$

وبناءً على تعريف دالة المساهمة (1.6.4)، يمكن كتابة العلاقة (4.6.4) على النحو الآتي:

$$E_{\theta} \left(\sum_{i=1}^n \frac{\partial \ln f(X_i; \theta)}{\partial \theta} \right)^2 = -n E_{\theta} \left(\frac{\partial^2 \ln f(X_i; \theta)}{\partial \theta^2} \right) \quad ; \quad \forall \theta \in \theta \quad (5.6.4)$$

مثال 1.6.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع بواسون $\Pi(\theta)$ ، فأوجد دالة المساهمة $U(X; \theta)$ ، ثم تحقق من صحة العلاقة (5.6.4).

كما نعلم:

$$f(x; \theta) = \frac{\theta^x}{x!} e^{-\theta} \quad , \quad x = 0, 1, \dots \quad , \quad \theta > 0$$

وعلى ذلك، فإن:

$$L(X; \theta) = \prod_{i=1}^n f(X_i; \theta) = \prod_{i=1}^n \frac{\theta^{X_i}}{X_i!} e^{-\theta} = \frac{\theta^{\sum X_i}}{\prod X_i!} e^{-n\theta}$$

$$\ln L(X; \theta) = \sum_{i=1}^n X_i \ln \theta - \sum_{i=1}^n \ln(X_i!) - n\theta$$

ومن ثم:

$$U(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta} = \frac{1}{\theta} \sum_{i=1}^n X_i - n = n \left(\frac{\bar{X}}{\theta} - 1 \right) \quad ; \quad \theta > 0$$

$$\frac{\partial U(X; \theta)}{\partial \theta} = -\frac{n}{\theta^2} \bar{X} \quad ; \quad \theta > 0$$

وبالتالي:

$$E_{\theta}[U(X; \theta)] = \frac{n}{\theta} E_{\theta} \bar{X} - n = n - n = 0$$

$$\begin{aligned} E_{\theta}[U(X; \theta)]^2 &= E_{\theta} \left[n \left(\frac{\bar{X}}{\theta} - 1 \right) \right]^2 = n^2 E \left(\frac{\bar{X}^2}{\theta^2} - \frac{2}{\theta} \bar{X} + 1 \right) = \\ &= \frac{n^2}{\theta^2} E \left(\frac{\sum X_i}{n} \right)^2 - \frac{2n^2}{\theta} E \bar{X} + n^2 \\ &= \frac{1}{\theta^2} E \left[\sum_{i=1}^n X_i^2 + 2 \sum_{i < j} X_i X_j \right] - 2n^2 + n^2 \\ &= \frac{1}{\theta^2} [n(\theta + \theta^2) + n(n-1)\theta^2] - 2n^2 + n^2 = \frac{n}{\theta} \end{aligned}$$

$$E_{\theta} \left(\frac{\partial U(X; \theta)}{\partial \theta} \right) = E_{\theta} \left(-\frac{n}{\theta^2} \bar{X} \right) = -\frac{n}{\theta^2} E \bar{X} = -\frac{n}{\theta}$$

أي أن:

$$E_{\theta} (U(X; \theta))^2 = -E_{\theta} \left(\frac{\partial U(X; \theta)}{\partial \theta} \right) = \frac{n}{\theta} \quad , \quad \theta > 0$$

ويمكننا الوصول إلى نفس النتيجة بطريقة أخرى على النحو الآتي:

$$\ln f(X_i; \theta) = -\theta + X_i \ln \theta - \ln(X_i!)$$

$$\frac{\partial \ln f(X_i; \theta)}{\partial \theta} = -1 + \frac{X_i}{\theta} \quad , \quad \frac{\partial^2 \ln f(X_i; \theta)}{\partial \theta^2} = -\frac{X_i}{\theta^2}$$

$$E_{\theta} \left[\sum_{i=1}^n \frac{\partial \ln f(X_i; \theta)}{\partial \theta} \right]^2 = E_{\theta} \left[\sum_{i=1}^n \left(-1 + \frac{X_i}{\theta} \right) \right]^2 = \frac{n}{\theta}$$

$$-n E_{\theta} \left[\frac{\partial^2 \ln f(X_i; \theta)}{\partial \theta^2} \right] = -n E_{\theta} \left(-\frac{X_i}{\theta^2} \right) = \frac{n}{\theta}$$

أي أن:

$$E_{\theta} \left[\sum_{i=1}^n \frac{\partial \ln f(X_i; \theta)}{\partial \theta} \right]^2 = -n E_{\theta} \left[\frac{\partial^2 \ln f(X_i; \theta)}{\partial \theta^2} \right] = \frac{n}{\theta}$$

FISHER INFORMATIONS

7.4 معلومات فيشر

سنناقش في هذا البند نوعاً من دوال المساهمة التي تلعب دوراً هاماً في الإحصاء وخاصة في مسائل التقدير وتسمى دالة معلومات فيشر (Fisher informations function) أو فقط معلومات فيشر حول المعلمة θ المتوفرة في العينة X ونرمز لها بـ $i_n(\theta)$.

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من توزيع نظامي $f(x; \theta)$ ويعتمد على معلمة وحيدة البعد θ ، فإن $i_n(\theta)$ تعرف بالعلاقة:

$$i_n(\theta) = \text{var} U(X; \theta) = E_{\theta} [U(X; \theta)]^2 \quad (1.7.4)$$

وهي تقيس كمية المعلومات المحتواة في العينة X حول المعلمة θ . ويدعى المقدار:

$$i(\theta) = i_1(\theta) = E_{\theta} \left[\frac{\partial \ln f(X_i, \theta)}{\partial \theta} \right]^2 \quad (2.7.4)$$

بكمية المعلومات (معلومات فيشر) حول المعلمة θ المتوفرة في ملاحظة واحدة، ونستخلص من العلاقات (1.6.4)، (3.6.4)، (1.7.4) و (2.7.4) أن:

$$i_n(\theta) = ni(\theta). \quad (3.7.4)$$

وهذا يعني أن كمية المعلومات المحتواة في عينة عشوائية حول المعلمة θ متناسبة طردياً مع حجم العينة n . وبعبارة أخرى أن كمية المعلومات $i_n(\theta)$ التي تقدمها العينة $X = (X_1, X_2, \dots, X_n)$ حول المعلمة θ تساوي n ضعف كمية المعلومات التي تعطيها ملاحظة واحدة.

وبما أن النموذج $f(x; \theta)$ نظامي، فهو قابل للاشتقاق مرتين بالنسبة لـ θ ، وعلى ذلك فباشتقاق العلاقة (3.6.4) مرتين بالنسبة لـ θ عندما $n = 1$ ، فنحصل على صيغة مكافئة من أجل $i(\theta)$:

$$0 = \int \frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} f(x; \theta) dx + \int \left[\frac{\partial \ln f(x; \theta)}{\partial \theta} \right] f(x; \theta) dx$$

أي أن:

$$i(\theta) = -E_{\theta} \left[\frac{\partial^2 \ln f(X_1; \theta)}{\partial \theta^2} \right] \quad (4.7.4)$$

وهذه العلاقة غالباً أسهل في إيجاد $i(\theta)$.

مثال 1.7.4

إذا كانت $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية من نموذج بيرنولي $B(1, \theta)$ ، فأوجد معلومات فيشر المختواة في ملاحظة واحدة ومن ثم في العينة حول المعلمة θ .

كما نعلم:

$$f(x; \theta) = \theta^x (1 - \theta)^{1-x} \quad ; \quad x = 0, 1 \quad , \quad 0 < \theta < 1$$

وعلى ذلك، فإن:

$$\ln f(x; \theta) = x \ln \theta + (1 - x) \ln(1 - \theta)$$

$$\frac{\partial \ln f(x; \theta)}{\partial \theta} = \frac{x}{\theta} - \frac{1-x}{1-\theta}$$

$$\frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} = -\frac{x}{\theta^2} - \frac{1-x}{(1-\theta)^2}$$

$$E_{\theta} \left[\frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} \right] = -\frac{\theta}{\theta^2} - \frac{1-\theta}{(1-\theta)^2} = -\frac{1}{\theta} - \frac{1}{1-\theta}$$

وبالتالي فكمية المعلومات المتوفرة في ملاحظة واحدة هي:

$$i_1(\theta) = -E_{\theta} \left[\frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} \right] = \frac{1}{\theta} + \frac{1}{1-\theta} = \frac{1}{\theta(1-\theta)}$$

وكمية المعلومات المتوفرة في العينة X حول المعلمة θ هي:

$$i_n(\theta) = ni(\theta) = \frac{n}{\theta(1-\theta)}$$

وبما أن تباين المتغير العشوائي ξ الذي يتبع توزيع بيرنولي هو $\theta(1-\theta)$ ،

إذن:

$$i(\theta) = \frac{1}{\text{var}_{\theta} \xi}$$

مثال 2.7.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من $N(\theta, \sigma^2)$ ، فأوجد معلومات فيشر في ملاحظة واحدة X_i ومن ثم في العينة العشوائية X .

هنا:

$$f(x; \theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2\sigma^2}(x-\theta)^2} ; \quad -\infty < x < +\infty, \quad -\infty < \theta < +\infty$$

ومن ثم:

$$\ln f(x; \theta) = \ln \frac{1}{\sigma\sqrt{2\pi}} - \frac{1}{2\sigma^2}(x-\theta)^2$$

$$U(X_1; \theta) = \frac{\partial \ln f(X_1, \theta)}{\partial \theta} = \frac{X_1 - \theta}{\sigma^2}$$

$$\frac{\partial^2 \ln f(X_1, \theta)}{\partial \theta^2} = -\frac{1}{\sigma^2}$$

وعلى ذلك، فإن:

$$i_1(\theta) = i(\theta) = -E_{\theta} \left[\frac{\partial^2 \ln f(X_1, \theta)}{\partial \theta^2} \right] = \frac{1}{\sigma^2}$$

$$i_n(\theta) = ni(\theta) = \frac{n}{\sigma^2}$$

وشكل الدالة $i(\theta)$ من أجل بعض النماذج وارد في الجدول (1.7.4)، ونترك إثبات ذلك للقارئ على سبيل المثال.

جدول (1.7.4)

| النموذج | $N(\mu, \theta^2)$ | $\Gamma(\lambda, \theta)$ | $K(\theta)$ | $B(n, \theta)$ | $\Pi(\theta)$ | $\bar{B}(r, \theta)$ |
|-------------|--------------------|---------------------------|-------------|------------------------|---------------|--------------------------|
| $i(\theta)$ | $2/\theta^2$ | λ/θ^2 | $1/2$ | $n/[\theta(1-\theta)]$ | $1/\theta$ | $r/[\theta(1-\theta)^2]$ |

وكمثال على النموذج غير النظامي نذكر التوزيع المنتظم $R(0, \theta)$ ، هنا من المطابقة $\int_0^{\theta} \frac{1}{\theta} dx \equiv 1$ لا ينتج أن $\int_0^{\theta} \frac{\partial}{\partial \theta} \left(\frac{1}{\theta} \right) dx = 0$ لأنه عند اشتقاق التكامل بالنسبة لحدده الأعلى يظهر أيضاً حد آخر. وفي هذه الحالة تكمن عدم النظامية في أن فضاء العينة G يعتمد على المعلمة المجهولة θ .

والتساؤل الذي يطرح نفسه الآن: ما هي العلاقة بين كمية المعلومات التي يقدمها إحصاء ما حول المعلمة θ وكمية المعلومات التي تعطيها العينة العشوائية حول تلك المعلمة؟ وهذا ما تجيب عنه المبرهنة الآتية.

مبرهنة 1.7.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من نموذج $f(x; \theta)$ ، وكان $T = T(X)$ إحصاء ما، فإن:

$$i_T(\theta) \leq i_n(\theta)$$

حيث $i_T(\theta)$ كمية المعلومات التي يعطيها الإحصاء $T(X)$ حول المعلمة θ ، وتتحقق المساواة عندما يكون T إحصاء كاف للمعلمة θ .

الإثبات

كما نعلم من نظرية الاحتمالات أن:

$$L(\mathbf{x};\theta) = h(t;\theta)g(\mathbf{x}|t;\theta) \quad (5.7.4)$$

حيث إن:

$h(t;\theta)$ دالة الكثافة (دالة الاحتمال) لتوزيع الإحصاء T .

$g(\mathbf{x}|t;\theta)$ دالة الكثافة (دالة الاحتمال) الشرطية للعينة \mathbf{X} بشرط أن $T = t$.

بأخذ لوغاريتم الطرفين في (5.7.4)، نجد:

$$\ln L(\mathbf{x};\theta) = \ln h(t;\theta) + \ln g(\mathbf{x}|t;\theta)$$

وبإجراء الاشتقاق مرتين بالنسبة لـ θ وأخذ توقع الطرفين نحصل على:

$$E_{\theta} \left[\frac{\partial^2 \ln L(\mathbf{X};\theta)}{\partial \theta^2} \right] = E_{\theta} \left[\frac{\partial^2 \ln h(T;\theta)}{\partial \theta^2} \right] + E_{\theta} \left[\frac{\partial^2 \ln g(\mathbf{X}|T;\theta)}{\partial \theta^2} \right]$$

وعلى ذلك فإن:

$$i_n(\theta) = i_T(\theta) + E_{\theta} \left[-\frac{\partial^2 \ln g(\mathbf{X}|t;\theta)}{\partial \theta^2} \right]$$

أو:

$$i_n(\theta) = i_T(\theta) + E_{\theta} \left[\frac{\partial \ln g(\mathbf{X}|t;\theta)}{\partial \theta} \right]^2$$

وبملاحظة أن المقدار الثاني في الطرف الأيمن لا يمكن أن يكون سالباً (صفر أو موجب)

فإن:

$$i_T(\theta) \leq i_n(\theta)$$

وتتحقق المساواة عندما

$$E_{\theta} \left[\frac{\partial \ln g(\mathbf{X}|t; \theta)}{\partial \theta} \right]^2 = 0$$

وهذا لا يمكن إلا إذا كانت الدالة $g(\mathbf{X}|t; \theta)$ مستقلة عن θ ، أي أن $T = T(\mathbf{X})$ إحصاء كاف.

هكذا، تبين المبرهنة (1.7.4) أن كمية المعلومات التي تعطيها العينة العشوائية \mathbf{X} حول المعلمة المجهولة θ أكبر من كمية المعلومات التي يعطيها أي إحصاء $T = T(\mathbf{X})$ ، باستثناء الإحصاء الكافي فيعطي نفس كمية المعلومات التي تعطيها العينة.

مثال 2.7.5

إذا كانت $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه:

$$f(x; \theta) = \theta e^{-\theta x} \quad , \quad x \geq 0$$

وعلمت أن $T(\mathbf{X}) = \sum_{i=1}^n X_i$ إحصاء كافياً لـ θ ، فأوجد معلومات فيشر في العينة وفي الإحصاء T .

بما أن:

$$L(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i; \theta) = \theta^n e^{-\theta \sum x_i}$$

فإن:

$$\ln L(\mathbf{x}; \theta) = n \ln \theta - \theta \sum x_i$$

$$\frac{\partial \ln L(\mathbf{x}; \theta)}{\partial \theta} = \frac{n}{\theta} - \sum x_i \quad , \quad \frac{\partial^2 \ln L(\mathbf{x}; \theta)}{\partial \theta^2} = -\frac{n}{\theta^2}$$

إذن:

$$i_n(\theta) = -E_\theta \left[\frac{\partial^2 \ln L(\mathbf{X}; \theta)}{\partial \theta^2} \right] = -E_\theta \left(-\frac{n}{\theta^2} \right) = \frac{n}{\theta^2}$$

وبما أن $T(\mathbf{X})$ متغير عشوائي مؤلف من مجموع n من المتغيرات العشوائية المستقلة ولكل منها التوزيع $f(x; \theta)$ ، فإن توزيعه:

$$h(t; \theta) = \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{-\theta t} \quad , \quad t > 0$$

وعلى ذلك:

$$\ln h(t; \theta) = n \ln \theta - \ln \Gamma(n) + (n-1) \ln t - \theta t$$

$$\frac{\partial \ln h(t; \theta)}{\partial \theta} = \frac{n}{\theta} - t \quad , \quad \frac{\partial^2 \ln h(t; \theta)}{\partial \theta^2} = -\frac{n}{\theta^2}$$

إذن:

$$i_T(\theta) = -E_\theta \left[\frac{\partial^2 \ln h(T; \theta)}{\partial \theta^2} \right] = -E_\theta \left(-\frac{n}{\theta^2} \right) = \frac{n}{\theta^2}$$

وبالتالي:

$$i_n(\theta) = i_T(\theta) = \frac{n}{\theta^2}$$

بينما لو أخذنا الإحصاء $T(\mathbf{X}) = X_1 + X_2$ (غير كاف طبعاً)، فنجد:

$$i_T(\theta) = \frac{2}{\theta} < i_n(\theta) = \frac{n}{\theta^2} \quad ; \quad n > 2$$

مثال 3.7.4

لتكن $\mathbf{X} = (X_1, X_2, \dots, X_n)$ عينة عشوائية من $\Pi(\theta)$ و $T = \sum_1^n X_i$

أوجد معلومات فيشر في العينة وفي الإحصاء T .

نلاحظ من الجدول (1.7.4) أن $i_1(\theta) = i(\theta) = 1/\theta$ وعليه $i_n(\theta) = ni(\theta) = n/\theta$

وبما أن $T = \sum_{i=1}^n X_i$ إحصاء كاف وتوزيعه هو:

$$h(t; \theta) = \frac{(n\theta)^t}{t!} e^{-n\theta} \quad ; \quad t = 0, 1, 2, \dots$$

فإن:

$$\ln h(t; \theta) = t \ln(n\theta) - \ln(t!) - n\theta$$

$$\frac{\partial \ln h(t; \theta)}{\partial \theta} = \frac{t}{\theta} - n \quad , \quad \frac{\partial^2 \ln h(t; \theta)}{\partial \theta^2} = -\frac{t}{\theta^2}$$

$$i_T(\theta) = -E_{\theta} \left[\frac{\partial^2 \ln h(T; \theta)}{\partial \theta^2} \right] = -E_{\theta} \left(-\frac{T}{\theta^2} \right) = \frac{n\theta}{\theta^2} = \frac{n}{\theta}$$

إذن:

$$i_n(\theta) = i_T(\theta) = \frac{n}{\theta}$$

يمكن تعميم مفهوم معلومات فيشر إلى الحالة التي يكون فيها النموذج الإحصائي، الذي يخضع له توزيع المتغير العشوائي الملاحظ X ، معتمداً على معلمة ذات r بعد $\theta = (\theta_1, \theta_2, \dots, \theta_r)$ ، أي معلمة r معلمة. فنحصل عندئذٍ على ما يسمى بمصفوفة معلومات فيشر أو فقط مصفوفة المعلومات (informations matrix) ونرمز لها بـ $I(\theta) = I$ في حالة ملاحظة واحدة وبـ $I_n = I_n(\theta)$ في حالة عينة بحجم n ، وتعرف على النحو الآتي:

$$I = \|g_{ij}\|_1 \quad I_n = nI \quad (6.7.4)$$

حيث إن:

$$g_{ij} = g_{ij}(\theta) = -E_{\theta} \left[\frac{\partial^2 \ln f(X; \theta)}{\partial \theta_i \partial \theta_j} \right] \quad ; \quad i, j = 1, 2, \dots, r$$

مثال 4.7.4

إذا كانت $X = (X_1, X_2, \dots, X_n)$ عينة عشوائية من التوزيع $N(\theta_1, \theta_2^2)$ ، فأوجد مصفوفة المعلومات.

هنا $\theta = (\theta_1, \theta_2)$ ودالة الكثافة:

$$f(x; \theta) = \frac{1}{\theta_2 \sqrt{2\pi}} e^{-\frac{1}{2\theta_2^2}(x-\theta_1)^2}, \quad -\infty < x < \infty$$

وعلى ذلك فإن:

$$\ln f(x; \theta) = -\frac{1}{2} \ln 2\pi - \frac{1}{2} \ln \theta_2 - \frac{1}{2\theta_2^2} (x - \theta_1)^2$$

$$\frac{\partial \ln f(x; \theta)}{\partial \theta_1} = \frac{(x - \theta_1)}{\theta_2^2}, \quad \frac{\partial^2 \ln f(x; \theta)}{\partial \theta_1^2} = -\frac{1}{\theta_2^2}$$

$$\frac{\partial \ln f(x; \theta)}{\partial \theta_2} = +\frac{1}{2\theta_2^2} - \frac{(x - \theta_1)^2}{2\theta_2^3}$$

$$\frac{\partial^2 \ln f(x; \theta)}{\partial \theta_2^2} = \frac{1}{\theta_2^2} - \frac{(x - \theta_1)^2}{\theta_2^4}$$

$$\frac{\partial^2 \ln f(x; \theta)}{\partial \theta_1 \partial \theta_2} = \frac{-2(x - \theta_1)}{\theta_2^3}$$

$$g_{11} = -E_{\theta} \left(-\frac{1}{\theta_2^2} \right) = \frac{1}{\theta_2^2}, \quad g_{12} = g_{21} = -E_{\theta} \left[-\frac{2(X_1 - \theta_1)}{\theta_2^3} \right] = 0$$

$$g_{22} = -E_{\theta} \left[\frac{1}{\theta_2^2} - \frac{3(X_1 - \theta_1)^2}{\theta_2^4} \right] = -\frac{1}{\theta_2^2} + \frac{3}{\theta_2^4} E(X_1 - \theta_1)^2$$

$$= -\frac{1}{\theta_2^2} + \frac{3}{\theta_2^4} \theta_2^2 = \frac{2}{\theta_2^2}$$

إذن مصفوفة المعلومات الموافقة لملاحظة واحدة:

$$I(\theta) = \begin{vmatrix} 1/\theta_2^2 & 0 \\ 0 & 2/\theta_2^2 \end{vmatrix}$$

والموافقة للعينة X :

$$I(\theta) = nI(\theta) = \begin{vmatrix} n/\theta_2^2 & 0 \\ 0 & 2n/\theta_2^2 \end{vmatrix}$$

تقارين

1. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بواسون $\Pi(\theta)$ ، فهل $T(X) = \sum_{i=1}^{n-1} X_i$ إحصاء كافي لـ θ ؟

2. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $B(1, \theta)$ ، فأثبت أن $T = \sum_{i=1}^n X_i$ إحصاء كافي لـ θ .

3. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع هندسي بمعلمة θ ، فأثبت أن $T = \sum_{i=1}^n X_i$ إحصاء كافي لـ θ .

4. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(2, \theta^2)$ ، فأثبت أن $T(X) = \sum_{i=1}^n (X_i - 2)^2$ إحصاء كاف للمعلمة θ^2 .

5. إذا كانت $X = (X_1, X_2)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta x^{\theta-1}, \quad 0 < x < 1$$

فبين الإحصاء الكافي من الإحصاءات الآتية:

$$X_1 + X_2, \quad X_2 - X_1, \quad X_1, \quad X_1 X_2$$

6. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x; \theta) = e^{2\theta-x}; \quad x \geq 2\theta$$

فأثبت أن $T = X_{(1)}$ إحصاء كاف للمعلمة θ .

7. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x;\theta) = \frac{\theta}{x^2}, \quad x > \theta$$

فهل $T = X_{(1)}$ إحصاء كاف للمعلمة θ ؟

8. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x;\theta) = \frac{2}{\theta^2 - 1} \theta^x; \quad 0 < x < 1, \quad \theta > 1$$

فأوجد إحصاءاً كافياً لـ θ .

9. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\mathcal{L}(\xi) \in \Gamma(\theta, \lambda)$ ،

فأثبت أن $T = \sum_{i=1}^n X_i$ إحصاء تام للمعلمة θ .

10. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, 4\theta^2)$ ، فأثبت

أن $T = (\bar{X}, S^2)$ إحصاء كافي للمعلمة θ لكن غير تام.

11. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع منتظم $R(\theta, 2\theta)$ ،

فأثبت أنه في هذه الحالة لا يوجد الإحصاء الكافي وحيد البعد للمعلمة θ ،

ثم بين أن الإحصاء $T = (X_{(1)}, X_{(n)})$ كاف لكن غير تام للمعلمة θ .

12. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \theta^x (1-\theta)^{1-x}, \quad x = 0, 1, \quad 0 < \theta < 1$$

فأوجد إحصاءاً كافياً للمعلمة θ أولاً ثم أوجد دالة مساهمة العينة X .

13. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x;\theta_1, \theta_2) = \frac{1}{\theta_1} e^{-\frac{x}{\theta_1}}; \quad x > \theta_2, \quad \theta_1 > \theta_2$$

أثبت أن $T = (X_{(1)}, n\bar{X})$ إحصاء كافي للمعلمة $\theta = (\theta_1, \theta_2)$.

14. ليكن المتغير العشوائي الملاحظ X يفترض قيمه في الفئة $[a(\theta), b]$ ، حيث إن $a(\theta)$ دالة مضطردة في θ ، أثبت أن القيمة الصغرى $X_{(1)}$ في العينة $X = (X_1, \dots, X_n)$ تعتبر إحصاءاً كافياً للمعلمة θ عندما فقط عندما تكون لدالة الكثافة $f(x; \theta)$ الشكل:

$$f(x; \theta) = \frac{g(x)}{h(\theta)} \quad ; \quad a(\theta) \leq x \leq b$$

ثم أثبت أن هذه النتيجة تعتبر صحيحة من أجل الإحصاء $X_{(n)}$ وفئة قيم X هي $[a, b(\theta)]$ ، حيث إن $b(\theta)$ دالة مضطردة في θ .

15. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \sigma^2)$ ، فأثبت أن $T = \bar{X}$ إحصاء كاف تام للمعلمة θ ، ثم أوجد دالة مساهمة العينة X .

16. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $R(\theta_1, \theta_2)$ فأثبت أن $T = (X_{(1)}, X_{(2)})$ إحصاء تام للمعلمة $\theta = (\theta_1, \theta_2)$.

17. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x; \theta) = \frac{e^{-\frac{(x-\theta_1)}{\theta_2}}}{\theta_2} \quad ; \quad x \geq \theta_1, \quad \theta = (\theta_1, \theta_2)$$

فأثبت أن $T = (X_{(1)}, \bar{X})$ إحصاء كاف للمعلمة θ .

18. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x; \theta) = e^{-x+\theta} (1 - e^{-x+\theta})^{-2} \quad ; \quad -\infty < x < \infty$$

فأثبت أن دالة المعلومات $i(\theta) = \frac{1}{3}$ ، ثم أوجد $i_n(\theta)$.

19. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x; \theta) = \frac{\ln \theta}{\theta - 1} \theta^x \quad ; \quad 0 < x < 1, \quad \theta > 1$$

فالمطلوب:

1. أوجد إحصاءاً كافياً لـ θ .
 2. أوجد دالة مساهمة العينة X .
 3. احسب معلومات فيشر المتوفرة في العينة X حول θ .
- 20 إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع

$$f(x; \theta) = 2\theta e^{-2\theta x} ; \quad x \geq 0$$

1. أوجد إحصاءاً كافياً لـ θ .
2. أوجد دالة مساهمة العينة X .
3. احسب معلومات فيشر المتوفرة في العينة X وفي الإحصاء الكافي الذي تحصلت عليه في (1).

21 إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(2\theta, \sigma^2)$ فالمطلوب:

1. أوجد إحصاءاً كافياً للمعلمة θ .
2. أوجد دالة مساهمة العينة X .
3. احسب معلومات فيشر المتوفرة في العينة X حول θ .

22 إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\Gamma(\theta, 2)$ ، وكان

$$T = \sum_{i=1}^n X_i \text{ إحصاء تام لـ } \theta, \text{ فأوجد الإحصاء الكافي لـ } \tau(\theta) = 2\theta + 3.$$

خواص مقدرات النقطة

1.5 مقدمة

يهتم علم الإحصاء بدراسة المجتمعات الإحصائية، وفي حالات عدة يقتصر الاهتمام على دراسة صفة مميزة لمفردات المجتمع الإحصائي، التي نغير عنها بمتغير عشوائي حقيقي ξ ، وبمعرفة التوزيع الاحتمالي لـ ξ يمكن الحصول على كافة الميزات العددية المختلفة (المعالم) لمجتمع الصفة المدروسة، وذلك باستخدام طرق نظرية الاحتمالات. وبعبارة أخرى، بمعرفة التوزيع $L(\xi)$ نعلم كل شيء عن المجتمع ξ . لكن عادة في التطبيقات الإحصائية التوزيع $L(\xi)$ غير معلوم، والهدف الرئيسي للمعينة هو الحصول على المعلومات واستخلاص النتائج التي تعتبر الأساس لإعطاء استدلالات حول مجتمع المتغير العشوائي ξ ، أي حول نوع توزيعه ومعامله المختلفة.

لنفترض بناءً على معطيات العينة العشوائية $X = (X_1, \dots, X_n)$ المأخوذة من مجتمع الصفة المدروسة ξ ، أو بناءً على التصورات النظرية لآلية تشكل الصفة ξ واستخدام مبرهنات النهاية المركزية، أمكن معرفة النموذج الإحصائي الذي يخضع له ξ (معرفة عائلة التوزيعات الاحتمالية التي ينتمي إليها توزيع ξ). وبعبارة أخرى، نفترض أن شكل دالة توزيع ξ معلومة وهي $F(x; \theta)$ ، لكنها تعتمد على معلمة غير معلومة θ . يصبح المطلوب هو تقدير القيمة الحقيقية لـ θ الموافقة للتوزيع الاحتمالي لـ ξ .

يمكن التمييز بين نوعين من التقدير: التقدير بنقطة (point estimation) والتقدير بفترة (interval estimation). في حالة التقدير بنقطة تستخدم المعلومات المتوفرة في العينة العشوائية الملاحظة $x = (x_1, \dots, x_n)$ للوصول إلى عدد واحد أو نقطة واحدة تكون تقديراً للمعلمة θ . أما في حالة التقدير بفترة، تستخدم المعلومات المتوفرة في العينة x للوصول إلى عددين أو نقطتين يفترض أن القيمة الحقيقية للمعلمة θ تقع بينهما باحتمال معين.

تعطى التقديرات النقطية عادة بدلالة دالة في مركبات العينة العشوائية X ، التي تدعى بالمقدّر وقيمتها عند عينة مشاهدة x بالتقدير، ولكل معلمة θ مقدرات مختلفة، وبالتالي لا بد من معايير للمفاضلة بينها واختيار أفضلها من أجل تقدير المعلمة θ .

سنعرض في هذا الفصل في إطار نموذج إحصائي للخواص الأساسية التي نرغب تحققها في المقدّر الجيد للمعلمة θ ، أو لدالة لها. وبشكل خاص سنبحث في المقدرات غير المتحيزة (unbiased estimators)، ونعطي الاهتمام الأكبر والأساسي للمقدرات الأكفأ (efficient estimators)، وذلك عندما تكون θ وحيدة البعد أو متعددة الأبعاد.

2.5 التقدير الإحصائي بنقطة

STATISTICAL POINT ESTIMATION

لقد سبق أن تعرضنا لهذا المفهوم في الفصل الثالث. فمثلاً، ذكرنا أن قيمة دالة التوزيع التجريبي في نقطة يمكن اعتبارها تقديراً لقيمة دالة التوزيع النظري في تلك النقطة، وأيضاً تعتبر مميزات عينة عشوائية (الوسط الحسابي، الوسيط، التباين، ... الخ) تقديرات للميزات النظرية الموافقة لها (ثوابت أو معالم المجتمع الذي سحبت منه العينة). ومصطلح "تقدير" (estimation) بني أساساً على أنه من أجل عينة كبيرة الحجم، احتمال أن يكون الفرق كبيراً بين قيم الميزات المختلفة للعينة وقيم

المميزات النظرية الموافقة لها صغير. ولهذا منطقياً (في المتوسط من أجل عينات كبيرة الحجم) اعتبار مميزات العينة المشاهدة كقيم تقريبية جيدة للمميزات النظرية الموافقة، عندما تكون هذه الأخيرة غير معلومة. هكذا، في هذا المصطلح (مصطلح تقدير) يتموضع المدلول المحدد للتقارب. وعند استخدام النظرية الإحصائية في التطبيق غالباً نحتاج لإيجاد القيم التقريبية للمميزات النظرية المختلفة للتوزيع المقترح (معالم الصفة المدروسة ξ) عند أي حجم للعينة، ومنها المحدود.

فيما يلي نفترض لدينا نموذج إحصائي ما (عائلة التوزيعات من نوع معين):

$$F = \{F(x; \theta)\}$$

الموافق لمنظومة تكرارات مستقلة من الملاحظات على متغير عشوائي ما ξ ، كما نفترض شروط الانتظام على النموذج $F(x; \theta)$ محققة، التي تضمن صحة النتائج والإثباتات الموافقة.

لتكن $X = (X_1, \dots, X_n)$ عينة من التوزيع $L(\xi) \in F$. هكذا المعلومة المسبقة عن المتغير العشوائي الملاحظ ξ تتمثل في أن دالة توزيعه $F(x; \theta)$ عضوة في عائلة دوال التوزيع المعلمية المعطاة F ، أي أن شكل (صيغة) دالة توزيع ξ معلوم (إلا أنه يعتمد على المعلمة θ). وبمعرفة قيمة المعلمة θ يتحدد تماماً توزيع ξ . وتصاغ بشكل عام مسألة تقدير المعلمة θ على النحو الآتي: باستخدام المعطيات الإحصائية التي توفرها العينة العشوائية الملاحظة x الوصول إلى تقدير للقيمة الحقيقية ولنرمز لها بـ θ_0 للمعلمة θ غير المعلومة.

ويمكن تلخيص الخطوات المتبعة لإيجاد التقدير النقطي (التقدير بنقطة) للمعلمة المجهولة θ بما يلي:

1. تعيين فئة القيم الممكنة للمعلمة غير المعلومة θ ، وتسمى هذه الفئة عادة بفضاء العينة (parametric space) ونرمز له بـ θ .
2. اختيار الإحصاء المناسب $T = T(X)$ ، الذي قيمته عند ملاحظة معينة

$x = (x_1, \dots, x_2)$ للينة العشوائية X تتخذ كقيمة تقريبية جيدة لـ θ_0 (القيمة الحقيقية لـ θ الموافقة لـ $\mathcal{L}(\xi)$)، وفي هذه الحالة يقال: أن الإحصاء $T = T(X)$ يقدر θ أو الإحصاء T مقدر لـ θ ، وتدعى الدالة $T(X)$ بمقدر (estimator) المعلمة θ ، وقيمتها المحسوبة من بيانات عينة مشاهدة $x = (x_1, \dots, x_2)$ هي $t = T(x)$ تسمى تقدير (estimate) للمعلمة θ .

يوجد، بشكل عام، أكثر من إحصاء يصلح كمقدر لمعلمة التوزيع θ ، أي أن المقدر T لمعلمة θ يمكن أن يأخذ أشكالاً مختلفة. فمثلاً، $T = \sum_{i=1}^n X_i$ ، $T = \prod_{i=1}^n X_i$ ، $T = X_{(n)}$ ، $T = \frac{X_{(n)} - X_{(1)}}{2}$... الخ. إن كل مقدر يفترض فئة من القيم، وهذه الفئة عادة (ليس دائماً) تساوي فئة القيم الممكنة للمعلمة θ ، أي فضاء المعلمة θ ، وإذا رمزنا لفئة القيم الممكنة لـ T بـ \mathcal{S} فإن $\mathcal{S} \subseteq \theta$.


والتساؤل الذي يطرح نفسه الآن: كيف نقارن المقدرات المختلفة لمعلمة θ لاختيار أفضلها؟ فمثلاً، إذا كان $T_1 = T_1(X)$ و $T_2 = T_2(X)$ مقدرين لمعلمة θ ، فأيهما نفضل؟ ولماذا؟.

للإجابة على هذا التساؤل يلزمنا معيار للجودة، وذلك لمقارنة المقدرات المختلفة للمعلمة θ ، وهذا المعيار بدوره ليس بالضرورة وحيداً، بل يمكن استخدام معايير مختلفة مرتبطة بالأهداف التي يبنى المقدر من أجلها، إلا أن أي معيار لجودة مقدر يتحدد بالمقياس المتخذ لقياس قرب قيم المقدر من القيمة الحقيقية θ_0 للمعلمة المقدر. بالإضافة إلى ذلك، نقيده عائلة المقدرات ببعض الشروط. وعلى ذلك، إذا تم تعيين عائلة المقدرات لمعلمة θ في نموذج إحصائي معطى وتم أيضاً اختيار مقياس القرب، فإن المقدر T الذي يوافق أصغر قيمة لذلك المقياس يعتبر الأفضل ضمن هذه العائلة من المقدرات.


كما نعلم أن كل مقدر $T = T(X)$ هو عبارة عن إحصاء، أي هو متغير عشوائي، وبالتالي له توزيع احتمالي نحصل عليه من عينات عشوائية متكررة مسحوبة من توزيع المتغير العشوائي الملاحظ ξ ، ولحسن الحظ تتوفر طرق رياضية

خواص مقدرات النقطة

لاشتقاق مثل هذا التوزيع (توزيع T). لذا، الشرط العام لبناء المقدرات النقطية $T(X)$ يتمثل في شرط التركز (بهذا المفهوم أو ذلك) لتوزيع T حول القيمة الحقيقية للمعلمة المقدرة. وكلما كانت درجة التركز هذه أكبر كلما كان المقدّر أفضل. فمثلا، ليكن المقدّرين $T_1(X)$ و $T_2(X)$ للمعلمة θ ، وتوزيع المعاينة لكل منهما كما هو مبين على الشكلين الآتيين:



شكل (1.2.5)



شكل (2.2.5)

نلاحظ من الشكل (1.2.5) أن:

$$ET_1 \approx \theta \quad , \quad ET_2 \neq \theta$$

وأن معظم قيم T_1 أقرب إلى θ إذا ما قورنت بقيم T_2 . ونلاحظ من الشكل (2.2.5) أن معظم قيم T_1 متمركزة حول θ على عكس قيم T_2 وعلى ذلك فإن المقدّر T_1 أفضل من المقدّر T_2 لتقدير المعلمة θ .

3.5 متوسط مربع الخطأ

MEAN SQUARED ERROR


إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مسحوبة من مجتمع $L(\xi)$ ،
 صيغة دالة توزيعه $F(x; \theta)$ معلومة، لكنها تعتمد على معلمة وحيدة البعد θ غير
 معلومة، وكان $T = T(X)$ مقدراً لـ θ ، فإن المقدار:

$$E_{\theta}(T - \theta)^2$$

يدعى بمتوسط مربع الخطأ (meansquared error) للمقدّر $T = T(X)$ للمعلمة θ أو
 بمتوسط الأخطاء المربعة للمقدّر T ويرمز له بـ $MSE(T)$. وعلى ذلك فإننا نفضل المقدّر
 الذي له أقل متوسط مربع خطأ. فمثلاً، إذا كان T_1, T_2 مقدّرين للمعلمة θ ، فإننا نفضل
 T_1 على T_2 إذا كان:


$$E_{\theta}(T_1 - \theta)^2 < E_{\theta}(T_2 - \theta)^2 \quad ; \quad \forall \theta \in \Theta$$

لكن نادراً ما نجد مقدراً له أقل متوسط مربع خطأ لجميع قيم $\theta \in \Theta$. فمثلاً،
 نادراً ما نجد مثل الحالة المبينة على الشكل (1.3.5).



شكل (1.3.5)

بينما على الغالب تصادفنا حالات من تلك المبينة على الشكل (2.3.5).



شكل (2.3.5)

أي أن T_1 أفضل من T_2 لبعض قيم θ ($\theta < \theta_0$) وأن T_2 أفضل من T_1 لبعض القيم الأخرى لـ θ ($\theta > \theta_0$).

بناءً على ما سبق يجب البحث عن معايير أخرى للمفاضلة بين المقدرات، وهناك بعض الصفات التي نرغب توفرها في المقدّر وهي:

1. الكفاية (sufficiency).

2. عدم التحيز (unbiasedness).

3. الاتساق (consistency).

4. الكفاءة (efficiency).

درسنا في الفصل الرابع الصفة الأولى، وسنتطرق في البنود التالية بشيء من التفصيل لبقية الصفات التي يفضل بشكل عام توفرها في المقدّر الجيد.

4.5 المقدرات غير المتحيزة UNBIASED ESTIMATORS

إذا كان $T = T(X)$ مقدراً لمعلمة θ في نموذج مفروض، فإن متوسط مربع الخطأ:

$$MES(T) = E_{\theta}(T - \theta)^2$$

يمكن كتابته على النحو الآتي:

$$\begin{aligned} E_{\theta}(T - \theta)^2 &= E_{\theta}[(T - E_{\theta}T) + (E_{\theta}T - \theta)]^2 \\ &= E_{\theta}(T - E_{\theta}T)^2 + (E_{\theta}T - \theta)^2 + 2(E_{\theta}T - \theta)E_{\theta}(T - E_{\theta}T) \end{aligned}$$

أي أن:

$$\text{MES}(T) = V_{\theta}T + b^2(\theta) \quad (1.4.5)$$

$$. b(\theta) = (E_{\theta}T - \theta) \quad \text{و} \quad E_{\theta}(T - E_{\theta}T) = E_{\theta}T - E_{\theta}T = 0 \quad \text{لأن}$$

يسمى $b(\theta)$ بمقدار التحيز (biased) في الإحصاء T كمقدّر للمعلمة θ ، وهو يبين الفرق بين متوسط المقدّر T ($E_{\theta}T$) والمعلمة المقدّرة θ [أنظر شكل (1.2.5)].

هكذا، نلاحظ أن متوسط مربع الخطأ لمقدّر T للمعلمة θ عبارة عن تباين المقدّر $V_{\theta}T$ مضافاً إليه مربع التحيز $b^2(\theta)$. وعلى ذلك، فإن متوسط مربع خطأ مقدّر T للمعلمة θ يكون أصغر ما يمكن إذا كان كل من $V_{\theta}T$ و $b^2(\theta)$ أصغر ما يمكن، أي أن قيم المقدّر أقرب ما يمكن من المعلمة θ .

بما أن $b^2(\theta)$ مقدار غير سالب وأصغر قيمة ممكنة له هي الصفر، ويحدث ذلك عندما $E_{\theta}T = \theta$ ، أي أن متوسط T ينطبق على المعلمة θ . وهذا يعني أنه لا يوجد تحيز في المقدّر T (لا توجد أخطاء نظامية)، وعندئذٍ يقال أن T مقدّر غير متحيز (unbiased estimator) للمعلمة θ . وفي هذه الحالة متوسط مربع خطأ المقدّر T مساوٍ لتباينه، أي أن $E_{\theta}(T - \theta)^2 = V_{\theta}T$ [أنظر الشكل (2.2.5)].

تعريف 1.4.5: المقدّر غير المتحيز Unbiased Estimator

يقال عن الإحصاء $T = T(X)$ أنه مقدّر غير متحيز للمعلمة θ (وحيدة البعد)، إذا حقق الشرط:

$$E_{\theta}T = \theta \quad ; \quad \forall \theta \in \theta \quad (2.4.5)$$

وإذا لم يحقق الإحصاء $T = T(X)$ الشرط (2.4.5) فيدعى بالمقدّر المتحيز (biased estimator) للمعلمة θ ، أي أن التقدير يشتمل على أخطاء نظامية.

أحياناً لا يطلب تقدير المعلمة θ فقط، وإنما بشكل عام دالة ما في θ نرمز لها بـ $\tau(\theta)$ وتدعى بدالة المعلمة. وفي هذه الحالة متوسط مربع خطأ المقدّر T لدالة المعلمة $\tau(\theta)$:

$$E_{\theta}[T - \tau(\theta)]^2 = V_{\theta}T + b^2(\theta)$$

حيث $b(\theta) = [E_{\theta}T - \tau(\theta)]$. ويقال أن الإحصاء $T = T(X)$ مقدّر غير متحيز لـ $\tau(\theta)$ ، إذا تحققت العلاقة:

$$E_{\theta}T = \tau(\theta) \quad ; \quad \forall \theta \in \theta \quad (3.4.5)$$

نلاحظ مما سبق أن المقدّر غير المتحيز يعطي إلى حد ما في المتوسط تقديرات مقبولة، لكن هذا لا يعني أن قيم المقدّر غير المتحيز، بشكل عام، تساوي $\tau(\theta)$ أو قريبة منها، وهذا يتوقف على درجة تشتت T حول $\tau(\theta)$ ، أي على تباين المقدّر T [أنظر شكل (2.2.5)]. هذا بالإضافة، كما سنبين لاحقاً، من أجل عائلة المقدرات غير المتحيزة يمكن بناء مبرهنة مفيدة تطبيقياً وسهلة بكفاية، فيها مقياس تركز (دقة) المقدّر عبارة عن تباينه. وهذا يعني أن نختار بين المقدرات غير المتحيزة على أساس تبايناتها ونفضل المقدّر غير المتحيز بأقل تباين.

مثال 1.4.5

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $\mathcal{L}(\xi) \in N(\theta, \sigma^2)$. والمطلوب:

1. أثبت أن المقدرات الآتية للمعلمة θ غير متحيزة:

$$T_1 = \frac{1}{n-1} \sum_{i=1}^{n-1} X_i \quad , \quad T_2 = \frac{1}{2}(\bar{X} + X_1) \quad , \quad T_3 = \frac{1}{3}(\bar{X} + X_1 + X_2)$$

2. أي المقدرات الثلاث T_i ، $i = 1, 2, 3$ أفضل كمقدّر لـ θ .

لإثبات أن مقدّر ما للمعلمة θ غير متحيز، يجب إثبات تحقق العلاقة (2.4.5).

بما أن $E_{\theta}\xi = \theta$ ، نجد:

$$E_{\theta}T_1 = E_{\theta}\left(\frac{1}{n-1} \sum_{i=1}^{n-1} X_i\right) = \frac{1}{n-1} \sum_{i=1}^{n-1} E_{\theta}X_i = \frac{n-1}{n-1}\theta = \theta$$

$$E_{\theta}T_2 = E_{\theta}\left[\frac{1}{2}(\bar{X} + X_1)\right] = \frac{1}{2}(E_{\theta}\bar{X} + E_{\theta}X_1) = \frac{1}{2}(\theta + \theta) = \theta$$

$$E_{\theta}T_3 = E_{\theta}\left[\frac{1}{3}(\bar{X} + X_1 + X_2)\right] = \frac{1}{3}(E_{\theta}\bar{X} + E_{\theta}X_1 + E_{\theta}X_2) = \frac{3\theta}{3} = \theta$$

إذن المقدرات الثلاث غير متحيزة لمتوسط المجتمع θ .

بما أن المقدرات الثلاث غير متحيزة، فإن المقدّر الأفضل هو الذي له أقل

تباين، لذا نحسب التباينات $V_{\theta}T_i$; $i = 1, 2, 3$:

$$V_{\theta}T_1 = V_{\theta}\left(\frac{1}{n-1}\sum_{i=1}^{n-1}X_i\right) = \frac{1}{(n-1)^2}\sum_{i=1}^{n-1}V_{\theta}X_i = \frac{n-1}{(n-1)^2}\sigma^2 = \frac{1}{n-1}\sigma^2$$

$$\begin{aligned} V_{\theta}T_2 &= V_{\theta}\left[\frac{1}{2}(\bar{X} + X_1)\right] = \frac{1}{4}V_{\theta}\left(\frac{1}{n}\sum_{i=2}^nX_i + \frac{n+1}{n}X_1\right) = \\ &= \frac{1}{4}\left(\frac{1}{n^2}\sum_{i=2}^nV_{\theta}X_i + \frac{(n+1)^2}{n^2}V_{\theta}X_1\right) = \frac{1}{4}\left(\frac{n-1}{n^2}\sigma^2 + \frac{(n+1)^2}{n^2}\sigma^2\right) \\ &= \frac{n+3}{4n}\sigma^2 \end{aligned}$$

$$\begin{aligned} V_{\theta}T_3 &= V_{\theta}\left[\frac{1}{3}(\bar{X} + X_1 + X_2)\right] = \frac{1}{9}V_{\theta}(\bar{X} + X_1 + X_2) = \\ &= \frac{1}{9}V_{\theta}\left(\frac{1}{n}\sum_{i=3}^nX_i + \frac{n+1}{n}X_1 + \frac{n+1}{n}X_2\right) = \\ &= \frac{1}{9}\left(\frac{1}{n^2}\sum_{i=3}^nV_{\theta}X_i + \frac{(n+1)^2}{n^2}V_{\theta}X_1 + \frac{(n+1)^2}{n^2}V_{\theta}X_2\right) = \\ &= \frac{1}{9}\left(\frac{(n-2)}{n^2}\sigma^2 + \frac{(n+1)^2}{n^2}\sigma^2 + \frac{(n+1)^2}{n^2}\sigma^2\right) = \frac{(2n+5)}{9n}\sigma^2 \end{aligned}$$

بمقارنة التباينات الثلاث نجد أن تباين المقدّر T_1 هو الأصغر، وبالتالي فهو

المقدّر الأفضل ضمن تلك المقدرات.

مثال 2.4.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع التوزيع الأسّي $\Gamma(1, \theta)$ فالمطلوب:

1. أثبت أن $T_1 = \frac{1}{2}(\bar{X} + X_1)$ مقدر غير متحيز للمعلمة θ واحسب تباينه.

2. أثبت أن $T_2 = \frac{n}{n+1} \bar{X}^2$ مقدر غير متحيز للدالة $\tau(\theta) = \theta^2$.

3. أوجد قيمة c التي تجعل $T_3 = \frac{c}{\bar{X}}$ مقدرًا غير متحيز لـ $\tau(\theta) = \frac{1}{\theta}$.

كما نعلم إذا كان ξ متغيراً عشوائياً خاضعاً للتوزيع $\Gamma(1, \theta)$ فإن كثافة توزيعه الاحتمالية [العلاقة (24.3.2)]:

$$f(x; \theta) = \frac{1}{\theta} e^{-\frac{x}{\theta}} ; \quad x > 0, \theta > 0$$

وأن:

$$E_{\theta} \xi = \theta \quad , \quad E_{\theta} \xi^2 = 2\theta^2 \quad , \quad V_{\theta} \xi = \theta^2$$

وعلى ذلك:

$$E_{\theta} T_1 = \frac{1}{2} E_{\theta} (\bar{X} + X_1) = \frac{1}{2} (E_{\theta} \bar{X} + E_{\theta} X_1) = \frac{1}{2} (\theta + \theta) = \theta$$

أي أن T_1 مقدر غير متحيز للمعلمة θ .

$$V_{\theta} T_1 = \frac{1}{4} V_{\theta} (\bar{X} + X_1) = \frac{1}{4} V_{\theta} \left[\frac{1}{n} \sum_{i=2}^n X_i + \frac{n+1}{n} X_1 \right]$$

$$= \frac{1}{4} \left[\frac{1}{n^2} \sum_{i=2}^n V_{\theta} X_i + \frac{(n+1)^2}{n^2} V_{\theta} X_1 \right]$$

$$= \frac{1}{4} \left[\frac{(n-1)}{n^2} \theta^2 + \frac{(n+1)^2}{n^2} \theta^2 \right] = \frac{n+3}{4n} \theta^2$$

$$E_{\theta} T_2 = \frac{n}{n+1} E_{\theta} \bar{X}^2 = \frac{n}{n+1} \left[V_{\theta} \bar{X} + (E \bar{X})^2 \right] = \frac{n}{n+1} \left(\frac{\theta^2}{n} + \theta^2 \right)$$

$$= \frac{n}{n+1} \frac{n+1}{n} \theta^2 = \theta^2$$

وهذا يعني أن T_2 مقدر غير متحيز لـ $\tau(\theta) = \theta^2$.
نلاحظ أن:

$$T_3 = \frac{c}{\bar{X}} = \frac{nc}{\sum X_i} = \frac{nc}{Y} \quad ; \quad Y = \sum_{i=1}^n X_i$$

وكما أشرنا سابقاً [مبرهنة (4.3.2)]، فإن المتغير العشوائي Y يخضع للتوزيع $\Gamma(n; \theta)$ ، أي أن:

$$h(y, \theta) = \frac{1}{\theta^n \Gamma(n)} y^{n-1} e^{-y/\theta} \quad , \quad y > 0$$

ومنها نجد:

$$E_\theta \left(\frac{1}{Y} \right) = \frac{1}{\theta^n \Gamma(n)} \int_0^\infty \frac{1}{y} y^{n-1} e^{-y/\theta} d\theta = \frac{1}{\theta^n \Gamma(n)} \int_0^\infty y^{n-2} e^{-y/\theta} d\theta$$

وبوضع $z = \frac{y}{\theta}$ نحصل على:

$$\begin{aligned} E_\theta \left(\frac{1}{Y} \right) &= \frac{1}{\theta^n \Gamma(n)} \int_0^\infty (\theta z)^{n-2} e^{-z} d\theta \\ &= \frac{1}{\theta^n \Gamma(n)} \theta^{n-1} \int_0^\infty z^{n-2} e^{-z} dz = \frac{1}{\theta^n \Gamma(n)} \theta^{n-1} \Gamma(n-1) = \frac{1}{n-1} \frac{1}{\theta} \end{aligned}$$

وعلى ذلك فإن:

$$E_\theta \left(\frac{c}{\bar{X}} \right) = E_\theta \left(\frac{nc}{Y} \right) = nc E_\theta \left(\frac{1}{Y} \right) = \frac{nc}{n-1} \frac{1}{\theta}$$

ولكي يكون $T_3 = \frac{c}{\bar{X}}$ مقدرًا غير متحيز لـ $\tau(\theta) = \frac{1}{\theta}$ ، يجب أن يتحقق شرط عدم التحيز (3.4.5)، أي أن:

$$\frac{cn}{(n-1)\theta} = \frac{1}{\theta}$$

ومنها نجد:

$$c = \frac{n-1}{n}$$

أي أن:

$$T_3 = \frac{n-1}{n\bar{X}} = \frac{n-1}{\sum_{i=1}^n X_i}$$

مثال 3.4.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يخضع لتوزيع بيرنولي $B(1, \theta)$ ، فالمطلوب:

1. بين أي من المقدرات الآتية لـ θ غير متحيز، ثم أوجد مقدار التحيز للمقدرات المتحيزة:

$$T_1 = 2\bar{X} - X_1, \quad T_2 = \bar{X} + X_1, \quad T_3 = \frac{X_1 + X_2}{2}, \quad T_4 = \frac{\bar{X}}{2}$$

2. ما هو المقدّر الأفضل من بين المقدرات غير المتحيزة؟

كما نعلم، إذا كان ξ متغير عشوائي خاضع لتوزيع $B(1, \theta)$ ، فإن:

$$f(x; \theta) = \theta^x (1 - \theta)^{1-x}; \quad x = 1, 2, \quad 0 < \theta < 1$$

$$E_0 \xi = \theta, \quad V_0 \xi = \theta(1 - \theta)$$

وعلى ذلك:

$$E_0 T_1 = E_0 (2\bar{X} - X_1) = 2E_0 \bar{X} - EX_1 = 2\theta - \theta = \theta$$

$$E_0 T_2 = E_0 (\bar{X} + X_1) = E_0 \bar{X} + EX_1 = \theta + \theta = 2\theta \neq \theta; \quad b(\theta) = 2\theta - \theta = \theta$$

$$E_0 T_3 = E_0 \left(\frac{X_1 + X_2}{2} \right) = \frac{1}{2} E_0 X_1 + \frac{1}{2} E_0 X_2 = \frac{1}{2} \theta + \frac{1}{2} \theta = \theta$$

$$E_0 T_4 = \frac{1}{2} E \bar{X} = \frac{1}{2} \theta \neq \theta; \quad b(\theta) = E_0 T_4 - \theta = \frac{1}{2} \theta - \theta = -\frac{1}{2} \theta$$

وهذا يعني أن كل من المقدرين T_1, T_3 غير متحيز، بينما كل من T_2, T_4

متحيز.

لنحسب الآن التباينات:

$$\begin{aligned}
 V_{\theta}T_1 &= V_{\theta}(2\bar{X} - X_1) = V_{\theta}\left(\frac{2}{n}\sum_{i=2}^n X_i - \frac{n-2}{n}X_1\right) \\
 &= \frac{4}{n^2}\sum_{i=2}^n V_{\theta}X_i + \frac{(n-2)^2}{n^2}V_{\theta}X_1 = \frac{4(n-1)}{n^2}[\theta(1-\theta)] + \frac{(n-2)^2}{n^2}[\theta(1-\theta)] \\
 &= \frac{4(n-1) + (n-2)^2}{n^2}[\theta(1-\theta)] = \theta(1-\theta)
 \end{aligned}$$

$$\begin{aligned}
 V_{\theta}T_2 &= V_{\theta}(\bar{X} + X_1) = V_{\theta}\left(\frac{1}{n}\sum_{i=2}^n X_i + \frac{n+1}{n}X_1\right) \\
 &= \frac{n-1}{n^2}[\theta(1-\theta)] + \frac{(n+1)^2}{n^2}[\theta(1-\theta)] = \frac{n+3}{n}[\theta(1-\theta)]
 \end{aligned}$$

$$V_{\theta}T_3 = V_{\theta}\left(\frac{X_1 + X_2}{2}\right) = \frac{1}{4}(V_{\theta}X_1 + V_{\theta}X_2) = \frac{1}{2}\theta(1-\theta)$$

$$\begin{aligned}
 V_{\theta}T_4 &= V_{\theta}\left(\frac{\bar{X}}{2}\right) = \frac{1}{4}V_{\theta}\bar{X} = \frac{1}{4}V_{\theta}\left(\frac{1}{n}\sum_{i=1}^n X_i\right) \\
 &= \frac{1}{4n^2}\sum_{i=2}^n V_{\theta}X_i = \frac{n}{4n^2}[\theta(1-\theta)] = \frac{1}{4n}[\theta(1-\theta)]
 \end{aligned}$$

مقارنة تباين المقدرين غير المتحيزين T_1, T_3 نجد أن تباين T_3 أقل من تباين T_1 مهما تكن $\theta \in \theta = (0,1)$ ، وبالتالي فالمقدر T_3 الأفضل لتقدير θ .

إذا كان T مقدرًا غير متحيز لمعلمة θ ، فإن قيمته عند عينة مشاهدة $x = (x_1, \dots, x_n)$ تدعى بتقدير غير متحيز لـ θ .

كما أشرنا سابقاً، أن المقدر غير المتحيز T لـ $\tau(\theta)$ (كحالة خاصة $\tau(\theta) = \theta$) يعطي إلى حد ما في المتوسط تقديرات معقولة، لكن هذا لا يعني بالضرورة أن قيمة T عن عينة مشاهدة تساوي $\tau(\theta)$ أو قريبة منها، وهذا يتعلق بدرجة تشتت T حول $\tau(\theta)$ ، أي على تباينه. وبعبارة أخرى، على درجة تجانس قيم T . وبناءً على ذلك يجب عدم التمسك والمبالغة في قيمة صفة عدم التحيز (unbiasedness)، حيث يمكن أن يكون شرط عدم التحيز قاسياً في بعض

الحالات ويؤدي إلى نتائج غير مرغوبة. بالإضافة إلى ذلك يمكن أن تكون المقدرات غير المتحيزة لدالة معلمية $\tau(\theta)$ (ومنها $\tau(\theta) = \theta$) من أجل نموذج مفروض غير موجود إطلاقاً، وفي حالات أخرى، بالرغم من أنها موجودة، لكنها تطبيقياً غير مفيدة. لنوضح ذلك من خلال المثالين التاليين:

مثال 4.4.5

لتكن X عينة عشوائية حجمها $n = 1$ ، مأخوذة من توزيع $\mathcal{L}(\xi) \in \Pi(\theta)$ ، ويطلب إيجاد المقدّر غير المتحيز لـ $\tau(\theta) = \frac{1}{\theta}$.

إذا كان $T(X)$ مقدراً غير متحيز لـ $\tau(\theta)$ ، فإن الشرط (3.4.5) يكتب على النحو الآتي:

$$\sum_{x=0}^{\infty} T(x) \frac{\theta^x}{x!} e^{-\theta} = \frac{1}{\theta} ; \quad \forall \theta \in \Theta = (0, \infty)$$

أو

$$\sum_{x=0}^{\infty} T(x) \frac{\theta^{x+1}}{x!} = e^{\theta} = \sum_{r=0}^{\infty} \frac{\theta^r}{r!} ; \quad \forall \theta \in (0, \infty)$$

ومن الواضح أن الدالة $T(X)$ المحققة للشرط الأخير والمستقلة عن θ غير موجودة (شرط الاستقلال عن θ يكمن في تعريف المقدّر لأنه إحصاء)، أي أن المقدّر غير المتحيز لـ $\tau(\theta)$ في الحالة المفروضة غير موجود.

مثال 5.4.5

لتكن X عينة عشوائية بحجم $n = 1$ ، مأخوذة من توزيع $\mathcal{L}(\xi) \in \bar{B}(1, \theta)$ ويطلب إيجاد المقدّر غير المتحيز لـ $\tau(\theta) = \theta$.
بتطبيق العلاقة (2.4.5) نجد:

$$\sum_{x=0}^{\infty} T(x) \theta^x = \frac{\theta}{1 - \theta} = \sum_{r=1}^{\infty} \theta^r ; \quad \forall \theta \in (0, 1)$$

و بمساواة الأمثال (المعاملات) حسب درجة θ ، نلاحظ أن المقدّر غير المتحيز الوحيد لـ θ في هذه الحالة يتمثل في الإحصاء:

$$T(X) = \begin{cases} 0 & ; \quad X = 0 \\ 1 & ; \quad X \geq 1 \end{cases}$$

لكن قيمتي هذا الإحصاء لا يتبعان لفضاء العينة $\theta = (0,1)$ للنموذج المعطى. لذا مثل هذا المقدّر عملياً غير مفيد.

يبين هذان المثالان، أنه ليس بالضرورة دائماً البحث فقط عن المقدّرات غير المتحيزة. بل أحياناً وكما يبين المثال التالي، إن المقدّر ذو التحيز الصغير $b(\theta)$ ومتوسط مربع الخطأ صغير (تحيز صغير وتباين صغير) أفضل من مقدّر غير متحيز ذو تباين كبير لتقدير دالة $\tau(\theta)$.

مثال 6.4.5

لتكن $X = (X_1, \dots, X_n)$ عينة من توزيع $\mathcal{L}(\xi) \in N(\theta_1, \theta_2^2)$ ، حيث $n \geq 2$. ويطلب تقدير $\tau(\theta) = \tau(\theta_1, \theta_2^2) = \theta_2^2$ ؛ $\theta = (\theta_1, \theta_2^2)$

نجد من العلاقة (1.7.3)، إذا كان $S^2 = S^2(X)$ تباين العينة فإن $E_\theta(S^2) = \frac{n-1}{n}\theta_2^2 \neq \theta_2^2$ ، أي أنه مقدّر متحيز لـ $\tau(\theta) = \theta_2^2$. وعلى ذلك فإن المقدّر غير المتحيز لـ $\tau(\theta) = \theta_2^2$ هو:

$$S^{*2} = \frac{n}{n-1}S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (4.4.5)$$

وحسب المبرهنة (5.9.3)، نجد:

$$\mathcal{L}_\theta \left(\frac{n-1}{\sigma^2} S^{*2} \right) = \chi_{(n-1)}^2$$

وبالتالي حسب العلاقة (32.3.2):

$$E_{\theta} \left(\frac{n-1}{\theta_2^2} S^{*2} \right) = (n-1) \quad , \quad V_{\theta} \left(\frac{n-1}{\theta_2^2} S^{*2} \right) = 2(n-1)$$

أو

$$E_{\theta}(S^{*2}) = \theta_2^2 \quad , \quad V_{\theta}(S^{*2}) = \frac{2}{n-1} \theta_2^4 \quad (5.4.5)$$

سنبين فيما بعد (فقرة 4.7.5)، حسب معيار أقل تباين، أن المقدّر S^{*2} يعتبر الأفضل ضمن كل المقدرات غير المتحيزة للدالة $\tau(\theta) = \theta_2^2$ في معلمي النموذج $N(\theta_1, \theta_2^2)$ ، أي أن تباينه المعطى بالعلاقة (5.4.5) أصغر من تباين أي مقدر غير متحيز آخر لـ $\tau(\theta) = \theta_2^2$ وذلك مهما تكن $\theta \in \Theta$.

لنبحث الآن في عائلة المقدرات من الشكل $T_{\lambda} = \lambda S^{*2}$ ، حيث λ عدد حقيقي. بما أن $E_{\theta} T_{\lambda} = \lambda E_{\theta}(S^{*2})$ ، فيوجد في هذه العائلة مقدر غير متحيز وحيد لـ $\tau(\theta) = \theta_2^2$ وهو S^{*2} ، أي الموافق لـ $\lambda = 1$.

لنحسب متوسط مربع الخطأ لمقدر ما $T_{\lambda} \neq S^{*2}$ ، أي $\lambda \neq 1$:

$$\begin{aligned} E_{\theta}(T_{\lambda} - \theta_2^2)^2 &= E_{\theta} \left[\lambda(S^{*2} - \theta_2^2) + (\lambda - 1)\theta_2^2 \right]^2 \\ &= \lambda^2 V_{\theta}(S^{*2}) + (\lambda - 1)^2 \theta_2^4 \end{aligned}$$

من ذلك، وحسب العلاقة (5.4.5) نجد:

$$E_{\theta}(T_{\lambda} - \theta_2^2)^2 = \left[\frac{2\lambda^2}{n-1} + (\lambda - 1)^2 \right] \theta_2^4 = \varphi(\lambda) \theta_2^4$$

تبلغ الدالة $\varphi(\lambda)$ قيمة صغرى عندما $\lambda^* = \frac{n-1}{n+1}$ وتساوي

$$\varphi(\lambda^*) = \frac{2}{n+1} .$$

وبأخذ العلاقة (5.4.5) بعين الاعتبار، نجد:

$$E_{\theta}(T_{\lambda^*} - \theta_2^2)^2 = \frac{2}{n+1} \theta_2^4 < \frac{2}{n-1} \theta_2^4 = E_{\theta}(S^{*2} - \theta_2^2)^2$$

هكذا، وفق معيار متوسط مربع الخطأ، عندما $n \geq 2$ ، فإن المقدّر المتحيز

$$T_{\lambda}^* = \lambda^* S^{*2} = \frac{n-1}{n+1} \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n+1} \sum_{i=1}^n (X_i - \bar{X})^2$$

الذي انحرافه (تحيزه) $b(\theta) = (E_0 T_{\lambda}^* - \theta_2^2) = -\frac{2}{n+1} \theta_2^2$ صغير عندما يكون حجم العينة n كبيراً بشكل كافٍ، يعتبر مقدراً أفضل من المقدّر غير المتحيز S^{*2} لـ $\theta_2^2 = \tau(\theta)$ في المعلمة θ_2^2 للنموذج $N(\theta_1, \theta_2^2)$. وهذا يعني غالبية قيم T_{λ}^* أقرب إلى القيمة الحقيقية لـ θ_2^2 من قيم S^{*2} المناظرة لها.

يبين هذا المثال، أنه لا يمكن اعتبار معيار مقارنة المقدّرات وحيداً، كما لا يوجد مقدّر وحيد لمعلمة مفروضة، يلائم كل الحالات.

5.5 المقدرات المتسقة CONSISTENT ESTIMATORS

يبدو لنا بوضوح من تعريف العينة العشوائية أن المقدّر المبني على أساس عينة تحوي n قياساً (أو ملاحظة) مثلاً يجب أن يكون أفضل بشكل عام، من المقدّر المبني على أساس عينة عشوائية تحوي عدداً أقل من n . ولإيضاح الفكرة أكثر، لنفترض أن T_1 مقدّر للمعلمة θ في مجتمع معطى مبني على عينة حجمها $n=1$ ، أي تحوي ملاحظة أو قياساً واحداً للمتغير العشوائي الملاحظ X ، وليكن T_2 مقدراً لنفس المعلمة مبنياً على أساس عينة عشوائية حجمها $n=2$ ، وبشكل عام لنفترض أن T_n هو مقدّر لـ θ مبني على أساس عينة حجمها n ، أي أن $T_1, T_2, \dots, T_n, \dots$ متتالية من المقدّرات لـ θ نرمز لها بـ $\{T_n\}$. تعني الفكرة السابقة أن المتتالية $\{T_n\}$ تتقارب احتمالياً إلى θ (أو تنتهي احتمالياً إلى θ) عندما $n \rightarrow \infty$ ، ولهذا يهمنا معرفة سلوك المقدّر T_n بازدياد حجم العينة.

تعريف 1.5.5: المقدّر المتسق

يقال عن مقدّر T_n لدالة معلمية $\tau(\theta)$ أنه متسق، إذا كان من أجل أي مقدار ε صغير موجب:

$$\lim_{n \rightarrow \infty} P[|T_n - \tau(\theta)| < \varepsilon] = 1 \quad (1.5.5)$$

وعندما $\tau(\theta) = \theta$ فالعلاقة (1.5.5) تكتب على النحو الآتي:

$$\lim_{n \rightarrow \infty} P[|T_n - \theta| < \varepsilon] = 1$$

أو

$$\lim_{n \rightarrow \infty} P[|T_n - \theta| \geq \varepsilon] = 0$$

وهذا يعني أن الإحصاء T_n يكون مقدراً متسقاً لـ $\tau(\theta)$ إذا اقترب من $\tau(\theta)$ بازدیاد حجم العينة n ، أي أن T_n يتقارب بالاحتمال (coversges in probability) من $\tau(\theta)$.

مثال 1.5.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع التوزيع $\mathcal{L}(\xi) \in N(\theta, \sigma^2)$ ، فهل $T_n = \bar{X}$ مقدّر متسق للمعلمة θ ؟
كما نعلم:

$$\mathcal{L}(X_i) \in N(\theta, \sigma^2) \quad ; \quad i = 1, \dots, n$$

$$\mathcal{L}(\bar{X}) \in N\left(\theta, \frac{\sigma^2}{n}\right)$$

ومن ثم:

$$\mathcal{L}\left(\frac{\bar{X} - \theta}{\sigma/\sqrt{n}}\right) = N(0,1)$$

لنحسب الآن:

$$\begin{aligned}
 P_{\theta}(|\bar{X} - \theta| > \varepsilon) &= 1 - P_{\theta}(|\bar{X} - \theta| \leq \varepsilon) \\
 &= 1 - P_{\theta}(-\varepsilon \leq \bar{X} - \theta \leq \varepsilon) \\
 &= 1 - P_{\theta}\left(-\frac{\varepsilon\sqrt{n}}{\sigma} \leq \frac{\bar{X} - \theta}{\sigma/\sqrt{n}} \leq \frac{\varepsilon\sqrt{n}}{\sigma}\right) \\
 &= 2 - 2\Phi\left(\frac{\varepsilon\sqrt{n}}{\sigma}\right)
 \end{aligned}$$

حيث أن $\Phi(z)$ دالة التوزيع الطبيعي المعياري $N(0,1)$. وبأخذ نهاية الطرفين عندما $n \rightarrow \infty$ نجد:

$$\lim_{n \rightarrow \infty} P(|\bar{X} - \theta| > \varepsilon) = 2 - 2\Phi(\infty) = 2 - 2 = 0$$

وحسب التعريف (1.5.5) فإن $T_n = \bar{X}$ مقدر متسق للمعلمة θ . وبما أن $E_{\theta}\bar{X} = \theta$ ، فإن $T_n = \bar{X}$ مقدر غير متحيز لـ θ . وهذا يعني أن المقدر المتسق يمكن أن يكون غير متحيز أيضاً.

إذا كان $T_n = T_n(X)$ مقدرًا متسقًا لـ $\tau(\theta)$ ، فأية قيمة ملاحظة له $t = T_n(x)$ تدعى بالتقدير المتسق (consistent estimate) لـ $\tau(\theta)$.

في حالات عدة تكون المبرهنة التالية مفيدة للتأكد من أن مقدرًا ما T_n متسق لـ $\tau(\theta)$ ، حيث أن طريقة التأكد من أن إحصاء ما متسق بتطبيق العلاقة (1.5.5) تكون أحياناً عملية صعبة.

مبرهنة 1.5.5

إذا كان T_n مقدرًا لـ $\tau(\theta)$ وحقق الشرط:

$$\lim_{n \rightarrow \infty} E_{\theta}[T_n - \tau(\theta)]^2 = 0 \quad (2.5.5)$$

فإن T_n مقدر متسق لـ $\tau(\theta)$.

إن الشرط المذكور في المبرهنة كافٍ وليس ضرورياً، أي إذا كان المقدّر T_n متسقاً ليس بالضرورة محققاً للشرط (2.5.5)، لكن العكس صحيح. والإثبات شبيه بإثبات متباينة تشيبيشيف. لنفترض للتبسيط أن $\tau(\theta) = \theta$ ، وعندئذٍ:

$$\begin{aligned} E_{\theta}(T_n - \theta)^2 &= \int_{-\infty}^{+\infty} (t - \theta)^2 f(t) dt = \\ &= \int_{-\infty}^{\theta - \delta} (t - \theta)^2 f(t) dt + \int_{\theta - \delta}^{\theta + \delta} (t - \theta)^2 f(t) dt + \int_{\theta + \delta}^{+\infty} (t - \theta)^2 f(t) dt \end{aligned}$$

ولدينا في التكاملين الأول والثالث $(t - \theta)^2 \geq \delta^2$ والتكامل الثاني غير سالب، إذن:

$$\begin{aligned} E_{\theta}(T_n - \theta)^2 &\geq \int_{-\infty}^{\theta - \delta} (t - \theta)^2 f(t) dt + \int_{\theta + \delta}^{+\infty} (t - \theta)^2 f(t) dt \geq \\ &\geq \delta^2 [P_{\theta}(T_n \leq \theta - \delta) + P_{\theta}(T_n \geq \theta + \delta)] = \delta^2 P_{\theta}(|T_n - \theta| \geq \delta) \end{aligned}$$

وعلى ذلك نجد:

$$P_{\theta}(|T_n - \theta| \geq \delta) \leq \frac{E(T_n - \theta)^2}{\delta^2}$$

بما أن الطرف الأيمن في هذه المتباينة ينتهي، حسب الفرض، إلى الصفر عندما $n \rightarrow \infty$ ، بالإضافة إلى أن الاحتمال لا يمكن أن يكون سالباً، فإن:

$$\lim_{n \rightarrow \infty} P_{\theta}(|T_n - \theta| \geq \delta) = 0$$

أي أن T_n مقدّر متسق لـ θ .

بما أن $E_{\theta}(T_n - \theta)^2 = V_{\theta}T_n + b^2(\theta)$ ، فإن تحقق الشرط (2.5.5) يكافئ تحقق الشرطين:

$$\lim_{n \rightarrow \infty} V_{\theta}T_n = 0$$

$$\lim_{n \rightarrow \infty} b^2(\theta) = 0 \Leftrightarrow \lim_{n \rightarrow \infty} E_{\theta}T_n = \theta$$

(3.5.5)

وهذا يعني أن كل مقدر متسق غير متحيز تقاربياً.

إذا كان T_n مقدر غير متحيز لـ θ فإن الشرط الثاني في (3.5.5) محقق، وبالتالي يكفي التأكد من أن تباينه ينتهي إلى الصفر عندما $n \rightarrow \infty$ لكي يكون مقدرًا متسقًا. أي نقول عن مقدر غير متحيز T_n لـ θ أنه متسق أيضاً إذا كان:

$$\lim_{n \rightarrow \infty} V_{\theta} T_n = 0$$

مثال 2.5.5

إذا كان X متغيراً عشوائياً يتبع توزيع ذي الحدين $B(n, \theta)$ ، فإن $T_n = \frac{X}{n}$ مقدر متسق للمعلمة θ ، حيث X عدد النجاحات في n تكرار بيرنولي.

بما أن $\mathcal{L}(X) \in B(n, \theta)$ ، فإن:

$$f(x; \theta) = C_n^x \theta^x (1 - \theta)^{n-x}, \quad x = 0, 1, \dots, n$$

وعلى ذلك نجد:

$$E_{\theta} T_n = \frac{1}{n} E_{\theta} X = \frac{1}{n} n\theta = \theta$$

وبالتالي T_n مقدر غير متحيز للمعلمة θ ، وكذلك فإن:

$$V_{\theta} T_n = \frac{1}{n^2} V_{\theta} X = \frac{1}{n^2} n\theta(1 - \theta) = \frac{\theta(1 - \theta)}{n}$$

وعلى ذلك نجد:

$$\lim_{n \rightarrow \infty} V_{\theta} T_n = 0.$$

وبما أن المقدر T_n غير متحيز وتباينه ينتهي إلى الصفر عندما $n \rightarrow \infty$ ، فحسب المبرهنة (1.5.5) يكون T_n مقدرًا متسقًا للمعلمة θ .

مثال 3.5.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مسحوبة من مجتمع يتبع توزيع

كوشي بالمعلمة θ ، أي أن:

$$f(x;\theta) = \frac{1}{\pi[1+(x-\theta)^2]}, \quad -\infty < x < +\infty$$

فإن متوسط العينة $T_n = \bar{X}$ يعتبر مقدرًا غير متسق للمعلمة θ .

كما نعلم أن توزيع متوسط العينة يخضع بدوره لتوزيع كوشي، أي أن:

$$f(\bar{x};\theta) = \frac{1}{\pi[1+(\bar{x}-\theta)^2]}, \quad -\infty < \bar{x} < +\infty$$

ولكي يكون $T_n = \bar{X}$ مقدرًا متسقًا لـ θ يجب أن يكون:

$$\lim_{n \rightarrow \infty} P_\theta(|\bar{X} - \theta| \leq \varepsilon) = 1$$

وبوضع $Y = \bar{X} - \theta$ نجد:

$$P_\theta(|\bar{X} - \theta| \leq \varepsilon) = P_\theta(|Y| \leq \varepsilon)$$

$$= \frac{1}{\pi} \int_{-\varepsilon}^{\varepsilon} \frac{dy}{1+y^2} = \frac{2}{\pi} \tan^{-1} y \Big|_0^\varepsilon$$

بما أن هذا المقدار مستقل عن حجم العينة، أي أن $P_\theta(|\bar{X} - \theta| \leq \varepsilon)$ لا يتأثر

بزيادة قيمة n ، فإن $T_n = \bar{X}$ مقدر غير متسق لـ θ .

بشكل عام، فإن متوسط العينة $T_n = \bar{X}$ المأخوذة من مجتمع متوسطه θ

وتباينه منتهي يعتبر مقدرًا متسقًا لـ θ [راجع مبرهنة تشيبيشيف (1.3.1)].

مثال 4.5.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع توزيع منتظم

$R(0, \theta)$ و $T_n = X_{(n)}$ ، فال المطلوب:

1. هل T_n مقدر متسق للمعلمة θ ؟

2. هل T_n مقدر غير متحيز للمعلمة θ ؟

بتطبيق العلاقة (3.10.3) نجد أن توزيع المعاينة للإحصاء $Y = X_{(n)}$ هو:

$$h(y; \theta) = \frac{ny^{n-1}}{\theta^n} \quad ; \quad 0 < y < \theta$$

بما أن:

$$\begin{aligned} P_{\theta}(|Y - \theta| > \varepsilon) &= P_{\theta}[(Y - \theta) < -\varepsilon] + P_{\theta}[(Y - \theta) > \varepsilon] \\ &= P_{\theta}(Y < \theta - \varepsilon) + P_{\theta}(Y > \theta + \varepsilon) \end{aligned}$$

و $P_{\theta}(Y > \theta + \varepsilon) = 0$ لأن Y تأخذ قيمها في الفترة $(0, \theta)$ ، فإن:

$$P_{\theta}(|Y - \theta| > \varepsilon) = P_{\theta}(Y < \theta - \varepsilon) = \int_0^{\theta - \varepsilon} \frac{ny^{n-1}}{\theta^n} dy = \left(\frac{\theta - \varepsilon}{\theta}\right)^n$$

بأخذ نهاية الطرفين عندما $n \rightarrow \infty$ نجد:

$$\lim_{n \rightarrow \infty} P_{\theta}(|Y - \theta| > \varepsilon) = \lim_{n \rightarrow \infty} \left(\frac{\theta - \varepsilon}{\theta}\right)^n = 0$$

أي أن $Y = X_{(n)}$ مقدر متسق للمعلمة θ . وحيث أن:

$$E_{\theta}Y = \frac{n\theta}{n+1} \neq \theta$$

فهذا يعني أن المقدّر $Y = X_{(n)}$ متسق لكن متحيز، وبالتالي فالمقدّر المتسق ليس بالضرورة غير متحيز.

مثال 5.5.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $\mathcal{D}(\xi) \in \Gamma(1, \theta)$ ، فإن $T_n = X_{(1)}$ مقدر غير متحيز للمعلمة θ ، لأن:

$$EX_{(1)} = \frac{1}{\theta} \int_0^{\infty} e^{-x/\theta} dx = \theta \int_0^{\infty} e^{-x/\theta} dx = \theta$$

إلا أنه غير متسق لأنه لا يعتمد على حجم العينة n ، أي لا يتأثر بزيادة n . وهذا يعني أن المقدّر غير المتحيز ليس بالضرورة متسقاً.

THE EFFICIENT ESTIMATOR

6.5 المقدّر الأكفأ

لا يجوز بناءً على الملاحظات السابقة اعتبار صفة عدم التحيز (unbiasedness) شرطاً لا بد من تحققه في أي مقدر، ومع ذلك ففي كثير من الحالات التي نصادفها في التطبيق يكون هذا الشرط (صفة عدم التحيز) منطقياً ومبرراً، ولهذا سيتم البحث لاحقاً وبشكل خاص في المقدرات غير المتحيزة.

ليكن المطلوب تقدير دالة معلمية معطاة $\tau(\theta)$ للمعلمة θ في عائلة التوزيعات $\mathcal{F} = \{F(x; \theta) ; \theta \in \Theta\}$ بناءً على معطيات العينة العشوائية $\mathbf{X} = (X_1, \dots, X_n)$ المسحوبة من مجتمع توزيعه ينتمي لهذه العائلة، ولنفترض وجود مقدرات غير متحيزة لـ $\tau(\theta)$ في المسألة المطروحة، أي وجود إحصاءات $T = T(\mathbf{X})$ محققة للشرط (3.4.5). لنرمز لعائلة المقدرات غير المتحيزة لـ $\tau(\theta)$ بـ U_τ ، أي أن $T \in U_\tau$ عندما المقدر T يحقق الشرط (3.4.5). بالإضافة لذلك نفترض أن تباينات المقدرات $T \in U_\tau$ محدودة، أي أن:

$$V_\theta T = E_\theta [T - \tau(\theta)]^2 < \infty ; \quad \forall \theta \in \Theta$$

يمكن في هذه الحالة قياس جودة المقدرات $T \in U_\tau$ بمقدار تبايناتها، ونحصل بذلك على مقياس بسيط لمقارنة المقدرات غير المتحيزة.

إذا كان T^* ، T مقدرين من العائلة U_τ ، وكان:

$$V_\theta T^* \leq V_\theta T ; \quad \forall \theta \in \Theta \quad (1.6.5)$$

فحسب مقياس أقل تباين بانتظام (وفق المعلمة θ) للمقدر T^* ، يعتبر هذا الأخير مقدرًا ليس أسوأ من المقدر T . وإذا تحققت المساواة الصارمة في العلاقة (1.6.5) من أجل قيمة واحدة على الأقل لـ θ ، فيتطلب ذلك إعطاء المقدر T^* الأفضلية كمقدر أكثر دقة لتقدير $\tau(\theta)$ بالمقارنة مع المقدر T . ويقال عندئذ أن T^* أفضل من T (الأكفأ نسبيًا relatively efficient) في تقدير $\tau(\theta)$.

تعريف 1.6.5 المقدر الأكفأ نسبياً Relatively Efficient Estimator

إذا كان كل من T و T^* مقدر غير متحيز لـ $\tau(\theta)$ ، وكانت المتباينة (1.6.5) محققة مهما تكن $\theta \in \Theta$ ، بالإضافة إلى تحقق المتباينة الصارمة من أجل قيمة واحدة على الأقل لـ θ ، فيقال أن T^* الأكفأ نسبياً من T لتقدير $\tau(\theta)$.

وتقاس الكفاءة النسبية للمقدر T^* مقارنة بـ T بالنسبة بين تباينهما

$$e = \frac{V_{\theta} T^*}{V_{\theta} T} \leq 1 \quad ; \quad \forall \theta \in \Theta \quad (2.6.5)$$

مثال 1.6.5

إذا كانت $X = (X_1, X_2, X_3, X_4)$ عينة عشوائية من توزيع $\mathcal{L}(\xi) \in \Gamma(1, \theta)$ وكان:

$$T_1 = X_1 \quad , \quad T_2 = \frac{(X_1 + X_2)}{2} \quad , \quad T_3 = \frac{(X_1 + X_2 + X_3)}{3} \quad , \quad T_4 = \bar{X}$$

فالمطلوب:

1. ما هو المقدر الأكفأ بين المقدرات T_i ، $i = 1, 2, 3, 4$ لـ θ ؟
2. احسب الكفاءة النسبية للمقدر الأكفأ مقارنة ببقية المقدرات الأخرى.

بما أن $\mathcal{L}(\xi) \in \Gamma(1, \theta)$ ، فإن:

$$E_{\theta} \xi = \theta \quad , \quad V_{\theta} \xi = \theta^2$$

وعلى ذلك:

$$E_{\theta} X_i = \theta \quad , \quad V_{\theta} X_i = \theta^2 \quad , \quad i = 1, 2, 3, 4$$

ومن ثم:

$$E_{\theta} T_1 = E_{\theta} X_1 = \theta \quad , \quad E_{\theta} T_2 = \frac{1}{2}(E_{\theta} X_1 + E_{\theta} X_2) = \theta$$

$$E_{\theta} T_3 = \frac{1}{3}(E_{\theta} X_1 + E_{\theta} X_2 + E_{\theta} X_3) = \theta \quad , \quad E_{\theta} T_4 = E_{\theta} \bar{X} = \theta$$

1. ما هو المقدّر الأكفأ بين المقدّرات T_i , $i = 1, 2, 3, 4$ لـ θ ؟
2. احسب الكفاءة النسبية للمقدّر الأكفأ مقارنة ببقية المقدّرات الأخرى.

بما أن $\mathcal{L}(\xi) \in \Gamma(1, \theta)$ ، فإن:

$$E_{\theta}\xi = \theta \quad , \quad V_{\theta}\xi = \theta^2$$

وعلى ذلك:

$$E_{\theta}X_i = \theta \quad , \quad V_{\theta}X_i = \theta^2 \quad , \quad i = 1, 2, 3, 4$$

ومن ثم:

$$E_{\theta}T_1 = E_{\theta}X_1 = \theta \quad , \quad E_{\theta}T_2 = \frac{1}{2}(E_{\theta}X_1 + E_{\theta}X_2) = \theta$$

$$E_{\theta}T_3 = \frac{1}{3}(E_{\theta}X_1 + E_{\theta}X_2 + E_{\theta}X_3) = \theta \quad , \quad E_{\theta}T_4 = E_{\theta}\bar{X} = \theta$$

وعلى ذلك فإن الإحصاءات T_i , $i = \overline{1, 4}$ مقدرات غير متحيزة لـ θ . وبالتالي فالمقدّر الأكفأ لتقدير $\tau(\theta) = \theta$ ضمن تلك المقدّرات هو المقدّر الذي له أصغر تباين (smallest variance)، لذا يجب حساب التباينات:

$$V_{\theta}T_1 = \theta^2 \quad , \quad V_{\theta}T_2 = \frac{\theta^2}{2} \quad , \quad V_{\theta}T_3 = \frac{\theta^2}{3} \quad , \quad V_{\theta}T_4 = \frac{\theta^2}{4}$$

نلاحظ أن

$$V_{\theta}T_4 < V_{\theta}T_3 < V_{\theta}T_2 < V_{\theta}T_1$$

وهذا يعني أن T_4 هو المقدّر الأكفأ ضمن هذه المجموعة من المقدّرات.

تقاس الكفاءة النسبية للمقدّر T_4 بالمقارنة مع كل من المقدّرات T_1, T_2, T_3 كالآتي:

$$\frac{V_{\theta}T_4}{V_{\theta}T_1} = \frac{\theta^2/4}{\theta^2} = 0.25 \quad , \quad \frac{V_{\theta}T_4}{V_{\theta}T_2} = \frac{\theta^2/4}{\theta^2/2} = 0.5 \quad , \quad \frac{V_{\theta}T_4}{V_{\theta}T_3} = \frac{\theta^2/4}{\theta^2/3} = \frac{3}{4} = 0.75$$

وربما توجد مقدرات غير متحيزة أخرى لـ θ أفضل (أكفأ) من المقدّر T_4 .

هكذا، يعتبر المقدّر $T^* \in U_\tau$ الأكفأ لتقدير $\tau(\theta)$ إذا حقق الشرط:

$$V_\theta T^* = \inf_{T \in U_\tau} V_\theta T \quad ; \quad \forall \theta \in \Theta \quad (3.6.5)$$

نلاحظ أن المقدّر الأكفأ T^* ليس بالضرورة موجوداً دائماً ضمن عائلة المقدرات غير المتحيزة U_τ لـ $\tau(\theta)$. حيث يمكن وجود مقدرين $T_1, T_2 \in U_\tau$ بحيث أن T_1 يوافق أصغر تباين ضمن عائلة المقدرات غير المتحيزة من أجل قيمة (أو قيم) معينة لـ $\theta \in \Theta$ ، بينما T_2 يوافق أصغر تباين ضمن عائلة المقدرات U_τ من أجل قيمة (أو قيم) أخرى لـ $\theta \in \Theta$. في مثل هذه الحالات، مقارنة المقدرات باستخدام مقياس واحد (التباين الأصغر) غير ممكنة. إلا أن الشرط (3.6.5) يبرز وبشكل وحيد المقدّر الأكفأ لـ $\tau(\theta)$ ضمن عائلة المقدرات غير المتحيزة U_τ ، إذا وجد مثل هذا المقدّر. وهذا ما تؤكدته المبرهنة التالية.

مبرهنة 1.6.5

إذا وجد المقدّر الأكفأ ضمن عائلة المقدرات غير المتحيزة U_τ لـ $\tau(\theta)$ ، فإنه يكون وحيداً (unique).

الإثبات

تعني المبرهنة أنه إذا كان كل من T_1 و T_2 مقدر غير متحيز بأقل تباين بانتظام في Θ لـ $\tau(\theta)$ (مقدر أكفأ لـ $\tau(\theta)$)، فإن $T_1 = T_2$ ، أي أن:

$$P_\theta(X \in \{x : T_1(x) \neq T_2(x)\}) = 0 \quad ; \quad \forall \theta \in \Theta$$

لنفترض أن لدينا مقدرًا جديدًا هو:

$$T_3 = \frac{T_1 + T_2}{2}$$

من الواضح أن:

$$E_\theta T_3 = \frac{1}{2}(E_\theta T_1 + E_\theta T_2) = \tau(\theta) \quad ; \quad \forall \theta \in \Theta$$

لأنه حسب الفرض T_1, T_2 مقدرين غير متحيزين لـ $\tau(\theta)$ ، أي أن:

$$E_{\theta}T_1 = E_{\theta}T_2 = \tau(\theta) \quad ; \quad \forall \theta \in \theta$$

وبالتالي فإن T_3 مقدر غير متحيز لـ $\tau(\theta)$.
كما أن:

$$\begin{aligned} V_{\theta}T_3 &= \frac{1}{4} V_{\theta}(T_1 + T_2) = \frac{1}{4} [V_{\theta}T_1 + V_{\theta}T_2 + 2\text{cov}_{\theta}(T_1, T_2)] \\ &= \frac{1}{4} [V_{\theta}T_1 + V_{\theta}T_2 + 2\rho\sqrt{V_{\theta}T_1 \times V_{\theta}T_2}] \quad ; \quad \forall \theta \in \theta \end{aligned}$$

بفرض T_1, T_2 غير مستقلين. وحسب الفرض:

$$V_{\theta}T_1 = V_{\theta}T_2 \quad ; \quad \forall \theta \in \theta$$

إذن:

$$V_{\theta}T_3 = \frac{1}{2}(1+\rho)V_{\theta}T_1 \quad ; \quad \forall \theta \in \theta$$

وحيث أننا نفترض أن T_1 مقدر أكفأ لـ $\tau(\theta)$ ، فإن:

$$V_{\theta}T_3 \geq V_{\theta}T_1 \quad ; \quad \forall \theta \in \theta$$

إذن

$$\frac{1}{2}(1+\rho)V_{\theta}T_1 \geq V_{\theta}T_1 \quad ; \quad \forall \theta \in \theta$$

أي أن

$$\frac{1+\rho}{2} \geq 1 \Rightarrow \rho \geq 1 \Rightarrow \rho = 1$$

لأنه كما نعلم معامل الارتباط $|\rho| \leq 1$. وهذا يعني وجود علاقة خطية بين المقدرين T_1, T_2 ، أي يمكن أن نكتب:

$$T_2 = a + bT_1 \quad ; \quad b > 0 \quad \dots(1)$$

وعلى ذلك فإن:

$$E_{\theta}T_2 = a + bE_{\theta}T_1 \Rightarrow \tau(\theta) = a + b\tau(\theta) \Rightarrow a = \tau(\theta)(1 - b) \dots (2)$$

و

$$V_{\theta}T_2 = b^2V_{\theta}T_1 \Rightarrow b^2 = 1 \Rightarrow b = 1$$

وبوضع $b = 1$ في العلاقة (2) نجد $a = 0$ ، وبالتالي فإن $T_1 = T_2$ وهو المطلوب.

مثال 2.6.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع التوزيع $L(\xi) \in B(1, \theta)$ ، فأثبت أن $T^* = T^*(X) = \bar{X}$ المقدّر الأكفأ للمعلمة θ .

بما أن:

$$f(x; \theta) = \theta^x(1 - \theta)^{1-x}, \quad x = 0, 1$$

فإن $V_{\theta}\xi = \theta(1 - \theta)$ ، $E_{\theta}\xi = \theta$ ، ومن ثم $E_{\theta}T^* = E_{\theta}\bar{X} = \frac{1}{n} \sum_{i=1}^n E_{\theta}X_i = \theta$ ، وهذا يعني أن $T^* = \bar{X}$ مقدّر غير متحيز للمعلمة θ .

وتبليين T^*

$$V_{\theta}T^* = V_{\theta}\bar{X} = \frac{1}{n^2} \sum_{i=1}^n V_{\theta}X_i = \frac{\theta(1 - \theta)}{n}$$

لنفترض الآن أن T مقدّر ما آخر غير متحيز لـ θ ، ولثبت تحقق العلاقة (1.6.5)، أي تحقق المتباينة:

$$V_{\theta}T \geq \frac{\theta(1 - \theta)}{n}; \quad \forall \theta \in \Theta = (0, 1) \dots (1)$$

بما أن توزيع المتغير العشوائي الملاحظ ξ يخضع لتوزيع بيرنولي، فإن توزيع العينة العشوائية $X = (X_1, \dots, X_n)$ يعطى بالاحتمالات:

$$L(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i; \theta) = \theta^{n\bar{x}} (1-\theta)^{n(1-\bar{x})} \quad \dots(2)$$

وكما نعلم:

$$1 \equiv \sum_{\mathbf{x}} L(\mathbf{x}; \theta) \quad , \quad \theta \equiv E_{\theta} T = \sum_{\mathbf{x}} t L(\mathbf{x}; \theta)$$

فباستقار هاتين المتطابقتين بالنسبة لـ θ ، نجد:

$$0 \equiv \sum_{\mathbf{x}} \frac{\partial L(\mathbf{x}; \theta)}{\partial \theta} = \sum_{\mathbf{x}} \frac{\partial \ln L(\mathbf{x}; \theta)}{\partial \theta} L(\mathbf{x}; \theta) = E_{\theta} \left(\frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right)$$

و

$$1 \equiv \sum_{\mathbf{x}} t \frac{\partial L(\mathbf{x}; \theta)}{\partial \theta} = \sum_{\mathbf{x}} t \frac{\partial \ln L(\mathbf{x}; \theta)}{\partial \theta} L(\mathbf{x}; \theta) = E_{\theta} \left(T(\mathbf{X}) \frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right)$$

لأن

$$\frac{\partial \ln L(\mathbf{x}; \theta)}{\partial \theta} = \frac{1}{L} \frac{\partial L(\mathbf{x}; \theta)}{\partial \theta}$$

وعلى ذلك يمكن كتابة:

$$\begin{aligned} 1 &\equiv E_{\theta} \left[T(\mathbf{X}) \frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right] - E_{\theta} \left[\frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right] \\ &= E_{\theta} \left\{ [T(\mathbf{X}) - \theta] \frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right\} = \text{cov}_{\theta} \left[T(\mathbf{X}), \frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right] \\ &= \rho \left[V_{\theta} T \times V_{\theta} \left(\frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right) \right]^{1/2} \end{aligned}$$

ومن ثم:

$$\rho^2 \left[V_{\theta} T \times V_{\theta} \left(\frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right) \right] = \rho^2 \left[V_{\theta} T \times E_{\theta} \left(\frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right)^2 \right] = 1$$

أي أن:

$$V_{\theta} T \times E_{\theta} \left(\frac{\partial \ln L(\mathbf{X}; \theta)}{\partial \theta} \right)^2 \geq 1$$

لأن معامل الارتباط ρ بالقيمة المطلقة لا يتجاوز الواحد، وبالتالي:

$$V_{\theta}T \geq \frac{1}{E_{\theta} \left(\frac{\partial \ln L(X; \theta)}{\partial \theta} \right)^2} ; \quad \forall \theta \in (0,1) \quad \dots(3)$$

بأخذ لوغاريتم الطرفين في (2) والاشتقاق بالنسبة لـ θ ، نجد:

$$\begin{aligned} \ln L(x; \theta) &= n\bar{x} \ln \theta + n(1 - \bar{x}) \ln(1 - \theta) \\ \frac{\partial \ln L(x; \theta)}{\partial \theta} &= \frac{n\bar{x}}{\theta} - \frac{n(1 - \bar{x})}{1 - \theta} = \frac{n(\bar{x} - \theta)}{\theta(1 - \theta)} \end{aligned}$$

وعلى ذلك:

$$\begin{aligned} V_{\theta} \left[\frac{\partial \ln(X; \theta)}{\partial \theta} \right] &= E_{\theta} \left[\frac{\partial \ln(X; \theta)}{\partial \theta} \right]^2 = \frac{n^2}{\theta^2(1 - \theta)^2} V_{\theta}(\bar{X} - \theta) \\ &= \frac{n^2}{\theta^2(1 - \theta)^2} \frac{\theta(1 - \theta)}{n} = \frac{n}{\theta(1 - \theta)} \quad \dots(4) \end{aligned}$$

وبالتعويض في المتباينة (3) نجد:

$$V_{\theta}T \geq \frac{1}{n/\theta(1 - \theta)} = \frac{\theta(1 - \theta)}{n}$$

أي أن المتباينة (1) محققة [المتباينة (1.6.5) محققة]. وهذا يعني أن المقدّر T^* هو الأكفأ لتقدير المعلمة $\theta = \tau(\theta)$.

لأهمية نموذج بيرنولي $B(1, \theta)$ في التطبيق نصيغ النتيجة المثبتة بشكل مبرهنة.

مبرهنة 2.6.5

يعتبر التكرار النسبي لظهور الحاد A في n تكراراً مستقلاً المقدّر الأكفأ لاحتمال هذا الحاد.

نشير كنتيجة لهذه المبرهنة إلى أن قيمة دالة التوزيع التجريبي $F_n^*(x)$ ، عند كل نقطة x (عدد حقيقي x)، تعتبر التقدير الأكفأ لدالة التوزيع النظري $F(x)$ (دالة توزيع المتغير العشوائي الملاحظ x) عند هذه النقطة. سنبرهن فيما يلي على خاصية هامة من خواص المقدّر الأكفأ.

مبرهنة 3.6.5

إذا كان المقدّر الأكفأ لتقدير $\tau_1(\theta)$ و T_2^* المقدّر الأكفأ لتقدير $\tau_2(\theta) \neq \tau_1(\theta)$ ، فعندئذ الإحصاء $T^* = a_1 T_1^* + a_2 T_2^*$ يعتبر المقدّر الأكفأ للدالة $\tau(\theta) = a_1 \tau_1(\theta) + a_2 \tau_2(\theta)$ مهما يكن الثابتان a_1, a_2 .

الإثبات

لنثبت أولاً الخاصية الهامة التالية للمقدّر الأكفأ:

إذا كان $\psi = \psi(X)$ إحصاء قيمته المتوقعة:

$$E_\theta \psi = 0 \quad ; \quad \forall \theta \in \theta$$

فإن:

$$\text{cov}(T_i^*, \psi) = 0 \quad ; \quad \forall \theta \in \theta, \quad i = 1, 2 \quad (4.6.5)$$

لإثبات ذلك، لناخذ $\tilde{T}_i = T_i^* + \lambda \psi$. نلاحظ بسهولة أن \tilde{T}_i مقدّر غير متحيز لـ $\tau_i(\theta)$ مهما تكن λ ، لأن:

$$E_\theta \tilde{T}_i = E_\theta T_i^* + \lambda E_\theta \psi = E T_i^* = \tau_i \quad ; \quad \theta \in \theta$$

وبما أن T_i^* المقدّر الأكفأ لـ $\tau_i(\theta)$ ، فإن:

$$V_\theta \tilde{T}_i = V_\theta T_i^* + \lambda^2 V_\theta \psi + 2\lambda \text{cov}(T_i^*, \psi) \geq V_\theta T_i^* \quad ; \quad \theta \in \theta \quad \dots(1)$$

أي أن:

$$\lambda^2 V_\theta \psi + 2\lambda \text{cov}(T_i^*, \psi) \geq 0$$

وبحل هذه المتباينة بالنسبة لـ λ نجد:

$$-\frac{|\text{cov}(T_i^*, \psi)|}{V_\theta \psi} - \frac{\text{cov}_\theta(T_i^*, \psi)}{V_\theta \psi} \leq \lambda \leq + \frac{|\text{cov}_\theta(T_i^*, \psi)|}{V_\theta \psi} - \frac{\text{cov}(T_i^*, \psi)}{V_\theta \psi}$$

وهذا يعني: إما:

$$\text{cov}(T_i^*, \psi) = 0 \quad , \quad \forall \theta \in \theta$$

وهو الحل المقبول، أو:

$$-\frac{|\text{cov}(T_i^*, \psi)|}{V_\theta \psi} - \frac{\text{cov}_\theta(T_i^*, \psi)}{V_\theta \psi} < \lambda < + \frac{|\text{cov}_\theta(T_i^*, \psi)|}{V_\theta \psi} - \frac{\text{cov}(T_i^*, \psi)}{V_\theta \psi}$$

وعندئذٍ $V_\theta \tilde{T}_i^* < V_\theta T_i^*$ وهذا يتعارض مع المتباينة (1)، وبالتالي فهو حل مرفوض.

لنفترض الآن أن T مقدر ما غير متحيز لـ $\tau(\theta)$ و $\psi = T^* - T$. وبما أن $E_\theta \psi = E_\theta T^* - E_\theta T = 0$ ، فحسب الخاصة السابقة نجد:

$$\begin{aligned} 0 &= \text{cov}_\theta(T^*, \psi) = \text{cov}(T^*, T^* - T) = E_\theta(T^* - \tau)(T^* - T) \\ &= E_\theta(T^* - \tau)[(T^* - \tau) - (T - \tau)] \\ &= E_\theta(T^* - \tau)^2 - E_\theta(T^* - \tau)(T - \tau) \\ &= V_\theta T^* - \text{cov}_\theta(T^*, T) \end{aligned}$$

أي أن:

$$[V_\theta T^*]^2 = [\text{cov}_\theta(T^*, T)]^2 = \rho^2 V_\theta T^* V_\theta T \leq V_\theta T^* V_\theta T$$

وبالتالي:

$$V_\theta T^* \leq V_\theta T \quad ; \quad \forall \theta \in \theta$$

وهذا يعني أن T^* المقدر الأكفأ لـ $\tau(\theta)$ وهو المطلوب إثباته.

7.5 معايير كفاءة المقدرات المبنية على متباينة كرامر وراو وتعميماتها

هناك العديد من المعالم أو الدوال المعلمية في الإحصاء التي يوجد لها مقدرات غير متحيزة بأقل تباين (المقدر الأكفأ). وسنبحث في هذا البند المعايير العامة لوجود المقدر الأكفأ لدالة في معلمة وحيدة البعد $\tau(\theta)$ وطرق إيجادها.

نفترض كالعادة $f(x; \theta)$ كثافة الاحتمال (أو دالة الاحتمال في حالة المنقطع) للمتغير العشوائي الملاحظ ξ ، $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع $\mathcal{L}(\xi) \in \mathcal{F} = \{F(x; \theta); \theta \in \Theta\}$ و $x = (x_1, \dots, x_n)$ قيمة مشاهدة لـ X . وتحقق النماذج \mathcal{F} شروط الانتظام \mathcal{F} preregularity conditions.

1.7.5 متباينة كرامر وراو والمقدر الأكفأ

Cramer-Roa Inequality and Efficient Estimator

سنناقش مسألة تقدير دالة معلمة معطاة $\tau(\theta)$ في معلمة (وحيدة البعد) نموذج $F(x; \theta)$. نفترض أن النموذج $F(x; \theta)$ نظامي والدالة $\tau(\theta)$ قابلة للاشتقاق بالنسبة θ ، و U_τ عائلة المقدرات غير المتحيزة لـ $\tau(\theta)$. عندئذٍ المبرهنة التالية صحيحة.

مبرهنة 1.7.5: متباينة كرامر وراو Cramer-Roa Inequality

من أجل أي مقدر $T = T(X) \in U_\tau$ ، فالمتباينة:

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{ni(\theta)} \quad \forall \theta \in \Theta \quad (1.7.5)$$

محقة. وتحقق المساواة (1.7.5) إذا كان المقدر T دالة خطية في مساهمة العينة من الشكل:

$$T(\mathbf{X}) - \tau(\theta) = \alpha(\theta)U(\mathbf{X}; \theta) \quad (2.7.5)$$

حيث أن $\alpha(\theta)$ دالة ما في المعلمة θ .

الإثبات

حسب الفرض $T \in U_\tau$ ، أي أن:

$$E_\theta T = \int_{R^n} T(\mathbf{x})L(\mathbf{x}; \theta)d\mathbf{x} = \tau(\theta) \quad ; \quad \forall \theta \in \Theta \quad (3.7.5)$$

وباشتقاق الطرفين بالنسبة لـ θ (وهذا ممكن لأن $F(\mathbf{x}; \theta)$ نموذج نظامي حسب الفرض) نجد:

$$\begin{aligned} \tau'(\theta) &= \int T(\mathbf{x}) \frac{\partial L(\mathbf{x}; \theta)}{\partial \theta} d\mathbf{x} = \int T(\mathbf{x}) \frac{\partial \ln L(\mathbf{x}; \theta)}{\partial \theta} L(\mathbf{x}; \theta) d\mathbf{x} \\ &= E_\theta [T(\mathbf{X})U(\mathbf{X}; \theta)] = \text{cov}_\theta [T(\mathbf{X})U(\mathbf{X}; \theta)] \end{aligned} \quad (4.7.5)$$

لأن $E_\theta U(\mathbf{X}; \theta) = 0$ [العلاقة (3.6.4)].

ولكن:

$$\text{cov}_\theta [T(\mathbf{X}), U(\mathbf{X}; \theta)] = \rho \sqrt{V_\theta T(\mathbf{X})V_\theta U(\mathbf{X}; \theta)} \leq \sqrt{V_\theta T(\mathbf{X})V_\theta U(\mathbf{X}; \theta)} \quad (5.7.5)$$

لأن $|\rho| \leq 1$.

بناءً على العلاقتين (4.7.5) و (5.7.5) نجد:

$$[\tau'(\theta)]^2 \leq V_\theta T(\mathbf{X})V_\theta U(\mathbf{X}; \theta) = i_n(\theta)V_\theta T(\mathbf{X})$$

لأن $V_\theta U(\mathbf{X}; \theta) = E_\theta [U(\mathbf{X}; \theta)]^2 = i_n(\theta)$ [راجع العلاقة (1.7.4)]. وبالتالي:

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{[\tau'(\theta)]^2}{ni(\theta)} \quad ; \quad \forall \theta \in \Theta$$

تؤول المتباينة في (5.7.5) إلى مساواة، إذا كانت العلاقة بين $T(X)$ و $U(X; \theta)$ خطية، أي أن $|\rho| = 1$ ، وعندئذ:

$$V_0 T = \frac{[\tau'(\theta)]^2}{ni(\theta)} \quad ; \quad \forall \theta \in \theta$$

يمكن كتابة العلاقة الخطية بين T و $U(X; \theta)$ على الصورة:

$$T(X) = a(\theta)U(X; \theta) + c(\theta)$$

ويأخذ التوقع الرياضي (القيمة المتوقعة) للطرفين نجد أن:

$$\tau(\theta) = c(\theta)$$

وبالتالي يمكن كتابة:

$$T(X) - \tau(\theta) = a(\theta)U(X; \theta)$$

وهو المطلوب.

تدعى المتباينة (1.7.5) بمتباينة كرامر وراو (Cramer-Roa Inequality) وهي تعين الحد الأدنى لتباين المقدرات غير المتحيزة (lower bound of the variance of unbiased estimators) للدالة المعلمية $\tau(\theta)$ المعطاة في معلمة نموذج نظامي.

لقد تم إثبات المبرهنة (1.7.5) باعتبار أن التوزيع $f(x; \theta)$ مستمر، ويمكن إثبات صحتها في حالة التوزيعات المنقطعة باستبدال التكامل بالمجموع، وهذا يعني أن المبرهنة (1.7.5) يمكن تطبيقها في حالة التوزيعات مستمرة كانت أم منقطعة.

ملاحظة

إذا كان $T = T(X)$ مقدر ما متحيز لـ $\tau(\theta)$ ومقدار تحيزه $b(\theta)$ قابل للاشتقاق بالنسبة θ ، فباستخدام المطابقة:

$$E_{\theta}T(\mathbf{X}) = \int_{R^n} T(\mathbf{x})L(\mathbf{x};\theta)d\mathbf{x} = \tau(\theta) + b(\theta) \quad ; \quad \forall \theta \in \Theta$$

بدلاً من المطابقة (3.7.5). وبإجراء مناقشة مشابهة لحالة مقدر غير متحيز، نجد:

$$V_{\theta}T \geq \frac{[\tau'(\theta) + b'(\theta)]^2}{ni(\theta)} \quad ; \quad \forall \theta \in \Theta$$

وهي تعميم للمتبينة (1.7.5)، أي تعطي الحد الأدنى لتباين المقدرات المتحيزة وغير المتحيزة لـ $\tau(\theta)$ (الحد الأدنى لتباين مقدر (lower bound of variance of an estimator)).

مبرهنة 2.7.5

إذا وجد مقدر $T^* \in U_{\tau}$ لتقدير $\tau(\theta)$ ، تباينه يساوي الحد الأدنى لتباينة كرامر وراو (5.7.5)، أي أن:

$$V_{\theta}T^* = \frac{[\tau'(\theta)]^2}{ni(\theta)} \quad , \quad \forall \theta \in \Theta \quad (7.7.5)$$

فإن T^* المقدر الأكفأ لتقدير $\tau(\theta)$ ، ويدعى للتمييز أحياناً بالمقدر الأمثل.

نلاحظ من تعريف المقدر الأمثل والمقدر الأكفأ لتقدير $\tau(\theta)$ ، بأن المقدر الأمثل هو الأكفأ في نفس الوقت، لكن العكس ليس بالضرورة صحيحاً. وهذا ما سنوضحه في أمثلة لاحقة. ونخلص من المبرهنة (2.7.5) إلى أن معيار الأمثلية لمقدر تقدير $\tau(\theta)$ يتمثل في تحقيق العلاقة (7.7.5)، وإذا وجد مقدر أمثل لدالة $\tau(\theta)$ فهو وحيد حسب المبرهنة (1.6.5)، لاعتبار المقدر الأمثل هو مقدر أكفأ أيضاً لـ $\tau(\theta)$. ويطلق على المعيار (7.7.5) لكفاءة مقدر معيار كرامر وراو.

إذا كان T^* المقدر الأمثل لـ $\tau(\theta)$ ، أي أن:

$$T^* - \tau(\theta) = a(\theta)U(\mathbf{X};\theta)$$

ومن ثم:

$$U(X; \theta) = \frac{T^* - \tau(\theta)}{\alpha(\theta)}$$

وبالتعويض في العلاقة (4.7.5)، نجد:

$$\begin{aligned} \tau'(\theta) &= \text{cov}[T^*(X), U(X; \theta)] = E_0[(T^* - \tau)U(X; \theta)] \\ &= E_0\left[(T^* - \tau)\left(\frac{T^* - \tau}{\alpha(\theta)}\right)\right] = \frac{1}{\alpha(\theta)} E_0(T^* - \tau)^2 = \frac{1}{\alpha(\theta)} V_0 T^* \end{aligned}$$

وعلى ذلك فإن تباين المقدّر الأمثل T^* لتقدير $\tau(\theta)$ يساوي:

$$V_0 T^* = \alpha(\theta) \tau'(\theta) \quad (8.7.5)$$

تجدر الإشارة هنا إلى الخاصة الهامة الآتية: بما أن مساهمة العينة $U(X; \theta)$ تُعَيَّن وبشكل وحيد بدلالة النموذج $F(x; \theta)$ ، لذا الصيغة (2.7.5) إن وجدت فهي وحيدة. وهذا يعني إذا وجد مقدّر أمثل T^* لدالة معلمية $\tau(\theta)$ ، فلا يوجد مقدّر أمثل من أجل أي دالة معلمية أخرى في θ مختلفة عن $\alpha\tau(\theta) + b$ ، حيث a و b ثوابت.

يمكن إثبات صحة هذه الخاصة بسهولة. لنفترض T^* المقدّر الأمثل لـ $\tau(\theta)$ و T_1^* المقدّر الأمثل لـ $\tau_2(\theta) = f(\tau)$ ؛ $\tau_2 \neq \tau$ حيث أن θ معلمة (وحيدة البعد) التوزيع $F(x; \theta)$ ، أي أن:

$$V_0 T^* = \frac{[\tau'(\theta)]^2}{i_n(\theta)} \quad , \quad V_0 T_1^* = \frac{[f'_\tau \tau'(\theta)]^2}{i_n(\theta)}$$

وعلى ذلك فإن:

$$\frac{f'^2_\tau}{V_0 T_1^*} = \frac{1}{V_0 T^*}$$

ولا يمكن أن تتحقق هذه المساواة إلا إذا كانت T_1^* دالة خطية في T^* ، أي أن $T_1^* = aT^* + b$ (حيث a و b ثوابت). وهذا يعني:

$$\tau_2(\theta) = a\tau(\theta) + b$$

مثال 1:7.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0$$

فالمطلوب:

1. أوجد الحد الأدنى لتباين المقدرات غير المتحيزة لـ $\tau(\theta) = \theta$.

2. أثبت أن المقدّر $T^* = \bar{X}$ هو المقدّر الأمثل لتقدير $\tau(\theta) = \frac{1}{\theta}$.

كما نعلم من المثال (2.7.5) أن $i_n(\theta) = \frac{n}{\theta^2}$ ، وعندما $\tau(\theta) = \theta$ فإن $\tau'(\theta) = 1$ ، وبالتالي الحد الأدنى لتباين المقدرات غير المتحيزة لـ θ يعطي بالحد الأدنى لتباينة كرامر وراو:

$$V_{\theta} T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{1}{n/\theta^2} = \frac{\theta^2}{n} \quad ; \quad \theta > 0, T \in U_{\tau}$$

أي أن الحد الأدنى هو $\frac{\theta^2}{n}$.

ولإثبات أن المقدّر $T^* = \bar{X}$ هو المقدّر الأمثل لـ $\tau(\theta)$ ، يلزمنا أولاً حساب $E_{\theta} T^*$ و $V_{\theta} T^*$.

كما نعلم أن التوزيع $f(x; \theta)$ عبارة عن حالة خاصة من توزيع جاما $\Gamma(\alpha, \beta)$ الموافق لـ $\alpha = 1, \beta = \frac{1}{\theta}$ [راجع الفقرة (5.3.2)]. وبالتالي حسب العلاقة (25.3.2)، وبوضع $\frac{1}{\theta}$ بدلاً من θ نجد:

$$E_{\theta}X_i = \frac{1}{\theta} \quad , \quad V_{\theta}X_i = \frac{1}{\theta^2} \quad ; \quad i = \overline{1, n}$$

وعلى ذلك:

$$E_{\theta}\bar{X} = \frac{1}{\theta} \quad , \quad V_{\theta}\bar{X} = \frac{1}{n\theta^2}$$

أي أن $T^* = \bar{X}$ مقدر غير متحيز لـ $\tau(\theta) = \frac{1}{\theta}$. وأن تباينه ينطبق على الحد الأدنى

لمتباينة كرامر وراو

$$\frac{[\tau'(\theta)]}{i_n(\theta)} = \frac{1/\theta^2}{1/\theta^2} = \frac{1}{n\theta^2}$$

وهذا يعني أن $T^* = \bar{X}$ المقدر الأمثل وأيضاً الأكفأ لتقدير $\tau(\theta) = \frac{1}{\theta}$.

مثال 2.7.5

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع التوزيع $L(\xi) \in \Gamma(2, \theta)$ ونرغب في إيجاد الحد الأدنى لتباين المقدرات غير المتحيزة لكل من:

$$\theta \quad , \quad \frac{1}{1+\theta} \quad , \quad \ln \theta$$

بما أن:

$$f(x; \theta) = \frac{1}{\theta^2} x e^{-x/\theta} \quad ; \quad x > 0$$

$$L(x; \theta) = \theta^{-2n} \prod_{i=1}^n x_i e^{-\frac{x_i}{\theta}}$$

$$\ln L(x; \theta) = -2n \ln \theta + \sum_{i=1}^n \ln x_i - \frac{1}{\theta} \sum_{i=1}^n x_i$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = -\frac{2n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i$$

$$\frac{\partial^2 \ln L(x; \theta)}{\partial^2 \theta} = +\frac{2n}{\theta^2} - \frac{2}{\theta^3} \sum_{i=1}^n x_i$$

فإن معلومات فيشر المتوفرة في العينة X حول المعلمة θ :

$$\begin{aligned} i_n(\theta) &= E_\theta \left[-\frac{\partial^2 \ln L(x; \theta)}{\partial^2 \theta} \right] = E_\theta \left(-\frac{2n}{\theta^2} + \frac{2}{\theta^3} \sum_{i=1}^n X_i \right) \\ &= -\frac{2n}{\theta^2} + \frac{2}{\theta^3} \sum_{i=1}^n E_\theta X_i = -\frac{2n}{\theta^2} + \frac{2}{\theta^3} (2n\theta) = \frac{2n}{\theta^2} \end{aligned}$$

لأن $E_\theta X_i = 2\theta$ [راجع العلاقة (23.3.2)، حيث $\alpha = 2$ ، $\beta = \theta$]. وكما نعلم، الحد الأدنى لتباين المقدّر غير المتحيزة لـ $\tau(\theta)$ يعطى بالحد الأدنى لتباينة كرامر وراو، وبالتالي:

$$1. \quad \text{الحد الأدنى لتباين المقدّرات غير المتحيزة لـ } \tau(\theta) = \theta$$

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{1}{2n/\theta^2} = \frac{\theta^2}{2n}$$

$$2. \quad \text{الحد الأدنى لتباين المقدّرات غير المتحيزة لـ } \tau(\theta) = \frac{1}{1+\theta}$$

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{1/(1+\theta)^4}{2n/\theta^2} = \frac{\theta^2}{2n(1+\theta)^4}$$

$$3. \quad \text{الحد الأدنى لتباين المقدّرات غير المتحيزة لـ } \tau(\theta) = \ln \theta$$

$$V_\theta T \geq \frac{1/\theta^2}{2n/\theta^2} = \frac{1}{2n}$$

مثال 3.7.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع التوزيع $\mathcal{P}(\xi) \in N(\theta, 4)$ ، فأوجد الحد الأدنى لتباين المقدّرات غير المتحيزة لكل من:

$$\theta, \quad \theta^2, \quad e^\theta$$

بما أن:

$$f(x; \theta) = \frac{1}{2\sqrt{2\pi}} \exp\left[-\frac{1}{8}(x - \theta)^2\right]$$

ومن ثم:

$$L(x; \theta) = (2\sqrt{2\pi})^{-n/2} \exp\left[-\frac{1}{8} \sum_{i=1}^n (x_i - \theta)^2\right]$$

$$\ln L(x; \theta) = -\frac{n}{2} \ln(2\sqrt{2\pi}) - \frac{1}{8} \sum_{i=1}^n (x_i - \theta)^2$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = \frac{1}{4} \sum_{i=1}^n (x_i - \theta) = \frac{n}{4} (\bar{x} - \theta)$$

$$\frac{\partial^2 \ln L(x; \theta)}{\partial \theta^2} = -\frac{n}{4}$$

وبالتالي:

$$i_n(\theta) = -E_\theta \left[\frac{\partial^2 L(x; \theta)}{\partial \theta^2} \right] = -E_\theta \left(-\frac{n}{4} \right) = \frac{n}{4}$$

وعلى ذلك، وبناءً على متباينة كرامر وراو، فإن:

$$1. \quad \text{الحد الأدنى لتباين المقدرات غير المتحيزة لـ } \tau(\theta) = \theta :$$

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{1}{n/4} = \frac{4}{n}$$

$$2. \quad \text{الحد الأدنى لتباين المقدرات غير المتحيزة لـ } \tau(\theta) = \theta^2 :$$

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{4\theta^2}{n/4} = \frac{16}{n} \theta^2$$

$$3. \quad \text{الحد الأدنى لتباين المقدرات غير المتحيزة لـ } \tau(\theta) = e^\theta :$$

$$V_\theta T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{e^{2\theta}}{n/4} = \frac{4}{n} e^{2\theta}$$

مثال 4.7.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع دالة كثافة توزيعه:

$$f(x; \theta) = \theta(1+x)^{-(1+\theta)}, \quad x \geq 0$$

فهل توجد دالة في θ (مقدرها الأمثل موجود؟)

بما أن:

$$L(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i, \theta) = \theta^n \prod_{i=1}^n (1+x_i)^{-(1+\theta)}$$

$$\ln L(\mathbf{x}; \theta) = n \ln \theta - (1+\theta) \sum_{i=1}^n \ln(1+x_i)$$

فإن مساهمة العينة X

$$U(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta} = +\frac{n}{\theta} - \sum_{i=1}^n \ln(1+X_i)$$

أي أن:

$$-\frac{1}{n} U(X; \theta) = \frac{1}{n} \sum_{i=1}^n \ln(1+X_i) - \frac{1}{\theta}$$

وإذا رمزنا بـ:

$$T = \frac{1}{n} \sum_{i=1}^n \ln(1+X_i), \quad \tau(\theta) = \frac{1}{\theta}, \quad \alpha(\theta) = -\frac{1}{n}$$

نجد:

$$\alpha(\theta)U(X; \theta) = T - \tau(\theta)$$

وحسب المبرهنة (1.7.5) [العلاقة (2.7.5)]، فإن المقدر $T = \frac{1}{n} \sum_{i=1}^n \ln(1+X_i)$

الأمثل للدالة $\tau(\theta) = \frac{1}{\theta}$ ، وأن تباينه:

$$V_{\theta} T = \frac{[\tau'(\theta)]^2}{i_n(\theta)} = \frac{1/\theta^4}{n/\theta^2} = \frac{1}{n\theta^2}$$

مثال 5.7.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه:

$$f(x; \theta) = \frac{1}{1+\theta} e^{-x/(1+\theta)}, \quad x > 0$$

فهل توجد دالة ما $\tau(\theta)$ مقدرها الأمثل موجود.

بما أن:

$$L(x; \theta) = (1+\theta)^{-n} \exp\left[\frac{-1}{1+\theta} \sum_1^n x_i\right]$$

$$\ln L(x; \theta) = -n \ln(1+\theta) - \frac{1}{1+\theta} \sum_1^n x_i$$

فإن:

$$U(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta} = -\frac{n}{1+\theta} + \frac{1}{(1+\theta)^2} \sum_{i=1}^n X_i = -\frac{n}{(1+\theta)^2} [\bar{X} - (1+\theta)]$$

أي أن:

$$\bar{X} - (1+\theta) = -\frac{(1+\theta)^2}{n} U(X; \theta)$$

وبوضع:

$$T = \bar{X}, \quad \tau(\theta) = (1+\theta), \quad \alpha(\theta) = -\frac{(1+\theta)^2}{n}$$

نحصل على العلاقة (2.7.5)، أي أن $T = \bar{X}$ المقدر الأمثل لـ $\tau(\theta) = (1+\theta)$

وتبينه:

$$V_\theta T = V_\theta \bar{X} = \frac{1}{n^2} \sum_{i=1}^n V_\theta X_i = \frac{1}{n^2} n(1+\theta)^2$$

لأن $V_\theta X_i = (1+\theta)^2$ [راجع العلاقة (23.3.2)]، حيث $\alpha = 1$ و $\beta = (1+\theta)$.

مثال 6.7.5

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه:

$$f(x; \theta) = \theta e^{-\theta x} \quad , \quad x > 0$$

وعلمت أن $T_1(X) = \frac{(n-1)}{n\bar{X}}$ مقدر غير متحيز للمعلمة θ ، فهل يعتبر المقدّر الأمثل
 لـ θ ؟

بما أن $\mathcal{L}(X_i) \in \Gamma\left(1, \frac{1}{\theta}\right)$ ، فإن $\mathcal{L}(Y = \sum X_i) \in \Gamma\left(n, \frac{1}{\theta}\right)$ ، أي أن:

$$g(y; \theta) = \frac{\theta^n}{\Gamma(n)} y^{n-1} e^{-\theta y} \quad ; \quad y > 0$$

وعلى ذلك:

$$\begin{aligned} E_{\theta}\left(\frac{1}{Y}\right) &= \int_0^{\infty} \frac{\theta^n}{\Gamma(n)} \frac{1}{y} y^{n-1} e^{-\theta y} dy \\ &= \frac{\theta}{n-1} \int_0^{\infty} \frac{\theta^{n-1}}{\Gamma(n-1)} y^{n-2} e^{-\theta y} dy = \frac{\theta}{n-1} \end{aligned}$$

لأن $h(y; \theta) = \frac{\theta^{n-1}}{\Gamma(n-1)} y^{n-2} e^{-\theta y}$ ما هي إلا دالة الكثافة الاحتمالية للتوزيع $\Gamma\left(n-1, \frac{1}{\theta}\right)$ ، ومن ثم تكامله من 0 إلى ∞ يساوي 1 (خاصة دالة الكثافة).

وبشكل مشابه نجد:

$$E_{\theta}\left(\frac{1}{Y}\right)^2 = \frac{\theta^2}{(n-1)(n-2)} \int_0^{\infty} \frac{\theta^{n-2}}{\Gamma(n-2)} y^{n-3} e^{-\theta y} dy = \frac{\theta^2}{(n-1)(n-2)}$$

وعلى ذلك:

$$V_{\theta}\left(\frac{1}{Y}\right) = E_{\theta}\left(\frac{1}{Y}\right)^2 - E^2\left(\frac{1}{Y}\right) = \frac{\theta^2}{(n-1)(n-2)} - \frac{\theta^2}{(n-1)^2} = \frac{\theta^2}{(n-2)(n-1)^2}$$

وبالتالي:

$$\begin{aligned} V_{\theta}T_1 &= (n-1)^2 V_{\theta}\left(\frac{1}{\sum_1^n X_i}\right) = (n-1)^2 V_{\theta}\left(\frac{1}{Y}\right) \\ &= (n-1)^2 \frac{\theta^2}{(n-2)(n-1)^2} = \frac{\theta^2}{(n-2)} \end{aligned}$$

لنحسب الآن الحد الأدنى لمتباينة كرامر وراو:

$$V_{\theta}T \geq \frac{[\tau'(\theta)]^2}{i_n(\theta)}$$

بما أن:

$$L(\mathbf{x}; \theta) = \theta^n e^{-\theta \sum x_i}$$

$$\ln L(\mathbf{x}; \theta) = n \ln \theta - \theta \sum_1^n x_i$$

$$\frac{\partial \ln L(\mathbf{x}; \theta)}{\partial \theta} = \frac{n}{\theta} - \sum_1^n x_i, \quad \frac{\partial^2 \ln L(\mathbf{x}; \theta)}{\partial \theta^2} = -\frac{n}{\theta^2}$$

فإن:

$$i_n(\theta) = E_{\theta}\left(-\frac{\partial^2 \ln L(\mathbf{x}; \theta)}{\partial \theta^2}\right) = \frac{n}{\theta^2}$$

إذن:

$$V_{\theta}T \geq \frac{1}{n/\theta^2} = \frac{\theta^2}{n}$$

وبالمقارنة نجد:

$$V_{\theta}T_1 = \frac{\theta^2}{(n-2)} > \frac{\theta^2}{n}$$

أي أن $T_1 = \frac{n-1}{n\bar{X}}$ ليس المقدّر الأمثل للمعلمة θ ، ومع ذلك فهو المقدّر الأكفأ ضمن عائلة المقدّرات غير المتحيزة لـ θ ، وهذا ما سنثبت لاحقاً.

إذا وجد المقدّر الأمثل T^* لتقدير $\tau(\theta)$ ، وإذا كان T أي مقدّر آخر غير متحيز لـ $\tau(\theta)$ ، فعندئذٍ كفاءة (efficiency) المقدّر T لتقدير $\tau(\theta)$ تعطى بالنسبة:

$$\text{eff} \frac{V_{\theta} T^*}{V_{\theta} T} < 1 \quad (9.7.5)$$

نلاحظ مما سبق:

1. المقدّر الأكفأ لدالة معلمية $\tau(\theta)$ في معلمة نموذج $F(x; \theta)$ غير موجود دائماً.
2. المقدّر الأمثل لدالة معلمية $\tau(\theta)$ في معلمة نموذج $F(x; \theta)$ غير موجود دائماً، حتى إذا كان المقدّر الأكفأ لـ $\tau(\theta)$ موجوداً.
3. المقدّر الأكفأ لـ $\tau(\theta)$ في معلمة نموذج $F(x; \theta)$ ليس بالضرورة الأمثل، وبعبارة أخرى فالحد الأدنى لتباينة كرامر وراو في حالات كثيرة لا يمكن بلوغه.
4. متباينة كرامر وراو تعطي الحد الأدنى لتباين المقدّرات $T \in U_{\tau}$. وبالتالي لها استخدامين:

♦ يمكن التأكد من مقدّر ما $T \in U_{\tau}$ أنه الأمثل أم لا لتقدير $\tau(\theta)$.

♦ قياس جودة المقدّر $T \in U_{\tau}$ بمقدار قرب $V_{\theta} T$ من الحد الأدنى لتباينة

كرامر وراو، أي قرب النسبة (9.7.5) من الواحد، بحيث إذا كانت

$$\text{eff} \approx 1 \text{ يمكن اعتبار } T \text{ كمقدّر جيد لـ } \tau(\theta).$$

هكذا، متباينة كرامر وراو تمكننا من التأكد من أن مقدّر ما $T \in U_{\tau}$ الأمثل أم لا لتقدير $\tau(\theta)$ ، وفي حالات عدة تساعدنا على إيجاد المقدّر الأمثل لـ $\tau(\theta)$

(إن وجد)، وخاصة إذا كان النموذج المفروض $F(x; \theta)$ ينتمي لعائلة النماذج الأسية. وهذا ما سنبينه في الفقرة التالية.

2.7.5 عائلة النماذج الأسية والمقدر الأكفأ

Family of Exponential Models and Efficient Estimator

سننتقل في هذه الفقرة لعائلة النماذج المعلمية، التي تدعى بالأسية الواردة في البند (4.4)، حيث إنه توجد المقدرات الأمثل دائماً في مثل هذه النماذج، ومن ثم الأكفأ لبعض الدوال المعلمية $\tau(\theta)$.

مبرهنة 3.7.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $f(x; \theta)$ ينتمي لعائلة النماذج الأسية، فيوجد المقدر الأمثل $T^* = T^*(X)$ لدالة معلمية ما $\tau(\theta)$. كما أن العكس صحيح، أي إذا كان $T^* = T^*(X)$ المقدر الأمثل لدالة $\tau(\theta)$ ، فإن النموذج $f(x; \theta)$ أسي.

الإثبات

لنفترض أن النموذج $f(x; \theta)$ ينتمي لعائلة النماذج الأسية، أي يمكن كتابته على الصورة:

$$f(x; \theta) = \exp[A(\theta)B(x) + C(\theta) + D(x)]$$

ومن ثم:

$$L(x; \theta) = \exp\left[A(\theta)\sum_{i=1}^n B(x_i) + nC(\theta) + \sum_{i=1}^n D(x_i)\right]$$

$$\ln L(x; \theta) = A(\theta)\sum_{i=1}^n B(x_i) + nC(\theta) + \sum_{i=1}^n D(x_i)$$

وعلى ذلك فمساهمة العينة X

$$U(\mathbf{X};\theta) = \frac{\partial \ln L(\mathbf{X};\theta)}{\partial \theta} = A'(\theta) \sum_{i=1}^n B(X_i) + nC'(\theta)$$

$$= nA'(\theta) \left[\frac{1}{n} \sum_{i=1}^n B(X_i) + \frac{C'(\theta)}{A'(\theta)} \right]$$

وبوضع:

$$T^* = \frac{1}{n} \sum_{i=1}^n B(X_i) \quad , \quad \tau(\theta) = -\frac{C'(\theta)}{A'(\theta)} \quad , \quad \alpha(\theta) = \frac{1}{nA'(\theta)}$$

نحصل على العلاقة (2.7.5)، أي أن $T^* = \frac{1}{n} \sum_{i=1}^n B(X_i)$ المقدّر الأمثل لـ $\tau(\theta) = -\frac{C'(\theta)}{nA'(\theta)}$ ، وحسب العلاقة (8.7.5) فإن:

$$V_{\theta} T^* = \frac{\tau'(\theta)}{nA'(\theta)} \quad (9.7.5)$$

ولإثبات صحة العكس، لنفترض $T^* = T^*(\mathbf{X})$ المقدّر الأمثل لدالة ما $\tau(\theta)$ في معلمة توزيع مفروض $F(x;\theta)$.

بما أن T^* المقدّر الأمثل لـ $\tau(\theta)$ ، فإن العلاقة (2.7.5) محققة:

$$T^*(\mathbf{X}) - \tau(\theta) = \alpha(\theta)U(\mathbf{X};\theta)$$

$$= \alpha(\theta) \frac{\partial \ln L(\mathbf{X};\theta)}{\partial \theta}$$

أي أن:

$$\frac{\partial \ln L(\mathbf{X};\theta)}{\partial \theta} = \frac{1}{\alpha(\theta)} T^*(\mathbf{X}) - \frac{\tau(\theta)}{\alpha(\theta)}$$

وبمكاملة الطرفين بالنسبة لـ θ نجد:

$$\ln L(\mathbf{X};\theta) = T^*(\mathbf{X}) \int \frac{1}{\alpha(\theta)} d\theta - \int \frac{\tau(\theta)}{\alpha(\theta)} d\theta =$$

$$= A_1(\theta)T^*(\mathbf{X}) + C_1(\theta) + D_1(\mathbf{X}) \quad \dots(1)$$

وفي حالة النماذج الأسية:

$$\ln L(X; \theta) = A(\theta) \sum_1^n B(X_i) + nC(\theta) + \sum_1^n D(X_i) \quad \dots (2)$$

وبمقارنة (1) بـ (2) نجد أن:

$$T^*(X) = \sum_1^n B(X_i) , \quad A_1(\theta) = A(\theta) , \quad C_1(\theta) = nC(\theta) , \quad D_1(X) = \sum_1^n D(X_i)$$

أي أن $F(x; \theta)$ ينتمي لعائلة النماذج الأسية، وهو المطلوب إثباته.

هكذا، حسب المبرهنة (3.7.5)، المقدّر الأمثل موجود فقط من أجل بعض الدوال $\tau(\theta)$ في حالة نماذج أسية.

ويمكن حساب دالة المعلومات $i_n(\theta)$ في حالة نماذج أسية (نظامية طبعاً) وفق الصيغة:

$$i_n(\theta) = n\tau'(\theta)A'(\theta)$$

وصحة هذه العلاقة تنتج مباشرة من مقارنة العلاقتين (7.7.5) و (9.7.5).

مثال 7.7.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta e^{-\theta x} ; \quad x > 0$$

فأوجد دالة منا $\tau(\theta)$ ، المقدّر الأمثل لها موجود.

يمكن كتابة الدالة $f(x; \theta)$ على الصورة:

$$f(x; \theta) = \exp(\ln \theta - \theta x)$$

وعلى ذلك فهي تنتمي إلى عائلة النماذج الأسية، حيث أن:

$$A(\theta) = -\theta , \quad B(x) = x , \quad C(\theta) = \ln \theta , \quad D(x) = 0$$

وبالتالي حسب المبرهنة (3.7.5) فإن الدالة:

$$\tau(\theta) = -\frac{C'(\theta)}{A'(\theta)} = -\frac{1/\theta}{-1} = \frac{1}{\theta}$$

والمقدّر الأمثل لها:

$$T^*(\mathbf{X}) = \frac{1}{n} \sum B(X_i) = \frac{1}{n} \sum X_i = \bar{X}$$

وبناءً على العلاقة (7.7.5) نجد:

$$V_{\theta} T^* = \frac{\tau'(\theta)}{nA'(\theta)} = \frac{-1/\theta^2}{n(-1)} = \frac{1}{n\theta^2}$$

مثال 8.7.5

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta x^{\theta-1} \quad ; \quad 0 < x < 1$$

فأوجد دالة ما $\tau(\theta)$ لها مقدّر أمثل، ثم احسب تباين هذا المقدّر.

يمكن كتابة الدالة $f(x; \theta)$ على الصورة:

$$f(x; \theta) = \exp(\theta \ln x + \ln \theta - \ln x)$$

وهو عنصر من عائلة النماذج الأسية حيث أن:

$$A(\theta) = \theta \quad , \quad B(x) = \ln x \quad , \quad C(\theta) = \ln \theta \quad , \quad D(x) = \ln x$$

وعلى ذلك وحسب المبرهنة (3.7.5)، فإن:

$$\tau(\theta) = -\frac{C'(\theta)}{A'(\theta)} = -\frac{1/\theta}{1} = -\frac{1}{\theta}$$

والمقدّر الأمثل لها:

$$T^*(X) = \frac{1}{n} \sum B(X_i) = \frac{1}{n} \sum \ln X_i$$

وبناءً على العلاقة (7.7.5) نجد:

$$V_{\theta} T^* = \frac{\tau'(\theta)}{nA'(\theta)} = \frac{+1/\theta^2}{n(1)} = \frac{1}{n\theta^2}$$

يتضمن الجدول (1.7.5) الدالة $\tau(\theta)$ ، المقدّر الأمثل لها والتباين الموافق له، وذلك لستة نماذج أسية، ونترك التأكد من ذلك للقارئ كتمارين.

جدول 1.7.5

| النموذج | $\tau(\theta)$ | T^* | $V_{\theta} T^*$ |
|---------------------------|---------------------|------------------------------|---------------------------|
| $N(\theta, \sigma^2)$ | θ | \bar{X} | σ^2/n |
| $N(\mu, \theta^2)$ | θ^2 | $1/n \sum_1^n (X_i - \mu)^2$ | $2\theta^2/n$ |
| $\Gamma(\lambda, \theta)$ | θ | \bar{X}/λ | $\theta^2/n\lambda$ |
| $B(k, \theta)$ | θ | \bar{X}/k | $\theta(1-\theta)/nk$ |
| $\Pi(\theta)$ | θ | \bar{X} | θ/n |
| $\bar{B}(r, \theta)$ | $\theta/(1-\theta)$ | \bar{X}/r | $\theta/[rn(1-\theta)^2]$ |

3.7.5 متباينة باختشاري والمقدّر الأكفأ

Bakhtshari Inequality and The Efficient Estimator

إن متباينة كرامر وراو تعطي الحد الأدنى (الأصغر على الإطلاق) لتباين المقدرات غير المتحيزة لدالة معلمية $\tau(\theta)$ في معلمة نموذج نظامي $F(x; \theta)$ عند وجود المقدّر الأمثل. لكن إذا كان المقدّر الأمثل لـ $\tau(\theta)$ غير موجود (وهذا

يمكن)، أي لا يوجد مقدر $T \in U_\tau$ يحقق العلاقة (2.7.5)، فعندئذٍ يتم البحث عن المقدر الأكفأ (المقدر غير المتحيز $T \in U_\tau$ بأقل تباين)، وهذا يتطلب تعيين التباين الأصغر ضمن مجموعة تباينات المقدرات غير المتحيزة U_τ لـ $\tau(\theta)$ وذلك مهما تكن $\theta \in \Theta$.

كما رأينا، إن الشرط الأساسي لبلوغ الحد الأدنى لتباينة كرامر وراو هو وجود مقدر $T^* \in U_\tau$ بحيث أن $T^* - \tau(\theta)$ دالة خطية في دالة المساهمة:

$$U(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta} = \frac{1}{L} \frac{\partial L}{\partial \theta}$$

مهما تكن $\theta \in \Theta$ (هنا ولاحقاً سنكتب أحياناً، وعلى سبيل الاختصار، L بدلاً من $L(X; \theta)$). لنفترض أن مثل هذا المقدر غير موجود، لكن ومع ذلك يمكن وجود مقدر $T^* \in U_\tau$ ، بحيث أن الفرق $T^* - \tau(\theta)$ دالة خطية في المقادير:

$$\frac{1}{L} \frac{\partial L}{\partial \theta}, \frac{1}{L} \frac{\partial^2 L}{\partial \theta^2}, \dots, \frac{1}{L} \frac{\partial^r L}{\partial \theta^r}$$

من أجل عدد ما $r \geq 2$. عندئذٍ يعتبر T^* المقدر الأكفأ لتقدير $\tau(\theta)$.

يدعى هذا المعيار للكفاءة، الذي يعتبر تعميماً لمعيار كرامر وراو (2.7.5)، بمعيار بختشاري ومبنى أيضاً على مبدأ بلوغ الحد الأدنى في التباينة الموافقة التي تدعى بتباينة بختشاري.

$$\text{لنرمز بـ } L^{(k)} = \frac{\partial^k L}{\partial \theta^k} \text{ و } \tau^{(k)} = \frac{d^{(k)} \tau(\theta)}{d\theta^k}$$

مبرهنة 4.7.5: متباينة بختشاري Bakhtshari Inequality

ليكن $T = T(X)$ مقدر غير متحيز لـ $\tau(\theta)$ ($T \in U_\tau$). عندها:

$$V_\theta T \geq \sum_{i,j=1}^r c_{ij} a_i a_j ; \quad \forall \theta \in \Theta \quad (11.7.5)$$

حيث أن:

$$c_{ij} = c_{ij}(\theta) = E_{\theta} \left(\frac{L^{(i)}}{L} \frac{L^{(j)}}{L} \right) \quad ; \quad i, j = 1, \dots, r$$

وتعين المعاملات $\alpha_i = \alpha_i(\theta)$ بحل منظومة المعادلات:

$$\sum_{j=1}^r c_{ij} \alpha_j = \tau^{(i)} \quad ; \quad i = 1, \dots, r \quad (12.7.5)$$

إذا كانت المصفوفة $C = \|c_{ij}\|_1^r$ نظامية ($|C| \neq 0$) و $C^{-1} = \|c^{ij}\|_1^r$ فإن المتباينة (11.7.5) مكافئة للمتباينة:

$$V_{\theta} T \geq \sum_{i,j=1}^r c^{ij} \tau^{(i)} \tau^{(j)} \quad ; \quad \forall \theta \in \Theta \quad (12.7.5)$$

وتتحقق المساواة في المتباينتين (11.7.5) و (12.7.5) عند تحقق الشرط التالي:

$$T - \tau = \sum_{i=1}^n a_i L^{(i)} / L \quad (13.7.5)$$

يستخدم معيار بختشاري عملياً على النحو الآتي: انطلاقاً من مشتقات دالة المعقولة بالنسبة لـ θ يتم اختيار تلك التركيبة الخطية لهم، بحيث نحصل على صيغة من الشكل (13.7.5)، وهذا يتم بافتراض وبشكل متتالي $r = 2, 3, \dots$. وإذا توصلنا عند قيمة ما لـ r إلى مثل هذه الصيغة، فإن الزوج الذي نحصل عليه عندئذٍ $\tau(\theta)$ و T هو عبارة عن الدالة المعلمية (المقدرة) والمقدر الأكفأ لها على الترتيب. وكحالة خاصة، عندما $r = 1$ نحصل على معيار كرامر وراو (2.7.4)، هكذا للتأكد من مقدر ما $T \in U_{\tau}$ أنه الأكفأ، يجب البحث عن إمكانية كتابة $T - \tau$ كدالة خطية في المقادير $\frac{L^{(1)}}{L}, \dots, \frac{L^{(r)}}{L}$ ، حيث $r \geq 1$.

مثال 9.7.5

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \sigma^2)$ ، ونرغب في إيجاد دالة $\tau(\theta)$ لها مقدر أكفأ.

بما أن:

$$L(\mathbf{x}; \theta) = \frac{1}{(\sigma\sqrt{2\pi})^n} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2\right\}$$

ومنها نجد:

$$\frac{1}{L} L^{(1)} = \frac{\partial \ln L}{\partial \theta} = \frac{n}{\sigma^2} (\bar{X} - \theta)$$

$$\begin{aligned} \frac{1}{L} L^{(2)} &= \frac{1}{L} \frac{\partial}{\partial \theta} \left(L \frac{\partial \ln L}{\partial \theta} \right) = \left(\frac{\partial \ln L}{\partial \theta} \right)^2 + \frac{\partial^2 \ln L}{\partial \theta^2} = \\ &= \frac{n^2}{\sigma^4} (\bar{X} - \theta)^2 - \frac{n}{\sigma^2} = \frac{n^2}{\sigma^4} \left[(\bar{X} - \theta)^2 - \frac{\sigma^2}{n} \right] \end{aligned}$$

$$\begin{aligned} \frac{1}{L} \left(\frac{2\theta\sigma^2}{n} L^{(1)} + \frac{\sigma^4}{n^2} L^{(2)} \right) &= 2\theta(\bar{X} - \theta) + \left[(\bar{X} - \theta)^2 - \frac{\sigma^2}{n} \right] = \\ &= 2\theta\bar{X} - 2\theta^2 + \bar{X}^2 - 2\theta\bar{X} + \theta^2 - \frac{\sigma^2}{n} = \\ &= \left(\bar{X}^2 - \frac{\sigma^2}{n} \right) - \theta^2 \end{aligned}$$

ونجد حسب معيار بختشاري أن الإحصاء:

$$T^* = T^*(\mathbf{X}) = \bar{X}^2 - \frac{\sigma^2}{n}$$

يعتبر المقدّر الأكفأ (غير متحيز بأقل تباين) لـ $\tau(\theta) = \theta^2$.

4.7.5 معيار الكفاءة في حالة معلمة متعددة الأبعاد

إن معياري كفاءة المقدّرات الواردين سابقا [العلاقين (2.7.5) و (13.7.5)] يخصان حالة معلمة وحيدة البعد.

لنعمم ما سبق على حالة معلمة متعددة الأبعاد. سنفترض أن $\theta = (\theta_1, \dots, \theta_r)$ متجه ذات r بعد. وليكن المطلوب البحث عن مقدّر من أجل

دالة معلمية عددية معطاة $\tau(\theta)$ ، القابلة للاشتقاق بالنسبة لـ θ_i ; $i = 1, 2, \dots, r$. ونفترض أن النموذج المعطى $F(x; \theta)$ نظامي، عندها المبرهنة التالي صحيحة.

مبرهنة 5.7.5

إذا كان $T = T(X)$ مقدر غير متحيز لدالة ما $\tau(\theta)$ ، فإن:

$$V_{\theta}T \geq \sum_{i,j=1}^r g_{ij}c_i c_j \quad ; \quad \forall \theta \in \Theta \quad (14.7.5)$$

حيث أن:

$$g_{ij} = g_{ij}(\theta) = E_{\theta} \left(\frac{\partial \ln L}{\partial \theta_i} \frac{\partial \ln L}{\partial \theta_j} \right) \quad ; \quad i, j = 1, 2, \dots, r$$

وتعين المعاملات $c_i = c_i(\theta)$ بحل منظومة المعادلات:

$$\sum_{j=1}^r g_{ij}c_j = \tau'_i = \frac{\partial \tau(\theta)}{\partial \theta_i} \quad ; \quad i = 1, 2, \dots, r$$

إذا كانت المصفوفة $I_n = I_n(\theta) = \|g_{ij}\|_1^r$ نظامية و $I_n^{-1} = \|g^{ij}\|_1^r$ ، فإن المتباينة (14.7.5) مكافئة للمتباينة:

$$V_{\theta}T \geq \sum_{i,j=1}^r g^{ij} \tau'_i \tau'_j \quad (15.7.5)$$

وتتحقق المساواة في المتباينتين (14.7.5) و (15.7.5) عندما:

$$T - \tau = \sum_{i=1}^r c_i \frac{\partial \ln L}{\partial \theta_i} \quad (16.7.5)$$

إذا كانت دالة المعقولة $L(x; \theta)$ قابلة للاشتقاق مرتين بالنسبة لـ θ ، فباشتقاق المطابقة:

$$\int L(x; \theta) dx \equiv 1$$

أولاً بالنسبة لـ θ_i ثم بالنسبة لـ θ_j ، نجد:

$$g_{ij} = -E_{\theta} \left(\frac{\partial^2 \ln L(\mathbf{X}; \theta)}{\partial \theta_i \partial \theta_j} \right) = -n E_{\theta} \left(\frac{\partial^2 \ln f(X_1; \theta)}{\partial \theta_i \partial \theta_j} \right) \quad (17.7.5)$$

تدعى المصفوفة $I_n(\theta)$ بمصفوفة المعلومات للعينة \mathbf{X} ، بينما $I(\theta) = I_1(\theta)$ تدعى بمصفوفة المعلومات للملاحظة واحدة. وتبين العلاقة (17.7.5) أنه من أجل منظومة ملاحظات متكررة ومستقلة $I_n(\theta) = nI(\theta)$.

بشكل مشابه لحالة معلمة وحيدة البعد (حقيقية) نسمي المقدّر غير المتحيز $T^* = T^*(\mathbf{X})$ من أجل $\tau(\theta)$ بالأمثل، إذا كان تباينه منطبقاً على الحد الأدنى للمتباينة (14.7.5) أو (15.7.5) وذلك مهما تكن $\theta \in \Theta$.

ينتج من المبرهنة (5.7.5) أن معيار الأمثلية (ويعني أيضاً الكفاءة) للمقدّر T يتمثل في المساواة (16.7.5). نورد فيما يلي مثلاً لاستخدام هذا المعيار.

مثال 10.7.5

لتكن $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $\mathcal{L}(\xi) \in N(\theta_1, \theta_2^2)$. ويطلب تقدير الدالة $\tau(\theta) = \tau(\theta_1, \theta_2) = \theta_1$ ، أي تقدير متوسط توزيع ξ . يمكن أخذ متوسط العينة \bar{X} كمقدّر غير متحيز لـ θ_1 . وهذا ما سنبينه كالاتي:

بما أن دالة المعقولية في الحالة المطروحة:

$$L(\mathbf{x}; \theta) = \prod_{i=1}^n f(x_i; \theta) = \frac{1}{(\theta_2 \sqrt{2\pi})^n} \exp \left\{ -\frac{1}{2\theta_2^2} \sum_{i=1}^n (x_i - \theta_1)^2 \right\}$$

فإن:

$$\frac{\partial \ln L}{\partial \theta_1} = \frac{n}{\theta_2^2} (\bar{X} - \theta_1) \quad , \quad \frac{\partial \ln L}{\partial \theta_2} = -\frac{n}{\theta_2} + \frac{1}{\theta_2^3} \sum_{i=1}^n (x_i - \theta_1)^2$$

ولإيجاد المعاملين $c_j; j = 1, 2$ نحتاج أولاً لحساب $g_{ij}; i, j = 1, 2$ بناءً على العلاقة (17.7.5):

$$g_{11} = -E_{\theta} \left[\frac{\partial^2 \ln L(\mathbf{X}; \theta)}{\partial \theta_1^2} \right] = -E_{\theta} \left(-\frac{n}{\theta_2^2} \right) = \frac{n}{\theta_2^2}$$

$$g_{12} = g_{21} = -E_{\theta} \left[\frac{\partial^2 \ln L(\mathbf{X}; \theta)}{\partial \theta_1 \partial \theta_2} \right] = -E_{\theta} \left[-\frac{2n}{\theta_2^3} (\bar{X} - \theta_1) \right] = \frac{2n}{\theta_2^3} E_{\theta} (\bar{X} - \theta_1) = 0$$

$$g_{22} = -E_{\theta} \left[\frac{\partial^2 \ln L(\mathbf{X}; \theta)}{\partial \theta_2^2} \right] = -E_{\theta} \left[+\frac{n}{\theta_2^2} - \frac{3}{\theta_2^4} \sum_{i=1}^n (X_i - \theta_1)^2 \right] =$$

$$= -\frac{n}{\theta_2^2} + \frac{3n}{\theta_2^2} = \frac{2n}{\theta_2^2}$$

وبحل جملة المعادلتين:

$$\frac{n}{\theta_2^2} c_1 + 0c_2 = 1$$

$$0c_1 + \frac{2n}{\theta_2^2} c_2 = 0$$

$$\text{نجد: } c_2 = 0 \text{ و } c_1 = \frac{\theta_2^2}{n}$$

إذن:

$$\sum_{i=1}^2 c_i \frac{\partial \ln L}{\partial \theta_i} = \frac{\theta_2^2}{n} \frac{\partial \ln L}{\partial \theta_1} = \frac{\theta_2^2}{n} \frac{n}{\theta_2^2} (\bar{X} - \theta_1) = \bar{X} - \theta_1$$

أي أن العلاقة (16.7.5) محققة، وبالتالي الإحصاء $T(\mathbf{X}) = \bar{X}$ المقدّر الأمثل، ومن ثم الأكفّال $\tau(\theta) = \theta_1$.

وبما أن $|I_n| \neq 0$ فإن $g^{11} = \frac{\theta_2^2}{n}$ ، $g^{22} = \frac{\theta_2^2}{2n}$ ، $g^{12} = g^{21} = 0$ ومن ثم الحد

الأدنى في المتباينة (15.7.5) يساوي:

$$\sum_{i,j=1}^2 g^{ij} \tau'_i \tau'_j = \frac{\theta_2^2}{n}$$

$$. V_{\theta} \bar{X} = \sum g^j \tau_j' \tau_j' = \frac{\theta_2^2}{n} , \quad V_{\theta} \bar{X} = \frac{\theta_2^2}{n} \text{ وكما نعلم}$$

لكن \bar{X} المقدّر الأمثل أيضاً لـ θ في النموذج $N(\theta, \sigma^2)$ [راجع الجدول (1.7.5)]، وهذا يعني أن \bar{X} المقدّر الأمثل لمتوسط النموذج الطبيعي وغير مرتبط بمعرفة التباين أم لا.

كما في حالة معلمة وحيدة البعد، المقدّرات الأمثل غير موجودة دائماً. فمثلاً، في مسألة تقدير التباين غير المعلوم في نموذج طبيعي، إذا كان متوسط النموذج معلوم، أي $N(\mu, \theta_2^2)$ ، فكما بينا في الفقرة (2.7.5) [أنظر الجدول (1.7.5)]، إن تباين العينة:

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$$

يعتبر المقدّر الأمثل وبنفس الوقت الأكفأ لتباين المجتمع، بينما في حالة نموذج طبيعي عام $N(\theta_1, \theta_2^2)$ هذا غير موجود.

أولاً: كما بينا سابقاً في البند (4.5) [مثال (6.4.5)]، إن تباين العينة S^2 مقدّر متحيز للدالة $\tau(\theta) = \theta_2^2$ ، بينما المقدّر غير المتحيز عندما $n \geq 2$ هو:

$$S^{*2} = \frac{n}{n-1} S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 ; \quad n \geq 2$$

ثانياً: إن الإحصاء S^{*2} ليس المقدّر الأمثل من أجل تقدير θ_2^2 ، وهذا يمكن إثباته بمقارنة تباينه $V_{\theta} S^{*2} = \frac{2\theta_2^4}{n-1}$ [راجع العلاقة (5.4.5)]، بالحد الأدنى في المتباينة (15.7.5). فعلاً، حسب العلاقة (17.7.5) نجد [راجع المثال (10.7.5)]:

$$g_{11} = \frac{n}{\theta_2^2} , \quad g_{12} = g_{21} = 0 , \quad g_{22} = \frac{2n}{\theta_2^2}$$

أي من أجل النموذج $N(\theta_1, \theta_2^2)$ مصفوفة المعلومات:

$$I_n(\theta) = \begin{vmatrix} g_{11} & g_{12} \\ g_{21} & g_{22} \end{vmatrix} = \begin{vmatrix} n/\theta_2^2 & 0 \\ 0 & 2n/\theta_2^2 \end{vmatrix} = n \begin{vmatrix} 1/\theta_2^2 & 0 \\ 0 & 2/\theta_2^2 \end{vmatrix} = nI(\theta)$$

وعلى ذلك فإن:

$$\det I_n(\theta) = g_{11}g_{22} = \frac{2n^2}{\theta_2^4} \neq 0, \quad g^{22} = \frac{\theta_2^2}{2n}$$

والجزء الأيمن من المتباينة (15.7.5) يساوي:

$$g^{22}(\tau_2')^2 = \frac{\theta_2^2}{2n}(2\theta_2)^2 = \frac{\theta_2^4}{n}$$

وهو أصغر من:

$$V_\theta S^{*2} = \frac{2\theta_2^4}{n-1}$$

وهذا غير كافٍ للقول بأن هنالك مقدر متحيز لـ $\tau(\theta) = \theta_2^2$ أكفاً نسبياً من المقدر S^{*2} .

سنبين بشكل عام في الحالة المطروحة أنه لا يوجد المقدر الأمثل [لا يتم بلوغ الحد الأدنى في المتباينة (14.7.5) أو (15.7.5) من أجل أي مقدر غير متحيز لـ $[\theta_2^2]$ ، بينما المقدر الأكفاً T^* موجود وهو S^{*2} .

باستخدام معيار مشابه لمعيار بختشاري من أجل معلمة متعددة الأبعاد، الذي يأخذ الشكل الآتي:

إذا كانت الصيغة:

$$T - \tau(\theta) = \frac{1}{L} \left[\sum_i c_i \frac{\partial L}{\partial \theta_i} + \sum_{i,j} c_{ij} \frac{\partial^2 L}{\partial \theta_i \partial \theta_j} + \dots + \sum_{i_1, i_2, \dots, i_r} c_{i_1 \dots i_r} \frac{\partial^r L}{\partial \theta_{i_1} \dots \partial \theta_{i_r}} \right] \quad (18.7.5)$$

محققة من أجل عدد صحيح ما $s \geq 2$ ومعاملات $c = c(\theta)$ ، فإن الإحصاء T يعتبر المقدّر الأكفأ للدالة $\tau = \tau(\theta)$.

بتطبيق هذا المعيار على الحالة المطروحة نجد:

$$\frac{1}{L} \frac{\partial L}{\partial \theta_1} = \frac{n}{\theta_2^2} (\bar{X} - \theta_1)$$

$$\frac{1}{L} \frac{\partial^2 L}{\partial \theta_1^2} = \frac{\partial^2 \ln L}{\partial \theta_1^2} + \left(\frac{\partial \ln L}{\partial \theta_1} \right)^2 = -\frac{n}{\theta_2^2} + \frac{n^2}{\theta_2^4} (\bar{X} - \theta_1)^2$$

$$\frac{1}{L} \frac{\partial L}{\partial \theta_2} = -\frac{n}{\theta_2} + \frac{1}{\theta_2^3} \sum_{i=1}^n (X_i - \theta_1)^2 = \frac{1}{\theta_2^3} \sum_{i=1}^n (X_i - \bar{X})^2 + \frac{n}{\theta_2^3} (\bar{X} - \theta_1)^2 - \frac{n}{\theta_2}$$

وعلى ذلك فإن:

$$\begin{aligned} \frac{1}{L} \left(\frac{\theta_2^3}{n-1} \frac{\partial L}{\partial \theta_2} - \frac{\theta_2^4}{n(n-1)} \frac{\partial L}{\partial \theta_1^2} \right) &= \frac{\theta_2^3}{n-1} \left[\frac{1}{\theta_2^3} \sum_{i=1}^n (X_i - \bar{X})^2 \right. \\ &+ \left. \frac{n}{\theta_2^3} (\bar{X} - \theta_1)^2 - \frac{n}{\theta_2} \right] - \frac{\theta_2^4}{n(n-1)} \left[-\frac{n}{\theta_2^2} + \frac{n^2}{\theta_2^2} (\bar{X} - \theta_1)^2 \right] \\ &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 + \frac{n}{n-1} (\bar{X} - \theta_1)^2 - \frac{n}{n-1} \theta_2^2 + \frac{1}{n-1} \theta_2^2 - \frac{n}{n-1} (\bar{X} - \theta_1)^2 \\ &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 - \theta_2^2 = S^{*2} - \theta_2^2 \end{aligned}$$

وهذا يعني، بناءً على المعيار (18.7.5)، أن الإحصاء $T^* = S^{*2}$ المقدّر الأكفأ لـ θ_2^2 في النموذج $N(\theta_1, \theta_2^2)$.

هكذا، في مسألة تقدير الدالة المعلمية $\tau(\theta) = \theta_2^2$ من أجل النموذج $N(\theta_1, \theta_2^2)$ لدينا معيار أكثر دقة من (15.7.5) للتقدير من أجل تباينات المقدّرات غير المتحيزة لـ $\tau(\theta)$ ، وهذا المعيار هو:

$$V_{\theta} T \geq \frac{2\theta_2^4}{n-1}$$

وتتحقق المساواة عندما $T^* = S^{*2}$.

8.5 الكفاية، التمام والمقدرات الأكفأ

SUFFICIENCY, COMPLETENESS AND EFFICIENT ESTIMATORS

إن معايير الكفاءة للمقدرات الواردة سابقاً، لها تطبيقات محدودة نسبياً، لأنها تتطلب شروط قاسية تمثل في نظامية النموذج، هذا بالإضافة إلى أنها في أفضل حالة يمكننا من إيجاد المقدرات الأكفأ من أجل دوال معلمية خاصة $\tau(\theta)$. فمثلاً، بينا أن المقدر الأكفأ من أجل التباين θ_2^2 في النموذج $N(\theta_1, \theta_2^2)$ هو عبارة عن $T(X) = S^{*2}$ ، إلا أن إيجاد المقدر الأكفأ للانحراف المعياري θ_2 باستخدام الطرق الواردة سابقاً غير ممكن. ويعتبر استخدام الإحصاءات الكافية الأسلوب الأنجع لبناء المقدرات الأكفأ، وبجنتها يشكل موضوع هذا البند.

مبرهنة 1.8.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $f(x; \theta)$ و $T = T(X)$ المقدر الأمثل لـ $\tau(\theta)$ ، حيث θ وحدة البعد، فإن T إحصاء كافي لـ $\tau(\theta)$.

الإثبات

بما أن T المقدر الأمثل لـ $\tau(\theta)$ ، فهو يحقق العلاقة (2.7.5):

$$T(x) - \tau(\theta) = a(\theta)U(x; \theta) = a(\theta) \frac{\partial \ln L(x; \theta)}{\partial \theta}$$

وبمكاملة الطرفين بالنسبة لـ θ نجد:

$$\ln L(x; \theta) = T(x) \int \frac{d\theta}{a(\theta)} - \int \frac{\tau(\theta)}{a(\theta)} d\theta = \varphi(T(x); \theta) - \psi(\theta) + c(x)$$

حيث أن:

$$\varphi(T(x); \theta) = T(x) \int \frac{d\theta}{\alpha(\theta)}, \quad \psi(\theta) = \int \frac{\tau(\theta)}{\alpha(\theta)} d\theta$$

وعلى ذلك فإن:

$$L(x; \theta) = e^{\varphi(t; \theta) - \psi(\theta) + c(x)}$$

وبوضع:

$$g(t; \theta) = e^{\varphi(t; \theta) - \psi(\theta)}, \quad h(x) = c(x)$$

نجد أن:

$$L(x; \theta) = g(t; \theta)h(x)$$

أي أن العلاقة (2.2.4) محققة، وبالتالي فالمقدر الأمثل $T = T(X)$ هو إحصاء كافي لـ $\tau(\theta)$.

هكذا المقدر الأمثل لدالة معلمية ما $\tau(\theta)$ موجود فقط عندما يكون الإحصاء الكافي لـ $\tau(\theta)$ موجوداً. لكن العكس ليس بالضرورة صحيحاً، أي يمكن وجود إحصاء كافي لـ $\tau(\theta)$ حتى في حالة عدم وجود المقدر الأمثل لـ $\tau(\theta)$ ، أي أن شرط الإحصاء الكافي أقل تحديداً من شرط المقدر الأمثل. وهذا يعني للبحث عن المقدر الأمثل ضمن العائلة U_τ يجب اقتصار البحث ضمن عائلة المقدرات غير المتحيزة والتي تعتبر في نفس الوقت إحصاءات كافية لـ $\tau(\theta)$ ، أي البحث ضمن عائلة أضيف من U_τ ولنرمز لها بـ U_τ^* ($U_\tau^* \subset U_\tau$).

1.8.5 الكفاية والمقدرات الأكفأ

Sufficiency and Efficient Estimators

إن للإحصاءات الكافية دوراً هاماً في إيجاد المقدرات الأكفأ (الأمثل إن وجدت). وسنرى في هذه الفقرة كيف أن الكفاية (sufficiency) تساعد في الحصول على مثل هذه المقدرات.

مبرهنة 2.8.5: مبرهنة راو وبلاكويل Rao-Blackwell Theorem

إذا كان المقدّر الأكفأ لدالة ما $\tau(\theta)$ موجوداً، فهو دالة في إحصاء كافي لهذه الدالة.

الإثبات

ليكن $T = T(X)$ إحصاءً كافياً و $T_1 = T_1(X)$ مقدّر غير متحيز لدالة معلمية معطاة $\tau(\theta)$. لنرى الدالة:

$$H(t) = E_{\theta}(T_1 | T = t) = \int T_1(x) L(x|t; \theta) dx$$

وبما أن $L(x|t; \theta)$ لا تعتمد على θ (لأن T إحصاء كافي لـ $\tau(\theta)$)، فالدالة $H(t)$ لا تعتمد على θ ، أي أن الدالة $H(T)$ إحصاء. ويمكن أيضاً إثبات أن هذه الدالة هي عبارة عن مقدّر غير متحيز لتقدير $\tau(\theta)$ على النحو الآتي:

إذا رمزنا بـ $g(t; \theta)$ لكثافة توزيع الإحصاء $T(X)$ ، فإن:

$$\begin{aligned} E_{\theta}[H(T)] &= \int H(t) g(t; \theta) dt = \\ &= \int T_1(x) \left[\int L(x|t; \theta) g(t; \theta) dt \right] dx \\ &= \int T_1(x) L(x; \theta) dx = E_{\theta} T_1(X) = \tau(\theta) \end{aligned}$$

لنبرهن الآن صحة المتباينة:

$$V_{\theta}[H(T)] \leq V_{\theta} T_1(X) \quad ; \quad \forall \theta \in \Theta$$

وأن المساواة محققة فقط عندما $T_1(X) = H(T)$. وذلك على النحو الآتي:

$$\begin{aligned} V_{\theta} T_1(X) &= E_{\theta}[T_1(X) - \tau(\theta)]^2 = E_{\theta}[(T_1 - H(T)) + (H(T) - \tau(\theta))]^2 \\ &= E_{\theta}[T_1 - H(T)]^2 + E_{\theta}[H(T) - \tau(\theta)]^2 \\ &\quad + 2E_{\theta}[(T_1 - H(T))(H(T) - \tau(\theta))] \end{aligned}$$

بما أن:

$$E_{\theta}[(T_1 - H(T))(H(T) - \tau(\theta))] = E_{\theta}[(T_1 - H(T))H(T)] = \\ = \int [E_{\theta}(T_1|T=t) - H(t)]H(t)g(t;\theta)dt = 0$$

فإن:

$$V_{\theta}T_1(X) = E[T_1 - H(T)]^2 + V_{\theta}H(T) \geq V_{\theta}H(T)$$

وتتحقق المساواة عندما $T_1 = H(T)$.

تنص هذه المبرهنة على أنه إذا كان لدينا مقدر T_1 غير متحيز لـ $\tau(\theta)$ ، وليس دالة في إحصاء كافي، فيمكن إيجاد مقدر غير متحيز لـ $\tau(\theta)$ ، دالة في إحصاء كافي وتباينه أقل من تباين T_1 . وهذا المقدر الأخير هو عبارة عن القيمة المتوقعة المشروطة $H(T) = E(T_1|T)$. وبالتالي المقدر الأكفأ (إذا وجد) لدالة معلمية $\tau(\theta)$ فهو حكماً دالة في إحصاء كافي لـ $\tau(\theta)$. وهذا يعني تطبيقاً، عند البحث عن المقدر الأكفأ لدالة معلمية ما يجب البحث ضمن عائلة المقدرات $T \in U_{\tau}^*$ ، التي تعتبر دوال في إحصاءات كافية لـ $\tau(\theta)$.

مثال 1.8.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بواسون:

$$f(x;\theta) = \frac{\theta^x}{x!} e^{-\theta} \quad , \quad x = 0, 1, \dots \quad , \quad \theta > 0$$

وكان $T_1 = X_1$ مقدر غير متحيز لـ θ و $T = \sum_{i=1}^n X_i$ إحصاء كافي لـ θ ، فأوجد مقدرًا لـ θ أفضل من T_1 .

حسب مبرهنة راو وبلاكويل (2.8.5) فالمقدر:

$$H(T) = E_{\theta}(T_1|T)$$

أفضل من المقدّر T_1 للمعلمة θ . ولتعيينه يلزمنا معرفة التوزيع المشروط للمتغير T_1 بشرط معرفة T .

$$\begin{aligned}
 P_{\theta}(T_1 = x_1 | T(X) = k) &= \frac{P_{\theta}(T_1 = x_1, T(X) = k)}{P_{\theta}(T(X) = k)} \\
 &= \frac{P_{\theta}\left(X_1 = x_1, \sum_2^n X_i = k - x_1\right)}{P_{\theta}\left(\sum_1^n X_i = k\right)} \\
 &= \frac{P_{\theta}(X_1 = x_1)P_{\theta}\left(\sum_2^n X_i = k - x_1\right)}{P_{\theta}\left(\sum_1^n X_i = k\right)} \\
 &= \frac{(e^{-\theta}\theta^{x_1}/x_1!)\left\{[(n-1)\theta]^{k-x_1} e^{-(n-1)\theta}/(k-x_1)!\right\}}{(n\theta)^k e^{-n\theta}/k!} \\
 &= \frac{k!}{x_1!(k-x_1)!} \left(\frac{1}{n}\right)^{x_1} \left(1-\frac{1}{n}\right)^{k-x_1} = C_k^{x_1} \left(\frac{1}{n}\right)^{x_1} \left(1-\frac{1}{n}\right)^{k-x_1}
 \end{aligned}$$

وهذا ما هو إلا توزيع ذي الحدين $B(k, 1/n)$. وبالتالي فإن:

$$H(T) = E(T_1 | T) = \frac{k}{n} = \frac{1}{n} \sum_1^n X_i = \bar{X}$$

ونلاحظ بسهولة أن:

$$E_{\theta}[H(T)] = E\bar{X} = \theta$$

$$V_{\theta}[H(T)] = V_{\theta}\bar{X} = \frac{\theta}{n} \leq V_{\theta}X_1 = \theta$$

أي أن المقدّر غير المتحيز \bar{X} أفضل من المقدّر غير المتحيز X_1 من أجل تقدير θ .

نخلص مما سبق إلى الملاحظات الآتية:

1. إذا كان المقدّر غير المتحيز T_1 لدالة ما $\tau(\theta)$ هو أصلاً دالة في إحصاء كافي، فإن المقدّر $H(T) = E_0(T_1|T)$ يكون مطابقاً للمقدّر T_1 ، أي لا نتوقع أن يكون هناك أي تحسن في قيمة التباين.
 2. نستطيع استخدام أي إحصاء كافي للحصول على المقدّر $H(T)$ ، ولكن يفضل استخدام الإحصاء الكافي الأصغر.
 3. مبرهنة راو وبلاكويل تبين كيفية الحصول على مقدّر غير متحيز أفضل من المقدّر غير المتحيز المفروض، وذلك بالاشتراط على الإحصاء الكافي الأصغر للدالة المقدّرة $\tau(\theta)$.
- إن للإحصاء الكافي التام (الإحصاء التام) دوراً هاماً عند البحث عن شكل واضح للمقدّرات الأكفأ، وهذا ما تبينه المبرهنة الآتية.

مبرهنة 3.8.5: مبرهنة ليمان وشيفي Lemann-Scheffe Theorem

إذا وجد إحصاء كافي تام لمعلمة نموذج $f(x; \theta)$ ، فإن أي دالة فيه تعتبر المقدّر الأكفأ لقيمتها المتوقعة.

الإثبات

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $f(x; \theta)$ ، $T = T(\mathbf{X})$ إحصاء كافي تام لـ θ وكان $H(T)$ دالة ما في T ، ورمزنا بـ:

$$E_0[H(T)] = \tau(\theta) \quad (1.8.5)$$

فتعني المبرهنة أن $H(T)$ المقدّر الأكفأ من أجل تقدير $\tau(\theta)$.

ينتج من تعريف الإحصاء التام أن $H(T)$ الدالة الوحيدة في T التي تحقق العلاقة (1.8.5)، لأنه إذا وجدت دالة ما أخرى $H_1(T)$ وتحقق العلاقة (1.8.5)، فإن:

$$E_0[H(T) - H_1(T)] = 0 \quad ; \quad \forall \theta \in \theta$$

وحسب التعريف (1.5.4) نجد:

$$H(t) \equiv H_1(t)$$

لايجاد المقدّر الأكفأ لـ $\tau(\theta)$ ، بناءً على المبرهنة (2.8.5)، يجب البحث في صف الدوال في T . لكن الإحصاء $H(T)$ الدالة الوحيدة في T كما بينا سابقاً، الذي يعتبر مقدّر غير متحيز لـ $\tau(\theta)$ ، وبالتالي فإنه المقدّر الأكفأ المطلوب.

هكذا، لنفترض وجود إحصاء كافي تام T للنموذج المدروس $f(x; \theta)$ ويطلب تقدير دالة معلمية معطاة $\tau(\theta)$. عندها:

1. إذا وجد مقدّر ما غير متحيز لـ $\tau(\theta)$ ، فيوجد أيضاً مقدّر آخر غير متحيز لـ $\tau(\theta)$ الذي يعتبر دالة في T . ويمكن القول أيضاً، أنه إذا لم يوجد مقدّر غير متحيز لـ $\tau(\theta)$ من الشكل $H(T)$ [أي العلاقة (1.8.5) ليس لها حل]، فإن عائلة المقدّرات غير المتحيزة U_τ لـ $\tau(\theta)$ نحالية.

2. المقدّر الأكفأ (إذا وجد) يعتبر دائماً دالة في T ، ويعين بشكل وحيد بالعلاقة (1.8.5).

3. المقدّر الأكفأ τ^* يمكن إيجاده وفق الصيغة:

$$\tau^* = H(T) = E_0(T_1|T)$$

انطلاقاً من أي مقدّر غير متحيز T_1 للدالة $\tau(\theta)$.

مثال 2.8.5

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من مجتمع يخضع للتوزيع $R(0, \theta)$ ، ونرغب في إيجاد المقدّر الأكفأ للمعلمة θ .

كما نعلم أن $T = X_{(n)}$ إحصاء كافي تام لـ θ [راجع مثال (1.5.4)]. وحسب العلاقة (3.10.3) فإن توزيع $X_{(n)}$ هو:

$$h(y) = \frac{n}{\theta^n} x^{n-1}, \quad 0 < x < \theta, \quad \theta > 0$$

وعلى ذلك فإن:

$$E_{\theta} X_{(n)} = \int_0^{\theta} \frac{n}{\theta^n} y^n dy = \frac{n}{n+1} \theta$$

وإذا رمزنا بـ:

$$H(T) = \frac{n+1}{n} X_{(n)}$$

فإن:

$$E_{\theta}[H(T)] = E_{\theta}\left[\frac{n+1}{n} X_{(n)}\right] = \theta$$

وحسب المرهنة (3.8.5) فإن $H(T)$ المقدّر الأكفأ لـ θ . ويمكن بسهولة إثبات أن:

$$V_{\theta}[H(T)] = \frac{\theta^2}{n(n+2)}$$

مثال 3.8.5

لنكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع يتبع التوزيع $\Gamma(1, 1/\theta)$ ، ويطلب إيجاد المقدّر الأمثل لكل من θ و $1/\theta$.

بما أن التوزيع $\Gamma(1, 1/\theta)$ ينتمي لعائلة النماذج الأسية فإن الإحصاء $T = \sum_{i=1}^n X_i$ يعتبر إحصاءً كافياً لـ θ [راجع المثال (1.4.4)]، ويمكن بسهولة إثبات أنه تام أيضاً.

لإيجاد المقدّر الأكفأ لـ θ (إن وجد) نبحث عن دالة ما في الإحصاء الكافي التام $T = \sum_{i=1}^n X_i$ توقعها الرياضي θ ، ونلاحظ بسهولة أن ذلك محقق في الدالة:

$$H_1(T) = \frac{n-1}{\sum_{i=1}^n X_i} = \frac{n-1}{T}$$

وبالتالي $H(T)$ المقدّر الأكفأ للمعلمة θ ، على الرغم من أنه ليس المقدّر الأمثل [راجع المثال (6.7.5)]، وهذا يعني أن المقدّر الأكفأ ليس بالضرورة أمثل لـ $\tau(\theta)$.

وبشكل مشابه نجد أن الإحصاء:

$$H_2(T) = \frac{T}{n} = \bar{X}$$

هو المقدّر الأكفأ لـ $1/\theta$.

تمارين

1. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $B(1, \theta)$:
 1. عين متوسط مربع الخطأ، ومن ثم مقدار التحيز (إن وجد) لكل من المقدّرات الآتية لتقدير المعلمة θ .

$$T_1 = \bar{X} \quad , \quad T_2 = \frac{X_1 + X_2}{2n} \quad , \quad T_3 = \frac{X_1 + X_2}{2}$$
 2. ما هو المقدّر الأفضل من بين المقدّرات غير المتحيزة في (1).
2. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, 4)$:
 1. عين متوسط مربع الخطأ، ومن ثم مقدار التحيز للمقدّر $T_1 = 2\bar{X}$ لتقدير المعلمة θ .
 2. هل $T_2 = \frac{n}{n+1}\bar{X}^2 + X_1$ مقدّر غير متحيز لـ $\tau(\theta) = \theta(1+\theta)$ ؟
3. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $f(x; \theta)$ بمتوسط θ وتباين σ^2 محدود، فأثبت أن المقدّر:

$$T = \frac{2}{n(n+1)} \sum_{i=1}^n iX_i$$

غير متحيز ومتسق لتقدير المعلمة θ .

4. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $B(1, \theta)$ ، فبين أي من المقدرات الآتية لتقدير المعلمة θ متسق:

$$T_1 = 2\bar{X} - X_1 \quad , \quad T_2 = \frac{X_1 + X_2}{2} \quad , \quad T_3 = \bar{X}$$

5. إذا كانت X عينة عشوائية بحجم $n = 2$ من توزيع $N(\theta, 1)$ ، وكانت:

$$T_1 = \frac{2}{3}X_1 + \frac{1}{3}X_2 \quad , \quad T_2 = \frac{1}{5}X_1 + \frac{4}{5}X_2 \quad , \quad T_3 = \bar{X}$$

فبين المقدّر الأفضل منهم.

6. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \frac{1}{\theta + 2} e^{-x/(\theta+2)} \quad ; \quad x < 0$$

فأوجد الحد الأدنى لتباين المقدرات غير المتحيزة لتقدير θ .

7. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta(1+x)^{-(1+\theta)} \quad ; \quad x > 0, \theta > 0$$

1. أوجد إحصاء كافي تام لـ θ (إن وجد).

2. أوجد الحد الأدنى لمتباينة كرامر وراو من أجل المقدرات غير المتحيزة

لتقدير $\tau(\theta) = 1/\theta$.

3. أوجد المقدّر الأكفأ لتقدير $\tau(\theta) = 1/\theta$ (إن وجد).

8. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \frac{\ln \theta}{\theta - 1} \theta^x \quad ; \quad 0 < x < 1, \theta > 1$$

1. أوجد إحصاء كافي تام لـ θ (إن وجد).

2. أوجد دالة ما في θ يوجد لها المقدّر الأكفأ.

9. لتكن X عينة عشوائية بحجم n من توزيع:

$$f(x;\theta) = e^{-(x-\theta)} ; x \geq \theta, -\infty < \theta < +\infty$$

1. هل يوجد إحصاء كافي تام لـ θ ؟ إن كان الجواب بنعم فأوجده.

2. أوجد المقدّر الأكفأ لتقدير θ (إن وجد).

3. أوجد دالة ما $\tau(\theta)$ يوجد لها المقدّر الأكفأ.

10. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $f(x;\theta)$. بمتوسط θ وتباين σ^2 .

1. أثبت أن $\sum_{i=1}^n a_i X_i$; $\sum_{i=1}^n a_i = 1$ مقدرات غير متحيزة لتقدير المعلمة θ .

2. عين قيمة الثوابت a_1, \dots, a_n بحيث يكون المقدّر $T(X)$ ذو تباين أصغري ضمن مجموعة المقدرات (1).

11. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \frac{2x}{\theta^2} ; 0 < x < \theta, \theta > 0$$

1. هل $Y_n = X_{(n)}$ إحصاء تام لـ θ ؟

2. هل يوجد المقدّر الأكفأ لـ θ ؟ إن كان الجواب بنعم فأوجده.

12. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\Pi(\theta)$.

1. هل يوجد مقدّر غير متحيز لتقدير $\tau_1(\theta) = \frac{1}{\theta}$.

2. أوجد مقدّر غير متحيز لتقدير $\tau_2(\theta) = (1 + \theta)e^{-\theta}$.

3. أوجد المقدّر الأكفأ لتقدير $\tau_2(\theta)$ (إن وجد).

13. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta x^{-2} \quad ; \quad x \geq 0, \theta > 0$$

فأوجد دالة ما $\tau(\theta)$ يوجد لها المقدّر الأكفأ.

14. لنفترض بناءً على ملاحظة واحدة على متغير عشوائي X يتبع توزيع:

$$f(x; \theta) = e^{-\theta} \frac{\theta^x / x!}{(1 - e^{-\theta})} \quad ; \quad x = 1, 2, \dots$$

يطلب تقدير الدالة $\tau(\theta) = 1 - e^{-\theta}$. أوجد الإحصاء $T(X_1)$ الذي يحقق شرط عدم التحيز. $E_{\theta} T(X_1) = 1 - e^{-\theta}$ ، وأثبت أنه غير مفيد تطبيقياً.

15. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\Gamma(\alpha, \theta)$ ، فأثبت أن

$$\begin{aligned} \text{الإحصاء } T(X) &= \frac{1}{n} \sum_{i=1}^n \ln X_i - \ln \alpha \\ V_{\theta} T &= \frac{\tau'(\theta)}{n} \quad \text{وأن تبينه } \tau(\theta) = \frac{\Gamma'(\theta)}{\Gamma(\theta)} \end{aligned}$$

16. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = e^{-x+\theta} (1 + e^{-x+\theta}) \quad ; \quad -\infty < x < \infty$$

1. أثبت أن الإحصاء $T(X) = \bar{X}$ مقدّر غير متحيز لتقدير θ ، وأن تبينه

$$V_{\theta} T = \frac{\pi^2}{3n}$$

2. أثبت أن دالة المعلومات $i(\theta) = \frac{1}{3}$

3. أثبت أن \bar{X} لا يعتبر المقدّر الأكفأ لتقدير المعلمة θ .

طرق إيجاد مقدرات النقطة

1.6 مقدمة

تطرقنا في الفصل السابق لمفهوم التقدير النقطي، وبيننا الخواص التي نريد لمقدر أن يتصف بها. وتعرضنا بشيء من التفصيل لتلك الصفات وأظهرنا أن المقدر الجيد بشكل عام هو الذي تتوفر فيه الصفات الآتية:

1. الكفاية .
2. عدم التحيز .
3. الإنساف .
4. الكفاءة .

وهناك عدة طرق تعطي مقدرات نقطية تتصف بكل أو بعض تلك الصفات. وفي هذا الفصل سندرس بعض الطرق الشائعة الاستخدام في الإحصاء للحصول على المقدرات.

2.6 طريقة المعقولة العظمى

MAXIMUM LIKELIHOOD METHOD

في مقالين نشرتا عام 1920م، عرض فيهما العالم فيشر (R. A. Fisher) أحد رواد الإحصاء في عصرنا طريقة عامة للتقدير أطلق عليها اسم "طريقة المعقولة العظمى" أو "الإمكان الأكبر"، كما بين مميزات هذه الطريقة. تعتبر طريقة

المعقولة العظمى إحدى أهم وأكثر الطرق انتشاراً في الإحصاء لتقدير معالم التوزيع الاحتمالي الإحصائي (النموذج الإحصائي) المقترح.

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه الاحتمالي $f(x; \theta)$ ، فإننا سنرمز لمقدر المعلمة θ الذي نحصل عليه باستخدام طريقة المعقولة العظمى بـ $\hat{\theta}(X)$ ، كما سنرمز لمقدر دالة معلمية $\tau(\theta)$ بـ $\hat{\tau} = \hat{\tau}(X)$ ، ومن ثم للتقدير بنقطة الموافق لعينة مشاهدة $x = (x_1, \dots, x_n)$ بـ $\hat{\theta} = \hat{\theta}(x)$ و $\hat{\tau} = \hat{\tau}(x)$ على الترتيب.

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع:

$$L(\xi) \in \mathcal{F}\{F(x; \theta); \theta \in \Theta\}$$

و $L(x; \theta)$ دالة المعقولة من أجل قيمة ملاحظة $x = (x_1, \dots, x_n)$ للعينة X .

تعريف 1.2.6

تدعى القيمة (النقطة) $\hat{\theta}(x) \in \Theta$ بتقدير المعقولة العظمى (maximum likelihood estimating) للمعلمة θ ، إذا كانت دالة المعقولة $L(x; \theta)$ تبلغ نهايتها العظمى عندها، أي أن:

$$L(x; \hat{\theta}) \geq L(x; \theta) \quad ; \quad \forall \theta \in \Theta \quad (1.2.6)$$

أو:

$$L(x; \hat{\theta}) = \sup_{\theta \in \Theta} L(x; \theta)$$

وهذا يعني أن التقدير $\hat{\theta}$ في حالة التوزيعات المنقطعة عبارة عن قيمة θ التي تجعل احتمال سحب العينة المشاهدة x (قيمة لـ X) أكبر ما يمكن. أما بالنسبة للتوزيعات المستمرة فإن قيمة θ التي تجعل احتمال الحصول على مفردات العينة X قريبة جداً من القيم التي حصلنا عليها (القيم x_1, \dots, x_n) أكبر ما يمكن.

ويمكن تفسير ما سبق على النحو الآتي:

إذا فرضنا أن θ معلومة ولتكن θ_0 ، فإن قيمة X التي يكون وقوعها أو تحققها أكثر احتمالاً هي تلك القيمة ولنرمز لها بـ $x' = (x'_1, \dots, x'_n)$ التي تجعل الدالة $L(x; \theta_0)$ أعظم ما يمكن. وعندما تأخذ θ قيمها الممكنة في فضاء المعلمة θ فإنها تعرف من أجل كل قيمة $\theta \in \Theta$ دالة كثافة (أو دالة احتمال) معينة وبالتالي مجتمعاً معيناً. وبعد الحصول فعلاً على قيمة مشاهدة $x = (x_1, \dots, x_n)$ للعينة $X = (X_1, \dots, X_n)$ ، فإننا نرغب في معرفة ذلك المجتمع الذي يمكن أن يعطي مثل تلك العينة المشاهدة x بأكبر احتمال ممكن، أي نريد إيجاد قيمة لـ θ من Θ (نرمز لها بـ $\hat{\theta}$) تجعل دالة المعقولية $L(x; \theta)$ عندها في نهايتها العظمى. وقيمة $\hat{\theta}$ هذه ستكون بشكل عام دالة في $x = (x_1, \dots, x_n)$ تسمى تقدير المعقولية العظمى (maximum likelihood estimate) و $\hat{\theta}(X)$ بمقدر المعقولية العظمى (maximum likelihood estimator).

إذا كان من أجل كل قيمة $x \in G$ دالة المعقولية $L(x; \theta)$ تبلغ نهايتها العظمى عند نقطة داخلية من فضاء المعلمة θ وقابلة للاشتقاق بالنسبة لـ θ ، فإن تقدير المعقولية العظمى $\hat{\theta} = \hat{\theta}(x)$ يحقق المعادلة:

$$\frac{\partial L(x; \theta)}{\partial \theta} = 0 \quad \text{أو} \quad \frac{\partial \ln L(x; \theta)}{\partial \theta} = 0 \quad (2.2.6)$$

بالإضافة إلى المتباينة:

$$\frac{\partial^2 L(x; \theta)}{\partial \theta^2} < 0 \quad \text{أو} \quad \frac{\partial^2 \ln L(x; \theta)}{\partial \theta^2} < 0 \quad (3.2.6)$$

وهذا يعني، أننا نحصل على التقدير $\hat{\theta}$ بحل المعادلة (2.2.6) بعد التأكد من تحقق المتباينة (3.2.6).

أما إذا كانت المعلمة θ متعددة الأبعاد، أي $\theta = (\theta_1, \dots, \theta_r)$ ، فإن التقدير $\hat{\theta}$ نحصل عليه بحل منظومة المعادلات:

$$\frac{\partial L(x; \theta)}{\partial \theta_i} = 0 \quad ; \quad i = 1, 2, \dots, r \quad (4.2.6)$$

أو

$$\frac{\partial \ln L(x; \theta)}{\partial \theta_i} = 0 \quad ; \quad i = 1, 2, \dots, r$$

التي تدعى بمعادلات المعقولة.

لنرى الآن بعض الأمثلة لإيجاد مقدرات المعقولة العظمى.

مثال 1.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه الاحتمالية:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0, \theta > 0$$

فأوجد مقدر المعقولة العظمى للمعلمة θ .

بما أن:

$$L(x; \theta) = \theta^n e^{-\theta \sum x_i}$$

فإن:

$$\ln L(x; \theta) = n \ln \theta - \theta \sum x_i$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = \frac{n}{\theta} - \sum x_i$$

وبوضع $\frac{\partial \ln L(x; \theta)}{\partial \theta} = 0$ نجد:

$$\frac{n}{\theta} - \sum x_i = 0$$

وبحل هذه المعادلة بالنسبة لـ θ نحصل على تقدير المعقولة العظمى:

$$\hat{\theta} = \hat{\theta}(x) = \frac{n}{\sum x_i} = \frac{1}{\bar{x}}$$

ومن ثم فإن مقدر المعقولة العظمى للمعلمة θ هو:

$$\hat{\theta}(X) = \frac{1}{\bar{X}}$$

مثال 2.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بواسون $\Pi(\theta)$ ، فأوجد مقدر المعقولة العظمى للمعلمة θ .

بما أن:

$$f(x; \theta) = \frac{\theta^x}{x_i!} e^{-\theta} \quad ; \quad x = 0, 1, 2, \dots$$

فإن:

$$L(x; \theta) = \frac{\theta^{\sum x_i}}{\prod x_i!} e^{-n\theta}$$

$$\ln L(x; \theta) = -n\theta + \sum x_i \ln \theta - \sum \ln(x_i!)$$

وبالتالي:

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = -n + \frac{\sum x_i}{\theta}$$

بوضع $\frac{\partial \ln L(x; \theta)}{\partial \theta} = 0$ وحلها بالنسبة لـ θ نجد:

$$-n + \frac{\sum x_i}{\theta} = 0$$

$$\hat{\theta} = \hat{\theta}(x) = \frac{\sum x_i}{n} = \bar{x}$$

ومقدر المعقولة العظمى لـ θ يكون:

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

ونلاحظ بسهولة أن \bar{X} مقدر غير متحيز لـ θ .

مثال 3.2.6

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\mu, \theta^2)$ ونرغب في إيجاد مقدر المعقولة العظمى لـ θ^2 .

كما نعلم:

$$f(x; \theta) = \frac{1}{\theta\sqrt{2\pi}} e^{-\frac{1}{2\theta^2}(x-\mu)^2}$$

وعلى ذلك:

$$L(x; \theta) = (2\pi\theta^2)^{-\frac{n}{2}} e^{-\frac{1}{2\theta^2}\sum(x_i-\mu)^2}$$

$$\ln L(x; \theta) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \theta^2 - \frac{1}{2\theta^2} \sum (x_i - \mu)^2$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = -\frac{n}{2\theta^2} + \frac{1}{2\theta^4} \sum_{i=1}^n (x_i - \mu)^2 = 0$$

وبحل هذه المعادلة بالنسبة لـ θ^2 نجد:

$$\hat{\theta}^2(x) = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$$

ومن ثم فمقدر المعقولة العظمى:

$$\hat{\theta}^2(X) = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$$

وهو مقدر غير متحيز لـ θ^2 .

مثال 4.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من التوزيع $N(\theta_1, \theta_2^2)$ ، فأوجد مقدر العقولية العظمى للمعلمة $\theta = (\theta_1, \theta_2^2)$.

بما أن:

$$f(x; \theta) = \frac{1}{\theta_2 \sqrt{2\pi}} e^{-\frac{1}{2\theta_2^2}(x-\theta_1)^2} ; \quad \theta = (\theta_1, \theta_2)$$

فإن:

$$L(x; \theta) = (2\pi)^{-\frac{n}{2}} (\theta_2^2)^{-\frac{n}{2}} e^{-\frac{1}{2\theta_2^2} \sum (x_i - \theta_1)^2}$$

$$\begin{aligned} \ln L(x; \theta) &= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \theta_2^2 - \frac{1}{2\theta_2^2} \sum_{i=1}^n (x_i - \theta_1)^2 \\ &= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \theta_2^2 - \frac{n}{2\theta_2^2} s^2 + \frac{n(\bar{x} - \theta_1)^2}{2\theta_2^2} \end{aligned}$$

حيث أن $s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ القيمة الملاحظة لتباين العينة S^2 .

وعلى ذلك نجد:

$$\frac{\partial \ln L(x; \theta)}{\partial \theta_1} = \frac{n(\bar{x} - \theta_1)}{\theta_2^2} = 0$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta_2^2} = -\frac{n}{2\theta_2^2} + \frac{n}{2\theta_2^4} s^2 + \frac{n(\bar{x} - \theta_1)^2}{2\theta_2^4} = 0$$

وبحل جملة المعادلتين نحصل على تقديري العقولية العظمى:

$$\hat{\theta}_1(x) = \bar{x} \quad , \quad \hat{\theta}_2^2(x) = s^2$$

ومن ثم مقدري العقولية العظمى:

$$\hat{\theta}_1(X) = \bar{X} \quad , \quad \hat{\theta}_2^2(X) = S^2$$

إن المقدّر \bar{X} لـ θ_1 غير متحيز بينما الإحصاء S^2 مقدّر لـ θ_2^2 متحيز. وبالتالي فإن مقدّر المعقولة العظمى لـ θ موجود ووحيد $\hat{\theta} = (\hat{\theta}_1, \hat{\theta}_1^2) = (\bar{X}, S^2)$. وهذا المقدّر دالة في الإحصاء الكافي $T = (T_1, T_2)$ ، حيث أن $T_1 = \bar{X}$ و $T_2 = \sum_{i=1}^n (X_i - \bar{X})$.

هكذا، فمقدّر المعقولة العظمى لدالة $\tau(\theta)$ يمكن أن يكون متحيزاً، أي ليس بالضرورة أن يكون مقدّر المعقولة العظمى غير متحيز.

مثال 5.2.6

بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع المنتظم $R(0, \theta)$ ، فأوجد مقدّر المعقولة العظمى للمعلمة θ .

بما أن:

$$f(x; \theta) = \frac{1}{\theta} \quad ; \quad 0 < x \leq \theta$$

فيمكن كتابتها على النحو الآتي [راجع مثال (11.2.4)].

$$f(x; \theta) = \frac{1}{\theta} \quad ; \quad \theta \geq x_{(n)} \quad , \quad x_{(n)} = \max x_i$$

وبالتالي فدالة المعقولة:


$$L(x; \theta) = \frac{1}{\theta^n} \quad ; \quad \theta \geq x_{(n)}$$

يعني هذا أن دالة المعقولة L متناقصة تماماً في θ . وبما أن θ لا يمكن أن تكون أصغر من $x_{(n)}$ ، فإن $L(x; \theta)$ تبلغ نهايتها العظمى عندما $\theta = x_{(n)}$. وبالتالي فمقدّر المعقولة العظمى لـ θ هو $\hat{\theta}(X) = X_{(n)}$. ونلاحظ أن دالة المعقولة $L(x; \theta)$ غير مستمرة عند النقطة $\theta = x_{(n)}$ ، ومن ثم مشتقتها عند هذه النقطة غير موجودة، أي أن تقدير المعقولة العظمى لا يعتبر حلاً لمعادلة المعقولة:

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = 0$$

وهذه صفة مميزة للحالات التي لا يكون فيها فضاء العينة G يعتمد على معلمة. لذا في مثل هذه الحالات يجب الحيلة وإتباع طرق أخرى (غير حل معادلة أو معادلات المعقولة) للحصول على مقدر المعقولة العظمى، وستتطرق لبعض هذه الطرق لاحقاً.

ولإيضاح تلك الميزة بيانياً، نفترض أن دالة المعقولة $L(x; \theta)$ يمكن تمثيلها بيانياً كما هي مبينة على الشكل (1.2.6)، حيث تعطي طريقة الاشتقاق النقطة θ' بينما التقدير المطلوب (التقدير الذي يجعل دالة المعقولة $L(x; \theta)$ تبلغ نهاية عظمى عنده) هو $\hat{\theta}$.



شكل (1.2.6)

مثال 6.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $R(\alpha, \beta)$ ، فأوجد مقدر المعقولة العظمى للمعلمة $\theta = (\alpha, \beta)$.

بما أن:

$$f(x;\theta) = \begin{cases} 1/(\beta - \alpha) & ; \alpha < x < \beta \\ 0 & ; x \leq \alpha \text{ or } x \geq \beta \end{cases}$$

فإن:

$$L(x;\theta) = \frac{1}{(\beta - \alpha)^n} \quad ; \quad \alpha < x_i < \beta \quad , \quad i = 1, \dots, n$$

وباشتقاق L جزئياً بالنسبة لكل من α, β والمساواة بالصفر نحصل على معادلتين، وبمجهلهما نجد أحد المعلمتين α, β على الأقل غير محدود. وهذه النتيجة (الحل) غير مقبولة (غير منطقية)، أي تخفق طريقة الاشتقاق في إعطاء التقدير المطلوب. لكن نلاحظ بوضوح من صيغة دالة المعقولة $L(x;\theta)$ أنها تبلغ أكبر قيمة لها عندما يكون الفرق $(\beta - \alpha)$ أصغر ما يمكن، وهذا يتحقق عندما $\beta - \alpha = x_{(n)} - x_{(1)}$ ، وبالتالي مقدر المعقولة العظمى:

$$\hat{\theta}(X) = (X_{(1)}, X_{(n)})$$

مثال 7.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \alpha, \beta) = \frac{1}{2\beta} \quad ; \quad \alpha - \beta \leq x \leq \alpha + \beta$$

فأوجد مقدر المعقولة العظمى للمعلمة $\theta = (\alpha, \beta)$


بما أن:

$$L(x;\theta) = \frac{1}{(2\beta)^n} \quad ; \quad \alpha - \beta \leq x_i \leq \alpha + \beta \quad , \quad i = 1, \dots, n$$

أي أن:

$$L(x;\theta) = \frac{1}{(2\beta)^n} \quad ; \quad \alpha - \beta \leq x_{(1)} < x_{(n)} \leq \alpha + \beta \quad , \quad i = 1, \dots, n$$

لإيجاد مقدرّ المعقولة العظمى نستخدم الطريقة البيانية، كما هي مبينة على الشكل (2.2.6)



شكل (2.2.6)

نلاحظ أن دالة المعقولة $L(x; \theta)$ تساوي $(1/2\beta)^n$ في المنطقة المظللة على الشكل (2.2.6)، وأن أكبر قيمة ممكنة لها عندما تكون β أصغر ما يمكن، وتكون β أصغر ما يمكن عند تقاطع الخطين:

$$\beta = \alpha - x_{(1)} \quad , \quad \beta = x_{(n)} - \alpha$$

وبالتالي بجلهما المشترك نجد:

$$\hat{\alpha} = \frac{x_{(1)} + x_{(n)}}{2} \quad , \quad \hat{\beta} = \frac{x_{(n)} - x_{(1)}}{2}$$

ومن ثم فإن مقدرّ المعقولة العظمى لـ $\theta = (\alpha, \beta)$ هو:

$$\hat{\theta}(X) = (\hat{\alpha}, \hat{\beta}) \quad ; \quad \hat{\alpha}(X) = \frac{X_{(1)} + X_{(n)}}{2} \quad , \quad \hat{\beta}(X) = \frac{X_{(n)} - X_{(1)}}{2}$$

مثال 8.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $L(x; \theta) \in R(\theta, \theta + 1)$ ، فأوجد مقدرّ المعقولة العظمى للمعلمة θ .

بما أن:

$$f(x; \theta) = 1 \quad , \quad \theta \leq x \leq \theta + 1$$

فإن دالة المعقولة $L(x; \theta)$ يمكن كتابتها بدلالة دالة خوفسيد على الصورة:

$$L(x; \theta) = e^{(\theta + 1 - x_{(n)})} e^{(x_{(1)} - \theta)}$$

ونلاحظ بوضوح من هذه الصيغة أن $L(x; \theta)$ تأخذ أكبر قيمة ممكنة لها عندما تكون:

$$\left. \begin{array}{l} \theta + 1 \geq x_{(n)} \\ \theta \leq x_{(1)} \end{array} \right\} \Rightarrow x_{(n)} - 1 \leq \theta \leq x_{(1)}$$

وعلى ذلك فإن تقدير المعقولة العظمى ليس وحيداً، حيث أن أية قيمة:

$$\hat{\theta}(x) \in [x_{(n)} - 1; x_{(1)}]$$

هي تقدير المعقولة العظمى. فمثلاً، كمقدرّ معقولة عظمى يمكن أخذ:

$$\hat{\theta}(X) = \frac{X_{(1)} + X_{(n)} - 1}{2}$$

وفي هذه الحالة $\hat{\theta}(X)$ دالة في الإحصاء الكافي $T = (X_{(1)}, X_{(2)})$. ونخلص من هذا المثال إلى أن مقدرّ المعقولة العظمى للمعلمة θ ليس بالضرورة وحيداً.

مثال 9.2.6

(نموذج طبيعي متعدد الأبعاد، تقدير المعقولة العظمى لمعالمه).

لنفترض أن المتغير العشوائي الملاحظ ξ متعدد الأبعاد (k بعد مثلاً) يخضع للتوزيع الطبيعي $N(\mu, \Sigma)$ ، حيث أن $\mu = (\mu_1, \dots, \mu_k)$ متجهة القيم المتوسطة و $\Sigma = \|\sigma_{ij}\|_1^k$ ($|\Sigma| \neq 0$) مصفوفة العزوم المركزية من المرتبة الثانية. إن عدد المعالم غير المعلومة (أخذين بالاعتبار تناظر المصفوفة Σ) يساوي $k + k(k+1)/2$.

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من التوزيع $\mathcal{L}(\xi)$ ، فالمطلوب إيجاد تقديرات المعقولة العظمى لمعالم هذا التوزيع.

بما أن X_i متغيرات عشوائية مستقلة وكل منها ذات k بعد، بكثافة:

$$f(x_i; \theta) = \frac{1}{\sqrt{(2\pi)^k |\Sigma|}} \exp\left[-\frac{1}{2}(x_i - \mu)' \Sigma^{-1} (x_i - \mu)\right] ; \quad \theta = (\mu, \Sigma)$$

فإن:

$$L(x, \theta) = \prod_{i=1}^n f(x_i; \theta) = (2\pi)^{-\frac{kn}{2}} |\Sigma|^{-\frac{n}{2}} \exp\left[-\frac{1}{2} \sum_{i=1}^n (x_i - \mu)' \Sigma^{-1} (x_i - \mu)\right] \quad (5.2.6)$$

لنرمز بـ $\bar{x} = (x_1 + \dots + x_n)/n$ عندها:

$$\begin{aligned} \sum_{i=1}^n (x_i - \mu)' \Sigma^{-1} (x_i - \mu) &= \\ &= \sum_{i=1}^n (x_i - \bar{x})' \Sigma^{-1} (x_i - \bar{x}) + n(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu) \end{aligned} \quad (6.2.6)$$

إذا رمزنا بـ $\hat{\Sigma}(x)$ لمصفوفة العزوم من المرتبة الثانية للعينة، فإن:

$$\hat{\Sigma}(x) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})' = \|\hat{\sigma}_{ij}\|_1^k$$

حيث أن $\hat{\sigma}_{ij}$ العزم المركزي من المرتبة الثانية للعينة وبحسب من العلاقة:

$$\hat{\sigma}_{ij} = \frac{1}{n} \sum_{i=1}^n (x_{ii} - \bar{x}_i)(x_{ii} - \bar{x}_j) ; \quad i, j = 1, \dots, k$$

$$\bar{x}_i = \frac{1}{n}(x_{1i} + \dots + x_{ni}) \text{ و } \mathbf{x}_l = (x_{l1}, \dots, x_{lk}); l = 1, \dots, n \text{ (هنا)}$$

$$.(\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_k))$$

وباستخدام المساواة $\mathbf{y}'\mathbf{B}\mathbf{y} = \text{tr}(\mathbf{B}\mathbf{Y})$ ، والمؤثر الخطي tr نجد:

$$\sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})' \Sigma^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}) = n \text{tr}(\Sigma^{-1} \hat{\Sigma}(\mathbf{x}))$$

وبناءً على المساواتين (6.2.6) و (7.2.6) يمكن كتابة دالة العقولية $L(\mathbf{x}; \theta)$ على الصورة:

$$L(\mathbf{x}; \theta) = (2\pi)^{-\frac{kn}{2}} \exp \left[-\frac{n}{2} (\bar{\mathbf{x}} - \boldsymbol{\mu})' \Sigma^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}) - \frac{n}{2} \text{tr} \Sigma^{-1} \hat{\Sigma}(\mathbf{x}) - \frac{n}{2} \ln |\Sigma| \right]$$

نلاحظ أن أكبر قيمة ممكنة لدالة العقولية L بالنسبة لـ θ توافق أصغر قيمة ممكنة للدالة:

$$\psi(\mathbf{x}, \boldsymbol{\mu}, \Sigma) = (\bar{\mathbf{x}} - \boldsymbol{\mu})' \Sigma^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}) + \left[\text{tr} \Sigma^{-1} \hat{\Sigma}(\mathbf{x}) - k - \ln |\Sigma^{-1} \hat{\Sigma}(\mathbf{x})| \right]$$

بالنسبة لـ $\boldsymbol{\mu}, \Sigma$. (إدخال الثابتين k و $\ln |\hat{\Sigma}|$ من أجل تبسيط الصياغات اللاحقة).

إذا رمزنا بـ $\lambda_1, \dots, \lambda_k$ لجذور المعادلة المميزة:

$$|\Sigma^{-1} \hat{\Sigma}(\mathbf{x}) - \lambda E_n| = 0 \quad \text{أو} \quad |\hat{\Sigma}(\mathbf{x}) - \lambda \Sigma| = 0$$

فإن:

$$\text{tr} \Sigma^{-1} \hat{\Sigma}(\mathbf{x}) - k - \ln |\Sigma^{-1} \hat{\Sigma}(\mathbf{x})| = \lambda_1 + \dots + \lambda_k - k - \ln(\lambda_1 + \dots + \lambda_k)$$

بما أن Σ^{-1} مصفوفة محددة وموجبة و $a \geq 0$ ، $a - 1 - \ln a \geq 0$ ، فإن:

$$\psi(\mathbf{x}, \boldsymbol{\mu}, \Sigma) \geq 0$$

وتتحقق المساواة فقط عندما $\lambda_1 = \lambda_2 = \dots = \lambda_k = 1$ و $\mu = \bar{x}$ أي عندما $\mu = \bar{x}$ و $\Sigma = \hat{\Sigma}(x)$ ، وبالتالي فإن مقدرَي المعقولة العظمى لـ μ و $\Sigma = \|\sigma_{ij}\|_1^k$ هما على الترتيب \bar{X} و $\hat{\Sigma}(x) = \|\hat{\sigma}_{ij}\|_1^k$.

يتمتع مقدرُ المعقولة العظمى لمعلمة θ ببعض الخواص الهامة، والتي سنذكرها بصيغة مبرهنات.

مبرهنة 1.2.6

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $f(x; \theta)$ يعتمد على معلمة θ (وحيدة البعد أو متعددة الأبعاد) و $\hat{\theta}(x)$ تقدير المعقولة العظمى لـ θ .

إذا كانت $q = q(\theta)$ دالة تناظر أحادية ما في θ معرفة على θ وتأخذ قيمها في $Q = \{q = (q_1, \dots, q_r)\} \subset R^r$ ، فإن تقدير المعقولة العظمى لـ $q = q(\theta)$ هو $\hat{q} = q(\hat{\theta})$.

الإثبات

بما أن $q = q(\theta)$ دالة تناظر أحادية في θ (حسب الفرض)، فإن الدالة العكسية موجودة وهي $\theta = \theta(q)$ ، عندها:

$$\sup_{\theta \in \Theta} L(x; \theta) = \sup_{q \in Q} L(x; \theta(q))$$

وإذا كانت الدالة $L(x; \theta)$ تبلغ أكبر قيمة ممكنة لها عند النقطة $\hat{\theta} = \hat{\theta}(x)$ ، فإن الدالة $L(x; \theta(q))$ في q تبلغ أكبر قيمة لها عند النقطة \hat{q} ، المحققة للمعادلة $\hat{\theta} = \theta(\hat{q})$ أي عند النقطة $\hat{q} = q(\hat{\theta})$.

تدعى هذه الخاصة لمقدرُ المعقولة العظمى بخاصة الثبات أو عدم الاختلاف (invariance property of maximum likelihood estimator). وتعطي هذه الخاصة إمكانية الحصول على مقدرات المعقولة العظمى لأسرة هامة من

الدوال المعلمية $\tau(\theta)$ ذات التناظر الأحادي في θ . وهذا ما سنوضحه من خلال الأمثلة الآتية.

مثال 10.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه الاحتمالي:

$$f(x; \theta) = \theta^x (1 - \theta)^{1-x} \quad ; \quad x = 0, 1$$

فأوجد مقدرّ المعقولة العظمى للدالة $\tau(\theta) = \frac{2\theta}{1+\theta}$.

نبحث أولاً عن مقدرّ المعقولة العظمى للمعلمة θ :

$$L(x; \theta) = \theta^{n\bar{x}} (1 - \theta)^{n(1-\bar{x})}$$

$$\ln L(x; \theta) = n\bar{x} \ln \theta + n(1 - \bar{x}) \ln(1 - \theta)$$

$$\frac{\partial \ln L}{\partial \theta} = \frac{n\bar{x}}{\theta} - \frac{n(1 - \bar{x})}{1 - \theta} = 0$$

ومنها

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

بما أن $\tau(\theta) = \frac{2\theta}{1+\theta}$ دالة تناظر أحادية في θ ، فحسب المبرهنة (1.2.6)،

نجد أن مقدرّ المعقولة العظمى لـ $\tau(\theta)$ هو:

$$\hat{g} = \tau(\hat{\theta}) = \frac{2\bar{X}}{1 + \bar{X}}$$

مثال 11.2.6

إذا كانت لدينا معطيات المثال (1.2.6)، فأوجد مقدرّ المعقولة العظمى لكل من الدوال المعلمية الآتية:

$$\tau_1(\theta) = \frac{1}{\theta} \quad , \quad \tau_2(\theta) = \ln \theta + 1 \quad , \quad \tau_3(\theta) = \frac{\ln \theta}{\theta}$$

بما أن مقدر المعقولة للمعلمة θ هو $\hat{\theta}(X) = \frac{1}{\bar{X}}$ وكل من الدوال العلمية

τ_1, τ_2, τ_3 ذات تناظر أحادي في θ ، فحسب المبرهنة (1.2.6) نجد:

$$\hat{g}_1 = \tau_1(\hat{\theta}) = \bar{X} \quad , \quad \hat{g}_2 = \tau_2(\hat{\theta}) = \ln \frac{1}{\bar{X}} + 1 \quad , \quad \hat{g}_3 = \tau_3(\hat{\theta}) = \bar{X} \ln \frac{1}{\bar{X}}$$

مبرهنة 2.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $f(x; \theta)$ ، وكان هناك إحصاء كافي للمعلمة θ ، فإن مقدر المعقولة العظمى للمعلمة θ يكون دالة في هذا الإحصاء الكافي.

الإثبات

نفترض أن $T = T(X)$ إحصاء كافي للمعلمة θ ، ومن ثم يمكن كتابة دالة المعقولة (حسب المبرهنة 1.2.4) على الصورة:

$$L(x; \theta) = g(t; \theta)h(x)$$

وعلى ذلك:

$$\ln L(x; \theta) = \ln g(t; \theta) + \ln h(x)$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = \frac{\partial \ln g(t; \theta)}{\partial \theta} = K(t; \theta)$$

لإيجاد مقدر المعقولة العظمى نضع:

$$K(T; \theta) = 0$$

وبحل هذه المعادلة بالنسبة لـ θ نجد:

$$\hat{\theta}(X) = \varphi(T)$$

مبرهنة 3.2.6

إذا وجد المقدّر الأمثل للمعلمة θ في توزيع $f(x; \theta)$ ، فإنه مقدّر المعقولة العظمى لهذه المعلمة.

الإثبات

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $f(x; \theta)$ ، ولنفترض أن $T^* = T^*(X)$ المقدّر الأمثل لتقدير المعلمة θ . بما أن T^* المقدّر الأمثل للمعلمة θ ، فإن:

$$E_{\theta} T^* = \theta \quad , \quad V_{\theta} T^* = \frac{1}{ni(\theta)}$$

وبالتالي حسب العلاقاتين (2.7.5) و (8.7.5) نجد:

$$U(X; \theta) = \frac{\partial \ln L(X; \theta)}{\partial \theta} = \frac{1}{ni(\theta)} (T^* - \theta)$$

بوضع:

$$\frac{1}{ni(\theta)} (T^* - \theta) = 0.$$

وبجملها بالنسبة لـ θ نجد أن:

$$\hat{\theta}(X) = T^*$$

مثال 12.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(\theta_1, \theta_2^2) \in \mathcal{L}(\xi)$ ، فلوجد مقدّر المعقولة العظمى للدالة:

$$\tau(\theta) = \Phi\left(\frac{x_0 - \theta_1}{\theta_2}\right) \quad ; \quad \theta = (\theta_1, \theta_2)$$

المثلة للاحتمال $P_\theta(\xi < x_0)$.

يمكن في هذه الحالة وضع $q(\theta) = (\tau(\theta), \theta_2)$ ، وهي دالة تناظر أحادية في $q(\theta)$ ، وبالتالي حسب المبرهنة (1.2.6) فتقدير المعقولة العظمى لـ $q(\theta)$ يكون:

$$\hat{q} = (\tau(\hat{\theta}), \hat{\theta}_2)$$

لكن كما نعلم [راجع المثال (4.2.6)] فتقدير المعقولة العظمى لكل من θ_2, θ_1 هو s, \bar{x} على الترتيب، إذن:

$$\hat{q} = \left(\Phi\left(\frac{x_0 - \bar{x}}{s}\right), s \right)$$

أي أن تقدير المعقولة العظمى لـ $\tau(\theta)$ هو:

$$\hat{\tau} = \tau(\hat{\theta}) = \Phi\left(\frac{x_0 - \bar{x}}{s}\right)$$

ومن ثم فمقدّر المعقولة العظمى لـ $\tau(\theta)$:

$$\hat{\tau}(X) = \Phi\left(\frac{x_0 - \bar{X}}{S}\right)$$

مثال 13.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع الطبيعي ثنائي البعد $N(\theta, \Sigma)$ ، حيث أن:

$$\theta = (0, 0) \quad , \quad \Sigma = \begin{vmatrix} \sigma^2 & \rho\sigma^2 \\ \rho\sigma^2 & \sigma^2 \end{vmatrix}$$

و $\sigma^2 > 0$ ، $|\rho| < 1$ مجهولين.

إن $\mathcal{L}(X_i) \in N(0, \Sigma); i = 1, \dots, n$ أي متغير عشوائي ذو بعدين كثافة توزيعه الاحتمالية:

$$f(x, y; \theta) = \frac{1}{2\pi} \exp \left\{ -\frac{x^2 + y^2}{2\sigma^2(1-\rho^2)} + \frac{\rho(x+y)}{\sigma^2(1-\rho^2)} - \frac{1}{2} \ln[\sigma^2(1-\rho^2)] \right\}; \theta = (\sigma^2, \rho)$$

نلاحظ هنا أن صيغة دالة المعقولة معقدة وهي تعتمد على معلمتين σ^2, ρ وبالتالي لتبسيط عملية إيجاد تقديري المعقولة العظمى $\hat{\sigma}^2$ و $\hat{\rho}$ من المفيد الانتقال إلى معلمة جديدة $q = (q_1, q_2)$ بدلاً من $\theta = (\sigma^2, \rho)$ ، بوضع:

$$q_1 = q_1(\theta) = -\frac{1}{2\sigma^2(1-\rho^2)}$$

$$q_2 = q_2(\theta) = \frac{\rho}{\sigma^2(1-\rho^2)}$$

. . . . (1)

وعندئذٍ يمكن كتابة دالة الكثافة الاحتمالية على الصورة:

$$f(x, y; \theta) = \frac{1}{2\pi} \exp \left[q_1(x^2 + y^2) + q_2xy + \tau(q) \right]$$

حيث أن $\tau(q) = (1/2) \ln(4q_1^2 - q_2^2)$

وعلى ذلك يمكن بسهولة إيجاد معادلتسي المعقولة لتقدير q_1, q_2 ، وهما:

$$\frac{1}{n} \sum_{i=1}^n (x_i^2 + y_i^2) = -\frac{\partial \tau(q)}{\partial q_1} = -\frac{4q_1}{4q_1^2 - q_2^2}$$

$$\frac{1}{n} \sum_{i=1}^n x_i y_i = -\frac{\partial \tau(q)}{\partial q_2} = -\frac{q_2}{4q_1^2 - q_2^2}$$

. . . . (2)

لكن من العلاقاتين في (1) نجد:

$$\sigma^2 = \frac{2q_1}{4q_1^2 - q_2^2}, \quad \rho = -\frac{q_2}{2q_1}$$

وبالتالي من العلاقتين في (2) نحصل على تقدير المعقولة العظمى:

$$\hat{\sigma}^2 = \frac{1}{2n} \sum_{i=1}^n (x_i^2 + y_i^2)$$

$$\hat{\rho} = 2 \sum_{i=1}^n x_i y_i / \sum_{i=1}^n (x_i^2 + y_i^2)$$

حيث أن (x_i, y_i) القيمة الملاحظة لـ X_i ; $i = 1, \dots, n$.

1.2.6 طريقة التراكم لحساب تقدير المعقولة العظمى بالتقريب

لا يتاح دائماً الحصول على تقديرات المعقولة العظمى بصورة صريحة محددة. في مثل تلك الحالات نلجأ إلى طريقة التقريب العددية لحل معادلة أو معادلات المعقولة (عندما يمكن صياغة مثل تلك المعادلات)، أي الحصول على تقدير المعقولة العظمى بالتقريب. وإحدى طرق التقريب هذه تدعى بطريقة التراكم، التي قدمت من قبل العالم فيشر، وتتمثل بما يلي:

لتكن θ معلمة حقيقية ودالة المعقولة $L(x; \theta)$ قابلة للاشتقاق مرتين بالنسبة لـ θ . ننشر دالة المساهمة $U(\theta) = U(x; \theta)$ [راجع الصيغة (1.6.4)] وفق متسلسلة تيلور في جوار النقطة θ_0 ، المتخذة كتقريب ابتدائي لـ $\hat{\theta} = \hat{\theta}(x)$ ، ونحسب هذا المنشور عند $\hat{\theta} = \theta$. عندئذٍ، بما أن $U(\hat{\theta}) = 0$ ، فإن:

$$0 = U(\theta_0) + (\hat{\theta} - \theta_0)U'(\theta^*)$$

حيث θ^* نقطة ما بين $\theta_0, \hat{\theta}$ وبالتالي:

$$\hat{\theta} = \theta_0 - \left(\frac{U(\theta_0)}{U'(\theta^*)} \right)$$

إذا استبدلنا الآن في هذه المساواة θ^* بـ θ_0 و $U'(\theta_0)$ بـ $EU'(X; \theta_0)$ فإننا نحصل على التقريب الأول: [راجع البند (7.5)]

$$\theta_1 = \theta_0 + \frac{U(\theta_0)}{ni(\theta_0)}$$

يمكن تكرار هذه العملية، بأخذ θ_1 كتقريب ابتدائي جديد، وهكذا فالتقريب $(k+1)$ وفق طريقة التراكم يحسب وفق العلاقة:

$$\theta_{k+1} = \theta_k + \frac{U(\theta_k)}{ni(\theta_k)}, \quad k = 0, 1, 2, \dots \quad (12.2.6)$$

تستمر عملية التكرار حتى بلوغ الدقة المطلوبة:

$$|\theta_{k+1} - \theta_k| < \varepsilon$$

إن اختيار النقطة الأولية θ_0 يعتبر هاماً. وعادة يتم أخذ قيمة ما بحيث تسهل حساب تقدير متسق للمعلمة θ ، عندها النقاط الثلاث θ_0 ، θ^* و $\hat{\theta}$ ، في حالة عينة كبيرة الحجم n ، تقع قريبة من القيمة الحقيقية للمعلمة المجهولة. وفي حالات عدة يمكن استخدام تقديرات طريقة العزوم، التي سنتطرق لها لاحقاً، كنقطة أولية θ_0 .
تجدر الإشارة، إلى أن طريقة التراكم بشكل عام تؤدي إلى الهدف وبشكل سريع، مع أنها في بعض الحالات لا تنتهي.

مثال 14.2.6

(نموذج كوشي تقدير المعلمة بطريقة التراكم).

لتكن $X = (X_1, \dots, X_n)$ عينة من توزيع كوشي $K(\theta)$ ، إن دالة المساهمة:

$$U(\theta) = 2 \sum_{i=1}^n \frac{(x_i - \theta)}{1 + (x_i - \theta)^2}$$

إن الحصول على حل دقيق لمعادلة المعقولة $U(\theta) = 0$ غير ممكن. وبما أن دالة المعلومات من أجل نموذج كوشي تساوي $1/2$ [راجع جدول (1.7.4)]، فالمتتالية (12.2.6) تأخذ الشكل:

$$\theta_{k+1} = \theta_k + (2/n)U(\theta_k) \quad , \quad k = 0,1,2,\dots$$

وكتقريب ابتدائي يمكن أخذ θ_0 تساوي وسيط العينة \bar{X} ، الذي يتقارب بالاحتمال، عندما $n \rightarrow \infty$ ، من القيمة الحقيقية للمعلمة θ ، التي تعتبر في الحالة المفروضة الوسيط النظري (وسيط المجتمع $\bar{\mu}$).

2.2.6 الخواص التقريبية لمقدر العقولية العظمى

إن طريقة العقولية العظمى لا تعطي دوماً مقدر غير متحيز. فمثلاً، نجد في المثال (4.2.6)، أن تباين العينة $S^2(X)$ هو مقدر العقولية العظمى للتباين θ_2^2 في النموذج $N(\theta_1, \theta_2^2)$ ، وهذا المقدر متحيز (biased). إلا أن مقدار التحيز $E_0 S^2 - \theta_2^2 = -\theta_2^2/n$ يتناقص بازدياد حجم العينة، وينتهي إلى الصفر عندما $n \rightarrow \infty$ ، أي أن مقدر العقولية العظمى يصبح غير متحيز. تدعى المقدرات المتحيزة التي تتمتع بمثل هذه الخاصة بغير المتحيزة تقاربياً أو غير المتحيزة بالتقارب (asymptotically unbiased).

إن خاصية تلك المقدرات المرتبطة بعدم التحيز تتحسن بازدياد حجم العينة. وهذه الحالة لها طبيعة عامة إلى حد ما. وبشكل خاص إن أهم خاصية لمقدرات العقولية العظمى تتمثل في أن لها طبيعة تقاربية، أي صحيحة من أجل عينات كبيرة. لذا فإن الاستخدام الواسع لمقدرات العقولية العظمى مرتبط أساساً بخواصها التقريبية. إن عرض مبرهنات التقارب لمقدرات العقولية العظمى تشكل محتوى هذه الفقرة، وللإشارة إلى ارتباط المقدرات بحجم العينة سنشير إليها بالدليل n .

عند التكلم عن الخواص التقاربية للمقدرات (أو الخواص من أجل عينات كبيرة)، فقبل كل شيء نهتم باتساقها، وبعبارة أخرى، بالتقارب بالاحتمال للمقدرات المفروضة من المميزات النظرية الموافقة لها، لأنه كما بينا في الفصل الثالث، أن غالبية مميزات العينة (عزوم العينة، القيم الحرجة، قيمة دالة التوزيع

التحريبي في كل نقطة، ... الخ) تتقارب بالاحتمال من المميزات النظرية الموافقة لها، عندما $n \rightarrow \infty$ ، وبالتالي تعتبر مقدرّات متسقة. لنقدم الآن التعريف الدقيق للاتساق.

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $\mathcal{L}(\xi) \in \mathcal{F}\{F(x; \theta) ; \theta \in \Theta\}$ حيث في الحالة العامة فضاء المعلمة Θ مجال مفتوح من الفضاء R^r .

يُدعى، حسب التعريف، المقدّر $T_n = T_n(X)$ من أجل دالة معلمية $\tau(\theta)$ بالمتسق، إذا حقق الشرط التالي:

$$T_n \xrightarrow{P_\theta} \tau(\theta) \quad ; \quad \forall \theta \in \Theta$$

أي أنه مهما تكن القيمة الحقيقية للمعلمة θ من فضاء المعلمة Θ ، فإن T_n يتقارب احتمالياً (بالنسبة للتوزيع P_θ) من القيمة الحقيقية للدالة المقدّرة $\tau(\theta)$.

إن خاصية الاتساق ضرورة من أجل أي قاعدة تقدير، إلا أنها في حقيقة الأمر، تعتبر خاصة تقاربية ومستقلة عن خواص المقدّر عند ثبات حجم العينة (خلافاً لخاصتي عدم التحيز والكفاءة).

لنرى الآن المعيار الهام والبسيط للاتساق.

مبرهنة 4.2.6

إذا كان:

$$E_\theta T_n = \tau(\theta) + \varepsilon_n \quad , \quad V_\theta T_n = \delta_n$$

و

$$\varepsilon_n = \varepsilon_n(\theta) \rightarrow 0 \quad , \quad \delta_n = \delta_n(\theta) \rightarrow 0 \quad ; \quad \forall \theta \in \Theta$$

عندما $n \rightarrow \infty$ ، فإن T_n مقدّر متسق للدالة $\tau(\theta)$.

الإثبات

بما أن:

$$|T_n - E_\theta T_n| = |(T_n - \tau) - (E_\theta T_n - \tau)| \geq |T_n - \tau| - |E_\theta T_n - \tau|$$

والحدث $\{|T_n - \tau| \geq \varepsilon\}$ محتوى في الحدث $\{|T_n - E_\theta T_n| \geq \varepsilon - |\varepsilon_n|\}$ فحسب متباينة تشيبيشيف نجد:

$$P_\theta(|T_n - \tau| \geq \varepsilon) \leq P_\theta(|T_n - E_\theta T_n| \geq \varepsilon - |\varepsilon_n|) \leq \frac{\delta_n}{(\varepsilon - |\varepsilon_n|)^2} \rightarrow 0$$

عندما $n \rightarrow \infty$ مهما تكن $\theta \in \Theta$.

نورد فيما يلي بعض الخواص لتقارب دوال في متغيرات عشوائية، المفيدة لاحقاً.

1. إذا كان $\eta_n \xrightarrow{P} \eta$ و φ دالة مستمرة، فإن: $\varphi(\eta_n) \xrightarrow{P} \varphi(\eta)$ وأيضاً $\mathcal{L}(\varphi(\eta_n)) \rightarrow \mathcal{L}(\varphi(\eta))$.

2. لتكن $\{\eta_n, \zeta_n\}$ متتالية أزواج من المتغيرات العشوائية. عندئذ:

$$\eta_n - \zeta_n \xrightarrow{P} 0, \zeta_n \xrightarrow{P} \zeta \Rightarrow \eta_n \xrightarrow{P} \zeta \quad .1$$

$$\eta_n - \zeta_n \xrightarrow{P} 0, \mathcal{L}(\zeta_n) \rightarrow \mathcal{L}(\zeta) \Rightarrow \mathcal{L}(\eta_n) \rightarrow \mathcal{L}(\zeta) \quad .2$$

$$\mathcal{L}(\eta_n) \rightarrow \mathcal{L}(\eta), \zeta_n \xrightarrow{P} 0 \Rightarrow \eta_n \zeta_n \xrightarrow{P} 0 \quad .3$$

$$\mathcal{L}(\eta_n) \rightarrow \mathcal{L}(\eta), \zeta_n \xrightarrow{P} c \Rightarrow \mathcal{L}(\eta_n + \zeta_n) \rightarrow \mathcal{L}(\eta + c) \quad .4$$

$$\mathcal{L}(\eta_n \zeta_n) \rightarrow \mathcal{L}(c\eta), \mathcal{L}(\eta_n / \zeta_n) \rightarrow \mathcal{L}(\eta / c); c \neq 0$$

$$\eta_n - \zeta_n \xrightarrow{P} 0, \mathcal{L}(\zeta_n) \rightarrow \mathcal{L}(\zeta) \Rightarrow \varphi(\eta_n) - \varphi(\zeta_n) \xrightarrow{P} 0 \quad .5$$

حيث φ دالة مستمرة. نترك برهان هذه الخصائص البسيطة للقارئ على

سبيل المثال.

3. إذا كانت $T_n = T_n(X)$ و $X = (X_1, \dots, X_n)$ مقيّر المعلمة وحيدة البعد θ في النموذج $F(x; \theta)$; $\theta \in \Theta$ ، بحيث أن:

$$\mathcal{L}_\theta(\sqrt{n}(T_n - \theta)) \rightarrow N(0, \sigma^2(\theta)) \quad ; \quad \forall \theta \in \Theta$$

عندما $n \rightarrow \infty$. وإذا كانت الدالة φ قابلة للاشتقاق و $\varphi' \neq 0$ ، فإن:

$$\mathcal{L}_\theta(\sqrt{n}(\varphi(T_n) - \varphi(\theta))) \rightarrow N\{0, [\varphi'(\theta)]^2 \sigma^2(\theta)\} \quad (13.2.6)$$

بالإضافة إلى ذلك، إذا كانت الدالة φ' مستمرة، فإن:

$$\mathcal{L}_\theta(\sqrt{n}(\varphi(T_n) - \varphi(\theta)) / \varphi'(T_n)) \rightarrow N(0, \sigma^2(\theta)) \quad (14.2.6)$$

وإذا كان $\sigma(\theta)$ مستمراً فإن:

$$\mathcal{L}_\theta\left(\sqrt{n} \frac{\varphi(T_n) - \varphi(\theta)}{\varphi'(T_n)\sigma(T_n)}\right) \rightarrow N(0, 1) \quad (15.2.6)$$

يعتمد الإثبات على منشور تيلور:

$$\varphi(T_n) - \varphi(\theta) = (T_n - \theta)(\varphi'(\theta) + \zeta_n)$$

حيث عندما $|T_n - \theta| < \delta = \delta_{(\varepsilon)}$ فإن $|\zeta_n| < \varepsilon$; $\forall \varepsilon > 0$.

من ذلك:

$$P_\theta(|\zeta_n| < \varepsilon) \geq P_\theta(|T_n - \theta| < \delta)$$

لكن الطرف الأيمن حسب الفرض، ينتهي إلى 1 عندما $n \rightarrow \infty$ وبالتالي

$$\zeta_n \xrightarrow{P_\theta} 0 \text{ . وبناءً على الخاصة [(3) من 2] :}$$

$$\sqrt{n}[\varphi(T_n) - \varphi(\theta)] - \sqrt{n}[(T_n - \theta) - \varphi'(\theta)] = \sqrt{n}(T_n - \theta)\zeta_n \xrightarrow{P_\theta} 0$$

وهذا يعني حسب الخاصة [(2) من 2] أن المتغير العشوائي $\sqrt{n}(\varphi(T_n) - \varphi(\theta))$ له أيضاً نفس التوزيع المقارب، كما للمتغير العشوائي $\sqrt{n}(T_n - \theta)\varphi'(\theta)$ أي التوزيع الطبيعي $N(0, [\varphi'(\theta)]^2 \sigma^2(\theta))$ ، وهذا ما تؤكدُه العلاقة (13.2.6). وإذا كانت φ' مستمرة، فحسب الخاصة 1:

$$\varphi'(T_n) \xrightarrow{P_\theta} \varphi'(\theta)$$

من ذلك وبما سبق وحسب الخاصة [(4) من 2] نحصل على العلاقة (14.2.6). وبإجراء مناقشة مشابهة، يمكن إثبات صحة الصيغة (15.2.6).

نقدم بدون إثبات تعميماً للخاصة 3 على حالة معلمة متجه $\theta = (\theta_1, \dots, \theta_r)$.

4. ليكن $T_n = (T_{1n}, \dots, T_{rn})$ مقدرًا للمعلمة θ ، المحقق للشرط $L_\theta(\sqrt{n}(T_n - \mu)) \rightarrow N(0, \Sigma(\mu))$ عندما $n \rightarrow \infty$ ومهما تكن $\theta \in \Theta$. عندئذٍ من أجل أي دالة φ في r متغير وقابلة للاشتقاق:

$$L_\theta(\sqrt{n}(T_n - \theta)) \rightarrow N(0, v^2(\theta)) \quad (14.2.6)$$

بفرض $v(\theta) \neq 0$ ، حيث $v^2(\theta) = \mathbf{b}'(\theta)\Sigma(\theta)\mathbf{b}(\theta)$ و $\mathbf{b}(\theta) = \left(\frac{\partial \varphi(\theta)}{\partial \theta_1}, \dots, \frac{\partial \varphi(\theta)}{\partial \theta_r} \right)$.

بالإضافة لذلك، إذا كانت الدالة φ مستمرة وقابلة للاشتقاق وكل عناصر مصفوفة العزوم من المرتبة الثانية $\Sigma(\theta)$ مستمرة بالنسبة لـ θ فإن:

$$L_\theta(\sqrt{n}(\varphi(T_n) - \varphi(\theta))/v(T_n)) \rightarrow N(0,1) \quad (17.2.6)$$

لنصيغ الآن الخواص المقاربة الأساسية لمقدرات المعقولة العظمى. لنفترض أن النموذج $F(x; \theta)$ نظامي، ودالة المعقولة $L_n(x; \theta)$ لها نهاية عظمى واحدة

بالنسبة لـ $\theta \in \Theta$ من أجل $n \geq 1$ و $x \in G$ ، أي أن مقدر المعقولة العظمى موجود $\hat{\theta}_n(X)$ عندئذٍ:

1. مقدر المعقولة $\hat{\theta}(X)$ للمعلمة θ متسق.

2. إذا كانت الدالة $f(x; \theta)$ قابلة للاشتقاق ثلاث مرات بالنسبة لـ θ وتوجد دالة $M(x)$ مستقلة عن θ ، بحيث أن:

$$\left| \frac{\partial^3 \ln f(x; \theta)}{\partial \theta_i \partial \theta_j \partial \theta_k} \right| \leq M(x) \quad , \quad E_{\theta} M(X_1) < \infty \quad ; \quad i, j, k = 1, \dots, r$$

فعندما $n \rightarrow \infty$ ، ومهما تكن $\theta \in \Theta$ ، فإن:

$$L_{\theta}(\sqrt{n}(\hat{\theta}_n - \theta)) \rightarrow N(0, I^{-1}(\theta)) \quad (18.2.6)$$

حيث أن $I(\theta)$ مصفوفة المعلومات، المعرفة بالعلاقة (6.7.4)، والتي تعبر حسب الفرض نظامية، أي غير شاذة ($|I(\theta)| \neq 0$). بالإضافة لذلك، إذا كانت الدالة $\tau(\theta)$ مستمر وقابلة للاشتقاق بالنسبة لـ θ و $\hat{\tau}_n = \tau(\hat{\theta}_n)$ مقدر المعقولة العظمى لها، فإن:

$$L_{\theta}(\sqrt{n}(\hat{\tau}_n - \tau(\theta))) \rightarrow N(0, \sigma_{\tau}^2(\theta)) \quad (19.2.6)$$

حيث أن:

$$\sigma_{\tau}^2(\theta) = b'(\theta)I^{-1}(\theta)b(\theta) \quad , \quad b(\theta) = \left(\frac{\partial \tau(\theta)}{\partial \theta_1}, \dots, \frac{\partial \tau(\theta)}{\partial \theta_r} \right)$$

هكذا، من أجل صف واسع من النماذج فإن مقدرات المعقولة العظمى متسقة وطبيعية بالتقارب.

في حالة معلمة θ وحيدة البعد تأخذ العلاقتان (18.2.6) و (19.2.6) الشكل:

$$\mathcal{L}_\theta(\sqrt{n}(\hat{\theta}_n - \theta)) \rightarrow N(0, 1/i(\theta)) \quad (20.2.6)$$

$$\mathcal{L}_\theta(\sqrt{n}(\hat{\tau}_n - \tau(\theta))) \rightarrow N(0, [\tau'(\theta)]^2 / i(\theta)) \quad (21.2.6)$$

حيث $i(\theta)$ دالة المعلومات المعرفة بالعلاقة (13.5).

إثبات خاصة أن مقدّر المعقولة العظمى طبيعي بالتقارب (في حالة معلمة وحيدة البعد) يعتمد على نشر دالة المساهمة $U_n(\theta) = U_n(X; \theta)$ وفق متسلسلة تيلور بالنسبة للقيمة الحقيقية للمعلمة θ وملاحظة هذا المنشور في النقطة $\hat{\theta}_n$ ، نجد:

$$0 = U_n(\hat{\theta}_n) = U_n(\theta) + (\hat{\theta}_n - \theta)U_n'(\theta) + \frac{1}{2}(\hat{\theta}_n - \theta)^2 U_n''(\theta^*)$$

حيث θ^* نقطة ما بين θ ، $\hat{\theta}_n$. وهذه المساواة يمكن كتابتها على الشكل:

$$\sqrt{n}(\hat{\theta}_n - \theta) = \frac{U_n(\theta)}{\sqrt{n} i(\theta)} \left[-\frac{U_n'(\theta)}{ni(\theta)} + \varepsilon_n \right]^{-1} \quad (22.2.6)$$

حيث:

$$|\varepsilon_n| = \frac{|\hat{\theta}_n - \theta| |U_n''(\theta^*)|}{2ni(\theta)} \leq \frac{|\hat{\theta}_n - \theta|}{2i(\theta)} \frac{1}{n} \sum_{j=1}^n M(X_j)$$

بما أن $\hat{\theta}_n \xrightarrow{P_\theta} \theta$ من الشرط المفروض على الدالة $M(x)$ ، وبناءً على الخاصية

[2 من 2] ينتج أن $\varepsilon_n \xrightarrow{P_\theta} 0$. وبتطبيق قانون الأعداد الكبيرة على المقدار:

$$\frac{1}{n} U_n'(\theta) = \frac{1}{n} \sum_{j=1}^n \frac{\partial^2 \ln f(X_j; \theta)}{\partial \theta^2}$$

أخذين بالاعتبار العلاقة (4.7.4) نجد:

$$-\frac{1}{ni(\theta)}U'_n(\theta) \xrightarrow{P_\theta} -\frac{1}{i(\theta)}E_\theta\left(\frac{\partial^2 \ln f(X_1; \theta)}{\partial \theta^2}\right) = 1$$

وبتطبيق مبرهنة النهاية المركزية على المتغير العشوائي:

$$\frac{1}{\sqrt{n} i(\theta)}U_n(\theta) = \frac{1}{\sqrt{n} i(\theta)} \sum_{j=1}^n \frac{\partial \ln f(X_j; \theta)}{\partial \theta}$$

أخذين بالاعتبار العلاقتين (3.6.4) و (4.7.4) نجد:

$$\mathcal{L}_\theta\left(\frac{1}{\sqrt{n} i(\theta)}U_n(\theta)\right) \rightarrow N\left(0, \frac{1}{i(\theta)}\right)$$

عندما $n \rightarrow \infty$. من ذلك ومن العلاقة (22.2.6) والخاصة [4] من 2 ينتج أن المتغير العشوائي $\sqrt{n}(\theta_n - \theta)$ له نفس التوزيع الحدي أيضاً، أي أن العلاقة (20.2.6) صحيحة.

تعتبر العلاقة (21.2.6) نتيجة مباشرة للعلاقة (20.2.6) والخاصة 3.

نسمي المقدار $\sigma^2(\theta)/n$ بالتباين المقارب للإحصاء T_n ، المحقق للشرط:

$$\mathcal{L}_\theta[\sqrt{n}(T_n - \tau(\theta))] \rightarrow N(0, \sigma^2(\theta))$$

عندما $n \rightarrow \infty$. عندئذٍ من العلاقتين (20.2.6) و (21.2.6) ينتج أن التباين المقارب لمقدّر المعقولة العظمى $\hat{\theta}_n$ (مقدّر المعقولة العظمى $\hat{\tau}_n$) ينطبق على الحد الأدنى في متباينة كرامر وراو (1.7.5)، من أجل تباينات كل المقدرات غير المتحيزة للدالة المعلمية المفروضة.

تعريف 2.2.6: المقدّر الأكفأ تقاربياً

Asymptotically Efficient Estimator

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $f(x; \theta)$ ، وكان المقدّر T_n للمعلمة θ طبيعياً بالتقارب $N(\theta, 1/ni(\theta))$ ، فإن هذا المقدّر يكون

الأمثل تقاربياً، ومن ثمّ الأكفأ تقاربياً (asymptotically efficient)، ومن أجل أيّ مقدّر T_n محقق للشرط:

$$\mathcal{L}_\theta(T_n) \rightarrow N(\theta, \sigma_T^2(\theta)/n) \quad (23.2.6)$$

فإن كفاءته التقريبية $eff(T_n, \theta)$ تعين كنسبة الحد الأدنى لمتباينة كرامر وراو إلى التباين المقارب للمقدّر T_n :

$$eff(T_n; \theta) = [i(\theta)\sigma_T^2(\theta)]^{-1} \quad (24.2.6)$$

ينتج من العلاقتين (20.2.6) و (24.2.6) الخاصة الثالثة لمقدّرات المعقولة العظمى.

3. يعتبر المقدّر $\hat{\theta}_n(X)$ للمعلمة θ أكفأ تقاربياً، أي أن كفاءته المقاربة:

$$e = eff(\hat{\theta}_n, \theta) \equiv 1 \quad ; \quad \forall \theta \in \theta$$

مثال 15.2.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية كبيرة من توزيع:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0$$

فأوجد مقدّر المعقولة العظمى لكل من θ ، $\tau(\theta) = \frac{1}{\theta}$ ، ثم أوجد التوزيع التقريبي لكل منهما.

بما أن:

$$L(x; \theta) = \theta^n e^{-n\theta \bar{x}}$$

فإن:

$$\ln L(x; \theta) = n \ln \theta - n\theta \bar{x}$$

$$\frac{\partial \ln L(x; \theta)}{\partial \theta} = \frac{n}{\theta} - n\bar{x} = 0 \Rightarrow \theta = \frac{1}{\bar{x}}$$

أي أن مقدرّ المعقولة العظمى للمعلمة θ هو $\hat{\theta}_n(X) = \frac{1}{\bar{X}}$ ، وبما أن $\tau(\theta) = \frac{1}{\theta}$ دالة تناظر أحادية في θ ، فإن مقدرّ المعقولة العظمى لـ $\frac{1}{\theta}$ هو $\tau(\hat{\theta}) = \bar{X}$.

لنحسب الآن معلومات فيشر حول المعلمة θ .

$$i_n(\theta) = -E_{\theta} \left(\frac{\partial^2 \ln L(X; \theta)}{\partial \theta^2} \right) = -E_{\theta} \left(-\frac{n}{\theta^2} \right) = \frac{n}{\theta^2} = ni(\theta)$$

وعلى ذلك فالتوزيع التقريبي للمقدر $\hat{\theta}_n(X) = \frac{1}{\bar{X}}$ حسب العلاقة (20.2.6) هو:

$$\mathcal{L}_{\theta} \left(\frac{1}{\bar{X}} \right) \approx N(\theta, 1/ni(\theta)) = N(\theta, \theta^2/n)$$

وبشكل مشابه فالتوزيع التقريبي للمقدر \bar{X} لـ $\tau(\theta) = \frac{1}{\theta}$ حسب العلاقة

(21.2.6) هو:

$$\mathcal{L}_{\theta}(\bar{X}) \approx N \left(\tau(\theta), \frac{[\tau'(\theta)]}{ni(\theta)} \right) = N \left(\frac{1}{\theta}, \frac{(-1/\theta^2)^2}{n/\theta^2} \right) = N \left(\frac{1}{\theta}, \frac{1}{n\theta^2} \right)$$

إن مقدرّات المعقولة العظمى ليست دائماً طبيعية بالتقارب. وكمثال على ذلك، نذكر مقدرّ المعقولة العظمى للمعلمة θ في توزيع $R(0, \theta)$ ، هو كما نعلم $\hat{\theta}_n(X) = X_{(n)}$. وأن:

$$\mathcal{L}_{\theta} \left(\frac{n}{\theta} (\theta - \hat{\theta}_n(X)) \right) \rightarrow \Gamma(1, 1)$$

عندما $n \rightarrow \infty$. أي أن توزيع $\hat{\theta}_n(X)$ المقارب هو توزيع أسّي. هكذا، التوزيع المقارب للمقدر $\hat{\theta}(X) = X_{(n)}$ ليس طبيعي، والسبب في ذلك يكمن في عدم نظامية النموذج $R(0, \theta)$.

THE METHOD OF MOMENTS

3.6 طريقة العزوم

تعتبر طريقة العزوم تاريخياً إحدى أقدم طرق التقدير، والتي قدمت من قبل العالم الإحصائي كارل بيرسون عام 1894م. ويتمثل جوهر هذه الطريقة في المساواة بين بعض عزوم المجتمع وعزوم العينة المناظرة لها، فنحصل بذلك على جملة من المعادلات بجلها بالنسبة لمعالم المجتمع نحصل على التقديرات المطلوبة، التي تدعى بتقديرات طريقة العزوم. وبعبارة أخرى تؤخذ العزوم التجريبية (عزوم العينة) كتقديرات للعزوم النظرية (عزوم المجتمع) الموافقة لها، ومنها نستخلص تقديرات معالم المجتمع بدلالة العزوم التجريبية. لنوضح ذلك على النحو الآتي: لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع:

$$\mathcal{L}(\xi) \in \mathbf{F} = \{F(x; \mu) \mid \mu \in \theta\}$$

حيث أن $\theta = (\theta_1, \dots, \theta_r) \in \theta \subseteq R^r$ ، ولنفترض أن العزوم الابتدائية الـ r الأولى للمتغير العشوائي الملاحظ ξ موجودة:

$$\alpha_k = E\xi^k \quad ; \quad k = 1, 2, \dots, r$$

وتعتبر هذه العزوم، بصورة عامة، دوال في المعلمة المجهولة θ ، أي أن:

$$\alpha_k = \alpha_k(\theta)$$

والعزوم الابتدائية التجريبية الموافقة لها:

$$A_{nk}(X) = \frac{1}{n} \sum X_i^k$$

و $\alpha_k = A_{nk}(x)$ قيم تلك العزوم عند العينة المشاهدة $x = (x_1, \dots, x_n)$.

بمساواة العزوم الابتدائية للمجتمع بما يناظرها من عزوم العينة فإننا نحصل على

المعادلات:

$$\alpha_k(\theta) = \alpha_k \quad ; \quad k = 1, 2, \dots, r \quad (1.3.6)$$

وبجمل هذه المعادلات بالنسبة لـ $\theta_1, \dots, \theta_r$ نصل إلى التقديرات $\tilde{\theta}_1, \dots, \tilde{\theta}_r$. ومن الواضح أن هذه التقديرات دوال في عزوم العينة.

يمكن بسهولة إثبات أن عزوم العينة $A_{nk}(X)$ تعتبر مقدرات غير متحيزة ومتسقة للعزوم النظرية $\alpha_k(\theta)$.

لنفرض أن التوافق بين $\theta_1, \dots, \theta_r$ و $\alpha_1, \dots, \alpha_r$ يمكن تمثيله بدوال مستمرة وذات تناظر أحادي، أي توجد دوال مستمرة $\varphi_1, \dots, \varphi_r$ بحيث أن:

$$\theta_i = \varphi_i(\alpha_1, \dots, \alpha_r) \quad ; \quad i = 1, \dots, r$$

والمقدرات الموافقة:

$$\tilde{\theta}_i(X) = \varphi_i(A_{1n}(X), \dots, A_{rn}(X))$$

حسب المبرهنة (2.14.1) متقاربة احتمالياً، عند كل $\theta \in \Theta$ ، من θ_i . وهذا يعني أن الإحصاءات $\tilde{\theta}_i(X)$ تعتبر مقدرات متسقة للمعالم θ_i ؛ $i = 1, \dots, r$.

هكذا، طريقة العزوم عند شروط معينة، تعطي مقدرات متسقة. وعندئذٍ المعادلات (1.3.6) في حالات عدة بسيطة وحلها (خلافاً لطريقة المعقولة العظمى) لا يتطلب عمليات حسابية معقدة. ولكن الكفاءة التقريبية للمقدرات التي نحصل عليها بهذه الطريقة أقل من واحد.

مثال 1.3.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\Gamma(\theta_1, \theta_2)$ ، فأوجد مقدر كل من المعلمتين θ_1, θ_2 باستخدام طريقة العزوم.

بما أن:

$$f(x; \theta_1, \theta_2) = \frac{1}{\theta_2^{\theta_1} \Gamma(\theta_1)} x^{\theta_1-1} e^{-x/\theta_2} \quad ; \quad \theta_1, \theta_2 > 0, \quad x > 0$$

وعلى ذلك:

$$\alpha_k = \frac{1}{\theta_2^{\theta_1} \Gamma(\theta_1)} \int_0^{\infty} x^k x^{\theta_1-1} e^{-x/\theta_2} dx = \frac{1}{\theta_2^{\theta_1} \Gamma(\theta_1)} \int_0^{\infty} x^{\theta_1+k-1} e^{-x/\theta_2} dx$$

وبوضع $y = \frac{x}{\theta_2}$ نجد:

$$\alpha_k = \frac{\theta_2^{\theta_1+k}}{\theta_2^{\theta_1} \Gamma(\theta_1)} \int_0^{\infty} y^{\theta_1+k-1} e^{-y} dy = \frac{\theta_2^k \Gamma(\theta_1 + k)}{\Gamma(\theta_1)}$$

وبإعطاء $k = 1, 2$ نحصل على:

$$\alpha_1 = \theta_1 \theta_2 \quad , \quad \alpha_2 = \theta_1 \theta_2^2 (1 + \theta_1)$$

لكن:

$$\alpha_1 = \frac{1}{n} \sum_1^n x_i = \bar{x} \quad , \quad \alpha_2 = \frac{1}{n} \sum_1^n x_i^2 = \overline{x^2}$$

وبالتالي فمعادلتى التقدير هما:

$$\theta_1 \theta_2 = \bar{x}$$

$$\theta_1 \theta_2^2 (1 + \theta_1) = \overline{x^2}$$

بجملتهما بالنسبة لـ θ_2, θ_1 نجد:

$$\tilde{\theta}_1 = \frac{\bar{x}^2}{x^2 - \bar{x}^2} = \frac{\bar{x}^2}{s^2}$$

$$\tilde{\theta}_2 = \frac{\overline{x^2} - \bar{x}^2}{\bar{x}^2} = \frac{s^2}{\bar{x}^2}$$

أي أن مقدرتي العزوم:

$$\tilde{\theta}_1(\mathbf{X}) = \frac{\bar{X}^2}{S^2}, \quad \tilde{\theta}_2(\mathbf{X}) = \frac{S^2}{\bar{X}^2}$$

مثال 2.4.6

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $\mathcal{L}(\xi) \in N(\theta_1, \theta_2^2)$ ، فأوجد مقدر العزوم للمعلمة $\theta = (\theta_1, \theta_2^2)$.

كما نعلم:

$$\alpha_1 = E_0 \xi = \theta_1, \quad \alpha_2 = V_0 \xi + (E_0 \xi)^2 = \theta_2^2 + \theta_1^2$$

$$\alpha_1 = \bar{x}, \quad \alpha_2 = \overline{x^2}$$

وبالمساواة نحصل على المعادلتين:

$$\theta_1 = \bar{x}$$

$$\theta_2^2 + \theta_1^2 = \overline{x^2}$$

بجملهما بالنسبة لـ θ_1, θ_2^2 نجد:

$$\tilde{\theta}_1 = \bar{x}$$

$$\tilde{\theta}_2^2 = \overline{x^2} - \bar{x}^2 = s^2$$

أي أن مقدر العزوم للمعلمة $\theta = (\theta_1, \theta_2^2)$ هو:

$$\theta(\mathbf{X}) = (\bar{X}, S^2)$$

وهذا نفس مقدر العقولية العظمى للمعلمة θ .

مثال 3.3.6

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع:

$$f(x; \theta) = \theta x^{\theta-1}, \quad 0 \leq x \leq 1$$

فأوجد مقدر العزوم للمعلمة θ .

$$\alpha_1 = \int_0^1 \theta x^\theta dx = \frac{\theta}{1+\theta}$$

وعلى ذلك:

$$\frac{\theta}{1+\theta} = \bar{x} \Rightarrow \tilde{\theta} = \frac{\bar{x}}{1-\bar{x}}$$

وبالتالي مقدر العزوم للمعلمة θ :

$$\tilde{\theta}(X) = \frac{\bar{X}}{1-\bar{X}}$$

وهو مختلف عن مقدر المعقولة العظمى:

$$\hat{\theta}(X) = -\frac{n}{\sum_1^n \ln X_i}$$

مثال 4.3.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $L(\xi) \in \Gamma(\alpha, 1/\beta)$ فأوجد مقدر العزوم لكل من المعلمتين α, β .

نعلم أن [راجع العلاقة (23.3.2)]

$$E_\theta \xi = \frac{\alpha}{\beta} \quad , \quad E_\theta \xi^2 = \frac{\alpha(\alpha+1)}{\beta^2} \quad , \quad \theta = (\alpha, \beta)$$

وعلى ذلك:

$$\frac{\alpha}{\beta} = \bar{x}$$

$$\frac{\alpha(\alpha+1)}{\beta^2} = \overline{x^2}$$

بجملهما بالنسبة لـ α, β نجد:

$$\tilde{\alpha} = \frac{\bar{x}^2}{s^2} \quad , \quad \tilde{\beta} = \frac{\bar{x}}{s^2}$$

أي أن:

$$\tilde{\alpha}(X) = \frac{\bar{X}^2}{S^2} \quad , \quad \tilde{\beta}(X) = \frac{\bar{X}}{S^2}$$

نلاحظ أن طريقة العزوم لا تستخدم عندما تكون العزوم من المراتب المطلوبة غير موجودة (فمثلاً، في حالة توزيع كوشي). بالإضافة لذلك، يقال بشكل عام أن مقدرات طريقة العزوم ليست أكفأ. لهذا تستخدم غالباً كتقريب أولي لإيجاد مقدرات أكثر كفاءة نحصل عليها بطرق أخرى (فمثلاً، طريقة التراكم).

OTHER METHODS

4.6 طرق أخرى

هنالك طرق أخرى مختلفة للحصول على مقدرات نقطية للمعالم. نذكر منها:

1. طريقة χ^2 الصغرى.
2. طريقة المسافات الصغرى.
3. طريقة بتمان.
4. طريقة بيز.

سندرس بشكل موجز في هذا البند الطرق الثلاث الأولى.

1.4.6 طريقة χ^2 الصغرى Minimum-Chi-Square Method

يمكن الحصول على مجموعة من الطرق لإيجاد تقديرات معالم توزيع $f(x; \theta)$ ، وذلك بناءً على صياغة مقياس D بهذه الطريقة أو تلك لقياس إنحراف دالة التوزيع التجريبي $F_n^*(x)$ عن $F(x; \theta)$. ويعتبر مثل هذا المقياس في كل الحالات دالة في العينة $X = (X_1, \dots, X_n)$ والمعلمة θ ، أي أن $D = D(X; \theta)$.

إذا وجد مثل هذا المقياس، فعندئذٍ كتقدير للمعلمة θ نأخذ القيمة التي تجعل D تبلغ أصغر قيمة ممكنة لها.

وإحدى أهم وأكثر مثل هذه المقاييس استخداماً هو ما يدعى بمقياس χ^2 ، الذي قدم من قبل العالم كارل بيرسون. ويتعين هذا المقياس (مقياس χ^2) على النحو الآتي: نقسم مجموعة القيم الممكنة Ω_{ξ} للمتغير العشوائي الملاحظ ξ (نطاق ξ range of) إلى k مجموعة جزئية (خلية cell) منفصلة $\zeta_1, \zeta_2, \dots, \zeta_k$ ؛ $i \neq j$ $\zeta_i \cap \zeta_j = \emptyset$ ؛ $i = 1, 2, \dots, k$. وليكن المتغير العشوائي γ_j يشير إلى عدد عناصر العينة $X = (X_1, \dots, X_n)$ التي تقع في الخلية ζ_j ، أي أن:

$$\gamma_j = \left| \left\{ i; X_i \in \zeta_j \right\} \right|; j = 1, \dots, k, \left(\sum_1^k \gamma_j = n \right)$$

لنرمز بـ $p_j(\theta)$ لاحتمال وقوع المتغير العشوائي الملاحظ ξ في الخلية ζ_j ، وهذا يمكن إيجاده، بحيث إذا كانت $F(x; \theta)$ دالة توزيع ξ فإن:

$$p_j(\theta) = P_{\theta}(\xi \in \zeta_j) = \int_{\zeta_j} dF(x; \theta); j = 1, \dots, k$$

$$\text{حيث أن } \sum_{j=1}^k p_j(\theta) = 1$$

إن التكرار النسبي $\frac{\gamma_j}{n}$ لوقوع عناصر العينة X في الخلية ζ_j يعتبر مقدر متسق للاحتمال $p_j(\theta)$ [راجع العلاقة (5.3.1)]، لهذا مقياس انحراف معطيات العينة عن القيم النظرية الموافقة لها يمكن إعطاءه بالمقياس المعرف على الصورة:

$$D = \sum_{j=1}^k c_j \left(\gamma_j / n - p_j(\theta) \right)^2$$

إذا وضعنا هنا $c_j = n / p_j(\theta)$ ، فنحصل على مقياس χ^2 :

$$\chi^2 = \sum_{j=1}^k \frac{n}{p_j(\theta)} \left(\frac{\gamma_j}{n} - p_j(\theta) \right)^2 = \sum_{j=1}^k \frac{(\gamma_j - np_j(\theta))^2}{np_j(\theta)} \quad (1.4.6)$$

يمثل المقدار $\sum_{j=1}^k (\gamma_j - np_j(\theta))^2$ مجموع مربعات الفروقات بين العدد الملاحظ والمتوقع لوقوع الملاحظات في الخلية j ; $j = \overline{1, k}$. ويمكن كتابة العلاقة (1.4.6) على النحو الآتي:

$$\chi^2 = \sum_{j=1}^k \frac{\gamma_j^2}{np_j(\theta)} - n$$

سنرمز للقيمة الملاحظة للمتغير العشوائي γ_j بـ n_j . وتجدر الإشارة هنا إلى أن مقدر χ^2 الصغرى يعتمد على التجزأة المقترحة k_1, k_2, \dots, k_k . لاحقاً سنستخدم أحياناً رمزاً آخرًا للدلالة على هذا المقياس يدعى بمقياس X^2 ، وله توزيع χ^2 .

إن مقدر المعلمة θ ، الذي نحصل عليه من شرط بلوغ المقياس χ^2 قيمته الصغرى، يدعى بمقدر طريقة χ^2 الصغرى. وأن هذا المقدر، عند شروط عامة، يتمتع بالخصائص التالية: متسق، طبيعي بالتقارب، والأكفأ تقاربياً (كمقدر المعقولة العظمى).

لإيجاد تقديرات طريقة χ^2 الصغرى يجب حل منظومة المعادلات:

$$\sum_{j=1}^k \frac{\gamma_j^2}{p_j^2(\theta)} \frac{\partial p_j(\theta)}{\partial \theta_i} = 0 \quad ; \quad i = 1, 2, \dots, r, \quad (\theta = (\theta_1, \dots, \theta_r)) \quad (2.4.6)$$

التي نحصل عليها من الشرط $\frac{\partial \chi^2}{\partial \theta} = 0$. لكن حل هذه المنظومة ليس سهلاً حتى في أبسط الحالات، لهذا تستبدل عادة بمنظومة المعادلات:

$$\sum_{j=1}^k \frac{\gamma_j}{p_j(\theta)} \frac{\partial p_j(\theta)}{\partial \theta_j} = 0 \quad ; \quad i = 1, 2, \dots, r \quad (3.4.6)$$

التي حلها أبسط بكثير. والمقدرات التي نحصل عليها بناءً على حل منظومة المعادلات (3.4.6)، عند شروط معينة، تتمتع في حالة عينات كبيرة الحجم بنفس

الخواص المقاربة التي تتمتع بها مقدرات طريقة χ^2 الصغرى باستخدام حل منظومة المعادلات (2.4.6).

لهذه الطريقة في تقدير معالم توزيع أهمية عند اختبار جودة التلاؤم باستخدام اختبار χ^2 .

مثال 1.4.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $L(\xi) \in \Pi(\theta)$ فأوجد مقدر طريقة χ^2 الصغرى:

لنأخذ:

$$\zeta_j = \{j-1\} \quad ; \quad j=1, \dots, k-2 \quad , \quad \zeta_k = \{k-1, k, \dots\}$$

عندئذ:

$$p_j(\theta) = f(j-1; \theta) = \frac{\theta^{j-1}}{(j-1)!} e^{-\theta} \quad ; \quad j=1, \dots, k-2$$

$$p_k(\theta) = \sum_{l=k-1}^{\infty} f(l; \theta) = \sum_{l=k-1}^{\infty} \frac{\theta^l}{l!} e^{-\theta}$$

حيث أن:

$$f(x; \theta) = \frac{\theta^x}{x!} e^{-\theta} \quad ; \quad x=0, 1, \dots$$

وعلى ذلك:

$$\frac{dp_j(\theta)}{d\theta} = \left[\frac{(j-1)\theta^{j-2}}{(j-1)!} - \frac{\theta^{j-1}}{(j-1)!} \right] e^{-\theta} = \left(\frac{j-1}{\theta} - 1 \right) \frac{\theta^{j-1}}{(j-1)!} e^{-\theta}$$

$$\begin{aligned} \frac{dp_k(\theta)}{d\theta} &= \sum_{l=k-1}^{\infty} \left(\frac{l\theta^{l-1}}{l!} e^{-\theta} - \frac{\theta^l}{l!} e^{-\theta} \right) = \\ &= \sum_{l=k-1}^{\infty} \left(\frac{l}{\theta} - 1 \right) \frac{\theta^l}{l!} e^{-\theta} = \sum_{l=k-1}^{\infty} \left(\frac{l}{\theta} - 1 \right) f(l; \theta) \end{aligned}$$

بالتعويض في (3.4.6) نجد:

$$\sum_{j=1}^{k-1} \frac{\gamma_j}{p_j(\theta)} \frac{dp_j(\theta)}{d\theta} + \frac{\gamma_k}{p_k(\theta)} \frac{d xp_k(\theta)}{d\theta} =$$

$$= \sum_{j=0}^{k-2} \left(\frac{j}{\theta} - 1 \right) \gamma_{j+1} + \gamma_k \sum_{l=k-1}^{\infty} \left(\frac{1}{\theta} - 1 \right) f(l; \theta) \Big/ \sum_{l=k-1}^{\infty} f(l; \theta) = 0$$

بحل هذه المعادلة بالنسبة لـ θ نحصل على مقدر طريقة χ^2 الصغرى للمعلمة θ :

$$\theta^*(X) = \frac{1}{n} \left[\sum_{j=0}^{k-2} j \gamma_{j+1} + \gamma_k \sum_{l=k-1}^{\infty} l f(l; \theta) \Big/ \sum_{l=k-1}^{\infty} f(l; \theta) \right]$$

نلاحظ أن الحد الأول (ضمن القوسين) يمثل مجموع X_i حيث أن $X_i \leq k-2$ ، والحد الثاني يساوي تقريبا مجموع X_i ، حيث $X_i \geq k-2$ (حيث أن القيم الملاحظة للمتغير ξ)، أي أن $\theta^*(X) \approx \bar{X}$.

مثال 2.4.6

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بيرنولي $B(1, \theta)$ ، ونريد إيجاد مقدر θ باستخدام طريقة χ^2 الصغرى.

لنأخذ $\gamma_j =$ عدد الملاحظات في العينة X المساوية لـ j ؛ $j = 0, 1$. أي أن مدى المتغير العشوائي الملاحظ ξ جزء إلى خليتين:

$$\zeta_0 = \{0\} \quad , \quad \zeta_1 = \{1\}$$

ومن ثم:

$$\chi^2 = \sum_{j=0}^1 \frac{[n_j - np_j(\theta)]^2}{np_j(\theta)} = \frac{(n_1 - n\theta)^2}{n} \frac{1}{\theta(1-\theta)}$$

أو:

$$\chi^2 = \sum_{j=0}^1 \frac{n_j^2}{np_j(\theta)} - n = \frac{n_0^2}{n(1-\theta)} + \frac{n_1^2}{n\theta} - n$$

حيث n_j القيمة الملاحظة للمتغير العشوائي γ_j ; $j = 0,1$

نلاحظ بسهولة أن القيمة الصغرى لـ χ^2 كدالة في θ هي عبارة عن قيمة χ^2 وذلك عندما $\theta = \theta^* = \frac{n_1}{n}$ ، ومن ثم مقدر χ^2 الصغرى للمعلمة θ هو


$$\theta^*(X) = \frac{\gamma_1}{n}$$

2.4.6 طريقة المسافة الصغرى Minumum-Distance method

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $F(x; \theta)$ ، ولتكن $d(F, G)$ دالة المسافة، التي تعين التباعد الأقصى بين دالتي التوزيع F و G .
وكمثال لدالة المسافة نذكر:

$$d(F, G) = \sup_x |F(x) - G(x)|$$

التي تمثل أكبر مسافة شاقولية (رأسية) بين F و G . ويبدو ذلك بوضوح على الشكل (1.4.6).



شكل (1.4.6)

إن تقدير طريقة المسافة الصغرى للمعلمة θ وليكن θ^* هو عبارة عن القيمة $\theta \in \Theta$ التي تجعل $d[F(x;\theta), F_n^*(x)]$ تبلغ نهاية صغرى، حيث $F_n^*(x)$ دالة التوزيع التجريبي. هكذا، يتم اختيار θ^* بحيث تكون $F(x;\theta^*)$ الأقرب إلى $F_n(x)$ ضمن عائلة النموذج $F = \{F(x;\theta), \theta \in \Theta\}$. ومن الطبيعي دائماً الرغبة في الحصول على مقدر المسافة الصغرى، لكن غالباً إيجاد ذلك أمر صعب. والمثال الآتي يعتبر استثناءً.

مثال 3.4.6

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بيرنولي:

$$F(x;\theta) = \begin{cases} 0 & ; x \leq 0 \\ 1 - \theta & ; 0 < x \leq 1 \\ 1 & ; x > 1 \end{cases}$$

حيث $0 \leq \theta \leq 1$.

لنرمز بـ n_j لعدد الملاحظات المساوية لـ j ; $j = 0, 1$. عندئذ:

$$F_n^*(x) = \begin{cases} 0 & ; x \leq 0 \\ n_0/n & ; 0 < x \leq 1 \\ 1 & ; x > 1 \end{cases}$$

والآن إذا استخدمنا دالة المسافة $d(F, G) = \sup_x |F(x) - G(x)|$ ، فإن:

$$d[F(x;\theta) - F_n^*(x)]$$

تبلغ نهاية صغرى إذا أخذنا:

$$1 - \theta = \frac{n_0}{n}$$

$$\theta = \frac{n_1}{n} = \frac{1}{n} \sum_1^n x_i = \bar{x}$$

أي أن مقدر المسافة الصغرى:

$$\theta^*(X) = \bar{X}$$

3.4.6 مقدر بتمان لمعلمة الموضع والمقياس

Pitman Estimator of Location and Scale Parametrec

لنعرف في البداية معلمة الموضع ومعلمة المقياس.

تعريف 1.4.6: معلمة الموضع Location Parameter

إذا كان التوزيع الاحتمالي $f(x; \theta)$ للمتغير العشوائي ξ يعتمد على معلمة ما θ وحيدة البعد، فيقال أن θ معلمة موضع إذا أمكن كتابة $f(x; \theta)$ كدالة في $(x - \theta)$ ، أي أن:

$$f(x; \theta) = g(x - \theta)$$

حيث $g(\cdot)$ دالة ما. وبعبارة أخرى نقول عن معلمة θ أنها معلمة موضع إذا كان التوزيع الاحتمالي للمتغير العشوائي $\xi - \theta = \zeta$ لا يعتمد على θ ، وتوزيع ζ يكون:

$$g(y) = f(y + \theta; 0)$$

مثال 4.4.6

إذا كان ξ متغير عشوائي دالة كثافته الاحتمالية:

$$f(x; \theta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\theta)^2} ; \quad -\infty < x < +\infty$$

فإن θ معلمة موضع لأن $f(x;\theta)$ دالة في $(x - \theta)$ وتوزيع $\zeta = \xi - \theta$ هو:

$$g(y) = f(y + \theta; 0) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2} ; \quad -\infty < x < +\infty$$

أي إذا كان $L(\xi) \in N(\theta, 1)$ فإن $L(\zeta) = N(0, 1)$.

وكمثال آخر لمعلمة الموضع نذكر المعلمة θ في التوزيع $R(\theta - 1/2, \theta + 1/2)$.

تعريف 2.4.6: معلمة مقياس Scale Parameter

إذا كان التوزيع الاحتمالي $f(x;\theta)$ للمتغير العشوائي ξ يعتمد على معلمة θ وحيدة البعد، فيقال أن θ معلمة مقياس إذا أمكن كتابة $f(x;\theta)$ على الصورة:

$$f(x;\theta) = \frac{1}{\theta} g\left(\frac{x}{\theta}\right)$$

حيث $g(\cdot)$ دالة ما. وعندئذ يكون توزيع المتغير العشوائي $\zeta = \frac{\xi}{\theta}$:

$$g(y) = f(\theta y, 1)$$

وهو لا يعتمد على θ .

مثال 5.4.6

إذا كان ξ متغير عشوائي كثافة توزيعه:

$$f(x;\theta) = \frac{1}{\theta} e^{-x/\theta} ; \quad x < 0$$

فإن θ معلمة مقياس، لأنه إذا وضعنا $\zeta = \frac{\xi}{\theta}$ فإن كثافة توزيع ζ هي:

$$g(y) = f(y\theta, 1) = e^{-y} ; \quad y > 0$$

لا يعتمد على θ .

وكأمثلة أخرى على معلمة المقياس نذكر المعلمة θ في النموذج الطبيعي $N(0, \theta^2)$ ، وكذلك θ في النموذج المنتظم $R(0, \theta)$.

Pitman Estimator for Location Parameter

تعطي البرهنة الآتية، التي سنقبلها بدون إثبات، مقدر بتمان لمعلمة موضع θ (وحيدة البعد) في التوزيع $f(x; \theta)$ ، وتبين أن له أقل متوسط مربع خطأ بانتظام بين مجموعة مقدرات الموضع (uniformly smallest mean square error).

مبرهنة 5.4.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من التوزيع $f(x; \theta)$ ، وكانت θ معلمة موضع وحيدة البعد، فإن الإحصاء $T(X)$ المعرف بالعلاقة:

$$T(X) = \frac{\int \theta L(X; \theta) d\theta}{\int L(X; \theta) d\theta}$$

هو مقدر للمعلمة θ بأقل متوسط مربع خطأ بانتظام بين مجموعة مقدرات الموضع، ويدعى هذا المقدر لمعلمة الموضع θ بمقدر بتمان (Pitman estimator)، ومن ثم فإن أية قيمة $t = T(x)$ تدعى بتقدير بتمان لـ θ .

مثال 6.4.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع $N(\theta, 4)$ فأوجد مقدر بتمان للمعلمة θ .

يمكن التأكد بسهولة أن θ معلمة موضع. وبما أن:

$$f(x; \theta) = \frac{1}{2\sqrt{2\pi}} e^{-\frac{1}{8}(\bar{x} - \theta)^2}$$

فإن:

$$L(x; \theta) = (8\pi)^{-\frac{n}{2}} \exp\left\{-\frac{1}{8}\left[\sum_{i=1}^n (x_i - \theta)^2\right]\right\} =$$

$$= (8\pi)^{-\frac{n}{2}} \exp\left\{-\frac{1}{8}\left[\sum_1^n (x_i - \bar{x})^2 + n(\theta - \bar{x})^2\right]\right\}$$

وعلى ذلك فإن تقدير بتمان:

$$\begin{aligned} t = T(x) &= \frac{\int \theta L(x; \theta) d\theta}{\int L(x; \theta) d\theta} = \frac{\int \theta \exp\left[-\frac{n}{8}(\theta - \bar{x})^2\right] d\theta}{\int \exp\left[-\frac{n}{8}(\theta - \bar{x})^2\right] d\theta} \\ &= \frac{\int \frac{\sqrt{n}}{2\sqrt{2\pi}} \theta e^{-\frac{n}{8}(\theta - \bar{x})^2} d\theta}{\int \frac{\sqrt{n}}{2\sqrt{2\pi}} e^{-\frac{n}{8}(\theta - \bar{x})^2} d\theta} \end{aligned}$$

نلاحظ أن $\frac{\sqrt{n}}{2\sqrt{2\pi}} e^{-\frac{n}{8}(\theta - \bar{x})^2}$ ما هي إلا دالة كثافة التوزيع الطبيعي للمتغير العشوائي θ . بمتوسط \bar{x} وتباين $\sigma^2 = \frac{4}{n}$ ، وبالتالي فإن التكامل في البسط عبارة عن $E\theta = \bar{x}$ بينما التكامل في المقام يساوي الواحد. أي أن $t = \bar{x}$ ، ومن ثم فمقدر بتمان:

$$T = T(X) = \bar{X}$$

يمكن التأكد من أن $T = \bar{X}$ مقدّر غير متحيز وتباينه يساوي الحد الأدنى في متباينة كرامر ورامر، أي أنه المقدّر الأمثل (ومن ثم الأكفأ) للمعلمة θ .

مثال 7.4.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع منتظم $R\left(\theta - \frac{1}{2}, \theta + \frac{1}{2}\right)$ ، فأوجد مقدّر بتمان للمعلمة θ .
بما أن θ معلمة موضع في التوزيع $R\left(\theta - \frac{1}{2}, \theta + \frac{1}{2}\right)$ ، و

$$f(x;\theta) = 1 \quad ; \quad \theta - \frac{1}{2} \leq x \leq \theta + \frac{1}{2}$$

فإن:

$$L(x;\theta) = 1 \quad ; \quad \theta - \frac{1}{2} \leq x_{(1)} \leq x_{(n)} \leq \theta + \frac{1}{2}$$

إذن:

$$L(x;\theta) = 1 \quad ; \quad y_n - \frac{1}{2} \leq \theta \leq y_1 + \frac{1}{2}$$

حيث أن:

$$y_1 = x_{(1)} \quad , \quad y_n = x_{(n)}$$

وعلى ذلك:

$$\begin{aligned} t = T(\mathbf{x}) &= \int_{y_n - \frac{1}{2}}^{y_1 + \frac{1}{2}} \theta L(\mathbf{x}; \theta) d\theta \Bigg/ \int_{y_n - \frac{1}{2}}^{y_1 + \frac{1}{2}} L(\mathbf{x}; \theta) d\theta = \int_{y_n - \frac{1}{2}}^{y_1 + \frac{1}{2}} \theta d\theta \Bigg/ \int_{y_n - \frac{1}{2}}^{y_1 + \frac{1}{2}} d\theta \\ &= \left(\frac{\theta^2}{2} \Bigg|_{y_n - \frac{1}{2}}^{y_1 + \frac{1}{2}} \right) \Bigg/ \left(\theta \Bigg|_{y_n - \frac{1}{2}}^{y_1 + \frac{1}{2}} \right) = \frac{1}{2} \frac{\left(y_1 + \frac{1}{2} \right)^2 - \left(y_n - \frac{1}{2} \right)^2}{\left(y_1 + \frac{1}{2} \right) - \left(y_n - \frac{1}{2} \right)} = \frac{y_1 + y_n}{2} \end{aligned}$$

وبالتالي فمقدر بتمان:

$$T(\mathbf{X}) = \frac{X_{(1)} + X_{(n)}}{2}$$

Pitman Estimator for Scal Parameter مقدر بتمان لمعلمة مقياس

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع متغير عشوائي ξ يفترض قيماً موجبة ويعتمد على معلمة مقياس وحيدة البعد $\theta > 0$ ، فإن المبرهنة الآتية تعطي مقدر بتمان لـ θ :

مبرهنة 2.4.6

إن مقدر بتمان لمعلمة المقياس θ في التوزيع $f(x;\theta)$ للمتغير العشوائي X يعطى بالعلاقة:

$$T = T(X) = \frac{\int_0^{\infty} \frac{1}{\theta^2} L(x;\theta) d\theta}{\int_0^{\infty} \frac{1}{\theta^3} L(x;\theta) d\theta}$$

وهذا المقدر هو دالة في إحصاء كافي.

مثال 8.4.6

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع منتظم:

$$f(x;\theta) = \frac{1}{\theta} \quad ; \quad 0 < x \leq \theta$$

فأوجد مقدر بتمان للمعلمة θ .

نلاحظ أن θ معلمة مقياس، لأنه بوضع $y = \frac{x}{\theta}$ نجد:

$$g(y) = f(\theta y, 1) = 1 \quad ; \quad 0 < y \leq 1$$

وهي لا تعتمد على θ .

بما أن:

$$L(x;\theta) = \frac{1}{\theta^n} \quad ; \quad \theta \geq x_{(n)} = y_n$$

فإن تقدير بتمان للمعلمة θ يكون:

$$T(x) = \frac{\int_{y_n}^{\infty} \frac{1}{\theta^2} \frac{1}{\theta^n} d\theta}{\int_{y_n}^{\infty} \frac{1}{\theta^3} \frac{1}{\theta^n} d\theta} = \frac{\int_{y_n}^{\infty} \frac{1}{\theta^{n+2}} d\theta}{\int_{y_n}^{\infty} \frac{1}{\theta^{n+3}} d\theta} = \frac{n+2}{n+1} y_n$$

وبالتالي مقدر بتمان للمعلمة θ :

$$T(\mathbf{X}) = \frac{n+2}{n+1} Y_n = \frac{n+2}{n+1} X_{(n)}$$

بما أن:

$$E_{\theta} Y_n = \frac{n}{n+1} \theta$$

لأن كثافة توزيع Y_n هو:

$$h(y) = \frac{n}{\theta^n} y^{n-1} \quad ; \quad 0 < y \leq \theta$$

وعلى ذلك فإن:

$$E_{\theta} T(\mathbf{X}) = \frac{n+2}{n+1} E Y_n = \frac{n+2}{n+1} \frac{n}{n+1} \theta = \frac{n(n+2)}{(n+1)^2} \theta = \theta - \frac{\theta}{(n+1)^2} \neq \theta$$

إذن فمقدرّ بتمان للمعلمة θ متحيز، ومقدار التحيز هذا:

$$E_{\theta} T - \theta = -\frac{\theta}{(n+1)^2}$$

وهو مقدار صغير عندما تكون n كبيرة.

يمكن إثبات أن المقدر $\frac{n+1}{n} Y_n$ لـ θ غير متحيز وبأقل تباين. ونترك إثبات ذلك للقارئ على سبيل المثال.

مثال 9.4.6

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \frac{1}{\theta} e^{-x/\theta} \quad ; \quad x > 0, \theta > 0$$

فأوجد مقدرّ بتمان للمعلمة θ .

نعلم من المثال (5.4.6) أن معلمة مقياس θ كما أن:

$$L(\mathbf{x}; \theta) = \frac{1}{\theta^n} e^{-\sum x_i / \theta}$$

وبالتالي فتقدير بتمان للمعلمة θ هو:

$$T(x) = \frac{\int_0^{\infty} \frac{1}{\theta^{n+2}} e^{-\sum x_i/\theta} d\theta}{\int_0^{\infty} \frac{1}{\theta^{n+3}} e^{-\sum x_i/\theta} d\theta}$$

$$= \frac{\Gamma(n+1) (\sum x_i)^{n+2}}{(\sum x_i)^{n+1} \Gamma(n+2)} = \frac{\sum x_i}{n+1}$$

ومن ثم فمقدر بتمان:

$$T(X) = \frac{n}{n+1} \bar{X}$$

وهو مقدر غير متحيز بأقل تباين.

تمارين

1. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta x^{-2} \quad ; \quad x \geq \theta > 0$$

1. أوجد مقدر العقولية لـ θ ، ثم بين إن كان متحيزاً أم لا.
2. أوجد مقدر العزوم للمعلمة θ ، ثم بين إن كان متحيزاً أم لا.

2. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \frac{1}{2} e^{-|x-\theta|} \quad ; \quad -\infty < \theta < +\infty$$

1. أوجد مقدر العقولية العظمى لـ θ .
2. أوجد مقدر العزوم لـ θ .
3. أوجد مقدر بتمان لـ θ .
4. هل ينتمي التوزيع $f(x; \theta)$ لعائلة النماذج الأسية؟

3. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع:

$$f(x; \theta) = \frac{1}{\theta} ; \quad 0 \leq x \leq \theta , \quad \theta > 0$$

1. أوجد مقدر θ باستخدام طريقة العزوم، وإذا رمزنا له بـ T_1 فأوجد متوسطه ومتوسط مربع الخطأ له.
2. أوجد مقدر المعقولية العظمى لـ θ وإذا رمزنا له بـ T_2 ، فأوجد متوسطه ومتوسط مربع الخطأ له.
3. أوجد المقدر الأكفأ لـ θ ، وإذا رمزنا له بـ T_4 ، فأوجد متوسطه ومتوسط مربع الخطأ له.
4. إذا رمزنا بـ $T_5 = X_{(1)} + X_{(n)}$ ، فأوجد متوسط ومتوسط مربع الخطأ له.

4. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta x^{\theta-1} ; \quad 0 < x < 1 , \quad \theta > 0$$

1. أوجد مقدر المعقولية العظمى لـ $\tau(\theta) = \frac{4\theta + 1}{1 + \theta}$.
2. هل توجد دالة في θ لها مقدر غير متحيز بأقل تباين؟.

5. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta(1+x)^{-(1+\theta)} ; \quad x < 0 , \quad \theta > 0$$

1. قدر θ باستخدام طريقة العزوم.
2. أوجد مقدر المعقولية العظمى لـ $\tau(\theta) = \frac{1}{\theta}$.
3. أوجد مقدر المعقولية لكل من الدوال:
 $\frac{2}{3+\theta}$, $\ln \theta$, $\frac{2\theta}{5\theta+4}$

6. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \frac{\ln \theta}{\theta - 1} \theta^x \quad ; \quad 0 < x < 1, \theta > 1$$

1. أوجد مقدر العقولية العظمى لـ θ .
2. هل يوجد المقدر الأمثل لـ θ ، إن وجد فما هو؟.
3. أوجد توزيع مقدر العقولية لـ θ عندما $n \rightarrow \infty$.
4. أوجد مقدر العقولية العظمى لـ $\tau(\theta) = 1/(1 + \theta)$ ، ثم أوجد توزيعه عندما $n \rightarrow \infty$.

7. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = c_2^x \theta (1 - \theta)^{2-x} \quad ; \quad x = 0, 1, 2, \theta > 0$$

1. أوجد مقدر العقولية العظمى لـ θ^2 ، هل هو غير متحيز؟
2. هل يوجد المقدر الأمثل لـ θ^2 .
3. أوجد توزيع مقدر العقولية العظمى لـ θ^2 عندما $n \rightarrow \infty$.
4. هل مقدر العقولية العظمى لـ θ^2 متسق.

8. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \begin{cases} \frac{2x}{\theta} & ; \quad 0 < x \leq \theta \\ \frac{2(1-x)}{1-\theta} & ; \quad \theta < x \leq 1 \end{cases}$$

حيث $0 \leq \theta \leq 1$.

1. قدر θ بطريقة العزوم.
2. أوجد مقدر العقولية العظمى لـ θ من أجل $n = 1$ و $n = 2$.
3. أوجد المقدر الأمثل لـ θ عندما $n = 1$ (إن وجد).
4. أوجد مقدر العقولية العظمى لـ θ .

9. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

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

1. أوجد مقدرّ المعقولية العظمى لـ θ .
2. أوجد مقدرّ المعقولية العظمى لـ $\tau(\theta) = \frac{1}{\theta}$.
3. أوجد مقدرّ العزوم للمعلمة θ .
4. أوجد توزيع مقدرّ المعقولية العظمى لـ θ .

10. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \frac{2x}{\theta^2} \quad ; \quad 0 < x < \theta, \quad \theta > 0$$

فأوجد:

1. مقدرّ المعقولية العظمى للمعلمة θ .
2. مقدرّ المعقولية العظمى لـ $\tau_1(\theta) = \frac{1}{\theta}$.
3. مقدرّ المعقولية العظمى لـ $\tau_2(\theta) = (1+\theta)e^{-\theta}$.

11. بفرض $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\Gamma(\theta, \lambda)$:

1. أثبت أن مقدر المعقولية العظمى لـ $\tau(\theta) = \frac{1}{\theta}$ هو $\hat{\tau}_n = \frac{\lambda}{\bar{X}}$.
2. هل المقدر $\hat{\tau}_n$ متسق.
3. أوجد توزيع $\hat{\tau}_n$ عندما $n \rightarrow \infty$.

12. أثبت أن:

$$\hat{\theta}(X) = \frac{\bar{X}}{r + \bar{X}}, \quad \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

مقدرّ المعقولية العظمى لـ θ في النموذج $B = (r, \theta)$ ، ثم احسب التباين التقريبي له، بفرض n كبيرة.

13. ليكن ξ متغير عشوائي يخضع للتوزيع:

$$f(x;\theta) = (2x/\theta)e^{-x^2/\theta} \quad ; \quad x \geq 0$$

أوجد مقدر المعقولة العظمى لـ θ بناءً على عينة عشوائية $X = (X_1, \dots, X_n)$

14. لدينا عينة عشوائية $((X_1, Y_1), \dots, (X_n, Y_n))$ من توزيع طبيعي ثنائي البعد:

$$N\left((0,0), \begin{vmatrix} 1 & \theta \\ \theta & 1 \end{vmatrix}\right) \quad ; \quad \theta \in (-1,1)$$

أثبت أن التباين التقريبي للمقدر $\hat{\theta}_n$ يساوي $(1-\theta^2)^2/n(1+\theta^2)$.

15. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \frac{1}{\theta} \quad ; \quad \theta \leq x \leq 2\theta$$

1. أوجد مقدر المعقولة العظمى لـ θ .

2. أوجد مقدر بتمان لـ θ .

16. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $Be(\theta_1, \theta_2)$ فأوجد

مقدر المعقولة العظمى ومقدر العزوم لـ $\theta = (\theta_1, \theta_2)$.

17. إذا كانت $((X_1, Y_1), \dots, (X_n, Y_n))$ عينة عشوائية من توزيع طبيعي ثنائي:

$$N((0,0), \Sigma); S = \begin{vmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{vmatrix}$$

فأوجد مقدر المعقولة العظمى للمعالم المجهولة $\sigma_1^2, \sigma_2^2, \rho$.

التقدير بفترة

1.7 مقدمة

تعرضنا في الفصلين السابقين إلى خواص المقدرات النقطية وطرق الحصول على أفضل مقدر نقطي من أجل معلمة θ (أو دالة لها) في نموذج معطى $\mathcal{F} = \{F(x; \theta), \theta \in \Theta\}$. لكن لم نستعرض مقياساً للثقة التي يتمتع بها مثل هذا المقدر.

ورأينا عند بحث المقدرات النقطية في الفصل السادس، إن أي مقدر نقطي يمثل بدالة $T = T(X)$ في العينة $X = (X_1, \dots, X_n)$. وتأخذ هذه الدالة عند كل ملاحظة x للعينة X قيمة وحيدة، أي نقطة واحدة $t = T(x)$ ، التي تتخذ كقيمة تقريبية (تقدير) للمعلمة المقدرة θ . هذا بالإضافة إلى أن قيم المقدر $T = T(X)$ عند ملاحظات متكررة للعينة X ، بشكل عام مختلفة فيما بينها وتختلف عن القيمة الحقيقية للمعلمة θ ، ومن ثم من المفيد أيضاً معرفة الخطأ الممكن ارتكابه نتيجة لاستخدام التقدير $t = T(x)$ بدلاً من القيمة الحقيقية للمعلمة غير المعلومة θ ، أي إيجاد مقياس لمثل ذلك الخطأ. لذا في حالات عدة من المفيد إيجاد فترة (أو منطقة في حالة معلمة متجه)، التي تشتمل على القيمة الحقيقية للمعلمة θ باحتمال كبير γ . في هذه الحالة يتم الحديث عن التقدير بفترة (interval estimation)، ويتم اختيار قيمة α مسبقاً، بحيث تعكس "درجة الاستعداد لقبول الخطأ". يصف طول الفترة دقة تقدير المعلمة، لذا يفضل اختيار أقصر فترة. وإذا أمكن بناء مثل هذه

الفترة، فإنها تعكس دقة أكبر لتقدير المعلمة. هكذا، مما سبق نجد أنه من المفيد إيجاد تقدير بفترة نتوقع أن تقع فيها القيمة الحقيقية للمعلمة، بالإضافة إلى مقياس للتأكد من أن المعلمة تقع داخل هذه الفترة. وهذا يعني بدلاً من تقدير المعلمة بنقطة واحدة فإننا نقدرها بفترة، وطرق الحصول على مثل هذه الفترات للمعالم المجهولة لتوزيع ستكون موضوع هذا الفصل.

2.7 فترات الثقة CONFIDENCE INTERVALS

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من التوزيع $f(x; \theta)$ ، الذي يعتمد على معلمة وحيدة البعد θ غير معلومة، ونرغب في تقدير θ بفترة.

لتقدير المعلمة θ بفترة يتم البحث عن إحصائين (مقدرين)

$$T_1 = T_1(X) \quad , \quad T_2 = T_2(X) \quad ; \quad T_1 < T_2$$

بحققان، عند قيمة معطاة $0 < \gamma < 1$. الشرط الآتي:

$$P_{\theta}(T_1(X) < \theta < T_2(X)) = \gamma \quad ; \quad \theta \in \Theta \quad (1.2.7)$$

تعريف 1.2.7: فترة الثقة Confidence Interval

إن الفترة العشوائية $(T_1(X), T_2(X))$ تسمى $100\gamma\%$ فترة ثقة للمعلمة θ ، أو $100\gamma\%$ مقدر فترة ثقة لـ θ ، ويسمى العدد γ بدرجة أو معامل الثقة (degree or coefficient confidence) ، كما تسمى T_1, T_2 بحدي الثقة الأدنى والأعلى (lower and upper confidence limits) على الترتيب للمعلمة θ .

هكذا، $100\gamma\%$ فترة ثقة للمعلمة θ عبارة عن فترة عشوائية محتواة في فضاء المعلمة θ ، أي أن $(T_1, T_2) \subset \theta$ ومرتبطة بالعينة X (لكن ليس بـ θ) وتشتمل على القيمة الحقيقية للمعلمة المجهولة θ باحتمال يساوي γ ، حيث γ لا تعتمد على θ .

إذا كان الشرط (1.2.7) محققاً، فهذا يعني عملياً الآتي: لنفترض أننا أجرينا عدداً كبيراً من التجارب المستقلة، وكل واحدة تتألف من n ملاحظة على متغير عشوائي ξ توزيعه $f(x; \theta)$ ، وكانت نتائج كل تجربة موصوفة بالعينة X . وحسبنا عند كل مشاهدة $x = (x_1, \dots, x_n)$ للعينة X الفترة $(T_1(x), T_2(x))$ ، فإن $100\gamma\%$ من هذه الفترات تشتمل على القيمة الحقيقية للمعلمة المجهولة θ . أي أن القيمة الحقيقية لـ θ تنتمي لفترة الثقة $(T_1(X), T_2(X))$ ، وهذه القاعدة يمكن أن تكون خاطئة في بعض الحالات، لكن عدد مثل هذه الحالات، عندما تكون γ قريبة من الواحد (أو $1 - \gamma = \alpha$ قريبة من الصفر)، صغير ويشكل $100\alpha\%$ من مجمل حالات تطبيق هذه القاعدة. وتدعى أيضاً القيمة $(T_1(x), T_2(x))$ للفترة العشوائية $(T_1(X), T_2(X))$ فترة ثقة $100\gamma\%$ لـ θ .

يتم البحث أحياناً عن فترات ثقة ذات جانب واحد (one-sided confidence interval)، وعلى الترتيب من الأعلى (الشكل T_1, T_2 $\theta < T_2(X)$) ومن الأدنى (الشكل $\theta > T_1(X)$)، أي أن أحد الحدين T_1, T_2 (وليس كلاهما) محدد، بحيث:

$$P_{\theta}(\theta < T_2(X)) = \gamma \quad (2.2.7)$$

$$P_{\theta}(\theta > T_1(X)) = \gamma$$

وبشكل مشابه تعرف فترة الثقة من أجل مركبات معلمة θ متعددة الأبعاد، فمثلاً من أجل المركبة θ_1 للمعلمة $\theta = (\theta_1, \theta_2)$:

$$P_{\theta}(T_1(X) < \theta_1 < T_2(X)) = \gamma \quad ; \quad \theta \in \Theta \quad (3.2.7)$$

وأيضاً فترة الثقة من أجل دالة معلمية حقيقية $\tau(\theta)$ (θ يمكن أن تكون وحيدة البعد أو متعددة الأبعاد):

$$P_{\theta}(T_1(X) < \tau(\theta) < T_2(X)) = \gamma \quad ; \quad \theta \in \Theta \quad (4.2.7)$$

ملاحظة

إذا كانت $\tau(\theta)$ دالة مضطردة تماماً في θ ، وكانت $(T_1(X), T_2(X))$ هي $100\gamma\%$ فترة ثقة لـ θ ، فإن $(\tau(T_1), \tau(T_2))$ هي $100\gamma\%$ فترة ثقة للدالة $\tau(\theta)$ (إذا كانت τ متزايدة تماماً) و $(\tau(T_2), \tau(T_1))$ هي $100\gamma\%$ فترة لـ $\tau(\theta)$ (إذا كانت τ متناقصة تماماً).

كما في التقدير بنقطة أن مسألة التقدير بفترة تمثل في:

1. طريقة بناء أو إيجاد فترة الثقة.
2. معايير تقييم جودة فترة الثقة، أي معايير المفاضلة بين فترات الثقة.

3.7 طريقة الكمية المحورية PIVOTAL QUANTITY METHOD

إحدى الطرق التي يمكننا في حالات عدة من بناء فترات الثقة تسمى طريقة الكمية المحورية. وقبل عرض هذه الطريقة لابد من تعريف الكمية المحورية (pivotal quantity) أولاً.

تعريف 1.3.7: الكمية المحورية Pivotal Quantity

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر $F(x, \theta)$ ، ووجد متغير عشوائي $Q = Q(X; \theta)$ يتصف بما يلي:

1. دالة في العينة X والمعلمة θ ، التي نريد بناء فترة الثقة من أجلها دون أي معلمة أخرى، ومعرفة عند كل نقطة $\theta \in \Theta$ وعند كل نقطة $x \in G$.
2. دالة مستمرة ومضطردة تماماً (متزايدة تماماً أو متناقصة تماماً) في θ من أجل كل $x \in G$.
3. التوزيع الاحتمالي لـ $Q(X; \theta)$ معلوم ولا يعتمد على المعلمة θ .

فمثل هذا المتغير العشوائي يسمى كمية محورية (pivotal quantity) من أجل المعلمة θ في $F(x; \theta)$.

وبشكل مشابه نعرف الكمية المحورية من أجل المركبات الفردية (فمثلاً θ_1) في حالة معلمة θ متعددة الأبعاد ونرمز لها بـ $Q(X; \theta_1)$ ، وأيضاً من أجل دالة معلمية حقيقية $\tau = \tau(\theta)$ (وحيدة البعد أو متعددة الأبعاد) ونرمز لها بـ $Q(X; \tau)$. وستتطرق فيما يلي، ومن أجل الاختصار والتبسيط لحالة معلمة وحيدة البعد θ أو دالة حقيقية لها.

مثال 1.3.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع طبيعي $N(\theta, \sigma^2)$ ، فإن:

$$Q(X; \theta) = \frac{\bar{X} - \theta}{\sigma/\sqrt{n}}$$

كمية محورية للتوزيع $N(\theta, \sigma^2)$ من أجل المعلمة θ وتوزيعها:

$$f_Q(q) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}q^2} ; \quad -\infty < q < \infty$$

لا يعتمد على المعلمة θ ، بينما \bar{X}/θ ليس كمية محورية لأن توزيعه $N(1, \sigma^2/n\theta)$ يعتمد على المعلمة θ .

مثال 2.3.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta e^{-\theta x} ; \quad x > 0$$

وكانت $Q(X; \theta) = \theta \sum_{i=1}^n X_i$ فإن توزيع Q :


$$f_Q(q) = \frac{1}{\Gamma(n)} q^{n-1} e^{-q} ; \quad q > 0$$

وبذلك تكون Q كمية محورية من أجل θ لأنها تحقق الشروط الثلاث المعرفة للكمية المحورية (يمكن للقارئ التأكد منها بسهولة).

لنفترض من أجل نموذج مستمر $F(x;\theta)$ يعتمد على معلمة وحيدة البعد θ أمكن إيجاد كمية محورية $Q(X;\theta)$ ، كثافة توزيعها الاحتمالية $f_Q(q)$ ، عندئذٍ نستطيع من أجل قيمة معينة معطاة $0 < \gamma < 1$ إيجاد عددين q_1, q_2 ; $q_1 < q_2$ (وهذا ممكن بطرق مختلفة طبعاً)، بحيث أن:

$$P(q_1 < Q(X;\theta) < q_2) = \int_{q_1}^{q_2} f_Q(q) dq = \gamma \quad (1.3.7)$$

أنظر شكل (1.3.7).



شكل (1.3.7)

لنعين الآن من أجل $x \in G$ العددين (التقديرين) $T_i(x)$; $i = 1, 2$ ، حيث $T_1(x) < T_2(x)$ ، وذلك كحلين للمعادلتين:


$$Q(x;\theta) = q_1 \quad , \quad Q(x;\theta) = q_2 \quad (2.3.7)$$

بالنسبة لـ θ [يتعين هذان العددان تماماً، حسب الشرط (2) المفروض على $Q(X;\theta)$]، عندئذٍ المتباينة المزوجة:

$$q_1 < Q(x;\theta) < q_2$$


$$T_1(x) < \theta < T_2(x)$$

كما يبدو ذلك بوضوح على الشكلين (2.3.7) و (3.3.7).



شكل (3.3.7)

$Q(\theta)$ دالة متزايدة تماماً في θ



شكل (2.3.7)

$Q(\theta)$ دالة متناقصة تماماً في θ

وبالتالي يمكن إعادة صياغة العلاقة (1.3.7) على الصورة:

$$P_{\theta}(T_1(X) < \theta < T_2(X)) = \gamma \quad ; \quad \theta \in \theta \quad (3.3.7)$$

هكذا، الفترة $(T_1(X), T_2(X))$ هي عبارة عن $100\gamma\%$ فترة ثقة للمعلمة θ وطولها (length of the confidence) هو $L_{\gamma} = T_2 - T_1$.

تجدد الإشارة هنا إلى الملاحظات الآتية:

1. q_1, q_2 مستقلان عن θ ، لأن توزيع Q لا يعتمد على θ .
2. من أجل كل قيمة معينة $0 < \gamma < 1$ هنالك أزواج عدة ممكنة (q_1, q_2) تحقق العلاقة:

$$P_{\theta}(q_1 < Q(X;\theta) < q_2) = \gamma \quad ; \quad \theta \in \Theta \quad (4.3.7)$$

وأن كل زوج من الأعداد (q_1, q_2) ينتج عنه فترة ثقة (t_1, t_2) ، وبالتالي يجب اختيار الزوج الذي يجعل القيمة المتوقعة لطول الفترة العشوائية (T_1, T_2) ، أي L_{γ} أصغر ما يمكن.

3. الميزة الرئيسية لطريقة الكمية المحورية تتمثل في أن المتباينة:

$$q_1 < Q(x;\theta) < q_2$$

يمكن إعادة صياغتها أو عكسها (inverted) أو تحويلها (pivoted) إلى متباينة من الشكل:

$$T_1(x) < \theta < T_2(x)$$

وذلك من أجل كل قيمة $x \in G$.

إن طريقة الكمية المحورية في بناء فترة الثقة للمعالم المجهولة في توزيع تشتمل على مرحلتين:

المرحلة الأولى: إيجاد كمية محورية.

المرحلة الثانية: إعادة صياغة المتباينة $q_1 < Q(x;\theta) < q_2$ وكتابتها على الشكل $T_1(x) < \theta < T_2(x)$.

4.7 بناء فترات الثقة باستخدام كمية محورية في حال المعاينة من توزيع طبيعي

سنتطرق في هذا البند لبناء فترات الثقة لبعض الحالات الهامة والشائعة تطبيقياً والمتعلقة بالمعاينة من توزيع طبيعي (sampling from the normal distribution).

1.4.7 فترة الثقة لمتوسط النموذج الطبيعي I

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية مأخوذة من توزيع $N(\theta, \sigma^2)$ ، ونريد بناء فترة ثقة للمعلمة θ .

بما أن:

$$Q(X; \theta) = \frac{\bar{X} - \theta}{\sigma/\sqrt{n}}$$

كمية محورية متناقصة تماماً في θ وتوزيعها:

$$\mathcal{L}\left(\frac{\bar{X} - \theta}{\sigma/\sqrt{n}}\right) = N(0,1)$$

فالمعادلتان (2.3.7) تكتبان على الصورة:

$$\frac{\bar{x} - \theta}{\sigma/\sqrt{n}} = q_1 \quad , \quad \frac{\bar{x} - \theta}{\sigma/\sqrt{n}} = q_2$$

ويحل كل منهما بالنسبة لـ θ نجد:

$$T_1(x) = \bar{x} - \frac{\sigma}{\sqrt{n}} q_2 \quad , \quad T_2(x) = \bar{x} - \frac{\sigma}{\sqrt{n}} q_1$$

وعلى ذلك فإن فترة ثقة للمعلمة θ هي عبارة عن أي فترة من الشكل:

$$\Delta_\gamma(X) = \left(\bar{X} - \frac{\sigma}{\sqrt{n}} q_2, \bar{X} - \frac{\sigma}{\sqrt{n}} q_1 \right) \quad (1.4.7)$$


حيث $q_1 < q_2$ أي عددين يحققان الشرط:

$$P(q_1 < Q < q_2) = \gamma$$

لكن $\mathcal{L}(Q) = N(0,1)$ ، إذن:

$$P(q_1 < Q < q_2) = \Phi(q_2) - \Phi(q_1) = \gamma \quad (2.4.7)$$

وفي الحقيقة هنالك أزواج عدة (q_1, q_2) تحقق العلاقة (2.4.7)، يمكن إيضاح بعضها من خلال الأشكال الآتية:



طول الفترة العشوائية $\Delta_\gamma(X)$ المعرفة بالعلاقة (1.4.7):

$$L_\gamma = L_\gamma(q_1, q_2) = \frac{\sigma}{\sqrt{n}}(q_2 - q_1) \quad (3.4.7)$$

يعتمد على q_1, q_2 وحجم العينة n . وبازدياد حجم العينة n يتناقص طول فترة الثقة، بينما بازدياد الفرق $(q_2 - q_1)$ يزداد طول فترة الثقة هذه، وهذا الفرق يتعلق بقيمة γ واختيار q_1, q_2 . لذا للحصول على أصغر فترة ثقة ضمن الفترات من الشكل (1.4.7) بافتراض n و γ معطاة، يجب البحث عن القيمة الصغرى لـ $L_\gamma(q_1, q_2)$ عند الشرط (2.4.7).

باشتقاق العلاقة (2.4.7) بالنسبة لـ q_1 نحصل على:

$$\varphi(q_2) \frac{dq_2}{dq_1} - \varphi(q_1) = 0 \Rightarrow \frac{dq_2}{dq_1} = \frac{\varphi(q_1)}{\varphi(q_2)}$$

حيث أن:

$$\varphi(x) = \Phi'(x)$$

وللحصول على القيمة الصغرى لـ L_γ نضع:

$$\frac{\partial L_\gamma}{\partial q_1} = \frac{\sigma}{\sqrt{n}} \left(\frac{dq_2}{dq_1} - 1 \right) = \frac{\sigma}{\sqrt{n}} \left(\frac{\varphi(q_1)}{\varphi(q_2)} - 1 \right) = 0 \Rightarrow \varphi(q_1) = \varphi(q_2)$$

ويتحقق ذلك عندما تكون $q_1 = q_2$ وهذا حل مرفوض [يتعارض مع الشرط (2.4.7)]. أو عندما تكون $q_1 = -q_2$ لأن الدالة $\varphi(q)$ زوجية. وبناءً على هذه النتيجة وأيضاً المعادلة (2.4.7) والعلاقة $\Phi(-x) = 1 - \Phi(x)$ نحصل على المساواة

$$\Phi(q_2) = \frac{1+\gamma}{2} = 1 - \frac{\alpha}{2} \quad ; \quad \gamma = 1 - \alpha$$

وباستخدام جدول التوزيع الطبيعي المعياري نجد $q_2 = Z_{\alpha/2}$ [القيمة الحرجة للتوزيع $N(0,1)$ الموافقة لاحتمال $(1 - \alpha/2)$].

هكذا، $100\gamma\%$ فترة ثقة المثلى [أصغر $100\gamma\%$ فترة ثقة من الشكل $\Delta_\gamma(X)$ من أجل المعلمة θ في النموذج $N(\theta, \sigma^2)$ هي الفترة:

$$\Delta_\gamma^*(X) = \left(\bar{X} - \frac{\sigma}{\sqrt{n}} Z_{\alpha/2}, \bar{X} + \frac{\sigma}{\sqrt{n}} Z_{\alpha/2} \right) \quad (4.4.7)$$

المتناظرة بالنسبة للنقطة العشوائية \bar{X} وطولها $2 \cdot \frac{\sigma}{\sqrt{n}} Z_{\alpha/2}$. فمثلاً، إذا كنا نرغب في تقدير متوسط مجتمع طبيعي بتباين معلوم $\sigma^2 = 225$ ، ولدينا عينة عشوائية بحجم $n = 20$ ومتوسط $\bar{x} = 64.3$ ، عندئذٍ من أجل $\gamma = 0.95$ نجد $Z_{(1+\gamma)/2} = Z_{0.975} = 1.96$. وبالتالي 97.5% فترة ثقة لمتوسط المجتمع θ بناءً على العينة المشاهدة:

$$64.3 - 1.96 \frac{15}{\sqrt{20}} < \theta < 64.3 + 1.96 \frac{15}{\sqrt{20}}$$

$$57.7 < \theta < 70.9$$

2.4.7 فترة الثقة لتباين النموذج الطبيعي II

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من التوزيع $N(\mu, \theta^2)$ ، ونريد بناء $100\gamma\%$ فترة ثقة للتباين غير المعلوم θ^2 .

يمكن بسهولة في هذه الحالة إيجاد كمية محورية تعتمد على $\theta^2 = \tau(\theta) = \tau$ ، وهي:

$$Q = Q(X; \tau) = \frac{1}{\tau} \sum_{i=1}^n (X_i - \mu)^2$$

بما أن:

$$\mathcal{L}\left(\frac{X_i - \mu}{\theta}\right) = N(0,1)$$

فحسب المبرهنة (7.3.2):

$$\mathcal{L}\left(\left(\frac{X_i - \mu}{\theta}\right)^2\right) = \chi_{(1)}^2$$

وبالتالي فإن:

$$\mathcal{L}(Q(X; \tau)) = \chi_{(n)}^2$$

بما أن Q دالة متناقصة تماماً في τ ، فيحل المعادلتين:

$$G(x, \tau_1) = \frac{1}{\tau_1} \sum_{i=1}^n (x_i - \mu)^2 = q_2$$

$$G(x, \tau_2) = \frac{1}{\tau_2} \sum_{i=1}^n (x_i - \mu)^2 = q_1$$

بالنسبة لـ τ_2, τ_1 نجد:

$$\tau_1 = T_1(x) = \frac{1}{q_2} \sum_{i=1}^n (x_i - \mu)^2$$

$$\tau_2 = T_2(x) = \frac{1}{q_1} \sum_{i=1}^n (x_i - \mu)^2 \quad ; \quad q_1 < q_2$$

وعلى ذلك فإن $100\gamma\%$ فترة ثقة لـ $\tau = \theta^2$ هي أي فترة من الشكل:

$$\Delta_\gamma(X) = \left(\frac{1}{q_2} \sum_{i=1}^n (X_i - \mu)^2, \frac{1}{q_1} \sum_{i=1}^n (X_i - \mu)^2 \right) \quad (5.4.7)$$


حيث أن q_1, q_2 عدداً يحققان العلاقة:

$$\int_{q_1}^{q_2} f_Q(q) dq = \gamma \quad (6.4.7)$$

و $f_Q(q)$ دالة كثافة توزيع $\chi^2_{(n)}$ المعرفة بالعلاقة (29.3.2)، ويمكن الحصول على q_1, q_2 بالمحاولة والخطأ، ولنرمز لهما بـ:

$$q_1 = \chi^2_{1-\alpha_1, n} \quad , \quad q_2 = \chi^2_{\alpha_2, n} \quad ; \quad \gamma = 1 - \alpha \quad , \quad \alpha = \alpha_1 + \alpha_2$$

[يمكن إيجاد أكثر من زوج (q_1, q_2) طبعاً، وهذا يتوقف على α_1, α_2].
ويبدوان بوضوح على الشكل (1.4.7).



شكل (1.4.7)

ومن ثم تأخذ فترة الثقة (5.4.7) الصورة الآتية:

$$\Delta_\gamma(X) = \left(\frac{1}{\chi^2_{\alpha_2, n}} \sum_{i=1}^n (X_i - \mu)^2, \frac{1}{\chi^2_{1-\alpha_1, n}} \sum_{i=1}^n (X_i - \mu)^2 \right) \quad (7.4.7)$$

للحصول على أصغر فترة ثقة من الشكل (4.4.7) يجب اختيار q_1, q_2 بحيث تجعل طول الفترة:

$$L_\gamma = \left(\frac{1}{q_1} - \frac{1}{q_2} \right) \sum_{i=1}^n (X_i - \mu)^2$$

أصغر ما يمكن عند الشرط (6.4.7)، أي البحث عن أصغر قيمة ممكنة للنسبة q_2/q_1 وباشتقاق العلاقة (6.4.7) بالنسبة لـ q_1 نجد:

$$\frac{dq_2}{dq_1} f_Q(q_2) - f_Q(q_1) = 0 \Rightarrow \frac{dq_2}{dq_1} = \frac{f_Q(q_1)}{f_Q(q_2)}$$

وعلى ذلك وباشتقاق L_γ بالنسبة لـ q_1 نجد:

$$\begin{aligned} \frac{\partial L_\gamma}{\partial q_1} &= \left(-\frac{1}{q_1^2} + \frac{1}{q_2^2} \frac{dq_2}{dq_1} \right) \sum_{i=1}^n (X_i - \mu)^2 = \\ &= \left(-\frac{1}{q_1^2} + \frac{1}{q_2^2} \frac{f_Q(q_1)}{f_Q(q_2)} \right) \sum_{i=1}^n (X_i - \mu)^2 = 0 \Rightarrow \\ q_1^2 f_Q(q_1) &= q_2^2 f_Q(q_2) \Rightarrow q_1 f_Q(q_1) = q_2 f_Q(q_2) \end{aligned}$$

وهذا يعني أن طول فترة الثقة المعرف في (5.4.7) يكون أصغر ما يمكن إذا اخترنا q_1, q_2 بحيث يحققان المساواة:

$$q_1 f_Q(q_1) = q_2 f_Q(q_2)$$

وبوضع:

$$q_1 = \chi_{1-\alpha_1, n}^2, \quad q_2 = \chi_{\alpha_2, n}^2; \quad \alpha_1 + \alpha_2 = 1 - \gamma$$

نحصل على المعادلة:

$$\left(\chi_{\alpha_2, n}^2 / \chi_{1-\alpha_1, n}^2 \right)^{n/2} = \exp \left[\left(\chi_{\alpha_2, n}^2 - \chi_{1-\alpha_1, n}^2 \right) / 2 \right] \quad (8.4.7)$$

ويعني هذا أن طول فترة الثقة من الشكل (5.4.7) يكون أقل ما يمكن إذا اخترنا α_1, α_2 بحيث يحققان المعادلة (8.4.7).

هكذا، إن الصعوبة الأساسية في الحصول على أصغر فترة ثقة وفق هذه الطريقة تكمن في اختيار α_1, α_2 بحيث يحققان المعادلة (8.4.7)، وهذا بالمحاولة والخطأ. لذا عادة يتم اختيار $\alpha_1 = \alpha_2 = \frac{1-\gamma}{2} = \frac{\alpha}{2}$ وذلك عندما يكون حجم


العينة $n \geq 20$ ، لأن النسبة $\chi^2_{\alpha_2, n} / \chi^2_{1-\alpha_1, n}$ تقترب من النسبة $\chi^2_{\alpha/2, n} / \chi^2_{1-\alpha/2, n}$ بازدياد حجم العينة n ، بحيث يصبح الفرق بين هاتين النسبتين لا يتجاوز 0.02 تقريباً عندما تكون $n \geq 20$ ، وهذا ما يبينه الجدول (1.4.7) من أجل درجة ثقة $\gamma = 0.95$ وبعض القيم لـ n . وتسمى فترة الثقة في هذه الحالة بفترة ثقة ذات ذيلين متساويين (شكل 2.4.7) وتأخذ الشكل:

$$\Delta_{\gamma}^* = \left(\frac{1}{\chi^2_{\alpha/2, n}} \sum_{i=1}^n (X_i - \mu)^2, \frac{1}{\chi^2_{1-\alpha/2, n}} \sum_{i=1}^n (X_i - \mu)^2 \right) \quad (9.4.7)$$

وهي كما ذكرنا صيغة تقريبية لأصغر فترة ثقة من الشكل (5.4.7).

جدول (1.4.7):

| n | $\chi^2_{1-\alpha/2, n}$ | $\chi^2_{\alpha/2, n}$ | $\chi^2_{1-\alpha_1, n}$ | $\chi^2_{\alpha_2, n}$ | $\chi^2_{\alpha/2, n} / \chi^2_{1-\alpha/2, n}$ | $\chi^2_{\alpha_2, n} / \chi^2_{1-\alpha_1, n}$ |
|----|--------------------------|------------------------|--------------------------|------------------------|---|---|
| 2 | 0.05 | 7.38 | 0.08 | 8.09 | 147.6 | 101.13 |
| 5 | 0.83 | 13.83 | 0.99 | 14.37 | 15.46 | 14.52 |
| 10 | 3.25 | 20.48 | 3.52 | 21.73 | 6.30 | 6.17 |
| 20 | 9.59 | 34.17 | 9.96 | 35.23 | 3.56 | 3.54 |



شكل (2.4.7)

فمثلاً، إذا كنا نرغب في تقدير فترة لتباين مجتمع طبيعي متوسطه $\mu = 65$ ، بناءً على عينة مشاهدة بحجم $n = 20$. وافترضنا $\sum_{i=1}^{20} (x_i - 65)^2 = 300$. فعندئذٍ من أجل درجة ثقة $\gamma = 0.95$ ، نجد:

$$q_1 = \chi_{0.975,20}^2 = 9.59 \quad , \quad q_2 = \chi_{0.025,20}^2 = 34.17$$

وبالتالي 95% فترة ثقة لـ θ^2 (أصغر فترة ثقة) حسب (9.4.7) تكون:

$$\Delta_{\gamma}^*(x) = \left(\frac{1}{34.17}(300), \frac{1}{9.59}(300) \right) = (8.79, 31.28)$$

وباستخدام الصيغة (8.4.7) نجد:

$$\Delta_{\gamma}^*(x) = \left(\frac{1}{35.23}(300), \frac{1}{9.96}(300) \right) = (8.52, 30.12)$$

ويتقلص الفرق بين ناتج الصيغتين (8.4.7) و (9.4.7) بازدياد حجم العينة n .

3.4.7 فترة الثقة للمتوسط والتباين في النموذج الطبيعي العام

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع طبيعي $N(\theta_1, \theta_2^2)$ ، ونريد بناء $100\gamma\%$ فترة ثقة لكل من $\theta = (\theta_1, \theta_2^2)$ ؛ $\tau_1(\theta) = \theta_1$ ، $\tau_2(\theta) = \theta_2^2$ ؛

نلاحظ أن:

$$Q(X; \theta_1) = \sqrt{n-1} \frac{\bar{X} - \theta_1}{S(X)}$$

دالة مستمرة ومتناقصة تماماً في θ_1 وتتبع توزيع ستودنت بـ $(n-1)$ درجة حرية، أي أن:

$$L(Q) = S(n-1)$$

وذلك حسب المبرهنة (6.9.3)، وبالتالي فإن $Q(X; \theta_1)$ كمية محورية.

لايجاد 100% فترة ثقة لـ θ_1 نتبع نفس الخطوات الواردة في الفقرة السابقة
(1.4.7) نجد:

$$\sqrt{n-1} \frac{\bar{x} - \theta_1}{S(x)} = q_2 \Rightarrow T_1(x) = \bar{x} - \frac{S(x)}{\sqrt{n-1}} q_2$$

$$\sqrt{n-1} \frac{\bar{x} - \theta_1}{S(x)} = q_1 \Rightarrow T_2(x) = \bar{x} - \frac{S(x)}{\sqrt{n-1}} q_1$$

وعلى ذلك فإن 100% فترة ثقة لـ θ_1 هي عبارة عن أي فترة من الشكل:

$$\Delta_\gamma(X) = \left(\bar{X} - \frac{S(x)}{\sqrt{n-1}} q_2, \bar{X} - \frac{S(x)}{\sqrt{n-1}} q_1 \right) \quad (10.4.7)$$

حيث أن $q_1 < q_2$ عددان يحققان الشرط:

$$P(q_1 < Q < q_2) = \int_{q_1}^{q_2} f(t) dt = \gamma$$


وأن $f(t) = f_Q(t)$ هي دالة كثافة توزيع ستودنت بـ $(n-1)$ درجة حرية. وطول هذه الفترة:

$$L_\gamma = \frac{S(X)}{\sqrt{n-1}} (q_2 - q_1) \quad (11.4.7)$$

ويكون أقل ما يمكن عندما يكون الفرق $(q_2 - q_1)$ أصغر ما يمكن، ونلاحظ بسهولة بناءً على تناظر توزيع t حول الصفر، أن ذلك يحدث عندما $q_1 = -q_2$. ويمكن إثبات ذلك جبرياً بنفس الأسلوب الذي اتبعناه في الفقرة (1.4.7)، أي أن:

$$q_2 = t_{(1-\gamma)/2, n-1} = t_{\alpha/2, n-1} \quad , \quad q_1 = t_{(1+\gamma)/2, n-1} = -t_{\alpha/2, n-1}$$

حيث $t_{\alpha/2, n-1}$ القيمة الحرجة لتوزيع $S(n-1)$ الموافق لاحتمال $\alpha/2$ ، ويمكن الحصول عليها من جدول توزيع t (الملحق جدول رقم 10).



شكل (3.4.7)

وعلى ذلك فإن $100\gamma\%$ فترة ثقة لـ θ_1 بأقل طول هي:

$$\Delta_\gamma(X) = \left(\bar{X} - \frac{S(x)}{\sqrt{n-1}} t_{\alpha/2, n-1}, \bar{X} + \frac{S(x)}{\sqrt{n-1}} t_{\alpha/2, n-1} \right) \quad (12.4.9)$$

وطولها:

$$L_\gamma = \frac{2S(x)}{\sqrt{n-1}} t_{\alpha/2, n-1} \quad (13.4.7)$$

والقيمة المتوقعة له:

$$E(L_\gamma) = \frac{2}{\sqrt{n-1}} t_{\alpha/2, n-1} E(S)$$

فمثلاً، من أجل عينة مشاهدة حجمها $n = 10$ ، $\bar{x} = 25$ ، و $S = 4$ ، فإن 95% فترة ثقة لـ θ_1 تكون:

$$\left(25 - \frac{4}{\sqrt{9}} (2.262), 25 + \frac{4}{\sqrt{9}} (2.262) \right)$$

أي أن:

$$-21.198 < \theta_1 < 28.016$$

أما لإيجاد $100\gamma\%$ فترة ثقة لـ θ_2^2 بطول أصغري، تتبع ذات الخطوات التي اتبعناها في الفقرة (2.4.7)، بعد تعيين كمية محورية $G(\mathbf{X}; \theta_2^2)$. نلاحظ أن:

$$Q = \frac{nS^2(\mathbf{X})}{\theta_2^2} \quad ; \quad S^2(\mathbf{X}) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

تتبع توزيع $\chi_{(n-1)}^2$ [حسب المبرهنة (5.9.3)]، وعلى ذلك فإن Q كمية محورية لتقدير $\tau_2 = \theta_2^2$ ، ومن ثم:

$$\frac{nS^2(x)}{\theta_2^2} = q_2 \Rightarrow T_1(x) = \frac{nS^2(x)}{q_2}$$

$$\frac{nS^2(x)}{\theta_2^2} = q_1 \Rightarrow T_2(x) = \frac{nS^2(x)}{q_1}$$

وبالتالي $100\gamma\%$ فترة ثقة لـ θ_2^2 هي عبارة عن أي فترة من الشكل:

$$\Delta_\gamma(\mathbf{X}) = \left(\frac{nS^2(\mathbf{X})}{q_2}, \frac{nS^2(\mathbf{X})}{q_1} \right) \quad (14.4.7)$$

حيث $q_1 < q_2$ عدنان يحققان الشرط:

$$P(q_1 < Q < q_2) = \int_{q_1}^{q_2} f(q) dq = \gamma$$

وأن $f_Q(q) = f(q)$ دالة كثافة توزيع $\chi_{(n-1)}^2$ ، أي

$$\text{أن: } q_1 = \chi_{1-\alpha_1, n-1}^2, \quad q_2 = \chi_{\alpha_2, n-1}^2 \quad ; \quad \alpha_1 + \alpha_2 = \alpha = 1 - \gamma$$

وطول هذه الفترة:

$$L_\gamma = nS^2 \left(\frac{1}{q_2} - \frac{1}{q_1} \right) \quad (15.4.7)$$

وعندما $n \geq 20$ فأصغر قيمة للطول L_γ هي:

$$L_\gamma^* = nS^2 \left(\frac{1}{\chi_{\alpha/2, n-1}^2} - \frac{1}{\chi_{1-\alpha/2, n-1}^2} \right)$$

وعلى ذلك $100\gamma\%$ فترة ثقة لـ θ_2^2 ، والتي تتمتع بطول أصغري ضمن $100\gamma\%$ فترات ثقة من الشكل (14.4.7) هي:

$$\Delta_\gamma^*(\mathbf{X}) = \left(\frac{nS^2(\mathbf{X})}{\chi_{\alpha/2, n-1}^2}, \frac{nS^2(\mathbf{X})}{\chi_{1-\alpha/2, n-1}^2} \right) \quad (16.4.7)$$

أما إذا كانت $n < 20$ فإن $100\gamma\%$ فترة ثقة لـ θ_2^2 ذات طول أصغري هي من الشكل:

$$\left(\frac{nS^2(\mathbf{X})}{\chi_{\alpha_2, n-1}^2}, \frac{nS^2(\mathbf{X})}{\chi_{1-\alpha_1, n-1}^2} \right) ; \quad \alpha_1 + \alpha_2 = \alpha \quad (17.4.7)$$

حيث أن $\chi_{1-\alpha_1, n-1}^2$ ، $\chi_{\alpha_2, n-1}^2$ يعينان من العلاقة (8.4.7) باستبدال n بـ $(n-1)$.

فمثلاً، من أجل عينة عشوائية بحجم $n = 20$ ، $S^2 = 9$ فإن فترة ثقة 90% لـ θ_2^2 هي:

$$\left(\frac{180}{16.919}, \frac{180}{3.325} \right)$$

أي أن:

$$10.645 < \theta_2^2 < 54.135$$

إن طريقة الكمية المحورية يمكن تطبيقها على حالات أخرى غير إيجاد فترات الثقة لمعالم توزيع، ونورد فيما يلي ثلاث حالات هامة تطبيقياً.

4.4.7 فترة الثقة للفرق بين متوسطي نموذجين طبيعيين

لتكن $X = (X_1, \dots, X_m)$ عينة عشوائية مأخوذة من توزيع $N(\theta_1^{(1)}, \theta_2^2)$ و $Y = (Y_1, \dots, Y_n)$ عينة عشوائية من توزيع $N(\theta_1^{(2)}, \theta_2^2)$ ، وكانت العينتان مستقلتين، ونريد بناء $100\gamma\%$ فترة ثقة للفرق $(\theta_1^{(1)} - \theta_1^{(2)})$.

نلاحظ أن النموذجين مختلفين فقط بمتوسطيهما، وكما نعلم:

$$\mathcal{L}_{\theta_1}(\bar{X}) = N\left(\theta_1^{(1)}, \frac{\theta_2^2}{m}\right), \quad \theta_1 = (\theta_1^{(1)}, \theta_2^2)$$

$$\mathcal{L}_{\theta_2}(\bar{Y}) = N\left(\theta_1^{(2)}, \frac{\theta_2^2}{n}\right), \quad \theta_2 = (\theta_1^{(2)}, \theta_2^2)$$

وعلى ذلك:

$$\mathcal{L}_{\theta}(\bar{X} - \bar{Y}) = N\left((\theta_1^{(1)} - \theta_1^{(2)}), \frac{m+n}{mn} \theta_2^2\right); \quad \theta = (\theta_1^{(1)}, \theta_1^{(2)}, \theta_2^2)$$

$$\mathcal{L}_{\theta}\left(\frac{(\bar{X} - \bar{Y}) - (\theta_1^{(1)} - \theta_1^{(2)})}{\sqrt{\frac{m+n}{mn} \theta_2^2}}\right) = N(0,1)$$

وكما نعلم أن [راجع مبرهنة (5.9.3)]:

$$\mathcal{L}_{\theta_1}(mS^2(X)/\theta_2^2) = \chi_{(m-1)}^2$$

$$\mathcal{L}_{\theta_2}(nS^2(Y)/\theta_2^2) = \chi_{(n-1)}^2$$

ومن ثم:

$$\mathcal{L}_{\theta}\left(\frac{mS^2(X) + nS^2(Y)}{\theta_2^2}\right) = \chi_{m+n-2}^2$$

بأخذ:

$$Q = \left(\frac{(\bar{X} - \bar{Y}) - (\theta_1^{(1)} - \theta_1^{(2)})}{\sqrt{\frac{m+n}{mn} \frac{mS^2(X) + nS^2(Y)}{m+n-2}}} \right) =$$

$$= \sqrt{\frac{mn(m+n-2)}{m+n}} \frac{(\bar{X} - \bar{Y}) - (\theta_1^{(1)} - \theta_1^{(2)})}{\sqrt{mS^2(X) + nS^2(Y)}}$$

نجد أن:

$$\mathcal{L}(Q) = S(m+n-2)$$

أي أن Q تتبع توزيع ستيودنت (توزيع t) بـ $(m+n-2)$ درجة حرية، لذا يمكن أخذ Q ككمية محورية لبناء فترة ثقة للفرق $(\theta_1^{(1)} - \theta_1^{(2)})$. ويتبع نفس الخطوات الواردة في الفقرة (3.4.7) نحصل على $100\gamma\%$ فترة ثقة لـ $(\theta_1^{(1)} - \theta_1^{(2)})$ المطلوبة وهي من الشكل:

$$\left((\bar{X} - \bar{Y}) \pm t_{\alpha/2, m+n-2} \left[\frac{m+n}{mn(m+n-2)} (mS^2(X) + nS^2(Y)) \right]^{1/2} \right) \quad (18.4.7)$$

إذا كان تباين النموذجين معلومين ويساويان على الترتيب σ_1^2, σ_2^2 فإن الكمية المحورية لتقدير فرق المتوسطين $(\theta^{(1)} - \theta^{(2)})$ يمكن بناءها بسهولة على النحو الآتي:

بما أن \bar{X}, \bar{Y} مستقلان، وأن:

$$\mathcal{L}_{\theta^{(1)}}(\bar{X}) = N(\theta^{(1)}, \sigma_1^2/m) \quad , \quad \mathcal{L}_{\theta^{(2)}}(\bar{Y}) = N(\theta^{(2)}, \sigma_2^2/n)$$

فإن:

$$\mathcal{L} \left(\frac{(\bar{X} - \bar{Y}) - (\theta^{(1)} - \theta^{(2)})}{\sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}}} \right) = N(0,1)$$

مهما تكن $\theta^{(1)}$ و $\theta^{(2)}$.

وعلى ذلك يمكن أخذ:

$$Q = \frac{(\bar{X} - \bar{Y}) - (\theta^{(1)} - \theta^{(2)})}{\sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}}}$$

ككمية محورية لبناء 100% فترة ثقة لـ $(\theta^{(1)}, \theta^{(2)})$. وبناء 100% فترة ثقة يتم بشكل مشابه لما ورد في الفقرة (1.4.7). وفترة الثقة المطلوبة تأخذ الشكل:

$$\left(\bar{X} - \bar{Y} \pm Z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{m} + \frac{\sigma_2^2}{n}} \right) ; \quad \frac{\alpha}{2} = \frac{1-\gamma}{2} \quad (19.4.7)$$

5.4.7 فترة الثقة للفرق $(\mu_1 - \mu_2)$ في حالة المعاينة من توزيع طبيعي ثنائي

لتكن $((X_1, Y_1), \dots, (X_n, Y_n))$ عينة عشوائية من مجتمع يخضع للتوزيع الطبيعي الثنائي. معام مجهولة:

$$\mu_x = \mu_1 , \quad \mu_y = \mu_2 , \quad \sigma_x^2 = \sigma_1^2 , \quad \sigma_y^2 = \sigma_2^2 , \quad \rho_{xy} = \rho$$

ونريد بناء 100% فترة ثقة للفرق $(\mu_1 - \mu_2)$.

إذا وضعنا

$$Z_i = X_i - Y_i ; \quad i = 1, \dots, n$$

فإن $Z = (Z_1, Z_2, \dots, Z_n)$ تعتبر عينة عشوائية مأخوذة من توزيع طبيعي. بمتوسط $\mu = (\mu_1 - \mu_2)$ وتباين $\sigma^2 = \sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2$ ، أي من توزيع $N(\mu, \sigma^2)$ ، وعلى ذلك فإن:

$$Q = \frac{\bar{Z} - \mu}{S(Z)/\sqrt{n-1}} ; \quad S^2(Z) = \frac{1}{n} \sum_{i=1}^n (Z_i - \bar{Z})^2 , \quad \bar{Z} = \frac{1}{n} \sum_{i=1}^n Z_i$$

$$L(Q) = S(n-1)$$

وبالتالي Q تعتبر كمية محورية، وأن $100\gamma\%$ فترة ثقة لـ $\mu = \mu_1 - \mu_2$ المطلوبة:

$$\left(\bar{Z} - \frac{S(Z)}{\sqrt{n-1}} t_{\alpha/2, n-1}, \bar{Z} + \frac{S(Z)}{\sqrt{n-1}} t_{\alpha/2, n-1} \right) \quad (20.4.7)$$

تستخدم هذه الطريقة في حالة المشاهدات الثنائية (paired observation)، أي عندما تكون كل ملاحظة x_i مترافقة مع ملاحظة y_i .

6.4.7 فترة الثقة للنسبة بين تباينين نموذجين طبيعيين

لنرى الآن الحالة التي تكون فيها $X = (X_1, \dots, X_m)$ عينة عشوائية من التوزيع $N(\theta_1^{(1)}, \theta_2^{(2)^2})$ ، بينما $Y = (Y_1, \dots, Y_n)$ عينة عشوائية من توزيع $N(\theta_1^{(2)}, \theta_2^{(2)^2})$ ، والعينتان مستقلتان، ويطلب تقدير النسبة $\theta_2^{(1)^2} / \theta_2^{(2)^2}$ غير المعلومة.

يمكن بناء كمية محورية في هذه الحالة على أساس المرهنة (9.3.2)، والتي تعطى بالمتغير العشوائي:

$$F = \frac{m(n-1)S^2(X) / \theta_2^{(1)^2}}{n(m-1)S^2(Y) / \theta_2^{(2)^2}}$$

وهذا الأخير يتبع توزيع F بـ $\gamma_1 = m-1$ ، $\gamma_2 = n-1$ درجة حرية من أجل أي قيم للمعالم $\theta_1^{(1)}, \theta_1^{(2)}, \theta_2^{(1)}, \theta_2^{(2)}$. وبالتالي يعتبر F كمية محورية لتقدير النسبة $\theta_2^{(1)^2} / \theta_2^{(2)^2}$ ، وعندئذ تبني $100\gamma\%$ فترة ثقة للنسبة $\theta_2^{(1)^2} / \theta_2^{(2)^2}$ بشكل مشابه لبناء $100\gamma\%$ فترة الثقة (16.4.7) الواردة في الفقرة (3.4.7) وتأخذ الشكل:

$$\left(\frac{m(n-1)S^2(X)}{n(m-1)S^2(Y)} / F_{\alpha/2, m-1, n-1}, \frac{m(n-1)S^2(X)}{n(m-1)S^2(Y)} / F_{1-\alpha/2, m-1, n-1} \right) \quad (21.4.7)$$

حيث إن القيمة الحرجة لتوزيع F الموافقة لاحتمال p و
 $\gamma_1 = m - 1$, $\gamma_2 = n - 1$ درجة حرية [الملحق جدول رقم 12].

فمثلاً، من أجل عينتان بحجم $m = n = 9$ و $S(x) = 10$, $S(y) = 8$ ، فإن 0.90
 فترة ثقة لـ $\theta_2^{(1)^2} / \theta_2^{(2)^2}$ هي:

$$(0.454, 5.375)$$

ومن أجل $n = m = 13$:

$$(0.578, 4.203)$$

حيث إن:

$$F_{0.95, 8, 8} = F_{0.05, 8, 8}^{-1} = 3.44 \quad , \quad F_{0.95, 12, 12} = F_{0.05, 12, 12}^{-1} = 0.69$$

5.7 طرق إيجاد كمية محورية

METHODS OF FINDING PIVOTAL QUANTITY

نلاحظ من خلال الأمثلة السابقة أن الخطوة الأساسية في مسألة بناء فترة ثقة
 لمعلمة θ (أو دالة $\tau(\theta)$) بإتباع طريقة الكمية المحورية تتمثل في إيجاد الدالة
 $Q(X; \theta)$. وإيجاد هذه الدالة يعتمد على خصوصية النموذج المفروض $f(x; \theta)$.
 وفي حالات عدة لا توجد مثل هذه الدالة أو من الصعوبة بمكان إيجادها، لكن
 يمكن تمييز مجموعة من النماذج المستمرة $F(x; \theta)$ ، التي توجد من أجلها دائماً
 كمية محورية لها شكل بسيط، وخاصة إذا كانت دالة التوزيع $F(x; \theta)$ مستمرة
 ومضطردة تماماً بالنسبة لـ θ من أجل كل نقطة في فضاء x ، فإن:

$$Q(X; \theta) = -2 \sum_{i=1}^n \ln F(X_i; \theta) \quad (1.5.7)$$

تعتبر كمية محورية، وهذا ما تؤكد المبرهنة الآتية.

مبرهنة 1.5.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر $F(x; \theta)$ ، وكانت دالة التوزيع $F(x; \theta)$ مستمرة ومضطردة تماماً (متزايدة تماماً أو متناقصة تماماً) في θ من أجل كل نقطة في فضاء x ، فتوجد كمية محورية لـ θ تعطى بالعلاقة

$$Q(X; \theta) = -2 \sum_{i=1}^n \ln F(X_i; \theta)$$

وتخضع لتوزيع $\chi^2_{(2n)}$.

الإثبات

نلاحظ بسهولة أن الدالة $Q(X; \theta)$ مستمرة ومضطردة تماماً في θ من أجل كل $x \in G$ ، لأن $F(X_i; \theta)$ دالة مستمرة ومضطردة تماماً في θ من أجل كل نقطة في فضاء x (حسب الفرض).

وكما نعلم أن المتغيرات العشوائية $X_i; \theta$ ؛ $i = \overline{1, n}$ مستقلة، ولكل منها توزيع منتظم $R(0,1)$ ، أي أن:

$$L_0(F(X_i; \theta)) = R(0,1) \quad ; \quad \theta \in \theta$$

ومن ثم $-\ln F(X_i; \theta)$ متغيرات عشوائية مستقلة ولكل منها توزيع جاما $\Gamma(1,1)$. وبناءً على ذلك وخواص توزيع جاما فإن المتغير العشوائي $-\sum \ln F(X_i; \theta)$ يتبع توزيع جاما $\Gamma(n,1)$ ، وبالتالي:

$$Q(X; \theta) = -2 \sum_{i=1}^n \ln F(X_i; \theta)$$

تتبع توزيع $\chi^2_{(2n)}$ ، وهذا الأخير لا يعتمد على θ . إذن $Q(X;\theta)$ كمية محورية لـ θ .
 يمكننا باستخدام الكمية المحورية (1.5.7) بناء فترة ثقة لـ θ على النحو
 الآتي:

نختار، عند درجة ثقة معينة γ ، عددين $q_1 < q_2$ يحققان العلاقة:

$$\int_{q_1}^{q_2} f_Q(q) dq = \frac{1}{2^n \Gamma(n)} \int_{q_1}^{q_2} q^{n-1} e^{-q/2} dq = \gamma \quad (2.5.7)$$


وبحل المعادلتين:

$$-2 \sum_{i=1}^n \ln F(x_i; \theta) = q_1 \quad (3.5.7)$$

$$-2 \sum_{i=1}^n \ln F(x_i; \theta) = q_2$$

بالنسبة لـ θ ، نحصل على العددين $T_1(x) < T_2(x)$. وبالتالي $(T_1(X), T_2(X))$ تكون
 فترة الثقة المطلوبة للمعلمة θ .

نلاحظ بوضوح أن الصعوبة الأساسية في تطبيق هذه الطريقة على مسألة معينة تكمن
 في إيجاد حلي المعادلتين (3.5.7)، أي في الحصول على $T_1(x), T_2(x)$. فمثلاً، إذا كانت
 $Q(X;\theta)$ متزايدة تماماً في θ ، فالشكل (1.5.7) يبين فترة الثقة $(T_1(x), T_2(x))$.



شكل (1.5.7)

مثال 1.5.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع منتظم $R(0, \theta)$ ، فأوجد $100\gamma\%$ فترة ثقة للمعلمة θ .
عما أن:

$$F(x; \theta) = \frac{x}{\theta} \quad ; \quad 0 \leq x \leq \theta, \quad \theta > 0$$

دالة مستمرة ومتناقصة تماماً في θ ، فحسب المبرهنة (1.5.7):

$$Q(X; \theta) = -2 \sum_1^n \ln F(X_i; \theta) = -2 \sum_1^n \ln X_i + 2n \ln \theta$$

كمية محورية للمعلمة θ تخضع لتوزيع $\chi_{(2n)}^2$ ، أي أن كثافة توزيعها:

$$f_Q(q) = \frac{1}{2^n \Gamma(n)} q^{n-1} e^{-q/2} \quad ; \quad q > 0$$

وباختيار عددين $q_1 < q_2$ يحققان العلاقة (2.5.7)، بإتباع طريقة التجربة والخطأ، وعادة يتم اختيار q_1, q_2 بحيث تكون هنالك احتمالات متساوية على ذيلي توزيع $\chi_{(2n)}^2$ ، أي يتم اختيار:

$$q_1 = \chi_{1-\alpha/2, 2n}^2, \quad q_2 = \chi_{\alpha/2, 2n}^2 \quad ; \quad \gamma = 1 - \alpha$$

ومن ثم بحل المعادلتين:

$$-2 \sum_1^n \ln x_i + 2 \ln \theta = q_1$$

$$-2 \sum_1^n \ln x_i + 2 \ln \theta = q_2$$

بالنسبة ل θ نجد:

$$T_1(x) = e^{q_1/2n} \left(\prod_1^n x_i \right)^{1/n}$$

$$T_2(x) = e^{q_2/2n} \left(\prod_1^n x_i \right)^{1/n}$$

وبالتالي $100\gamma\%$ فترة ثقة للمعلمة θ عبارة عن أي فترة من الشكل:

$$(T_1(\mathbf{X}), T_2(\mathbf{X}))$$

حيث أن:

$$T_j(\mathbf{X}) = e^{q_j/2n} \left(\prod_{i=1}^n X_i \right)^{1/n} ; \quad j = 1, 2$$

يمكن، في هذه المسألة، أخذ كمية محورية أخرى وهي:

$$Q(\mathbf{X}; \theta) = (X_{(n)} / \theta)^n$$

تتبع التوزيع المنتظم $R(0,1)$ ، وعندئذٍ $100\gamma\%$ فترة ثقة لـ θ تأخذ الشكل:

$$(X_{(n)} / q^{1/n}, X_{(n)} / (q - \gamma)^{1/n})$$

حيث أن $0 < \gamma \leq q \leq 1$. ومن الواضح أن أصغر $100\gamma\%$ فترة ثقة لـ θ توافق $q = 1$:

$$(X_{(n)}, X_{(n)} / \alpha^{1/n}) ; \quad \gamma = 1 - \alpha$$

مثال 2.5.7

إذا كانت $\mathbf{X} = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع كثافة توزيعه:

$$f(x; \theta) = \theta x^{\theta-1} ; \quad 0 < x < 1, \theta > 0$$

فأوجد $100\gamma\%$ فترة ثقة للمعلمة θ .

بما أن:

$$F(x; \theta) = \theta \int_0^x x^{\theta-1} dx = x^\theta$$

وهي دالة مستمرة ومنتزعة تماماً في θ مهما تكن $0 < x < 1$ ، فحسب المبرهنة

(1.5.7) توجد كمية محورية لـ θ تعطى بالعلاقة (1.5.7):

$$Q(X; \theta) = -2 \sum_1^n \ln F(X_i; \theta) = -2\theta \sum_1^n \ln X_i$$

وتوزيعها:

$$L_\theta(Q) = \chi_{(2n)}^2 \quad ; \quad \theta \in \theta$$

وباختيار عددين q_1, q_2 يحققان العلاقة:

$$P_\theta \left(q_1 < -2\theta \sum_1^n \ln X_i < q_2 \right) = \gamma$$

من أجل قيمة معطاة γ ، وبجمل المعادلتين:

$$-2\theta \sum_1^n \ln x_i = q_1$$

$$-2\theta \sum_1^n \ln x_i = q_2$$

بالنسبة لـ θ عند عينة مشاهدة $x = (x_1, \dots, x_n)$ نجد:

$$T_1(x) = \frac{q_2}{2 \sum_1^n \ln x_i} \quad , \quad T_2(x) = \frac{-q_1}{2 \sum_1^n \ln x_i}$$

وبالتالي $100\gamma\%$ فترة ثقة للمعلمة θ هي من الشكل:

$$\Delta_\gamma = \left(-q_2 / 2 \sum_1^n \ln X_i \quad , \quad -q_1 / 2 \sum_1^n \ln X_i \right)$$

وأن طول هذه الفترة:

$$L_\gamma = (q_2 - q_1) \frac{1}{2 \sum_1^n \ln X_i}$$

والقيمة المتوقعة لهذه الفترة:

$$E_{\theta}(L_T) = (q_2 - q_1)E\left(1/2 \sum_1^n \ln X_i\right)$$

وعادةً، كما أشرنا سابقاً، نختار:

$$q_1 = \chi_{1-\alpha/2, 2n}^2 \quad , \quad q_2 = q_1 = \chi_{\alpha/2, 2n}^2$$

نلاحظ من تعريف الكمية المحورية أنها تعتمد على المعلمة المراد تقديرها بالإضافة إلى العينة X ، ومن ثم فهي تعتمد على إحصاء من خلال اعتمادها على العينة X . ويفضل أن يكون هذا الإحصاء كافياً (إن وجد) للمعلمة المطلوب إيجاد فترة ثقة لها. وإذا رمزنا بـ C لإحصاء كافي للمعلمة θ ، فيمكن كتابة الكمية المحورية Q على الصورة:

$$Q(X; \theta) = Q(C, \theta)$$

وعندئذٍ الملاحظتان التاليتان تساعدان، في حالات عدة، في إيجاد كمية محورية للمعلمة θ المراد تقديرها.

1. إذا كانت θ معلمة موضع (location parameter)، أي إذا كان التوزيع الاحتمالي للمجتمع الذي سحبت منه العينة العشوائية $X = (X_1, \dots, X_n)$ يمكن كتابته على الصورة:

$$f(x; \theta) = f(x - \theta)$$

فنبحث عن Q كدالة في $(C - \theta)$ ، أي من الشكل:

$$Q(X; \theta) = Q(C - \theta)$$

2. إذا كانت θ معلمة مقياس (scale parameter)، أي إذا كان التوزيع الاحتمالي للمجتمع الذي سحبت منه العينة $X = (X_1, \dots, X_n)$ يمكن كتابته على الصورة:

$$f(x; \theta) = f\left(\frac{x}{\theta}\right)$$

فنبحث عن Q كدالة في $\frac{C}{\theta}$ ، أي من الشكل:

$$Q(X; \theta) = Q\left(\frac{C}{\theta}\right)$$

لنوضح كيفية الاستفادة من تلك الملاحظتين للحصول على كمية محورية $Q(X; \theta)$ مفيدة لبناء فترة ثقة لمعلمة θ من خلال الأمثلة الآتية.

مثال 3.5.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

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

فأوجد $100\gamma\%$ فترة ثقة لـ θ .

بما أن θ معلمة موضع و $C = X_{(n)}$ إحصاء كافي لها، فنأخذ:

$$Q(X; \theta) = n(C - \theta)$$

وهي دالة مستمرة ومتناقضة تماماً في θ مهما تكن $x \in G$.

كما نعلم [راجع العلاقة (3.10.3)] أن توزيع $C = X_{(n)}$ هو:

$$h(c; \theta) = ne^{-n(c-\theta)} \quad ; \quad c > \theta$$

ومن ثم توزيع Q هو:

$$f_Q(q) = e^{-q} \quad ; \quad q > 0$$

ولا يعتمد على θ . إذن فإن $Q(X; \theta) = n(C - \theta)$ كمية محورية للمعلمة θ ويمكن الاستفادة منها لبناء $100\gamma\%$ فترة ثقة لـ θ على النحو الآتي:

نختار عددين $q_1 < q_2$ ، عند قيمة معينة معطاة γ ، بحيث يحققان العلاقة:

$$P(q_1 < Q(X; \theta) < q_2) = \int_{q_1}^{q_2} e^{-q} dq = e^{-q_1} - e^{-q_2} = \gamma \quad \dots (1)$$

وبحل المعادلتين بالنسبة لـ θ :

$$n(c - \theta) = q_1 \quad , \quad n(c - \theta) = q_2$$

عند عينة مشاهدة $x = (x_1, \dots, x_n)$ نحصل على العددين:


$$\theta_1 = T_1(x) = c - \frac{q_2}{n} \quad , \quad \theta_2 = T_2(x) = c - \frac{q_1}{n}$$

بحققان العلاقة:


$$P(T_1(x) < \theta < T_2(x)) = \gamma$$

ومن ثم فإن $100\gamma\%$ فترة ثقة للمعلمة θ هي من الشكل:

$$\left(C - \frac{q_2}{n} , C - \frac{q_1}{n} \right)$$



شكل (3.5.7)



شكل (2.5.7)

وطول هذه الفترة:

$$L_\gamma = \frac{1}{n}(q_2 - q_1) \quad \dots (2)$$

وأصغر قيمة له توافق $q_1 = 0$. ويمكن إثبات ذلك جبرياً كالاتي:

باشتقاق العلاقة (1) بالنسبة لـ q_1 نجد:

$$-e^{-q_1} + e^{-q_2} \frac{dq_2}{dq_1} = 0 \Rightarrow \frac{dq_2}{dq_1} = e^{q_2 - q_1} \dots (3)$$

وباشتقاق العلاقة (2) بالنسبة لـ q_1 والاستفادة من (1) و (3) نجد:

$$\begin{aligned} \frac{\partial L_\gamma}{\partial q_1} &= \frac{1}{n} \left(\frac{dq_2}{dq_1} - 1 \right) = \frac{1}{n} (e^{q_2 - q_1} - 1) \\ &= \frac{1}{n} [e^{q_2} (\gamma + e^{-q_2}) - 1] = \frac{\gamma}{n} e^{q_2} > 0 \end{aligned}$$

وهذا يعني أن L_γ دالة متزايدة في q_1 ، ومن ثم فأقل قيمة لها عندما $q_1 = 0$ (لأن $q > 0$)، وبوضع $q_1 = 0$ في العلاقة (1) نجد:

$$1 - e^{-q_2} = \gamma \Rightarrow q_2 = -\ln(1 - \gamma) = -\ln\alpha \quad ; \quad \alpha = 1 - \gamma$$

وبالتالي تكون $100\gamma\%$ فترة الثقة المطلوبة (أصغر فترة ثقة) للمعلمة θ هي:

$$\left(C + \frac{\ln\alpha}{n}, C \right)$$

وأن طولها:

$$L_\gamma = -\frac{\ln\alpha}{n}$$

وكذلك اتبعنا نفس الأسلوب في إيجاد كمية محورية لبناء $100\gamma\%$ فترة ثقة للمعلمة θ في النموذج الطبيعي I (بند 1.4.7)، حيث أن θ معلمة موضع.

مثال 4.5.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \frac{1}{\theta} \quad ; \quad 0 < x < \theta$$

فأوجد $100\gamma\%$ فترة ثقة للمعلمة θ .

بما أن θ معلمة مقياس و $C = X_{(n)}$ إحصاء كافي لها، لذلك نبحث عن كمية محورية كدالة في $\frac{C}{\theta}$ ولناخذ:

$$Q(X;\theta) = \frac{C}{\theta} \quad ; \quad \theta > 0$$

وهي دالة مستمرة ومتناقصة تماماً في θ من أجل كل $x \in G$. ويمكن معرفة توزيعها بسهولة على النحو الآتي:

بما أن توزيع $C = X_{(n)}$ [راجع العلاقة (13.3)] هو:

$$h(c;\theta) = \frac{nc^{n-1}}{\theta^n} \quad ; \quad 0 < c < \theta$$

فإن توزيع Q :

$$f_Q(q) = nq^{n-1} \quad ; \quad 0 < q < 1$$

وهو لا يعتمد على θ ، إذن Q كمية محورية:

لبناء $100\gamma\%$ فترة ثقة لـ θ باستخدام الكمية المحورية Q نتبع ما يلي:

نختار عددين $q_1 < q_2$ بحيث أن:

$$P(q_1 < Q < q_2) = \int_{q_1}^{q_2} f_Q(q) dq = n \int_{q_1}^{q_2} q^{n-1} dq = q_2^n - q_1^n = \gamma \quad \dots (1)$$

وبحل المعادلتين بالنسبة لـ θ :


$$\frac{c}{\theta} = q_1 \quad , \quad \frac{c}{\theta} = q_2$$

عند عينة مشاهدة $x = (x_1, \dots, x_n)$ ، نجد:


$$T_1(x) = \theta_1 = \frac{c}{q_2} \quad , \quad T_2(x) = \theta_2 = \frac{c}{q_1}$$

أي أن 100% فترة ثقة لـ θ هي من الشكل:

$$\Delta_\gamma = \left(\frac{C}{q_2}, \frac{C}{q_1} \right)$$



شكل (5.5.7)



شكل (4.5.7)

وطول الفترة:

$$L_\gamma = C \left(\frac{1}{q_1} - \frac{1}{q_2} \right) \quad \dots (2)$$

وأن أقصر فترة توافق $q_2 = 1$ ، ويمكن إثبات ذلك كالاتي:

نشتق (1) بالنسبة لـ q_2 :

$$nq_2^{n-1} - nq_1^{n-1} \frac{dq_1}{dq_2} = 0 \Rightarrow \frac{dq_1}{dq_2} - \left(\frac{q_2}{q_1} \right)^{n-1} \quad \dots (3)$$

وباشتقاق (1) بالنسبة لـ q_2 والاستفادة من (3) نجد:

$$\begin{aligned} \frac{\partial L_\gamma}{\partial q_2} &= C \left(-\frac{1}{q_1^2} \frac{dq_1}{dq_2} + \frac{1}{q_2^2} \right) \\ &= C \left[-\frac{1}{q_1^2} \left(\frac{q_2}{q_1} \right)^{n-1} + \frac{1}{q_2^2} \right] = -C \left(\frac{q_2^{n+1} - q_1^{n+1}}{q_2^2 q_1^{n+1}} \right) < 0. \end{aligned}$$

وهذا يعني أن L_γ دالة متناقصة في q_2 وتكون أقل قيمة لها عندما تكون q_2 أكبر ما يمكن أي $q_2 = 1$ (لأن $0 < q < 1$). ومن ثم بالتعويض في (1) نجد:

$$1 - q_1^n = \gamma \Rightarrow q_1 = \sqrt[n]{1 - \gamma} = \alpha^{1/n} \quad ; \quad \gamma = 1 - \alpha$$

وتكون $100\gamma\%$ فترة الثقة المطلوبة لـ θ هي من الشكل:

$$(C, C\alpha^{-1/n})$$

وأتبعنا نفس الأسلوب عند بناء فترة الثقة للمعلمة θ^2 في توزيع $N(\mu, \theta^2)$ الوارد في الفقرة (2.4.7)، حيث θ^2 معلمة مقياس.

STATISTICAL METHOD

6.7 طريقة الإحصاء

إن طريقة الكمية المحورية لبناء فترة ثقة للمعلمة وحيدة البعد θ قابلة للتطبيق في حالات عدة، وغير ممكنة في حالات أخرى ومنها حالة توزيع منقطع، وذلك إما لعدم إمكانية إيجاد مثل هذه الكمية أو لصعوبة بناء فترة الثقة بهذه الطريقة والمتمثلة بتعيين حدي الثقة. وعندئذ يمكن استخدام طريقة أخرى تعتمد على إحصاء ما $T = T(X)$ لبناء فترة ثقة لـ θ ، لذا تسمى هذه الطريقة بـ "طريقة الإحصاء".

نفترض كالعادة لدينا عينة عشوائية $X = (X_1, \dots, X_n)$ من توزيع $f(x; \theta)$ يعتمد على معلمة وحيدة البعد. ونرغب في بناء فترة ثقة للمعلمة θ . نختار إحصاء ما $T = T(X)$ ، وهذا ممكن بطرق مختلفة. فمثلاً، إذا وجد إحصاء كافي للمعلمة

θ ، فيؤخذ T إحصاء كافي، أو إذا لم يوجد إحصاء كافي لـ θ فيؤخذ T مقدر نقطي لها، ومن الممكن أن يكون مقدر المعقولة العظمى. ويتم اختيار T عملياً بحيث تكون العمليات التي نحتاجها لبناء فترة الثقة لـ θ ممكنة وسهلة قدر الإمكان، ومنها سهولة معرفة توزيعه الاحتمالي $F_T(t; \theta)$.

سوف نوضح هذه الطريقة في الفقرتين الآتيتين باعتبار T متغير مستمر ومن ثم باعتبار T متغير منقطع.

1.6.7 حالة T متغير مستمر

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع مستمر $F(x; \theta)$ يعتمد على معلمة وحيدة البعد θ . إذا كان $T = T(X)$ إحصاء ما مستمر دالة توزيعه معلومة $F_T(t; \theta)$ ، مستمرة ومضطردة تماماً في θ ، فيمكن بناء فترة ثقة للمعلمة θ بناءً على هذا الإحصاء.

نعرف عند كل $\theta \in \Theta$ عددين $t_i = \tau_i(\theta)$ ؛ $i = 1, 2$ بحيث $t_1 < t_2$ ويحققان العلاقة:

$$P_\theta(t_1 < T(X) < t_2) = F_T(t_2; \theta) - F_T(t_1; \theta) = \gamma \quad (1.6.7)$$


أو:

$$F_T(t_1; \theta) = \alpha_1 \quad , \quad F_T(t_2; \theta) = 1 - \alpha_2 \quad ; \quad \alpha_1 + \alpha_2 = \alpha \quad , \quad \gamma = 1 - \alpha \quad (2.6.7)$$


ويتم عادة اختيار هذين العددين بحيث يحققان:

$$F_T(t_1; \theta) = \alpha/2 \quad ; \quad F_T(t_2; \theta) = 1 - \alpha/2 \quad (3.6.7)$$

أي يتم البحث عن فترة ثقة ذات ذيلين متساوي الاحتمال. ويمكن إيضاح الحالتين على الشكلين (1.6.7) و (2.6.7).



شكل (2.6.7)




شكل (1.6.7)

لنعرف الفئة الجزئية D_γ من $\theta \times \mathcal{T}$ حيث \mathcal{T} فضاء القيم الممكنة للإحصاء T ، على النحو الآتي:

$$D_\gamma = \{(\theta, t) ; t_1(\theta) < t < t_2(\theta)\} \quad (4.6.7)$$

ويمكن تمثيلها بيانياً بافتراض $t_1(\theta), t_2(\theta)$ متزايدتان تماماً في θ كما هو مبين بالمنطقة المظلمة على الشكل (3.6.7).



شكل (3.6.7)

عندئذٍ، حسب العلاقة (1.6.7)، فإن:

$$P_{\theta}((\theta, T(X)) \in D_{\gamma}) = \gamma ; \theta \in \Theta$$

وعند قيمة معينة $t' \in \mathcal{I}$ ، فإن:


$$D_{\gamma}(t') = \{\theta : (\theta, t') \in D_{\gamma}\}$$

أنظر شكل (3.6.7).

لنرى الآن الفئة العشوائية $\theta \in D_{\gamma}(T(X))$. يقع الحادث $\theta \in D_{\gamma}(T(X))$ فقط عندما $T(X) \in (t_1(\theta), t_2(\theta))$ ، وبالتالي، عند كل قيمة لـ θ ، فاحتماله يساوي γ ، أي أن:

$$P_{\theta}(\theta \in D_{\gamma}(T(X))) = \gamma ; \theta \in \Theta$$

وبالتالي، تم تعيين فئة عشوائية $D_{\gamma}(T(X))$ تشتمل على القيمة الحقيقية للمعلمة θ باحتمال يساوي γ . وإذا كانت هذه الفئة تمثل فترة، نكون قد توصلنا إلى بناء $100\gamma\%$ فترة ثقة للمعلمة θ ، وهي محققة، إذا كانت الدالتان $t_i(\theta)$ ؛ $i = 1, 2$ من نفس النوع (متزايدتان تماماً أو متناقصتان تماماً في θ). وهذا صحيح دوماً لكون الدالة $F_T(t; \theta)$ مستمرة ومضطردة تماماً بالنسبة لـ θ (حسب الفرض). ويبدو ذلك بوضوح على الشكل (4.6.7) في حالة دالة متناقصة تماماً في θ .



شكل (4.6.7)

هكذا، حسب الفروض المقدمة تمثل الفئة $D_Y(t)$ ، عند كل قيمة t لـ $T(X)$ ، فترة حدها $\theta_1(t) < \theta_2(t)$ ، وبالتالي 100% فترة ثقة للمعلمة θ هي $(T_1(X), T_2(X))$ ، حيث أن $T_i(X) = \theta_i(T(X))$ ؛ $i = 1, 2$.

يعطي التمثيل البياني المدلول الواضح لهذه الطريقة، فالرسم المبني وفق الخط الرأسي (من أجل أي قيمة $\theta' \in \theta$) نحدد من الشرط (3.6.7) القيمتين المناظرتين لها $(t_1(\theta'), t_2(\theta'))$. وبشكل مشابه الرسم البياني وفق الخط الأفقي من أجل أي قيمة ملاحظة $t' = T(x)$ قيمة ملاحظة للعينة X نحصل على القيمتين المناظرتين لها $\theta_1(t'), \theta_2(t')$ ، بحيث أن $\theta \in (\theta_1, \theta_2)$. هكذا، إذا اعتبرنا الرسم وفق الخط الرأسي، فحدي المنطقة D_Y يوصفان بالنقطتين المتغيرتين $(\theta, t_1), (\theta, t_2)$ بحيث يحققان الشرط (3.6.7). أما إذا كان الرسم وفق الخط الأفقي، فحدي المنطقة D_Y يمكن وصفهما بشكل مكافئ بالنقطتين المتغيرتين $(t, \theta_1), (t, \theta_2)$ بأخذ القيمة الملاحظة t للإحصاء $T(X)$ كمتغير مستقل. عندئذ يمكن إعادة صياغة العلاقة (3.6.7) على النحو الآتي:

1. إذا كانت الدالتان $t_i(\theta)$ ؛ $i = 1, 2$ متزايدتان تماماً في θ [شكل (3.6.7)] ويقابل ذلك تناقص الدالة $F_T(t; \theta)$ بالنسبة لـ θ ، فإن:

$$F_T(t; \theta_1) = 1 - \alpha_2 \quad , \quad F_T(t; \theta_2) = \alpha_1 \quad (5.6.7)$$

وعندما $\alpha_1 = \alpha_2 = \alpha/2$


$$F_T(t; \theta_1) = 1 - \alpha/2 \quad , \quad F_T(t; \theta_2) = \alpha/2 \quad (6.6.7)$$

2. إذا كانت الدالتان $t_i(\theta)$ ؛ $i = 1, 2$ متناقصتان تماماً في θ [شكل (5.6.7)]، ويقابل ذلك تزايد الدالة $F_T(t; \theta)$ بالنسبة لـ θ ، فإن:

$$F_T(t; \theta_1) = \alpha_1 \quad , \quad F_T(t; \theta_2) = 1 - \alpha_2 \quad (7.6.7)$$

وعندما $\alpha_1 = \alpha_2 = \alpha/2$

$$F_T(t; \theta_1) = \alpha/2 \quad , \quad F_T(t; \theta_2) = 1 - \alpha/2 \quad (8.6.7)$$



شكل (5.6.7)

هكذا، خوارزمية بناء $100\gamma\%$ فترة ثقة للمعلمة θ ، في حالة دالة التوزيع $F_T(t; \theta)$ للإحصاء T مستمرة ومضطردة تماماً بالنسبة لـ θ ، يمكن إنجازها كالآتي:

لتكن $t = T(x)$ قيمة ملاحظة للإحصاء $T = T(X)$ ، بحل المعادلتين:

$$F_T(t, \theta) = \alpha/2 \quad , \quad F_T(t, \theta) = 1 - \alpha/2 \quad ; \quad \gamma = 1 - \alpha$$

بالنسبة لـ θ ، نحصل على عددين $\theta_1 < \theta_2$ ، حيث تشتمل الفترة (θ_1, θ_2) على القيمة الحقيقية للمعلمة θ باحتمال يساوي γ . وإذا كانت γ قريبة من الواحد (أو $\alpha = 1 - \gamma$ قريبة من الصفر)، فاحتمال الخطأ في تطبيق هذه القاعدة يكون صغيراً ويساوي α ، أي نحصل بالنتيجة على $100\gamma\%$ فترة ثقة للمعلمة θ وهي من الشكل:

$$(T_1(X), T_2(X)) \quad ; \quad T_i(X) = \theta_i(T(X)) \quad ; \quad i = 1, 2$$

لنوضح ما سبق من خلال الأمثلة الآتية:

مثال 1.6.7

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \sigma^2)$ ، ونريد بناء $100\gamma\%$ فترة ثقة للمعلمة θ .

كما نعلم $T = T(X) = \bar{X}$ إحصاء كافي وفي نفس الوقت مقدر المعقولة العظمى لـ θ ، وتوزيعه:

$$\mathcal{L}_\theta(\bar{X}) = N\left(\theta, \frac{\sigma^2}{n}\right)$$

أي أن:

$$F_T(\bar{x}; \theta) = \Phi\left(\frac{\bar{x} - \theta}{\sigma/\sqrt{n}}\right)$$

وهذه دالة مستمرة ومضطردة في θ ، وبالتالي:

$$F_T(t_1(\theta); \theta) = \Phi\left(\frac{t_1(\theta) - \theta}{\sigma/\sqrt{n}}\right) = \alpha_1$$

ومن جدول التوزيع الطبيعي [الملحق جدول رقم 9] نجد:


$$\frac{t_1(\theta) - \theta}{\sigma/\sqrt{n}} = Z_{\alpha_1} \Rightarrow t_1(\theta) = \theta + \frac{\sigma}{\sqrt{n}} Z_{\alpha_1} \quad \dots(1)$$

وبالمثل:

$$F_T(t_2(\theta); \theta) = \Phi\left(\frac{t_2(\theta) - \theta}{\sigma/\sqrt{n}}\right) = 1 - \alpha_2$$

$$\frac{t_2(\theta) - \theta}{\sigma/\sqrt{n}} = Z_{\alpha_2} \Rightarrow t_2(\theta) = \theta + \frac{\sigma}{\sqrt{n}} Z_{\alpha_2} \quad \dots(2)$$

يمكن تمثيل (1) و (2) بيانياً كما في الشكل (6.6.7).



شكل (6.6.7)

نلاحظ أن $t_i(\theta)$; $i = 1, 2$ دالتان متزايدتان تماماً في θ . وعلى ذلك فإن:

$$\bar{x} = \theta_1 + \frac{\sigma}{\sqrt{n}} Z_{1-\alpha_2} \Rightarrow \theta_1 = \bar{x} - \frac{\sigma}{\sqrt{n}} Z_{1-\alpha_2}$$

$$\bar{x} = \theta_2 + \frac{\sigma}{\sqrt{n}} Z_{\alpha_1} \Rightarrow \theta_2 = \bar{x} - \frac{\sigma}{\sqrt{n}} Z_{\alpha_1}$$

ويمكن الحصول على θ_1, θ_2 بطريقة أخرى على النحو الآتي:

بما أن $t_i(\theta)$; $i = 1, 2$ دالتان متزايدتان تماماً في θ و $F_T(t; \theta)$ دالة متناقصة

في θ ، فنحصل على θ_1 من حل المعادلة بالنسبة لـ θ_1 :

$$F_T(\bar{x}; \theta_1) = \Phi\left(\frac{\bar{x} - \theta_1}{\sigma/\sqrt{n}}\right) = 1 - \alpha_2$$

$$\frac{\bar{x} - \theta_1}{\sigma/\sqrt{n}} = Z_{1-\alpha_2} \Rightarrow \theta_1 = \bar{x} - \frac{\sigma}{\sqrt{n}} Z_{1-\alpha_2}$$

ونحصل على θ_2 بحل المعادلة بالنسبة لـ θ_2 :

$$F_T(\bar{x}; \theta_2) = \phi\left(\frac{\bar{x} - \theta_2}{\sigma/\sqrt{n}}\right) = \alpha_1$$

$$\frac{\bar{x} - \theta_2}{\sigma/\sqrt{n}} = Z_{\alpha_1} \Rightarrow \theta_1 = \bar{x} - \frac{\sigma}{\sqrt{n}} Z_{\alpha_1}$$

وتكون $\left(\bar{x} - \frac{\sigma}{\sqrt{n}} Z_{1-\alpha_2}, \bar{x} - \frac{\sigma}{\sqrt{n}} Z_{\alpha_1}\right)$ هي فترة ثقة للمعلمة θ

حيث أن $\gamma = 1 - (\alpha_1 + \alpha_2) = 1 - \alpha$

إذا أخذنا $\alpha_1 = \alpha_2 = \alpha/2$ فنحصل على فترة ثقة للمعلمة θ ذات

ذيلين متساويي الاحتمال:

$$\left(\bar{x} - \frac{\sigma}{\sqrt{n}} Z_{\alpha/2}, \bar{x} + \frac{\sigma}{\sqrt{n}} Z_{\alpha/2}\right)$$

وهي نفس فترة الثقة التي حصلنا عليها في الفقرة (1.4.7) علاقة (4.4.7).

مثال 2.6.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع منتظم $R(0, \theta)$

فأوجد فترة ثقة للمعلمة θ .

نعلم أن $T = T(X) = X_{(n)}$ إحصاء كافي للمعلمة θ وأن توزيعه:

$$f_T(t; \theta) = \frac{nt^{n-1}}{\theta^n} \quad ; \quad 0 \leq t \leq \theta$$

ومن ثم دالة توزيعه:

$$F_T(t; \theta) = \int_0^t \frac{nt^{n-1}}{\theta^n} dt = \left(\frac{t}{\theta}\right)^n \quad ; \quad 0 \leq t \leq \theta$$

بجمل المعادلتين:


$$F_T(t_1(\theta), \theta) = \left(\frac{t_1(\theta)}{\theta} \right)^n = \alpha_1$$

$$F_T(t_2(\theta), \theta) = \left(\frac{t_2(\theta)}{\theta} \right)^n = 1 - \alpha_2 \quad ; \quad \gamma = 1 - \alpha \quad , \quad \alpha = \alpha_1 + \alpha_2$$

بالنسبة لـ t_2 و t_1 نجد:

$$t_1(\theta) = \theta \alpha_1^{1/n} \quad , \quad t_2(\theta) = \theta (1 - \alpha_2)^{1/n}$$

ويمكن تمثيلهما بيانياً كما هو مبين على الشكل (7.6.7):



شكل (7.5.7)

وبما أن دالة التوزيع $F_T(t; \theta)$ مستمرة ومتناقصة تماماً في θ ، فنحصل على حدي الثقة $\theta_1 < \theta_2$ بحل المعادلتين، عند قيمة ملاحظة $t = x_{(n)}$ لـ $T = X_{(n)}$:

$$F_T(x_{(n)}; \theta_1) = \left(\frac{x_{(n)}}{\theta_1} \right)^n = 1 - \alpha_2$$

$$F_T(x_{(n)}; \theta_2) = \left(\frac{x_{(n)}}{\theta_2} \right)^n = \alpha_1$$

بالنسبة لـ θ_2 و θ_1 نجد:

$$T_1(x) = \theta_1 = x_{(n)}(1 - \alpha_2)^{-1/n} \quad , \quad T_2(x) = \theta_2 = x_{(n)}\alpha_1^{-1/n}$$

وتكون:

$$\Delta_\gamma(X) = (T_1(X), T_2(X)) = (X_{(n)}(1 - \alpha_2)^{-1/n}, X_{(n)}\alpha_1^{-1/n})$$

هي %100 فترة ثقة للمعلمة θ . وطول هذه الفترة هو:

$$L_\gamma = X_{(n)} \left(\frac{1}{\sqrt[n]{\alpha_1}} - \frac{1}{\sqrt[n]{1 - \alpha_2}} \right)$$

وتكون هذه الفترة أقصر ما يمكن إذا اخترنا α_1, α_2 بحيث يكون المقدار بين القوسين أقل ما يمكن، ويحدث ذلك عندما تكون $\alpha_2 = 0$, $\alpha_1 = \alpha$, وفي هذه الحالة تكون $(X_{(n)}, X_{(n)}\alpha^{-1/n})$ هي %100 فترة ثقة للمعلمة θ . وهي نفس الفترة التي حصلنا عليها باستخدام طريقة الكمية المحورية في المثال (1.5.7).

مثال 3.6.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0 \quad , \quad \theta > 0$$

أوجد %100 فترة ثقة للمعلمة θ .

نعلم أن $T = \sum_1^n X_i$ إحصاء كافي للمعلمة θ وأن توزيعه:

$$f_T(t; \theta) = \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{-\theta t} \quad ; \quad t > 0$$

[راجع مثال (1.4.4)].

ويمكن التأكد بسهولة أن المتغير العشوائي $Y = 2\theta T$ يخضع لتوزيع $\chi_{(2n)}^2$ ،

وبالتالي نحصل على $t_1(\theta)$ بحل المعادلة بالنسبة لـ t_1 :

$$F_T(t_1(\theta); \theta) = F_Y(2\theta t_1(\theta); \theta) = \alpha_1$$

ومن جدول توزيع χ^2 بـ $2n$ درجة حرية [الملحق جدول رقم 11] نجد:

$$\chi_{1-\alpha_1, 2n}^2 = 2\theta t_1(\theta) \Rightarrow t_1(\theta) = \chi_{1-\alpha_1, 2n}^2 / 2\theta$$


أما للحصول على $t_2(\theta)$ نقوم بحل المعادلة الآتية بالنسبة لـ t_2 :

$$F_T(t_2(\theta); \theta) = F_Y(2\theta t_2(\theta); \theta) = 1 - \alpha_2$$

ومن جدول χ^2 بـ $2n$ درجة حرية نجد:

$$\chi_{\alpha_2, 2n}^2 = 2\theta t_2(\theta) \Rightarrow t_2(\theta) = \chi_{\alpha_2, 2n}^2 / 2\theta$$

ويمكن تمثيلها بيانياً كما هو مبين على الشكل (8.6.7).



شكل (8.6.7)

نلاحظ من الشكل أن الدالتين $t_1(\theta), t_2(\theta)$ متناقصتان تماماً في θ ، وهو مختلف عن المثالين السابقين. وهذا يقابل تزايد دالة التوزيع $F_T(t; \theta)$ بالنسبة لـ θ ، وبالتالي نحصل على θ_1 بحل المعادلة:

$$F_T(t; \theta_1) = F_Y(2\theta_1 t; \theta_1) = \alpha_1 \Rightarrow$$

$$\chi_{1-\alpha_1, 2n}^2 = 2\theta_1 t \Rightarrow \theta_1 = \chi_{1-\alpha_1, 2n}^2 / 2t$$

وكما نحصل على θ_2 محل المعادلة:

$$F_T(t; \theta_2) = F_Y(2\theta_2 t; \theta_2) = 1 - \alpha_2 \Rightarrow$$

$$\chi_{\alpha_2, 2n}^2 = 2\theta_2 t \Rightarrow \theta_2 = \chi_{\alpha_2, 2n}^2 / 2t$$

وبذلك تكون:

$$\left(\frac{\chi_{1-\alpha_1, 2n}^2}{2\sum X_i}, \frac{\chi_{\alpha_2, 2n}^2}{2\sum X_i} \right)$$

هي 100% فترة ثقة للمعلمة θ ، وبأخذ $\alpha_1 = \alpha_2 = \alpha/2$ نحصل على:

$$\left(\frac{\chi_{1-\alpha/2}^2}{2\sum X_i}, \frac{\chi_{\alpha/2}^2}{2\sum X_i} \right)$$

نلاحظ من الأمثلة السابقة، أننا لا نحتاج عملياً لتعيين $t_1(\theta), t(\theta)$ عند بناء فترات الثقة، ومن أجل قيمة ملاحظة t لـ $T = T(X)$ ، نحتاج فقط لإيجاد $\theta_1 < \theta_2$.

2.6.7 حالة T متغير منقطع

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع منقطع $F(x; \theta)$ يعتمد على معلمة وجيدة البعد θ ، إذا كان $T = T(X)$ إحصاء ما منقطع دالة توزيعه $F_T(t; \theta)$ مستمرة ومضطربة تماماً في θ ، فيمكن بناء 100% فترة ثقة للمعلمة θ باستخدام هذا الإحصاء.

يمكن إجراء مناقشة مشابهة لحالة T متغير مستمر من أجل T متغير منقطع، والاختلاف الوحيد يتمثل بما يلي:

نتيجة لكون دالة التوزيع $F_T(t; \theta)$ درجية، فإن:

$$P_{\theta}(t_1 < T(X) < t_2) = F(t_2; \theta) - F_T(t_1 + 0; \theta)$$

حيث أن $F_T(t; \theta) = P(T < t)$. ولا يمكن دائماً، من أجل قيمة معطاة γ ، إيجاد فترة ثقة للمعلمة θ لها درجة ثقة مساوية تماماً لـ γ . لهذا يتم البحث عن فترات ثقة للمعلمة θ ذات درجة ثقة لا تقل عن القيمة المختارة γ ، أي يتم اختيار عددين $t_1 < t_2$ يحققان الشرط:

$$P_{\theta}(t_1 < T(X) < t_2) = F_T(t_2; \theta) - F_T(t_1 + 0; \theta) \geq \gamma$$

بدلاً من الشرط (1.6.7) في حالة T متغير مستمر.


ومن ثم بدلاً من الشرطين (2.6.7) نأخذ:

$$F(t_1 + 0; \theta) \leq \alpha_1 \quad , \quad F(t_2; \theta) \geq 1 - \alpha_2 \quad (10.6.7)$$

وعندما $\alpha_1 = \alpha_2 = \alpha/2$ نجد:

$$F(t_1 + 0; \theta) \leq \alpha/2 \quad , \quad F(t_2; \theta) \geq 1 - \alpha/2 \quad (11.6.7)$$

تعتبر الدالتان $t_i(\theta)$; $i = 1, 2$ ، في هذه الحالة، درجتان، ويبدو ذلك بوضوح على الشكل (9.6.7).



شكل (9.6.7)

إن خوارزمية بناء فترة ثقة للمعلمة θ بدرجة ثقة لا تقل عن γ ، في حالة نموذج منقطع، هي ذات خوارزمية بناء $100\gamma\%$ فترة ثقة للمعلمة θ في حالة النموذج المستمر، على أن نعين $\theta_1 < \theta_2$ من العلاقتين:

$$F(t+0; \theta) \leq \alpha_1 \quad , \quad F(t; \theta) \geq 1 - \alpha_2 \quad (12.6.7)$$

أو من العلاقتين:

$$F(t+0; \theta) \leq \alpha/2 \quad , \quad F(t; \theta) \geq 1 - \alpha/2 \quad (13.6.7)$$

عندما نأخذ $\alpha_1 = \alpha_2 = \alpha/2$.

مثال 4.5.7

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بيرنولي $B(1; \theta)$ ، ونريد بناء فترة ثقة للمعلمة θ .

نعلم أن $T(X) = \bar{X}$ إحصاء كافي للمعلمة θ ، والمتغير العشوائي T يفترض القيم $0, 1/n, \dots, n/n$ ويخضع لتوزيع ذي الحدين $B(n; \theta)$:

$$F_T\left(T = \frac{k}{n}; \theta\right) = \sum_{r=0}^{k-1} C_n^r \theta^r (1-\theta)^{n-r} \quad ; \quad k = 1, \dots, n$$

ومشتق هذه الدالة بالنسبة لـ θ :

$$\frac{d}{d\theta} F_T\left(\frac{k}{n}; \theta\right) = -nC_{n-1}^{k-1} \theta^{k-1} (1-\theta)^{n-k} < 0$$

وهذا يعني أن الدالة $F_T(t; \theta)$ متناقصة تماماً بالنسبة لـ θ . وبالتالي، بتطبيق الطريقة الواردة أعلاه، نحصل على عددين $\theta_1 < \theta_2$ من العلاقتين:

$$F_T\left(\frac{k}{n}; \theta_1\right) = \sum_{r=0}^{k-1} C_n^r \theta_1^r (1-\theta_1)^{n-r} \geq 1 - \alpha_2$$

$$F_T\left(\frac{k+1}{n}; \theta_2\right) = \sum_{r=0}^k C_n^r \theta_2^r (1-\theta_2)^{n-r} \leq \alpha_1 \quad ; \quad \gamma = 1 - \alpha, \alpha = \alpha_1 + \alpha_2$$

وذلك باتباع طريقة التجربة والخطأ.

فمثلاً، إذا كانت $x = (x_1, \dots, x_{20})$ عينة مشاهدة و $T(x) = \bar{x} = \frac{4}{20}$. ونريد بناء فترة ثقة بمعامل ثقة لا يقل عن 0.93.

تأخذ العلاقتان السابقتان الصورة الآتية:

$$F_T\left(\frac{4}{20}; \theta_1\right) = \sum_{r=0}^3 C_{20}^r \theta_1^r (1-\theta_1)^{20-r} \geq 1 - \alpha_2$$

$$F_T\left(\frac{5}{20}; \theta_2\right) = \sum_{r=0}^4 C_{20}^r \theta_2^r (1-\theta_2)^{20-r} \leq \alpha_1 \quad ; \quad \gamma = 1 - (\alpha_1 + \alpha_2)$$

باستخدام جدول توزيع ذي الحدين واتباع أسلوب التجربة والخطأ، نجد:

عندما: $\alpha_1' = 0.0509$, $1 - \alpha_2' = 0.9841$, $\gamma \leq 1 - \alpha_1' - \alpha_2' = 0.9332$ فإن:

$\theta_1 = 0.05$; $\theta_2 = 0.40$ ، وبالتالي 93.32% فترة ثقة للمعلمة θ هي (0.05, 0.40).

مثال 5.6.7

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بواسون $\Pi(\theta)$ ، ونريد بناء فترة ثقة للمعلمة θ بمعامل ثقة لا يقل عن γ .

كما نعلم $T = T(X) = \bar{X}$ إحصاء كافي ومقدر المعقولة العظمى لـ θ ، ويفترض القيم $\frac{k}{n}$; $k = 0, 1, \dots$

بما أن $\mathcal{L}_\theta\left(\sum_1^n X_i\right) = \Pi(n\theta)$ ، فإن:

$$F_T\left(\frac{k}{n}; \theta\right) = \sum_{r=0}^{k-1} e^{-n\theta} \frac{(n\theta)^r}{r!}$$

ومشتقه بالنسبة لـ θ :

$$\frac{d}{d\theta} F_T\left(\frac{k}{n}; \theta\right) = -ne^{-n\theta} \frac{(n\theta)^{k-1}}{(l-1)!} < 0$$

وهذا يعني أن دالة التوزيع $F_T(t; \theta)$ متناقصة تماماً في θ . وبالتالي فإن فترة الثقة بدرجة ثقة لا تقل عن γ هي (θ_1, θ_2) ، حيث θ_1, θ_2 يعينان من العلاقتين:

$$F_T\left(\frac{k}{n}; \theta_1\right) = \sum_{r=0}^{k-1} e^{-n\theta_1} \frac{(n\theta_1)^r}{r!} \geq 1 - \alpha_2$$

$$F_T\left(\frac{k+1}{n}; \theta_2\right) = \sum_{r=0}^k e^{-n\theta_2} \frac{(n\theta_2)^r}{r!} \leq \alpha_1$$

فمثلاً، إذا كانت $x = (x_1, \dots, x_{10})$ عينة مشاهدة لـ X و $T(x) = \bar{x} = \frac{3}{10}$ ونريد بناء فترة ثقة لـ (θ_1, θ_2) بمعامل ثقة لا يقل عن $\gamma = 0.95$.

$$F_T\left(\frac{3}{10}; \theta_1\right) = \sum_{r=0}^2 e^{-10\theta_1} \frac{(10\theta_1)^r}{r!} \geq 1 - \alpha_2 \quad \dots(1)$$

$$F_T\left(\frac{4}{10}; \theta_2\right) = \sum_{r=0}^3 e^{-10\theta_2} \frac{(10\theta_2)^r}{r!} \leq \alpha_1$$

بالعودة إلى جدول توزيع بواسون واتباع أسلوب التجربة والخطأ، بحيث $\alpha_1 + \alpha_2 \leq 1 - \gamma = 0.05$ نجد:

$$\sum_{r=0}^2 e^{-0.6} \frac{(0.6)^r}{r!} = 0.9779 = 1 - \alpha'_2 \Rightarrow \alpha'_2 = 0.0221 \quad \dots(2)$$

$$\sum_{r=0}^3 e^{-8.7} \frac{(8.7)^r}{r!} = 0.0262 = \alpha'_1$$

ومقارنة (1) و (2) نجد:

$$10\theta_1 = 0.6 \Rightarrow \theta_1 = 0.06$$

$$10\theta_2 = 8.7 \Rightarrow \theta_2 = 0.87$$

وبالتالي 95.17% فترة ثقة للمعلمة θ هي $(0.06, 0.87)$.

7.7 فترات الثقة عندما يكون حجم العينة كبيراً

LARGE SAMPLE CONFIDENCE INTERVAL

رأينا من خلال الأمثلة السابقة بأن فترة الثقة لمعلمة θ في نموذج $f(x;\theta)$ يعتمد على اختيار الإحصاء $T = T(X)$. أي أن اختيار إحصاءات مختلفة T يؤدي إلى فترات ثقة مختلفة بشكل عام. إلا أن الهدف النهائي يتمثل في الحصول على أقصر فترة ثقة عند قيمة معينة مسبقاً γ . لنفترض استخدمنا مقدرات غير متحيزة وطبيعية تقريباً. عندئذٍ طول فترة الثقة متناسبة طردياً مع تباين المقدّر، وهذا يعني كلما كان التباين أقل فإن طول فترة الثقة يكون أقصر. وبالتالي، إذا وجد المقدّر الأكفأ أو الأكفأ تقاربياً، فيمكننا في حالات عدة وبسهولة تامة بناء فترات فترة تقريبية وهي الأقصر أو الأقصر تقاربياً، عند معامل ثقة معينة γ .

لقد لاحظنا عند دراستنا للخواص المقاربة لمقدّر المعقولة العظمى $\hat{\theta}_n$ للمعلمة θ في توزيع $f(x;\theta)$ أنه الأكفأ تقاربياً وتوزيعه المقارب طبيعي بمتوسط $E_{\theta}(\hat{\theta}_n(X)) = \theta$ وتباين $\sigma_n^2 = \frac{1}{ni(\theta)}$ ، أي أن:

$$\mathcal{L}_{\theta}(\hat{\theta}_n(X)) = N\left(\theta, \frac{1}{ni(\theta)}\right) ; \quad \theta \in \Theta$$

عندما $n \rightarrow \infty$.

ومن ثم عندما يكون حجم العينة كبيراً فإن $\hat{\theta}_n(X)$ يتبع تقريباً توزيع طبيعي $N\left(\theta, \frac{1}{ni(\theta)}\right)$ ، حيث أن:

$$ni(\theta) = -E\left(\frac{\partial^2 \ln L}{\partial \theta^2}\right)$$

معلومات فيشر. وعلى ذلك فإن:

$$\mathcal{L}((\hat{\theta}_n(X) - \theta)\sqrt{ni(\theta)}) \approx N(0,1)$$

هكذا، إذا وجد مقدر المعقولية العظمى $\hat{\theta}_n(X)$ للمعلمة θ في نموذج $f(x;\theta)$ يمكن استخدامه بسهولة تامة للحصول على فترة ثقة تقريبية لهذه المعلمة.

وعندئذٍ يمكن اختيار $(\hat{\theta}_n(X) - \theta)/\sqrt{ni(\theta)}$ ككمية محورية تقريبية. وبإتباع خوارزمية الطريقة المحورية [راجع بند (3.7)] نحصل على فترة الثقة $(T_1(X), T_2(X))$ بمعامل ثقة يساوي تقريباً γ .

نفترض $X = (X_1, \dots, X_n)$ عينة عشوائية كبيرة الحجم من توزيع $f(x;\theta)$ مستمر أو منقطع، و $\hat{\theta}_n(X)$ مقدر المعقولية العظمى للمعلمة θ ، وإذا كان γ معامل الثقة المطلوب، فإنه يمكن إيجاد عددين $q_1 < q_2$ بحيث يكون:

$$P_\theta(q_1 < (\hat{\theta}_n(X) - \theta)\sqrt{ni(\theta)} < q_2) = \gamma$$

وفي هذه الحالة نعلم أن فترة الثقة تكون أقصر ما يمكن [راجع فقرة (1.4.7)] عندما تكون:

$$q_2 = -q_1 = Z_{\alpha/2} \quad ; \quad \gamma = 1 - \alpha$$

وبتحويل المتباينة:

$$-Z_{\alpha/2} < (\hat{\theta}_n(x) - \theta)\sqrt{i(\theta)} < Z_{\alpha/2}$$

نحصل على:

$$\hat{\theta}_n(x) - \frac{Z_{\alpha/2}}{\sqrt{ni(\theta)}} < \theta < \hat{\theta}_n(x) + \frac{Z_{\alpha/2}}{\sqrt{ni(\theta)}}$$

وبالتالي فإن $100\gamma\%$ فترة ثقة للمعلمة θ هي:

$$\left(\hat{\theta}_n(X) - \frac{Z_{\alpha/2}}{\sqrt{ni(\theta)}}, \hat{\theta}_n(X) + \frac{Z_{\alpha/2}}{\sqrt{ni(\theta)}} \right)$$

مثال 1.7.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية كبيرة الحجم من توزيع $N(0, \theta^2)$ فأوجد $100\gamma\%$ فترة ثقة للتباين θ^2 .

نعلم أن مقدر المعقولة العظمى للمعلمة θ^2 [راجع مثال (3.2.6)] هو:

$$\hat{\theta}_n(X) = \frac{1}{n} \sum_1^n X_i^2$$

ويمكن التأكد بسهولة أن:

$$i_n(\theta) = ni(\theta) = \frac{n}{2\theta^4}$$

وبالتالي:

$$Q(X; \theta) = \left(\hat{\theta}_n(X) - \theta^2 \right) \sqrt{ni(\theta)} = \left(\frac{1}{n} \sum_1^n X_i^2 - \theta^2 \right) \sqrt{\frac{n}{2\theta^4}}$$

$$\mathcal{L}(Q) \approx N(0,1)$$

وبتحويل المتباينة:

$$-Z_{\alpha/2} < \left(\frac{1}{n} \sum_1^n X_i^2 - \theta^2 \right) \sqrt{\frac{n}{2\theta^4}} < Z_{\alpha/2}$$

إلى متباينة مزدوجة بالنسبة لـ θ^2 نجد:

$$\frac{\sum X_i^2/n}{1 + Z_{\alpha/2} \sqrt{n/2}} < \theta^2 < \frac{\sum X_i^2/n}{1 - Z_{\alpha/2} \sqrt{n/2}}$$

ومن ثم $100\gamma\%$ فترة الثقة التقريبية المطلوبة للمعلمة θ^2 هي من الشكل:

$$\left(\frac{\sum X_i^2/n}{1 + Z_{\alpha/2} \sqrt{n/2}}, \frac{\sum X_i^2/n}{1 - Z_{\alpha/2} \sqrt{n/2}} \right)$$

مثال 2.7.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بواسون $\Pi(\theta)$ وكانت n كبيرة، فأوجد $100\gamma\%$ فترة ثقة تقريبية للمعلمة θ .
يمكن التأكد بسهولة أن:

$$\hat{\theta}_n(X) = \bar{X} \quad ; \quad i_n(\theta) = \frac{n}{\theta}$$

ومن ثم:

$$Q(X; \theta) = (\bar{X} - \theta) \sqrt{n/\theta}$$

$$\mathcal{L}(Q) \approx N(0,1)$$

إن المتباينة:

$$-Z_{\alpha/2} < (\bar{X} - \theta) \sqrt{n/\theta} < Z_{\alpha/2} \quad \dots (1)$$

لا يمكن تحويلها مباشرة كمتباينة مزدوجة في θ ، ولكن بملاحظة أن:

$$P\left(\left(\bar{X} - \theta\right)^2 < \frac{\theta}{n} Z_{\alpha/2}^2\right) = \gamma$$

لأن:

$$P\left(|\bar{X} - \theta| < \frac{\theta}{n} Z_{\alpha/2}\right) = \gamma$$

يمكن أخذ المتباينة:

$$(\bar{X} - \theta)^2 < \frac{\theta}{n} Z_{\alpha/2}^2 \quad \dots (2)$$

كمتباينة مكافئة للمتباينة المزدوجة (1). وبإعادة كتابة (2) كصيغة من الدرجة الثانية في θ وتحويلها نحصل على $100\gamma\%$ فترة الثقة المطلوبة للمعلمة θ وهي:

$$\bar{X} + \frac{Z_{\alpha/2}^2}{2n} \pm \left(\frac{\bar{X}Z_{\alpha/2}}{n} - \frac{Z_{\alpha/2}^4}{4n^2} \right)^{1/n}$$

يمكن تجاوز الصعوبة التي واجهتنا في تحويل المتباينة (1) في هذا المثال وفي كثير من المسائل وذلك باستبدال θ بمقدرها $\hat{\theta}_n(X)$ في عبارة $i_n(\theta)$.

بالعودة للمثال السابق نجد أن $Q(X; \theta)$ تصبح:

$$Q(X; \theta) = (\bar{X} - \theta) \sqrt{\frac{n}{\bar{X}}}$$

وعندئذٍ يمكن تحويل المتباينة المزروجة:

$$-Z_{\alpha/2} < (\bar{X} - \theta) \sqrt{\frac{n}{\bar{X}}} < Z_{\alpha/2}$$

إلى:

$$\bar{X} - Z_{\alpha/2} \sqrt{\frac{\bar{X}}{n}} < \theta < \bar{X} + Z_{\alpha/2} \sqrt{\frac{\bar{X}}{n}}$$

وعملياً فإن هذه الفترة لا تختلف كثيراً عن الفترة السابقة. فمثلاً، إذا كانت $\gamma = 0.95$ ، $\bar{x} = 10$ ، فإن $Z_{\alpha/2} = 1.96$ ، ومن ثم الفترة السابقة هي (9.40, 10.63)، بينما الفترة الأخيرة (9.38, 10.62).

مثال 3.7.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بيرنولي $B(1, \theta)$ ، وكانت n كبيرة، فأوجد $100\gamma\%$ فترة ثقة تقريبية لـ θ .

كما نعلم أن مقدر المعقولة العظمى لـ θ هو:

$$\hat{\theta}_n(X) = \bar{X}$$

ومعلومات فيشر:

$$i_n(\theta) = \frac{n}{\theta(1-\theta)} \approx \frac{n}{\bar{X}(1-\bar{X})}$$

وبالتالي:

$$Q(X;\theta) = (\bar{X} - \theta) \sqrt{\frac{n}{\bar{X}(1-\bar{X})}}$$

وتكون فترة الثقة المطلوبة:

$$\left(\bar{X} - Z_{\alpha/2} \sqrt{\frac{\bar{X}(1-\bar{X})}{n}}, \bar{X} + Z_{\alpha/2} \sqrt{\frac{\bar{X}(1-\bar{X})}{n}} \right)$$

مثال 4.7.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x;\theta) = \theta e^{-\theta x} ; \quad x > 0, \quad \theta > 0$$

وكانت n كبيرة، فأوجد $100\gamma\%$ فترة ثقة تقريبية لـ θ .

كما نعلم أن مقدرّ المعقولة العظمى لـ θ هو:

$$\hat{\theta}(X) = \frac{1}{\bar{X}}$$

[راجع مثال (1.2.6)]. وأن $i_n(\theta) = \frac{n}{\theta^2} \approx \frac{n}{\bar{X}^2}$ ، وبالتالي:

$$Q(X;\theta) = \left(\frac{1}{\bar{X}} - \theta \right) \sqrt{\frac{n}{\bar{X}^2}}$$

وتكون فترة الثقة المطلوبة:

$$\left(\frac{1}{\bar{X}} - Z_{\alpha/2} \frac{\bar{X}}{\sqrt{n}}, \frac{1}{\bar{X}} + Z_{\alpha/2} \frac{\bar{X}}{\sqrt{n}} \right)$$

يمكن استخدام طريقة تقريبية لبناء فترات ثقة. كما نعلم $U(X;\theta) = \frac{\partial \ln L}{\partial \theta}$ عبارة عن متغير عشوائي توقعه صفر وتباينه $i_n(\theta)$ ، ومن ثم إذا أخذنا:

$$Q(X;\theta) = \frac{U(X;\theta)}{\sqrt{i_n(\theta)}} \quad \dots \dots (1)$$

فإن:

$$E_{\theta}(Q) = 0 \quad , \quad \text{var}(Q) = 1$$

لكن:

$$U(X;\theta) = \frac{\partial \ln L}{\partial \theta} = \sum_1^n \frac{\partial}{\partial \theta} \ln f(X_i;\theta)$$

أي يمكن النظر إلى المتغير $Q(X;\theta)$ ، عند كل قيمة $\theta \in \theta$ كمجموع n من المتغيرات $\frac{\partial}{\partial \theta} \ln f(X_i;\theta)$ مقسوماً على انحرافه المعياري، وبالتالي حسب مبرهنة النهاية المركزية فإن:

$$\mathcal{L}(Q) = N(0,1)$$

عندما $n \rightarrow \infty$. ومن ثم يمكن استخدام (1) ككمية محورية تقريبية، عندما تكون n كبيرة، لإيجاد فترات الثقة.

فمثلاً، بالعودة إلى المثال السابق نجد:

$$U(X;\theta) = \frac{n}{\theta} - \sum X_i \quad ; \quad i_n(\theta) = \frac{n}{\theta^2}$$

وبالتالي:

$$Q(X;\theta) = \frac{U(X;\theta)}{\sqrt{i_n(\theta)}} = \frac{\frac{n}{\theta} - \sum X_i}{\sqrt{n}/\theta} = \sqrt{n}(1 - \theta \bar{X})$$

ويمكن تحويل المتباينة:

$$-Z_{\alpha/2} < \sqrt{n}(1 - \theta\bar{X}) < Z_{\alpha/2}$$

إلى:

$$\frac{1 - Z_{\alpha/2}/\sqrt{n}}{\bar{X}} < \theta < \frac{1 + Z_{\alpha/2}/\sqrt{n}}{\bar{X}}$$

ومن ثم $100\gamma\%$ فترة الثقة المطلوبة للمعلمة θ هي:

$$\left(\frac{1 - Z_{\alpha/2}/\sqrt{n}}{\bar{X}} < \theta < \frac{1 + Z_{\alpha/2}/\sqrt{n}}{\bar{X}} \right)$$

8.7 مناطق الثقة من أجل معلمة متعددة الأبعاد

تطرقنا حتى الآن لتقدير فترة ثقة لمعلمة وحيدة البعد (سلمية)، أي لكيفية بناء فترة عشوائية $(T_1(X), T_2(X))$ تغطي القيمة الحقيقية للمعلمة المجهولة θ باحتمال لا يقل عن γ . لكن هنالك حالات يتعلق فيها التقدير بمعلمة متعددة الأبعاد $\theta = (\theta_1, \dots, \theta_r)$ ، فعندئذٍ بدلاً من فترات ثقة نعين مناطق ثقة $\mathcal{G} = \mathcal{G}(X) \subset \theta$ بناءً على شرط مشابه للشرط (1.2.7):

$$P_{\theta}(\theta \in \mathcal{G}(X)) = \gamma \quad ; \quad \theta \in \theta \quad (1.8.7)$$

هكذا، $100\gamma\%$ منطقة ثقة هي عبارة عن فئة جزئية عشوائية من فضاء المعلمة $\theta \subset R^r$ ، المرتبطة بالعينة X (وليس بـ θ)، والتي تغطي القيمة الحقيقية للمعلمة المجهولة θ باحتمال يساوي γ .

الطريقة العامة لبناء منطقة الثقة تتمثل بما يلي: نضع مقابل كل قيمة $\theta \in \theta$ فئة جزئية $H(\theta)$ من فضاء العينة G ، أي أن $H(\theta) \subset G$ ، بحيث يتحقق الشرط:

$$P_{\theta}(X \in H(\theta)) = \gamma \quad (2.8.7)$$

بهذا الشكل نحصل على أسر الفئات الجزئية $\{H(\theta); \theta \in \theta\}$.

لنعين الآن من أجل كل $x \in G$ فئة جزئية $\theta \in \mathcal{H}$ وفق القاعدة التالية
 بذلك، نحصل من فضاء المعلمة θ على أسرة الفئات
 الجزئية $\{\mathcal{H}(x); x \in G\}$. لسرى الفئة الجزئية العشوائية $\mathcal{H}(X)$. إن الحادثين
 $\{X \in \mathcal{H}(\theta)\}$ و $\{\theta \in \mathcal{H}(X)\}$ متكافئان، لأنه حسب البناء كل منهما يقتضي
 الآخر، وبالتالي احتماليهما متساويان عند كل قيمة $\theta \in \theta$. بأخذ العلاقة
 (2.8.7) بعين الاعتبار، نجد من أجل $\mathcal{H}(X)$ تتحقق المساواة (1.8.7)، ومن ثم
 $\mathcal{H}(X)$ تمثل $100\gamma\%$ منطقة ثقة من أجل المعلمة θ .

نجد الإشارة هنا، إلى أن هذه الطريقة لبناء منطقة الثقة لا تعطي منطقة ثقة
 وحيدة (لأنه عند درجة ثقة معطاة γ ، يمكن اختيار الفئة $\mathcal{H}(\theta)$ بطرق مختلفة).
 وتهدف المسألة إلى بناء منطقة ثقة ذات قياس أصغري (أصغر ما يمكن)، التي
 تضمن أكبر دقة (عند γ معطاة) للمعلمة θ . في مسائل معينة الفئة $\mathcal{H}(\theta)$ ،
 المحققة للشرط (1.8.7)، تبنى عادة بواسطة إحصاء ما $T(X)$ (بشكل عام يقال
 متجه) توزيعه معلوم. لنوضح هذه الطريقة من خلال الأمثلة الآتية.

مثال 1.8.7

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع طبيعي عام $N(\theta_1, \theta_2^2)$ ، ونريد
 بناء منطقة ثقة للمعلمة $\theta = (\theta_1, \theta_2^2)$ ، أي منطقة ثقة للمتوسط والتباين في آن واحد
 (simultaneous confidence region for the mean and variance).

في الفقرة (3.4.7) تم بناء فترتي الثقة على انفراد لكل من المتوسط θ_1
 والتباين θ_2^2 غير المعلومين في النموذج $N(\theta_1, \theta_2^2)$ [راجع العلاقاتين (12.4.7) و
 (16.4.7)] وهما:


$$\left(\bar{X} - \frac{S}{\sqrt{n-1}} t_{\alpha/2, n-1}, \bar{X} + \frac{S}{\sqrt{n-1}} t_{\alpha/2, n-1} \right) \dots \dots (1)$$

$$\left(\frac{nS^2}{\chi_{\alpha/2, n-1}^2}, \frac{nS^2}{\chi_{1-\alpha/2, n-1}^2} \right) \dots \dots (2)$$

$$P\left(\bar{X} - \frac{S}{\sqrt{n-1}} t_{\alpha/2, n-1} < \theta_1 < \bar{X} + \frac{S}{\sqrt{n-1}} t_{\alpha/2, n-1}\right) = \gamma$$

$$P\left(\frac{nS^2}{\chi_{\alpha/2, n-1}^2} < \theta_2^2 < \frac{nS^2}{\chi_{1-\alpha/2, n-1}^2}\right) = \gamma$$

قد نفكر للوهلة الأولى بدمج فترتي الثقة (1) و (2) للحصول على منطقة ثقة للمعلمة $\theta = (\theta_1, \theta_2^2)$ كما هي مبينة على الشكل (1.8.7) بالمنطقة المظللة.



شكل (1.8.7)

ومن الواضح أن هذه المنطقة $y(X)$ هي منطقة ثقة للمعلمة $\theta = (\theta_1, \theta_2^2)$ ولكن معامل الثقة غير محدد. وأن معامل الثقة ليس γ^2 لأن الحادثين (1) و (2) غير مستقلين (المتغيران العشوائيان $(\bar{X} - \theta_1)/S$ و S^2 اللذان على أساسهما بنيت فترتي الثقة مرتبطان).

يمكن بناء $100\gamma\%$ منطقة ثقة للمعلمة $\theta = (\theta_1, \theta_2^2)$ باستخدام الإحصاء ذو البعدين $T = (\bar{X}, S^2)$ ، حيث أن الإحصائين \bar{X}, S^2 مستقلان [راجع مبرهنة (5.9.3)]، وذلك على النحو الآتي:

عما أن:

$$\mathcal{L}_\theta \left(\frac{\bar{X} - \theta_1}{\theta_2 / \sqrt{n}} \right) = N(0,1)$$

$$\mathcal{L}_\theta \left(\frac{nS^2}{\theta_2^2} \right) = \chi_{(n-1)}^2$$

نعين من أجل كل $\theta \in \Theta$ الفئة الجزئية $H(\theta)$ كالآتي:

$$H(\theta) = \left\{ x : \left| \frac{\bar{x} - \theta_1}{\theta_2 / \sqrt{n}} \right| < t = z_{\alpha_1/2}, t' = \chi_{1-\alpha_2/2, n-1} < \frac{nS^2}{\theta_2^2} < t'' = \chi_{\alpha_2/2, n-1} \right\}$$


حيث أن $\Phi(-Z_{\alpha_1/2}) = \alpha_1/2$ ، $S^2 = S^2(x)$ ، $\gamma = \gamma_1 \gamma_2$ ، $\gamma_1 = 1 - \alpha_1$ ، $\gamma_2 = 1 - \alpha_2$ عندئذٍ، بناءً على استقلال \bar{X} و S^2 نجد:

$$P_\theta(X \in H(\theta)) = P_\theta \left(\left| \frac{\bar{X} - \theta_1}{\theta_2 / \sqrt{n}} \right| < z_{\alpha_1/2} \right) P_\theta \left(t' < \frac{nS^2}{\theta_2^2} < t'' \right) = \gamma_1 \gamma_2 = \gamma$$

أي أن الفئات الجزئية $H(\theta)$ تحقق الشرط (2.8.7). وبجمل المتباينتين المزدوجتين المعرفتين للفئات الجزئية $H(\theta)$ بالنسبة لـ θ_1, θ_2^2 نحصل على مناطق الثقة $\gamma(x)$ المطلوبة المعينة بالشرطين:

$$\theta_2^2 > (\bar{x} - \theta_1)^2 n / t' \quad , \quad ns^2 / t'' < \theta_2^2 < ns^2 / t'$$

وتمثل المنطقة $\gamma(x)$ بجزء من المستوي المحدد بالقطع المكافئ $\theta_2^2 = (\bar{x} - \theta_1)^2 n / t'$ والمستقيمين $\theta_2^2 = ns^2 / t'$ و $\theta_2^2 = ns^2 / t''$. وهذا ما يبدو بوضوح بالمنطقة المظلمة على الشكل (2.8.7).



شكل (2.8.7)

تقارين

1. لتكن X ملاحظة واحدة من توزيع:

$$f(x;\theta) = \theta x^{\theta-1} \quad ; \quad 0 < x < 1, \theta > 0$$

والمطلوب:

1. أوجد كمية محورية وأستخدمها لإيجاد مقدر فترة ثقة للمعلمة θ .
2. أثبت أن $(Y/2, Y)$ فترة ثقة للمعلمة θ ، ثم عين معامل الثقة الموافق لها.
3. أوجد أفضل $100\gamma\%$ فترة ثقة للمعلمة θ .

2. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \theta)$ ، فأوجد كمية محورية للمعلمة θ ، وأستخدمها للحصول على مقدر فترة ثقة لها.

3. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $R\left(\theta - \frac{1}{2}, \theta + \frac{1}{2}\right)$ وكانت $Y = (Y_1, \dots, Y_n)$ العينة المرتبة الموافقة للعينة X ، فأثبت أن فترة ثقة للمعلمة θ واحسب معامل الثقة لها.

4. لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0, \theta > 0$$

والمطلوب:

1. أوجد $100\gamma\%$ فترة ثقة لمتوسط المجتمع.

2. أوجد $100\gamma\%$ فترة ثقة لتباين المجتمع.

3. ما هو احتمال أن هاتين الفترتين تغطيان القيمة الحقيقية للمتوسط والقيمة الحقيقية للتباين في آن واحد؟

4. أوجد مقدر فترة ثقة لـ $\tau(\theta) = e^{-\theta}$.

تنبيه: استخدم نتائج المثال (3.6.7) والملاحظة في البند (2.7).

5. لتكن X ملاحظة واحدة من مجتمع توزيعه:

$$f(x; \theta) = \theta e^{-\theta x} \quad ; \quad x > 0, \theta > 0$$

والمطلوب:

1. إذا كانت $(X, 2X)$ فترة ثقة لـ $\tau(\theta) = 1/\theta$ فأوجد معامل الثقة لها.

2. أوجد فترة ثقة أخرى لـ $\tau(\theta) = 1/\theta$ لها نفس معامل الثقة، لكن توقع طولها أصغر.

6. لتكن $X = (X_1, X_2)$ عينة عشوائية من توزيع $N(\theta, 1)$ ، ويطلب:

1. إذا كانت $(X_{(1)}, X_{(2)})$ عبارة عن $100\gamma\%$ فترة ثقة للمعلمة θ ، فأوجد الطول المتوقع لها.

2. أوجد مقدر فترة الثقة للمعلمة θ باستعمال $(\bar{X} - \theta)$ كمية محورية بمعامل ثقة γ ، ثم قارن طول هذه الفترة بالطول المتوقع في (1).

7. إذا كانت $x = (3.3, -0.3, -0.6, -0.9)$ عينة عشوائية ملاحظة من توزيع طبيعي $N(\theta, \sigma^2 = 9)$ ، فأوجد 90% فترة ثقة للمتوسط θ ، وإذا افترضنا التباين غير معلوم، فما هي 90% فترة ثقة لـ θ ؟

8. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من مجتمع توزيعه $N(\theta_1, \theta_2^2)$ ، فما هو حجم العينة n اللازم ليكون 90% فترات ثقة للمعلمة θ_1 أطولها أقل من $\theta_2/5$ ، وذلك باحتمال يساوي 0.95.

9. لدينا خمس مجتمعات طبيعية لها نفس التباين غير المعلوم. سحبنا عينة عشوائية من كل مجتمع، فكانت النتائج على النحو الآتي:

$$S^2 : 40 \quad 30 \quad 20 \quad 42 \quad 50$$

$$n \quad 6 \quad 4 \quad 3 \quad 7 \quad 8$$

حيث $S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$. أوجد فترة ثقة للتباين المشترك.

10. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع منظم $R(\theta/2; \theta)$ ، فأثبت أن $(X_{(n)}, X_{(n)}/\sqrt{1-\gamma})$ هي 100% فترة ثقة للمعلمة θ .

11. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع جاما $\Gamma(\theta, \gamma)$ وكانت n كبيرة، فبين أن أقصر 100% فترة ثقة تقريبية للمعلمة θ هي:

$$\left(\frac{\bar{X}}{\gamma} \left(1 - z_{\alpha/2} / \sqrt{n\gamma}\right), \frac{\bar{X}}{\gamma} \left(1 + z_{\alpha/2} / \sqrt{n\gamma}\right) \right)$$

12. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $\bar{B}(r, \theta)$ وكانت n كبيرة، فبين أن أقصر 100% فترة ثقة تقريبية للمعلمة θ هي:

$$\left(\hat{\theta}_n(X) \pm z_{\alpha/2} \sqrt{\hat{\theta}_n(X)(1-\hat{\theta}_n(X))^2 / (rn)} \right) = \frac{1}{r + \bar{X}} \left(\bar{X} \pm z_{\alpha/2} \sqrt{r\bar{X} / [n(r + \bar{X})]} \right)$$

13. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع أسي:

$$f(x; \theta) = e^{-(x-\theta)} \quad ; \quad 0 \leq x < \theta$$

فبين أن $100\gamma\%$ فترة ثقة للمعلمة θ هي:

$$\left(X_{(1)} + \frac{\ln(1-\gamma)}{n}, X_{(1)} \right) \quad ; \quad X_{(1)} = \min X_i$$

14. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta_1) = \theta_1 e^{-\theta_1 x} \quad ; \quad x > 0, \theta_1 > 0$$

وكانت $Y = (Y_1, \dots, Y_n)$ عينة عشوائية من توزيع:

$$f(y; \theta_2) = e^{-\theta_2 y} \quad ; \quad y > 0, \theta_2 > 0$$

فالمطلوب:

1. أوجد $100\gamma\%$ فترة ثقة للمعلمة $\theta = \theta_1/\theta_2$.

2. أوجد منطقة ثقة للمعلمة $\theta = (\theta_1, \theta_2)$ على الصورة:

$$\left\{ (\theta_1, \theta_2) : \theta_1 \sum_{i=1}^n X_i + \theta_2 \sum_{i=1}^n Y_i \leq c \right\}$$

15. إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \theta^2)$ ، فالمطلوب:

1. بين أن $100\gamma\%$ فترة ثقة للتباين θ^2 لها الشكل:

$$\left(\bar{X} / (1 + z_{\alpha/2} / \sqrt{n}), \bar{X} / (1 - z_{\alpha/2} / \sqrt{n}) \right)$$

2. إذا كانت n كبيرة، فأوجد $100\gamma\%$ فترة ثقة تقريبية لـ θ^2 .

3. إذا كانت $x = (x_1, \dots, x_{100})$ عينة ملاحظة من $N(\theta, \theta^2)$ ، وكانت

$$\alpha = 0.05, \bar{x} = 3$$

طرق تقدير بييز

1.8 مقدمة

في دراستنا السابقة لطرق التقدير (بنقطة أو فترة). كنا نفترض أن لدينا مجتمع صيغة توزيعه معلومة $f(x; \theta)$ لكنها تحتوي على معلمة ثابتة غير معلومة θ من فضاء المعلمة θ ، ونرغب في تقدير θ بناءً على المعلومات المتوفرة في عينة عشوائية $x = (x_1, \dots, x_n)$ مأخوذة من هذا المجتمع. وبعبارة أخرى إن معلوماتنا المتوفرة حول المعلمة θ قبل سحب العينة العشوائية x تتمثل في أنها قيمة ثابتة، لكنها غير معلومة، وهي إحدى نقاط فضاء المعلمة θ .

تتوفر في حالات عدة معلومات إضافية حول المعلمة غير المعلومة θ تبين أنها متغيرة (غير ثابتة)، ويمكن اعتبارها كقيمة لمتغير عشوائي نرمز له بـ Θ ، ومن ثم له توزيع احتمالي. فمثلاً، لنفترض أننا نرغب في تقدير نسبة العطب في إنتاج مصنع ما لأجهزة التلفاز. وفي يوم ما أخذنا لأعلى التعيين 10 أجهزة ولنرمز لنتائج الملاحظة بـ X_1, \dots, X_{10} ، حيث $X_i = 1$ إذا كان التلفاز معطوب و $X_i = 0$ إذا كان التلفاز غير معطوب (سليم)، أي يمكن اعتبار $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع:

$$f(x; \theta) = \theta^x (1 - \theta)^{1-x} \quad ; \quad x = 0, 1, \quad 0 \leq \theta \leq 1$$

يمكن التأكيد بسهولة من أن مقدر المعقولة العظمى لـ θ هو $\hat{\theta}(X) = \bar{X}$ وهو نفس مقدر العزوم. لنفترض الآن توفر بعض المعلومات الإضافية حول المعلمة

θ ، وذلك قبل سحب عينة عشوائية، وهي أننا لاحظنا خلال أيام مختلفة أن نسبة العطب θ في إنتاج المصنع المذكور متغيرة وأن هذا التغير يمكن تمثيله بمتغير عشوائي Θ دالة احتمالها:

$$g_{\theta}(\theta) = 6\theta(1-\theta) \quad ; \quad 0 \leq \theta \leq 1$$

والسؤال المهم الآن، هو: كيف يمكن استخدام هذه المعلومات الإضافية حول المعلمة θ لتقدير θ_0 حيث θ_0 قيمة Θ يوم سحب عينة عشوائية x ؟.

تدعى طرق التقدير الإحصائية التي تجيب على هذا السؤال بطرق تقدير يبيز (Bayesian method of estimation).

هكذا، فطرق التقدير السابقة تفترض أن المعلمة θ التي نريد تقديرها عبارة عن قيمة ثابتة غير معلومة، لكن في طرق تقدير يبيز ينظر إلى المعلمة θ كقيمة لمتغير عشوائي Θ له توزيع احتمالي.

إذا كان Θ متغير عشوائي له توزيع احتمالي، فسنرمز لدالة توزيع Θ بـ $G(\theta) = G_{\theta}(\theta)$ ولدالة الكثافة (أو دالة الاحتمال) بـ $g(\theta) = g_{\theta}(\theta)$ ، ونفترض أن هاتين الدالتين معرفتان على فضاء المعلمة θ ، ولا تحتويان على معالم غير معلومة.

في مسائل كثيرة ليس واقعياً افتراض أن θ قيمة لمتغير عشوائي Θ ، وفي مسائل أخرى يبدو ذلك ممكناً، ولكن توزيع Θ غير معلوم، وحتى إن كان معلوماً فهو يحتوي على معالم أخرى غير معلومة. ومع ذلك، يكون منطقياً في بعض المسائل الافتراض بأن توزيع Θ معلوم تماماً أو يمكن اشتقاقه، وسندرس فيما يلي هذه الحالة.

2.8 التوزيع القبلي والبعدي

PRIOR AND POSTERIOR DISTRIBUTION

نستعمل حتى الآن الرمز $f(x;\theta)$ للدلالة على توزيع متغير عشوائي X من أجل كل قيمة $\theta \in \Theta$. وعندما نريد الإشارة إلى أن المعلمة θ قيمة لمتغير عشوائي

⊙، سنرمز لتوزيع ξ بـ $f_{\xi|\theta} = f(x|\theta)$ للتمييز عن $f(x;\theta)$. ويجب ملاحظة أن $f(x|\theta)$ ترمز للتوزيع الشرطي (المشروط) للمتغير العشوائي ξ بافتراض $\theta = \Theta$ ، ومن ثم ترمز $f(x;\theta)$ للتوزيع المشترك للمتغيرين Θ و ξ .

لتكن $X = (X_1, \dots, X_n)$ عينة عشوائية بحجم n من توزيع $f(x|\theta)$ ، حيث أن θ قيمة لمتغير عشوائي Θ . ولنفرض أن توزيع Θ معلوم تماماً، أي أن $g(\theta)$ معلومة (لا تحتوي على معالم غير معلومة)، ونريد تقدير $\tau(\theta)$ (ومنها $\tau(\theta) = \theta$). كيف يمكننا الاستفادة من المعلومات الإضافية المتمثلة بمعرفة توزيع Θ في عملية التقدير؟ في الفصول السابقة كنا نستخدم دالة العقلية $L(x|\theta)$ كعبارة تشتمل على كل معلوماتنا حول المعلمة θ ، أي أن دالة العقلية تتضمن العينة الملاحظة $x = (x_1, \dots, x_n)$ وكذلك صيغة التوزيع $f(x;\theta)$. والآن نحتاج لعبارة تشتمل على كل المعلومات التي تحتويها دالة العقلية بالإضافة إلى المعلومات الإضافية المتمثلة بمعرفة التوزيع $g(\theta)$ الذي يدعى بالتوزيع القبلي لـ Θ (prior distribution)، وهذا يلخص ما نعرفه حول θ قبل سحب عينة عشوائية. وبعبارة أخرى نبحث عن دالة تلخص ما نعرفه حول θ بعد أخذ عينة عشوائية، أي نبحث عن التوزيع البعدي لـ Θ بعد الحصول على عينة عشوائية $x = (x_1, \dots, x_n)$.

تعريف 1.2.8 التوزيع القبلي Prior Distribution

يدعى التوزيع $g(\theta) = g_0(\theta)$ بالتوزيع القبلي لـ Θ وهو توزيع احتمالي يحتوي على كل معلوماتنا حول المعلمة θ قبل الحصول على عينة عشوائية $x = (x_1, \dots, x_n)$. نلاحظ أن الدالة $g(\theta)$ تصف درجة اعتقادنا (ثقتنا) في القيم الممكنة لـ Θ قبل المعاينة.

تعريف 2.2.8 التوزيع البعدي Posterior Distribution

يدعى التوزيع $g(\theta|x)$ بالتوزيع البعدي لـ Θ ، وهو توزيع احتمالي شرطي لـ Θ ، عند $X = x$ ، ويصف درجة اعتقادنا في القيم الممكنة للمعلمة Θ بعد

الحصول على x . أي يشتمل على كل المعلومات حول θ بعد الحصول على عينة عشوائية x .

نلاحظ من التعريفين أن الحصول على عينة عشوائية x تغير درجة اعتقادنا أو نقتنا في القيم المختلفة لـ θ ، وذلك بتحويل التوزيع القبلي إلى التوزيع البعدي، وهذا ما تؤكدته نظرية الاحتمالات بشكل عام.

تستخدم تقنيات يميز التوزيع القبلي $g(\theta)$ والتوزيع المشترك للعينة العشوائية X و θ ، أي $f(x; \theta)$ لحساب التوزيع البعدي $g(\theta|x)$ لـ θ .

كما نعلم من نظرية الاحتمالات أن التوزيع المشترك $f(x; \theta)$ لـ θ و X يساوي إلى التوزيع الهامشي لأحدهما مضروباً بالتوزيع الشرطي للآخر، أي أن:

$$f(x; \theta) = g(\theta)f(x|\theta) = f(x)g(\theta|x)$$

ومن ثم:

$$g(\theta|x) = \frac{g(\theta)f(x|\theta)}{f(x)} \quad (1.2.8)$$

حيث أن:

$$f(x) = \begin{cases} \int g(\theta)f(x|\theta)d\theta & \text{حالة } \theta \text{ متغير مستمر} \\ \sum_{\theta} g(\theta)f(x|\theta) & \text{حالة } \theta \text{ متغير منقطع} \end{cases}$$

$$f(x|\theta) = \prod_{i=1}^n f(x_i|\theta)$$

نلاحظ من العلاقة (1.2.8) أن:

$$g(\theta|x) \propto g(\theta)f(x|\theta) = g(\theta)L(x|\theta) \quad (2.2.8)$$

أي أن الدالة $f(x)$ يمكن أن تدخل في ثابت التناسب.

إذا وجد إحصاء كافي $T(X)$ للمعلمة θ ، وكان توزيعه $h(t|\theta)$ ، فيمكن كتابة العلاقة (2.2.8) على الصورة:

$$g(\theta|x) \propto g(\theta)h(t|\theta)N(x)$$

ويمكن إدخال $N(x)$ في ثابت التناسب:

$$g(\theta|x) \propto g(\theta)h(t|\theta)$$

يتم تعيين ثابت التناسب باعتبار $g(\theta|x)$ دالة كثافة شرطية (أو دالة احتمال شرطية) لمتغير عشوائي Θ ، أي أن:

$$\int g(\theta|x)d\theta = 1 \quad \text{في حالة } \Theta \text{ مستمرة}$$

أو:

$$\sum_{\theta} g(\theta|x) = 1 \quad \text{في حالة } \Theta \text{ منقطعة}$$

مثال 1.2.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \theta^x (1-\theta)^{1-x} \quad ; \quad x = 0,1$$

وكان التوزيع القبلي لـ Θ :

$$g(\theta) = 6\theta(1-\theta) \quad ; \quad 0 \leq \theta \leq 1$$

فأوجد التوزيع البعدي لـ Θ .

بما أن:

$$f(x|\theta) = L(x|\theta) = \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} = \theta^t (1-\theta)^{n-t} \quad ; \quad t = \sum_{i=1}^n x_i$$

$$f(x) = \int g(\theta)L(x|\theta)d\theta = 6 \int_0^1 \theta^{t+1} (1-\theta)^{n-t+1} d\theta = 6\beta(t+2, n-t+2)$$

وذلك بناءً على العلاقة (36.3.2). ويكون التوزيع البعدي لـ Θ :

$$g(\theta) = \frac{g(\theta)f(\mathbf{x}|\theta)}{f(\mathbf{x})} = \frac{1}{\beta(t+2, n-t+2)} \theta^{t+1} (1-\theta)^{n-t+1} ; \quad 0 \leq \theta \leq 1$$

نلاحظ أن التوزيع القبلي ما هو إلا توزيع $Be(2,2)$ وكذلك التوزيع البعدي هو $Be(t+2, n-t+2)$ ، أي أن كلا التوزيعين من عائلة توزيعات بيتا.

مثال 2.2.8

إذا كانت $\mathbf{x} = (x_1, \dots, x_n)$ عينة عشوائية من توزيع بواسون:

$$f(\mathbf{x}|\theta) = \frac{\theta^x}{x!} e^{-\theta} ; \quad x = 0, 1, \dots$$

وكان التوزيع القبلي لـ Θ هو $\Gamma(2, 1/3)$ ، أي أن:

$$g(\theta) = 9\theta e^{-3\theta} ; \quad \theta > 0$$

فأوجد التوزيع البعدي لـ Θ .

بما أن:

$$L(\mathbf{x}|\theta) = f(\mathbf{x}|\theta) = \prod_{i=1}^n \frac{\theta^{x_i}}{x_i!} e^{-\theta} = \frac{\theta^t}{\prod_1^n (x_i!)} e^{-n\theta} ; \quad t = \sum_{i=1}^n x_i$$

فإن:

$$g(\theta|\mathbf{x}) \propto g(\theta)L(\mathbf{x}|\theta) = \frac{9}{\prod_1^n (x_i!)} \theta^{t+1} e^{-(n+3)\theta} \propto \theta^{t+1} e^{-(n+3)\theta} ; \quad \theta > 0$$

وهذا يعني أن التوزيع $g(\theta|\mathbf{x})$ ما هو إلا توزيع جاما $\Gamma\left(t+2, \frac{1}{n+3}\right)$

وحسب العلاقة (20.3.2)، فإن:

$$f(\theta|x) = \frac{(n+3)^{t+2}}{\Gamma(t+2)} \theta^{t+1} e^{-(n+3)\theta} ; \theta > 0$$

نلاحظ أيضاً أن التوزيع البعدي ينتمي لنفس عائلة التوزيعات التي ينتمي إليها التوزيع القبلي وهي عائلة التوزيعات الجماوية $\Gamma(\alpha, \beta)$.

مثال 3.2.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \theta e^{-\theta x} ; x > 0, \theta > 0$$

وكان التوزيع القبلي لـ Θ هو $\Gamma(a+1, 1/b)$ ، أي أن:

$$g(\theta) = \frac{b^{a+1}}{\Gamma(a+1)} \theta^a e^{-b\theta} ; \theta > 0$$

وعلمت بأن $T(X) = -\sum_{i=1}^n \ln X_i$ إحصاء كافي للمعلمة θ ، فأوجد باستخدام الإحصاء الكافي $T(X)$ التوزيع البعدي لـ Θ .

كما نعلم [راجع المثال (3.2.4)] أن توزيع الإحصاء الكافي $T(X) = -\sum_{i=1}^n \ln X_i$ هو عبارة عن توزيع $\Gamma(n, 1/\theta)$ ، أي أن:

$$h(t|\theta) = \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{-\theta t} ; t > 0$$

وحيث أن:

$$g(\theta|x) \propto g(\theta)h(t|\theta)$$

فإن

$$g(t|\theta) \propto \theta^{a+n} e^{-(b+t)\theta}$$

وهذا يعني أن التوزيع البعدي لـ Θ هو $\Gamma\left(a+n+1, \frac{1}{b+t}\right)$ ، أي أن:

$$g(\theta|x) = \frac{(b+t)^{a+n+1}}{\Gamma(a+n+1)} \theta^{a+n} e^{-(b+t)\theta} ; \theta > 0$$

نلاحظ أيضاً أن التوزيعين القبلي والبعدي لـ Θ ينتميان إلى عائلة التوزيعات الجماوية (أي نفس العائلة).

نلاحظ من خلال الأمثلة السابقة أن التوزيع البعدي لـ Θ هو توزيع مستمر، ومن ثم يتبادر للذهن القارئ بأن التوزيعات البعدية هي دوماً توزيعات مستمرة، وهذا غير صحيح. ويمكن إيضاح ذلك من خلال المثال الآتي:

مثال 4.2.8

إذا كانت X ملاحظة مفردة على متغير عشوائي X توزيعه:

$$f(x|\theta) = \theta^x (1-\theta)^{1-x} ; x = 0,1 , \theta = 0.3, 0.4$$

وكان التوزيع القبلي لـ Θ معطى بالجدول:

| θ | $\theta_1 = 0.3$ | $\theta_2 = 0.4$ |
|-------------|------------------|------------------|
| $g(\theta)$ | 0.4 | 0.6 |

فأوجد التوزيع البعدي لـ Θ .

بما أن:

| θ | θ_1 | θ_2 |
|---------------------|------------|------------|
| $f(x_1 = 0 \theta)$ | 0.7 | 0.6 |
| $f(x_2 = 1 \theta)$ | 0.3 | 0.4 |

فيان:

$$g(\theta_1|x_1) = \frac{g(\theta_1)f(x_1|\theta_1)}{\sum_{\theta} g(\theta)f(x_1|\theta)} = \frac{(0.4)(0.7)}{(0.4)(0.7) + (0.6)(0.6)} = \frac{28}{64} = \frac{7}{16}$$

$$g(\theta_2|x_1) = \frac{g(\theta_2)f(x_1|\theta_2)}{\sum_{\theta} g(\theta)f(x_1|\theta)} = \frac{(0.6)(0.6)}{0.64} = \frac{36}{64} = \frac{9}{16}$$

وبشكل مشابه:

$$g(\theta_1|x_2) = \frac{g(\theta_1)f(x_2|\theta_1)}{\sum_{\theta} g(\theta)f(x_2|\theta)} = \frac{(0.4)(0.3)}{(0.4)(0.3) + (0.6)(0.4)} = \frac{12}{36} = \frac{1}{3}$$

$$g(\theta_2|x_2) = \frac{g(\theta_2)f(x_2|\theta_2)}{\sum_{\theta} g(\theta)f(x_2|\theta)} = \frac{(0.4)(0.3)}{0.36} = \frac{24}{36} = \frac{2}{3}$$

وبذلك فإن التوزيع البعدي لـ θ :

| θ | $x_1 = 0$ | $x_2 = 1$ |
|-----------------|-----------|-----------|
| $g(\theta_1 x)$ | 7/16 | 1/3 |
| $g(\theta_2 x)$ | 9/16 | 2/3 |

3.8 التوزيعات القبلية المرافقة

CONJUGATE PRIOR DISTRIBUTION

رأينا من خلال الأمثلة السابقة أنه بالإمكان وبسهولة إيجاد التوزيع البعدي لـ θ بناءً على معرفة التوزيع القبلي لـ θ ، وهذا ما كنا نفترضه دائماً. لكن المسألة ليست بهذه البساطة، حيث في مسائل كثيرة يكون التوزيع القبلي لـ θ غير معلوم، وبالتالي يجب تعيينه.

توجد عدة طرق لاختيار التوزيعات القبلية لـ θ أهمها اثنان:

1. التوزيعات القبلية المرافقة:

2. التوزيعات القبلية غير المُعلِّمة.

وسندرس في هذا البند الطريقة الأولى.

رأينا في المثال (1.2.8) أن كلا التوزيعين القبلي والبعدي لـ θ عضو في عائلة توزيعات بيتا $Be(u_1, u_2)$ ، حيث التوزيع القبلي $Be(2, 2)$ والتوزيع البعدي

و كذلك رأينا في المثال (2.2.8) أن التوزيع القبلي والبعدي لـ Θ هما على الترتيب $\Gamma\left(2, \frac{1}{3}\right)$ و $\Gamma\left(t+2, \frac{1}{n-3}\right)$ ، أي كلاهما عضو في عائلة التوزيعات الجماوية $\Gamma(\alpha, \beta)$. ونلاحظ نفس الصفة في المثال (3.2.8). وبعبارة أخرى، نلاحظ في الأمثلة الثلاث أن التوزيع القبلي والبعدي لـ Θ هما نفس النموذج الإحصائي. وفي مثل تلك الحالات يقال عن التوزيع القبلي $g(\theta)$ أنه مرافق للتوزيع الاحتمالي الذي سحبت منه العينة العشوائية (توزيع مجتمع الصفة المدروسة G).

تعريف 1.3.8

يقال عن مجموعة التوزيعات القبلية لـ Θ أنها تشكل عائلة G مرافقة للتوزيع الاحتمالي الذي سحبت منه العينة العشوائية إذا كان التوزيع البعدي لـ Θ ، المشتق بناءً على توزيع قبلي $g(\theta) \in G$ ، ينتمي إلى نفس عائلة التوزيعات التي ينتمي إليها التوزيع القبلي $g(\theta)$ مهما كانت العينة المشاهدة x . وتسمى هذه الخاصية أحياناً بخاصية الانغلاق تحت المعاينة (closed under sampling).

وتصبح المسألة الآن: كيف نحصل على التوزيع القبلي المرافق؟

لنفترض للتبسيط أن $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع أسّي:

$$f(x|\theta) = e^{A(\theta)B(x)+C(\theta)+D(x)}$$

عندئذ دالة المعقولة L (كدالة في θ عند عينة مشاهدة x):

$$L(x|\theta) = L(\theta) = e^{A(\theta)\sum B(x_i)+nC(\theta)+\sum D(x_i)}$$

ومن ثم يمكن كتابة:

$$L(\theta) = L(\theta, n, \sum B(x_i)) \propto e^{nC(\theta)+A(\theta)\sum B(x_i)} \quad \dots(1)$$

إذا اخترنا التوزيع القبلي لـ Θ متناسب مع دالة المعقولة، أي أن:

$$g(\theta; a_1, b_1) \propto L(\theta; a_1, b_1) \propto e^{a_1 C(\theta) + b_1 A(\theta)} \quad \dots (2)$$

وبدمج (ضريباً) الدالتين الواردتين في الطرف الأيمن في (1) و (2)، وبأخذ التوزيع البعدي لـ Θ متناسباً مع العبارة الناتجة عن الدمج، نجد:

$$g(\theta | x; a_2, b_2) \propto e^{a_2 C(\theta) + b_2 A(\theta)}$$

حيث أن $a_2 = a_1 + n$ و $b_2 = b_1 + \sum B(x_i)$ وهذا يعني أن التوزيع البعدي لـ Θ ينتمي لنفس عائلة التوزيعات، التي ينتمي إليها التوزيع القبلي لـ Θ ، أي أن التوزيع القبلي $g(\theta; a_1, b_1)$ هو توزيع مرافق للتوزيع الاحتمالي $f(x|\theta)$.

مثال 1.3.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع بواسون:

$$f(x|\theta) = \frac{\theta^x}{x!} e^{-\theta} \quad ; \quad x = 0, 1, \dots$$

فأوجد توزيع قبلي مرافق، ومن ثم أوجد التوزيع البعدي بناءً عليه.

إن دالة المعقولة:

$$L(x|\theta) = \frac{\theta^{\sum x_i}}{\prod_1^n (x_i!)} e^{-n\theta} \quad x_i = 0, 1, \dots$$

ويمكن كتابتها على الصورة:

$$L(\theta; n, t) \propto \theta^t e^{-n\theta} \quad ; \quad t = \sum_{i=1}^n x_i$$

لذلك نأخذ التوزيع القبلي:

$$g(\theta; a_1, b_1) \propto \theta^{a_1} e^{-b_1 \theta} \quad ; \quad \theta > 0$$

وهذا ما هو إلا توزيع $\Gamma\left(a_1 + 1, \frac{1}{b_1}\right)$ ، أي أن:

$$g(\theta; \alpha_1, b_1) = \frac{b_1^{\alpha_1+1}}{\Gamma(\alpha_1+1)} \theta^{\alpha_1} e^{-b_1\theta} \quad ; \quad \theta > 0 \quad \dots(1)$$

حيث أن α_1, b_1 ($\alpha_1 > -1, b_1 > 0$) ثوابت التوزيع. وبالتالي التوزيع البعدي لـ Θ يكون:

$$g(\theta|x) \propto \theta^{\alpha_1+t} e^{-(n+b_1)\theta} \quad ; \quad \theta > 0$$

وهذا عبارة عن توزيع $\Gamma\left(\alpha_1+t+1, \frac{1}{n+b_1}\right)$ ، حيث أن α_1, b_1 ثوابت التوزيع، أي أن:

$$g(\theta|x) = \frac{(n+b_1)^{\alpha_1+t+1}}{\Gamma(\alpha_1+t+1)} \theta^{\alpha_1+t} e^{-(n+b_1)\theta} \quad ; \quad \theta > 0$$

بما أن التوزيع القبلي (1) والتوزيع البعدي (2) لـ Θ عضوان في عائلة التوزيعات الجماوية $\Gamma(\alpha, \beta)$ ، فإن التوزيع (1) هو توزيع قبلي لـ Θ مرافق للتوزيع الذي سحبت منه العينة العشوائية x .

وبشكل عام إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع $f(x|\theta)$ ، وكانت $L(\theta) = L(x|\theta)$ دالة المعقولة. فيمكن كتابة دالة المعقولة على الصورة:

$$L(\theta; \alpha)$$

حيث أن α هي ثوابت دالة المعقولة باعتبارها دالة في θ . وإذا افترضنا التوزيع القبلي $g(\theta)$ لـ Θ على أنه متناسب مع دالة المعقولة، أي أن:

$$g(\theta; \alpha_1) \propto L(\theta; \alpha_1)$$

حيث α_1 هي ثوابت التوزيع القبلي. بدمج دالة الإمكان مع التوزيع القبلي (ضرباً)، وأخذ التوزيع القبلي متناسباً مع هذا الجداء نحصل على التوزيع البعدي لـ Θ ، أي أن:

$$g(\theta|x; \alpha_2) \propto g(\theta; \alpha_1) L(\theta; \alpha) \propto L(\theta; \alpha_1) L(\theta; \alpha) \propto L(\theta; \alpha_2)$$

حيث α_2 هي ثوابت التوزيع البعدي لـ Θ وهي دالة في (α, α_1) .

مثال 2.3.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \frac{1}{\theta} \quad ; \quad 0 < x < \theta$$

فأوجد توزيع قبلي مرافق، ومن ثم أوجد التوزيع البعدي لـ Θ .

إن دالة المعقولة:

$$L(\theta; n) = \frac{1}{\theta^n} \quad ; \quad \theta > x_{(n)}$$

راجع علاقة (11.2.4). بأخذ التوزيع القبلي لـ Θ :

$$g(\theta; a, b) \propto \frac{1}{\theta^{a+1}} \quad ; \quad \theta > b$$

حيث $a, b > 0$ ثوابت التوزيع. ويحسب ثابت التناسب c_1 على النحو الآتي:

$$\int_b^{\infty} g(\theta; a, b) d\theta = c_1 \int_b^{\infty} \frac{1}{\theta^{a+1}} d\theta = 1 \Rightarrow c_1 = ab^a$$

نحصل على التوزيع القبلي لـ Θ :

$$g(\theta) = g(\theta; a + b) = \frac{ab^a}{\theta^{a+1}} \quad ; \quad \theta > b$$

وبالتالي فالتوزيع البعدي لـ Θ :

$$g(\theta|x) \propto \frac{1}{\theta^{n+a+1}} \quad ; \quad \theta > t = \max(b, x_{(n)})$$

ويعين ثابت التناسب c_2 على النحو الآتي:

$$\int_t^{\infty} g(\theta|x) d\theta = c_2 \int_t^{\infty} \frac{d\theta}{\theta^{n+a+1}} = 1 \Rightarrow c_2 = (n+a)t^{n+a}$$

أي أن التوزيع البعدي لـ Θ هو:

$$g(\theta|x) = \frac{(n+a)t^{n+a}}{\theta^{n+a+1}} ; \theta > t$$

مثال 3.3.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = C_n^x \theta^x (1-\theta)^{n-x} ; x = 0, 1, \dots, n$$

فأوجد التوزيع البعدي لـ Θ .

بما أن دالة المعقولة:

$$L(\theta) = L(x|\theta) = \prod_{i=1}^n C_n^{x_i} \theta^{x_i} (1-\theta)^{n-x_i} \propto \theta^t (1-\theta)^{n^2-t} ; 0 < \theta < 1, t = \sum_1^n x_i$$

فإن التوزيع القبلي:

$$g(\theta) \propto \theta^a (1-\theta)^b$$

ومن ثم فالتوزيع البعدي:

$$g(\theta|x) \propto \theta^{a+t} (1-\theta)^{b+n^2-t}$$

وهذا ما هو إلا توزيع $Be(a+t-1, b+n^2-t-1)$ ، أي أن:

$$g(\theta|x) = \frac{1}{Be(a+t-1, b+n^2-t-1)} \theta^{a+t} (1-\theta)^{b+n^2-t} ; 0 < \theta < 1$$

وهو المطلوب.

4.8 التوزيعات القبلية غير المُعلِّمة

NON-INFORMATIVE PRIOR DISTRIBUTIONS

في حالات عدة تكون معلوماتنا القبلية (قبل سحب عينة عشوائية) قليلة أو نادرة حول المعلمة θ ، بل شبه معدومة بحيث لا تتجاوز معرفتنا كون θ متغيرة ويمكن اعتبارها قيمة لتغير عشوائي Θ . ونرغب في تمثيل هذه المعرفة البسيطة بتوزيع احتمالي يعبر عنها. تدعى مثل هذه التوزيعات الاحتمالية القبلية بالتوزيعات القبلية غير المُعلِّمة (non-informative priors distribution) وأحياناً تسمى بالتوزيعات القبلية الجاهلة (ignorance prior distribution)، وهي عبارة عن توزيعات تعبر عن المعرفة القليلة أو شبه المعدومة، وتوافق الحالة التي تكون المعلومات المتوفرة لدينا حول المعلمة θ قبل المعاينة ليست ذات أهمية بالمقارنة مع المعلومات المتوقع الحصول عليها من العينة العشوائية.

إن حالة المعرفة شبه المعدومة أو المعرفة البسيطة المحدودة حول المعلمة تفترض عدم التمييز بين القيم المختلفة الممكنة لهذه المعلمة، أي إعطائها نفس الوزن أو الأهمية. وتوجد عدة طرق للتعبير عن ذلك، نذكر منها:

1. التوزيع المنتظم

وهنا نميز حالتين:

الحالة الأولى: إذا كانت المعلمة θ تأخذ قيمة في مدى محدود (a, b) أو في المدى $(-\infty, +\infty)$ ، فنختار عندئذٍ توزيعاً قبلياً منتظماً Θ على هذه الفترة.

إذا كانت $a < \theta < b$ ، فإن:

$$g(\theta) = \frac{1}{b-a} \quad (1.4.8)$$

وإذا كانت $-\infty < \theta < \infty$ ، فإن:

$$g(\theta) \propto d\theta \quad ; \quad -\infty < \theta < \infty \quad (2.4.8)$$

الحالة الثانية: إذا كانت المعلمة θ تأخذ قيماً في المدى $(0, \infty)$ ، فإننا نختار توزيعاً قبلياً منتظماً لـ $\tau(\theta) = \ln \theta$ على الفترة $(-\infty, +\infty)$ ، أي أن:

$$g(\theta) \propto \frac{d\theta}{\theta} \quad ; \quad 0 < \theta < \infty \quad (3.4.8)$$

نلاحظ أن التوزيعات القبلية غير المعلمة لـ Θ في (2.4.8) و (3.4.8) هي توزيعات غير تامة أو ناقصة (*improper*) لأن تكامل هذه التوزيعات على فضاء المعلمة θ يعطي ما لانهاية (∞) . وهذه ليست مشكلة عملياً لأنه يمكن استخدام التوزيع الناقض كدالة وزن تخصص أوزاناً متساوية على مسافة لانهاية.

2. قاعدة عدم الاختلاف أو الثبات (invariance)

هذه الطريقة للحصول على التوزيعات القبلية غير المعلمة مبنية على افتراض أن العنصر الاحتمالي في التوزيع القبلي لا يتغير تحت تأثير أي تحويل. وهذا الافتراض يبرر اختيار التوزيع القبلي ليتناسب مع الجذر التربيعي الموجب لمعلومات فيشر، أي أن:

$$g(\theta) \propto \sqrt{i(\theta)} \quad (4.4.8)$$

مثال 1.4.8

إذا كان X متغير عشوائي توزيعه:

$$f(x|\theta) = \theta^x (1-\theta)^{1-x} \quad ; \quad x = 0, 1, \quad 0 < \theta < 1$$

أوجد توزيع قبلي غير مُعلم للمتغير Θ .

بما أن $0 < \theta < 1$ ، فحسب العلاقة (1.4.8):

$$g(\theta) = 1 \quad ; \quad 0 < \theta < 1$$

يعتبر توزيع قبلي غير مُعلم.

ويمكن الحصول على توزيع قبلي غير مُعَلِّم لـ θ باستخدام معلومات فيشر [العلاقة (4.4.8)]:

$$\ln f(x|\theta) = x \ln \theta + (1-x) \ln(1-\theta)$$

$$\frac{\partial \ln f(x|\theta)}{\partial \theta} = \frac{x}{\theta} - \frac{1-x}{1-\theta}$$

$$\frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} = -\frac{x}{\theta^2} - \frac{1-x}{(1-\theta)^2}$$

$$i(\theta) = -E \left[\frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} \right] = \frac{1}{\theta(1-\theta)}$$

وعلى ذلك فإن:

$$g(\theta) \propto \frac{1}{\sqrt{\theta(1-\theta)}}$$

وهناك توزيع قبلي آخر غير مُعَلِّم وغير تام ويستخدم في حالة توزيع ذي الحدين وتوزيع بيرنولي، وهو:

$$g(\theta) \propto \frac{1}{\theta(1-\theta)} \quad (5.4.8)$$

مثال 2.4.8

إذا كان X متغير عشوائي توزيعه:

$$f(x|\theta) = C_n^x \theta^x (1-\theta)^{n-x} \quad ; \quad x = 0, 1, \dots, n, \quad 0 < \theta < 1$$

أوجد توزيع قبلي غير مُعَلِّم للمتغير θ .

بما أن $0 < \theta < 1$ ، فإن التوزيع القبلي المنتظم:

$$g(\theta) = 1 \quad ; \quad 0 < \theta < 1$$

يعتبر توزيع قبلي غير مُعَلِّم لـ θ .

ويمكن الحصول على توزيع قبلي لـ Θ باستخدام معلومات فيشر:

$$\ln f(x|\theta) = \ln C_n^x + x \ln \theta + (n-x) \ln(1-\theta)$$

$$\frac{\partial \ln f(x|\theta)}{\partial \theta} = \frac{x}{\theta} - \frac{n-x}{1-\theta}$$

$$\frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} = -\left[\frac{x}{\theta^2} + \frac{n-x}{(1-\theta)^2} \right]$$

$$i(\theta) = -E\left[\frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} \right] = E\left[\frac{X}{\theta^2} + \frac{n-X}{(1-\theta)^2} \right] = \frac{n}{\theta} - \frac{n}{1-\theta} = \frac{n}{\theta(1-\theta)}$$

ومن ثم:

$$g(\theta) \propto \sqrt{\frac{n}{\theta(1-\theta)}}$$

مثال 3.4.8

بفرض X متغير عشوائي توزيعه:

$$f(x|\theta) = \theta e^{-\theta x} \quad ; \quad x > 0, \theta > 0$$

اقترح توزيع قبلي غير معلّم لـ Θ .

بما أن $0 < \theta < \infty$ ، فإن:

$$g(\theta) \propto \frac{1}{\theta}$$

وباستخدام معلومات فيشر:

$$\ln f(x|\theta) = \ln \theta - \theta x$$

$$\frac{\partial \ln f(x|\theta)}{\partial \theta} = \frac{1}{\theta} - x, \quad \frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} = -\frac{1}{\theta^2}$$

$$i(\theta) = -E \left[\frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} \right] = \frac{1}{\theta^2}$$

وعلى ذلك:

$$g(\theta) \propto \frac{1}{\theta}$$

5.8 حالة عدة معالم

اقتصر بحثنا فيما سبق من هذا الفصل على حالة مجتمع توزيعه $f(x|\theta)$ يحتوي على معلمة غير معلومة وحيدة البعد (حقيقية). سندرس الآن الحالة التي تكون فيها θ متعددة الأبعاد ولتكن $k > 1$; $\theta = (\theta_1, \dots, \theta_k)$.

إذا كان اهتمامنا يتركز على إحدى مركبات θ (معلمة وحيدة البعد)، فإن المركبات الأخرى تعتبر معالم مزعجة أو مقلقة لنا ولا نحتاجها، وبالتالي نرغب في التخلص منها، وهذا ممكن بإيجاد التوزيع الهامشي للمتغير الذي يعيننا. فمثلاً، بفرض $\theta = (\theta_1, \theta_2)$ ، فالتوزيع البعدي المشترك لـ θ_1, θ_2 عند $X = x$ نرمز له بـ $g(\theta_1, \theta_2 | x)$. وإذا كان اهتمامنا يقتصر على المعلمة θ_1 ، فإن المعلمة θ_2 تعتبر مقلقة أو مزعجة، ويمكن التخلص منها بالحصول على التوزيع البعدي الهامشي للمتغير θ_1 على النحو الآتي:

$$g(\theta_1 | x) = \begin{cases} \int g(\theta_1, \theta_2 | x) d\theta_2 \\ \sum_{\theta_2} g(\theta_1, \theta_2 | x) \end{cases}$$

مثال 1.5.8

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع $N(\theta, \phi)$ ، وكان المتغيران θ, ϕ مستقلان، فأوجد التوزيع البعدي لكل من θ, ϕ .

بما أن المتغيرين Θ, Φ مستقلان، فيمكن اقتراح التوزيع القبلي لـ (Θ, Φ) :

$$g(\theta, \phi) \propto \frac{d\theta d\phi}{\phi}$$

وكما نعلم دالة المعقولية:

$$L(\mathbf{x}|\theta, \phi) = \left(\frac{1}{2\pi\phi}\right)^{n/2} e^{-\frac{\sum(x_i - \theta)^2}{2\phi}}$$

وعلى ذلك، فإن التوزيع البعدي لـ (Θ, Φ) يكون:

$$L(\mathbf{x}|\theta, \phi) \propto \frac{e^{-\frac{\sum(x_i - \theta)^2}{2\phi}}}{\phi^{\frac{n}{2}+1}}$$

وحيث أن:

$$\sum_{i=1}^n (x_i - \theta) = \sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \theta)^2 = nS^2 + n(\bar{x} - \theta)^2 ; S^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

فإن:

$$g(\theta, \phi|\mathbf{x}) \propto \frac{e^{-\frac{ne^2 + n(\bar{x} - \theta)^2}{2\phi}}}{\phi^{\frac{n}{2}+1}}$$

بمكاملة الطرف الأيمن بالنسبة لـ Φ نحصل على التوزيع البعدي الهامشي لـ Θ :

$$g(\theta|\mathbf{x}) \propto \left[\frac{1}{ns^2 + n(\theta - \bar{x})^2} \right]^{n/2} \propto 1 / \left[1 + \frac{(\theta - \bar{x})^2}{s^2} \right]^{n/2}$$

وبوضع:

$$t = \frac{(\theta - \bar{x})}{s} \sqrt{n-1}$$

حيث t يتبع توزيع $S(n-1)$ [راجع المبرهنة (5.9.3)], نجد:

$$g(\theta|x) \propto 1 / \left[1 + \frac{t^2}{n-1} \right]^{n/2}$$

وبشكل مشابه نجد التوزيع البعدي الهامشي لـ Φ :

$$g(\phi|x) \propto \frac{e^{-\frac{ns^2}{2\phi}}}{\phi^{\frac{n}{2}+1}} \int_{-\infty}^{+\infty} e^{-\frac{n(\theta-\bar{x})^2}{2\phi}} d\theta \propto \frac{\sqrt{2\pi} e^{-\frac{ns^2}{2\phi}}}{\phi^{\frac{n}{2}+1}} \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi\phi}} e^{-\frac{n(\theta-\bar{x})^2}{2\phi}} d\theta$$

وبملاحظة أن التكامل الأخير يساوي 1، نجد:

$$g(\phi|x) \propto \frac{e^{-\frac{ns^2}{2\phi}}}{\phi^{\frac{n+1}{2}}} = \left(\frac{1}{\phi} \right)^{\frac{n+1}{2}} e^{-\frac{ns^2}{2\phi}}$$

وهذا يعني أن $\tau(\theta, \phi) = \frac{1}{\theta}$ يتبع توزيع جاما $\Gamma\left(\frac{n+3}{2}, \frac{2}{ns^2}\right)$ ، ومن ثم فإن:

$$\mathcal{L}\left(\frac{ns^2}{\Phi}\right) = \chi_{(n-1)}^2$$

مثال 2.5.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \theta_1 e^{-\theta_1 x} \quad ; \quad x > 0$$

وكانت $y = (y_1, \dots, y_n)$ عينة عشوائية من توزيع:

$$f(y|\theta) = \theta_2 e^{-\theta_2 y} \quad ; \quad y > 0$$

أوجد توزيع قبلي لـ $\Theta = (\Theta_1, \Theta_2)$ ، ثم أوجد التوزيع البعدي لـ $\frac{\Theta_1}{\Theta_2}$.

بفرض أن التوزيعين القبليين لـ Θ_1, Θ_2 مستقلان، فإن:

$$g(\theta_1, \theta_2) = g(\theta_1)g(\theta_2) \propto \frac{1}{\theta_1\theta_2}$$

ودالة المعقولة:

$$L(\theta_1, \theta_2 | \mathbf{x}, \mathbf{y}) = \theta_1^m \theta_2^n e^{-\theta_1 t - \theta_2 u} \quad ; \quad t = \sum_1^m x_i, \quad u = \sum_1^n y_i$$

وعلى ذلك فالتوزيع البعدي لـ $\Theta = (\Theta_1, \Theta_2)$ هو:

$$g(\theta | \mathbf{x}, \mathbf{y}) \propto \theta_1^{m-1} \theta_2^{n-1} e^{-\theta_1 t - \theta_2 u}$$

$$g(\theta | \mathbf{x}, \mathbf{y}) \propto (\theta_1^{m-1} e^{-t\theta_1}) (\theta_2^{n-1} e^{-u\theta_2})$$

وباستعمال حقيقة أن تكامل دالة كثافة توزيع جاما (20.3.2) من 0 إلى ∞ يساوي الواحد، أي أن:

$$\int_0^{\infty} x^{\alpha-1} e^{-x/\beta} dx = \beta^\alpha \Gamma(\alpha)$$

نجد:

$$L(\theta_1, \theta_2 | \mathbf{x}, \mathbf{y}) = \frac{t^m u^n}{\Gamma(m)\Gamma(n)} \theta_1^{m-1} \theta_2^{n-1} e^{-t\theta_1 - u\theta_2} = g(\theta_1 | \mathbf{x}) g(\theta_2 | \mathbf{y})$$

وهذا يعني أن التوزيعين البعديين لـ Θ_1 و Θ_2 مستقلان، وأن:

$$\mathcal{L}(\Theta_1) = \Gamma\left(m, \frac{1}{t}\right)$$

$$\mathcal{L}(\Theta_2) = \Gamma\left(n, \frac{1}{u}\right)$$

وحسب المبرهنة (4.3.2) فإن:

$$\mathcal{L}\left(T = \sum_1^m X_i\right) \in \Gamma\left(m, \frac{1}{\theta_1}\right)$$

$$\mathcal{L}\left(T = \sum_1^n Y_i\right) \in \Gamma\left(n, \frac{1}{\theta_2}\right)$$

ومن ثم:

$$\mathcal{L}(2\Theta_1 T) = \chi_{2m}^2 \quad , \quad \mathcal{L}(2\Theta_2 T) = \chi_{2n}^2$$

وبالتالي حسب المرهنة (9.3.2) فإن:

$$L\left(\frac{2\theta_1 T/2m = \frac{nT}{mU} \Theta_1}{2\theta_2 U/2n} = F_{2m,2n}\right)$$

BAYES POINT ESTIMATE

6.8 تقدير بيز بنقطة

لاحظنا مما سبق أن التوزيع البعدي يحل محل دالة المعقولة، حيث يشتمل على المعلومات المتوفرة حول المعلمة θ قبل الحصول على عينة عشوائية $x = (x_1, \dots, x_n)$ من مجتمع الصفة المدروسة ξ ، بالإضافة إلى المعلومات التي تقدمها العينة x حول هذه المعلمة. وبالتالي لتقدير المعلمة θ يمكن استخدام نفس الأسلوب الذي أتبع باستخدام دالة المعقولة $L(x|\theta)$ لتقدير θ . وبعبارة أخرى، يمكن تقدير المعلمة θ بالقيمة التي تعظم التوزيع البعدي، أي بموال التوزيع البعدي لـ Θ . كما يمكن استخدام أحد مقاييس التزعة المركزية الأخرى للتوزيع البعدي لـ Θ كالتوسط والوسيط لتقدير المعلمة θ ، ويستخدم عادة متوسط (القيمة المتوقعة) التوزيع البعدي لـ Θ كتقدير نقطة لـ θ . كما يمكن تقدير أي دالة معلمية $\tau(\theta)$ بالقيمة المتوقعة لـ $\tau(\Theta)$.

إذا رمزنا بـ θ^* و $\tau^*(\theta)$ لتقديري بيز بنقطة لـ θ و $\tau(\theta)$ على الترتيب، الموافقين للتوزيع القبلي $g(\theta)$ ، فإن:

$$\theta^* = E(\Theta|x) = \begin{cases} \int \theta g(\theta|x) d\theta \\ \sum_0^1 \theta g(\theta|x) \end{cases} \quad (1.6.8)$$

$$\tau^*(\theta) = E[\tau(\Theta)|x] = \begin{cases} \int \tau(\theta) g(\theta|x) d\theta \\ \sum_0^1 \tau(\theta) g(\theta|x) \end{cases} \quad (2.6.8)$$

نلاحظ وجود تشابه بين تقدير بيز بنقطة لـ θ وتقدير بيمان لمعلمة الموضوع θ .

مثال 1.6.8

لتكن $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \theta^x (1-\theta)^{1-x} \quad ; \quad x = 0, 1$$

وأن التوزيع القبلي لـ Θ هو $R(0,1)$. أوجد تقدير بيز لـ θ و $\tau(\theta) = \theta(1-\theta)$.

بما أن:

$$f(x|\theta) = \theta^t (1-\theta)^{n-t} \quad ; \quad t = \sum_{i=1}^n x_i$$

$$f(x) = \int_0^1 \theta^t (1-\theta)^{n-t} d\theta = \beta(t+1, n-t+1)$$

فإن:

$$g(\theta|x) = \frac{g(\theta)f(x|\theta)}{f(x)} = \frac{1}{\beta(t+1, n-t+1)} \theta^t (1-\theta)^{n-t} \quad ; \quad 0 \leq \theta \leq 1$$

وعلى ذلك فإن تقدير بيز بنقطة للمعلمة θ الموافق للتوزيع القبلي $R(0,1)$

هو:

$$\begin{aligned}
 E(\Theta|x) &= \frac{1}{\beta(t+1, n-t+1)} \int_0^1 \theta^{t+1} (1-\theta)^{n-t} d\theta \\
 &= \frac{\beta(t+2, n-t+1)}{\beta(t+1, n-t+1)} = \frac{\Gamma(t+2)\Gamma(n-t+1)\Gamma(n+2)}{\Gamma(t+1)\Gamma(n-t+1)\Gamma(n+3)} \\
 &= \frac{t+1}{n+2} = \frac{\sum x_i + 1}{n+2}
 \end{aligned}$$

ومن ثم فمقدّر بييز لـ θ الموافق لتوزيع قبلي منظم $R(0,1)$:

$$\theta^*(X) = E(\Theta|X) = \frac{\sum X_i + 1}{n+2}$$

نلاحظ أن مقدّر المعقولية لـ θ هو $\sum X_i/n$ وهو مقدّر غير متحيز، بينما مقدّر بييز لـ θ متحيز.

للحصول على مقدّر بييز لـ $\tau(\theta) = \theta(1-\theta)$ نحسب:

$$\begin{aligned}
 E[\tau(\Theta)|x] &= \frac{1}{\beta(t+1, n-t+1)} \int_0^1 \theta^{t+1} (1-\theta)^{n-t+1} d\theta \\
 &= \frac{\beta(t+2, n-t+2)}{\beta(t+1, n-t+1)} = \frac{(t+1)(n-t+1)}{(n+3)(n+2)} = \frac{(\sum x_i + 1)(n - \sum x_i + 1)}{(n+3)(n+2)}
 \end{aligned}$$

ومن ثم مقدّر بييز لـ $\theta(1-\theta)$ الموافق للتوزيع القبلي $R(0,1)$ هو:

$$\frac{(\sum X_i + 1)(n - \sum X_i + 1)}{(n+3)(n+2)}$$

مثال 2.6.8

إذا كانت $X = (X_1, \dots, X_n)$ عينة عشوائية من توزيع بيرنولي $B(1, \theta)$ ، وكان التوزيع القبلي لـ Θ هو $R(0,1)$ ، فأوجد مقدّر بييز للمعلمة θ .

بما أن التوزيع القبلي لـ Θ :

$$g(\theta) = 1 \quad ; \quad 0 < \theta < 1$$

فهذا يعني أن معلوماتنا السابقة حول المعلمة θ (قبل الحصول على عينة عشوائية) قليلة جداً، لذا نفترض أن جميع قيم Θ متساوية الإمكانية، حيث لا يوجد مبرر لإعطاء بعض قيم Θ أهمية أكبر من غيرها.

ويمكن التأكد بسهولة أن التوزيع البعدي لـ Θ :

$$g(\theta|\mathbf{x}) = \frac{1}{b(t+1, n-t+1)} \theta^t (1-\theta)^{n-t} \quad ; \quad 0 < \theta < 1$$

وبالتالي تقدير بيز لـ θ :

$$\begin{aligned} \theta^* = E(\Theta|\mathbf{x}) &= \frac{1}{\beta(t+1, n-t+1)} \int_0^1 \theta^{t+1} (1-\theta)^{n-t} dt \\ &= \frac{\beta(t+2, n-t+1)}{\beta(t+1, n-t+1)} = \frac{\Gamma(t+2)\Gamma(n-t+1)\Gamma(n+2)}{\Gamma(n+3)\Gamma(t+1)\Gamma(n-t+1)} \\ &= \frac{t+1}{n+2} \quad ; \quad t = \sum_1^n x_i \end{aligned}$$

أي أن مقدر بيز لـ θ :

$$\theta^*(\mathbf{X}) = E(\Theta|\mathbf{X}) = \left(1 + \sum_1^n X_i\right) / (n+2)$$

مثال 3.6.8

لتكن لدينا معطيات ونتائج المثال (2.2.8)، ونريد إيجاد تقدير بيز بنقطة للمعلمة θ الموافق للتوزيع القبلي $\Gamma\left(2, \frac{1}{2}\right)$.

بما أن:

$$g(\theta|\mathbf{x}) = \frac{(n+3)^{t+2}}{\Gamma(t+2)} \theta^{t+1} e^{-(n+1)\theta} \quad ; \quad \theta > 0$$

فإن تقدير بايز بنقطة للمعلمة θ :

$$\begin{aligned}\theta^* &= E(\Theta|\mathbf{x}) = \frac{(n+3)^{t+2}}{\Gamma(t+2)} \int_0^\infty \theta^{t+2} e^{-(n+1)\theta} d\theta \\ &= \frac{(n+3)^{t+2}}{\Gamma(t+2)} \frac{\Gamma(t+3)}{(n+3)^{t+3}} = \frac{t+2}{n+3} \quad ; \quad t = \sum_{i=1}^n x_i\end{aligned}$$

لأن:

$$\int_0^\infty \theta^{t+2} e^{-(n+1)\theta} d\theta = \frac{\Gamma(t+3)}{(n+3)^{t+3}}$$

وبناءً على تعريف دالة كثافة توزيع جاما وخواص دالة الكثافة [العلاقة (20.3.2)]. ومن ثم فمقدر بايز للمعلمة θ :

$$\theta^*(X) = \frac{T+2}{n+3} \quad ; \quad T = \sum_{i=1}^n X_i$$

مثال 4.6.8

إذا كانت لدينا معطيات ونتائج المثال (3.2.8)، فأوجد مقدر بايز للمعلمة θ ، الموافق لتوزيع قبلي $\Gamma\left(a+1, \frac{1}{b}\right)$:

بما أن:

$$g(\theta|\mathbf{x}) = \frac{(b+t)^{a+n+1}}{\Gamma(a+n+1)} \theta^{a+n} e^{-(b+t)\theta} \quad ; \quad \theta > 0$$

فإن:

$$\begin{aligned}\theta^* &= E(\Theta|\mathbf{x}) = \frac{(b+t)^{a+n+1}}{\Gamma(a+n+1)} \int_0^\infty \theta^{a+n+1} e^{-(b+t)\theta} d\theta \\ &= \frac{(b+t)^{a+n+1}}{\Gamma(a+n+1)} \frac{\Gamma(a+n+2)}{(b+t)^{a+n+2}} = \frac{a+n+1}{b+t} \quad ; \quad t = -\sum_{i=1}^n \ln x_i\end{aligned}$$

وبالتالي مقدر بيز لـ θ :

$$\theta^*(X) = \frac{a+n+1}{b+T} \quad ; \quad T = -\sum_{i=1}^n \ln X_i$$

مثال 5.6.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع $N(\theta, \sigma^2)$ ، وكان التوزيع القبلي للمتغير Θ هو $N(a, b^2)$ ، حيث a, b^2 مقادير ثابتة ومعلومة، فأوجد تقدير بيز للمعلمة θ .

كما نعلم \bar{X} إحصاء كافي للمعلمة θ وأن $L_0(\bar{X}) \in N\left(\theta, \frac{\sigma^2}{n}\right)$. وعلى ذلك فإن:

$$\begin{aligned} g(\theta|x) &= g(\theta)h(\bar{x}|\theta) \propto e^{-\frac{n(\bar{x}-\theta)^2}{2\sigma^2} - \frac{(\theta-a)^2}{2b^2}} \\ &= e^{-\frac{1}{2b^2\sigma^2}[nb^2(\bar{x}-\theta)^2 + \sigma^2(\theta-a)^2]} \\ &= e^{-\frac{nb^2+\sigma^2}{2b^2\sigma^2}\left[\theta^2 - 2\frac{nb^2\bar{x}+\sigma a^2}{nb^2+\sigma^2}\theta + \frac{nb^2\bar{x}^2+\sigma^2 a^2}{nb^2+\sigma^2}\right]} \\ &\propto e^{-\frac{nb^2+\sigma^2}{2b^2\sigma^2}\left(\theta - \frac{nb^2\bar{x}+\sigma a^2}{nb^2+\sigma^2}\right)^2} \end{aligned}$$

وبالتالي:

$$\begin{aligned} L(\Theta|x) &= N\left(\frac{nb^2\bar{x} + \sigma a^2}{nb^2 + \sigma^2}, \frac{b^2\sigma^2}{nb^2 + \sigma^2}\right) \\ &= N\left(\frac{b^2\bar{x} + (\sigma^2/n)a}{b^2 + (\sigma^2/n)}, \frac{b^2(\sigma^2/n)}{b^2 + (\sigma^2/n)}\right) \\ &= N(\theta^*, \sigma^{*2}) \end{aligned}$$

وعلى ذلك فإن تقدير بيز للمعلمة θ

$$\theta^* = \frac{b^2 \bar{x} + (\sigma^2/n)a}{b^2 + (\sigma^2/n)}$$

الموافق للتوزيع القبلي $N(a, b^2)$.

إذا كانت:

1. $b^2 = \infty$ ، فإن $\theta^* = \bar{x}$ وهو نفس تقدير المعقولة العظمى. وهذا يعني أن

المعلومات المتوفرة حول θ قبل سحب العينة قليلة جداً، وأن المعلومات مصدرها الأساسي معطيات العينة x .

2. $b^2 = 0$ ، فإن $\theta^* = a$. وهذا يعني مهما تكن العينة x فإن $\theta = a$ باحتمال

يساوي الواحد.

مثال 6.6.8

إذا كانت x ملاحظة مفردة على متغير عشوائي θ يخضع لتوزيع $B(n, \theta)$ ، وكان التوزيع القبلي لـ θ هو $Be(\alpha, \beta)$ ، فأوجد تقدير بييز للمعلمة θ .

بما أن:

$$f(x|\theta) = C_n^x \theta^x (1-\theta)^{n-x} \quad ; \quad x = 0, 1, \dots, n$$

$$g(\theta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} \quad ; \quad 0 < \theta < 1$$

ومن ثم:

$$f(x; \theta) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} C_n^x \theta^x (1-\theta)^{n-x}$$

$$= C_n^x \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \theta^{x+\alpha-1} (1-\theta)^{n-x+\beta-1}$$

$$f(x) = \int_0^1 f(x, \theta) d\theta = C_n^x \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \int_0^1 \theta^{x+\alpha-1} (1-\theta)^{n-x+\beta-1} d\theta$$

$$= C_n^x \frac{\Gamma(\alpha + \beta) \Gamma(\alpha + x) \Gamma(n - x + \beta)}{\Gamma(\alpha) \Gamma(\beta) \Gamma(n + \alpha + \beta)} ; \quad x = 0, 1, \dots, n$$

وعلى ذلك:

$$g(\theta|x) = \frac{f(x;\theta)}{f(x)} = \frac{\Gamma(n + \alpha + \beta)}{\Gamma(\alpha + x) \Gamma(n - x + \beta)} \theta^{x+\alpha-1} (1 - \theta)^{n-x+\beta-1} ; \quad 0 < \theta < 1$$

$$\begin{aligned} \theta^* = E(\theta|x) &= \frac{\Gamma(n + \alpha + \beta)}{\Gamma(\alpha + x) \Gamma(n - x + \beta)} \int_0^1 \theta^{x+\alpha} (1 - \theta)^{n-x+\beta-1} d\theta \\ &= \frac{\Gamma(n + \alpha + \beta)}{\Gamma(\alpha + x) \Gamma(n - x + \beta)} \frac{\Gamma(x + \alpha + 1) \Gamma(n - x + \beta)}{\Gamma(n + \alpha + \beta + 1)} \\ &= \frac{x + \alpha}{\alpha + \beta + n} \end{aligned}$$

7.8 تقدير بيز بفترة BAYES INTERVAL ESTIMATE

رأينا في البند السابق (6.8) أن تقدير بيز بنقطة لمعلمة θ هو عبارة عن قيمة وحيدة، وعادة تكون القيمة المتوقعة $E(\theta|x)$ ، لكن لم نرفق مثل هذا التقدير بأي مقياس يعبر عن درجة الثقة التي يتمتع بها. لذا في حالات عدة من المفيد استبدال التقدير بنقطة للمعلمة θ مجموعة من النقاط أي بفترة، التي تشتمل على القيمة الحقيقية للمعلمة θ باحتمال كبير γ . وكما أشرنا سابقاً فإن هذه الفترة تسمى بفترة ثقة لـ θ والاحتمال γ بمعامل الثقة (درجة الثقة).

إن طريقة بيز في بناء فترات ثقة تتمثل بما يلي:

لتكن $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع $f(x|\theta)$ ، الذي يعتمد على معلمة مجهولة، و $g(\theta|x)$ ، $g(\theta)$ التوزيع القبلي والبعدى على الترتيب للمتغير θ .


لتقدير المعلمة θ بفترة يتم البحث عن عددين:

$$t_1 = T_1(x) \quad , \quad t_2 = T_2(x) \quad ; \quad t_1 < t_2$$

بحققان، عند قيمة معينة مسبقاً γ ، الشرط الآتي:

$$\int_{t_1}^{t_2} g(\theta|x) d\theta = \gamma \Leftrightarrow P(t_1 < \Theta < t_2) = \gamma \quad (1.7.8)$$

تدعى الفترة (t_1, t_2) بـ $100\% \gamma$ فترة ثقة بايز للمعلمة θ ، وتبدو بوضوح على الشكل (1.7.8).



شكل (1.7.8)

نلاحظ أن الزوج (t_1, t_2) المحقق للعلاقة (1.7.8) ليس وحيداً، بل توجد أزواج عدة تحقق تلك العلاقة. ونفضل دائماً فترة الثقة (t_1, t_2) ذات أصغر طول، أي نبحث عن فترة الثقة (t_1, t_2) الموافقة لأصغر فرق $(t_2 - t_1)$ عند الشرط (1.7.8).

مثال 7.6.8

لتكن لدينا معطيات ونتائج المثال (5.6.8)، ونريد بناء فترة بايز بمعامل ثقة

$$\gamma = 1 - \alpha$$

بما أن:

$$g(\theta|x) = \frac{1}{\sigma^* \sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{\theta - \theta^*}{\sigma^*} \right)^2} ; \quad -\infty < \theta < +\infty$$

حيث:

$$\theta^* = \frac{b^2 \bar{x} + (\sigma^2/n)a}{b^2 + (\sigma^2/n)} , \quad \sigma^* = \frac{b^2 (\sigma^2/n)}{b^2 + (\sigma^2/n)}$$

وهذا يعني أن:

$$\mathcal{L}\left(\frac{\Theta - \theta^*}{\sigma^*}\right) = N(0,1)$$

ومن ثم البحث عن أقصر فترة (t_1, t_2) ، بحيث:

$$P(t_1 < \Theta < t_2) = \gamma$$

تكافئ البحث عن أقصر فترة (z_1, z_2) ، بحيث:

$$P\left(z_1 < \frac{\Theta - \theta^*}{\sigma^*} < z_2\right) = \gamma$$

لكن كما نعلم [راجع العلاقة (4.4.7)] أقصر فترة من الشكل (z_1, z_2) هي التي تقابل ذيلين متساويين الاحتمال، أي أن:

$$z_1 = -z_{\alpha/2} , \quad z_2 = z_{1-\alpha/2} = z_{\alpha/2}$$

وعلى ذلك فإن $100\% \gamma$ فترة ثقة يميز للمعلمة θ هي:

$$(\theta^* - \sigma^* z_{\alpha/2} < \theta < \theta^* + \sigma^* z_{\alpha/2})$$

مثال 8.6.8

مصنع لإنتاج المصابيح الكهربائية، عمر المصباح ξ مقدر بساعة إضاءة يتبع تقريباً التوزيع الطبيعي. بمتوسط غير معلوم θ وانحراف معياري يساوي 100 ساعة إضاءة. تشير الخبرة الماضية إلى أن θ قيمة لمتغير عشوائي طبيعي Θ بمتوسط 800 ساعة إضاءة وانحراف معياري 10 ساعات إضاءة. أخذت عينة عشوائية من 25 مصباحاً من إنتاج المصنع، فتبين أن متوسط عمر مصابيح هذه العينة يساوي 780 ساعة إضاءة. أوجد 95% فترة ثقة يميز للمعلمة θ .

بما أن، حسب الفرض:

$$f(x|\theta) = \frac{1}{(2\pi)^{25/2} 100^{25}} \exp\left[-\frac{1}{2} \sum_{i=1}^{25} \left(\frac{x_i - \theta}{100}\right)^2\right]; \quad -\infty < x_i < \infty, \quad i = 1, \dots, 25$$

$$g(\theta) = \frac{1}{10\sqrt{2\pi}} \exp\left[-\frac{1}{2} \left(\frac{\theta - 800}{10}\right)^2\right]; \quad -\infty < \theta < \infty$$

فإن:

$$\begin{aligned} f(x, \theta) &= g(\theta)f(x|\theta) = \\ &= \frac{1}{(2\pi)^{13} 10^{51}} \exp\left\{-\frac{1}{2} \left[\sum_{i=1}^{25} \left(\frac{x_i - \theta}{100}\right)^2 + \left(\frac{\theta - 800}{10}\right)^2 \right]\right\} \\ &= \frac{1}{(2\pi)^{13} 10^{51}} \exp\left[-\frac{1}{2} \sum_{i=1}^{25} \left(\frac{x_i - 780}{100}\right)^2\right] \times \\ &\times \exp\left\{-\frac{1}{2} \left[(25) \left(\frac{780 - \theta}{100}\right)^2 + \left(\frac{\theta - 800}{10}\right)^2 \right]\right\} \end{aligned}$$

لأن:

$$\sum_{i=1}^{25} (x_i - \theta)^2 = \sum_{i=1}^{25} (x_i - 780)^2 + 25(780 - \theta)^2$$

وباستخدام طريقة الإتمام إلى مربع كامل نجد:

$$25\left(\frac{780-\theta}{100}\right)^2 + \left(\frac{\theta-800}{10}\right)^2 = \frac{\theta^2 - 15920\theta + 635.28}{80} = \frac{(\theta-796)^2 + 1664}{80}$$

وبالتالي:

$$f(x;\theta) = k \exp\left[-\frac{1}{2}\left(\frac{\theta-796}{\sqrt{80}}\right)^2\right]$$

حيث k دالة في قيم العينة.

وعلى ذلك:

$$f(x) = \int_{-\infty}^{+\infty} f(x,\theta)d\theta = k\sqrt{2\pi}\sqrt{80} \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}\sqrt{80}} e^{-\frac{1}{2}\left[\frac{(\theta-796)}{\sqrt{80}}\right]^2} d\theta = k\sqrt{2\pi}\sqrt{80}$$

ومن ثم التوزيع البعدي لـ θ يكون:

$$g(\theta|x) = \frac{f(x,\theta)}{f(x)} = \frac{1}{\sqrt{2\pi}\sqrt{80}} \exp\left[-\frac{1}{2}\left(\frac{\theta-796}{80}\right)^2\right] ; \quad -\infty < \theta < \infty$$

وهذا يعني أن التوزيع البعدي لـ θ طبيعي. متوسط $\theta^* = 796$ وانحراف

معياري $\sigma^* = \sqrt{80}$ ، و 95% فتره ثقة يبيز تعطى على النحو الآتي:

$$\theta^* - 1.96\sigma^* < \theta < \theta^* + 1.96\sigma^*$$

أي أن:

$$796 - 1.96\sqrt{80} < \theta < 796 + 1.96\sqrt{80}$$

أو:

$$778.5 < \theta < 813.5$$

نحصل على نفس النتيجة باستخدام نتيجة المثال السابق، ووضع:

$$a = \theta^* = 796 \quad , \quad b^2 = \sigma^{*2} = 80 \quad , \quad \gamma = 0.95 \quad , \quad z_{\alpha/2} = z_{0.025} = 1.96$$

مثال 9.7.8

إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \theta x^{\theta-1} \quad ; \quad 0 \leq x \leq 1$$

وكان التوزيع القبلي لـ θ هو $g(\theta) \propto \frac{1}{\theta}$ ، فأوجد $\gamma 100\%$ فترة ثقة بييز للمعلمة θ .

بما أن $T(X) = -\sum_{i=1}^n \ln X_i$ إحصاء كافي للمعلمة θ وأن:

$$h(t|\theta) = \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{-t\theta} \quad ; \quad t > 0$$

[راجع المثال (3.2.4)]، فإن:

$$g(\theta|t) \propto g(\theta)h(t|\theta) \propto \theta^{n-1} e^{-t\theta}$$

وعلى ذلك:

$$g(\theta|t) = \frac{t^n}{\Gamma(n)} \theta^{n-1} e^{-t\theta} \quad ; \quad \theta > 0$$

ومن ثم يمكن التأكد بسهولة أن توزيع $\chi^2 = 2\theta T$ يخضع لتوزيع $\chi^2_{(2n)}$.

الآن يمكن إيجاد قيمتين $\alpha_1 + \alpha_2 = 1 - \gamma$ بحيث يحققان الشرط:

$$P(\chi^2_{1-\alpha_1, 2n} < 2\theta t < \chi^2_{\alpha_2, 2n}) = 0.95$$

ومن ثم:

$$P\left(\frac{\chi_{1-\alpha_1, 2n}^2}{2t} < \theta < \frac{\chi_{\alpha_2, 2n}^2}{2t}\right)$$

وكما نعلم أقصر فترة هي الموافقة لـ $\alpha_1, \alpha_2 = 0.025$. وبذلك تكون 95% فترة ثقة يميز للمعلمة θ هي من الشكل:

$$\left(\frac{\chi_{1-\alpha/2, 2n}^2}{2t}, \frac{\chi_{\alpha/2, 2n}^2}{2t}\right)$$

فمثلاً، إذا كان:

$$n = 10, \quad t = -\sum_1^{10} \ln x_i = 8, \quad \gamma = 0.95$$

فإن 95% فترة ثقة يميز للمعلمة θ هي:

$$\left(\frac{9.591}{16}, \frac{34.17}{16}\right) = (0.6, 2.1)$$

تمارين

1. إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = e^{-(x-\theta)}; \quad x \geq \theta, \quad -\infty < \theta < \infty$$

وكان التوزيع القبلي لـ θ هو:

$$g(\theta) = e^{-\theta}; \quad \theta > 0$$

فأوجد:

1. التوزيع البعدي لـ θ .
2. تقدير يميز بنقطة لـ θ الموافق للتوزيع القبلي $g(\theta)$.

2. لتكن $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \theta x^{\theta-1} ; \quad 0 < x < 1, \theta > 0$$

بافتراض أن التوزيع القبلي لـ θ هو:

$$g(\theta) = \frac{\lambda^r}{\Gamma(r)} \theta^{r-1} e^{-\theta\lambda} ; \quad \theta > 0$$

حيث أن r و λ مقدارين ثابتين معلومين.

1. ما هو التوزيع البعدي لـ θ .

2. أوجد مقدر بييز للمعلمة θ الموافق للتوزيع القبلي المعطى $g(\theta)$.

3. إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع $N(\theta, 1)$ وكان التوزيع

القبلي لـ θ هو $N(\mu, 1)$ ، فأوجد:

1. التوزيع البعدي لـ θ .

2. مقدر بييز للمعلمة θ الموافق للتوزيع القبلي $N(\mu, 1)$.

4. بفرض أن $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع $R(1, \theta)$ ، والتوزيع

القبلي لـ θ هو $R(0, 1)$ ، فأوجد التوزيع البعدي لـ θ ومن ثم مقدر بييز

للمعلمة الموافق للتوزيع القبلي $R(0, 1)$.

5. إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:

$$f(x|\theta) = \frac{1}{\theta} e^{-\theta x} ; \quad x > 0$$

فأوجد توزيع قبلي مرافق لـ θ ، ومن ثم أوجد التوزيع البعدي لـ θ .

6. إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع $N(\theta_1, \sigma_1^2)$ و

$y = (y_1, \dots, y_n)$ عينة عشوائية من توزيع $N(\theta_2, \sigma_2^2)$ ، وكانت العيتان

مستقلتان، وكان التوزيع البعدي لكل من Θ_1 و Θ_2 منتظم على الفترة $(-\infty, \infty)$ فأوجد:

1. التوزيع البعدي لـ $\Theta_1 - \Theta_2$.
 2. مقدر يميز للمعلمة $\theta_1 - \theta_2$.
 3. فترة يميز للفرق $\theta_1 - \theta_2$ بمعامل ثقة γ .
7. إذا كانت لدينا معطيات ونتائج المثال (3.4.8) فأوجد $100\gamma\%$ فترة ثقة للمعلمة θ .
8. إذا كانت لدينا معطيات ونتائج المثال (2.5.8) فأوجد $100\gamma\%$ فترة ثقة يميز للمعلمة $\theta_1 - \theta_2$.
9. إذا كانت $x = (x_1, \dots, x_n)$ عينة عشوائية من توزيع:
- $$f(x|\theta) = \theta(1 - \theta)^{x-1}, \quad x = 1, 2, \dots$$
- وكان التوزيع القبلي لـ Θ هو $R(0,1)$ ، فأوجد 95% فترة ثقة يميز للمعلمة θ .
10. إذا كانت لدينا معطيات التمرين (4)، فأوجد 90% فترة ثقة يميز للمعلمة θ .
11. إذا كانت لدينا معطيات التمرين (5)، فأوجد 95% فترة ثقة يميز للمعلمة θ .

المراجع العلمية

أولاً: المراجع باللغة العربية

1. د. أنيس كنجو، الإحصاء الرياضي، مطبعة زيد ثابت، 1979.
2. د. أنيس كنجو، الإحصاء وطرق تطبيقه في ميادين البحث العلمي، الجزء الأول والثاني، مؤسسة الرسالة، بيروت، 1987.
3. د. جلال مصطفى الصياد، الاستدلال الإحصائي، دار المريخ للنشر، الرياض، المملكة العربية السعودية، 1993.
4. د. عبدالحفيظ محمد فوزي مصطفى، نظرية الاحتمالات (I ، II)، أكاديمية الدراسات والعلوم الجوية، مصراته، ليبيا، 1997.

ثانياً: المراجع باللغة الإنجليزية

1. Alexander, M. M.; Franklin, A. G. and Duanc, C. B., *Introduction to The Theory of Statistics*, third edition, 1974.
2. Beaumout, G. P., *Intermediate Mathematical Statistics*, Champan and Hall, London and New York, 1980.
3. Hogg, R. V. and Craing, A. T., *Introduction to Mathematical Statistics*, Collier McMillan publisher, 1978.
4. Lymann, O., *An Introduction to Statistical Methods and Data Analysis*, Second edition, Duxbury press, Boston, USA, 1984.

5. Rohntgi, V. K., *An Introduction to Probability and Mathematical Statistics*, John Wiley and Sons, 1976.
6. Zacks, S., *Parametric Statistical Inference*, Pergamon press, 1981.

ثالثاً: المراجع باللغة الروسية

1. جرسيموفيتش، أ. ن.، الإحصاء الرياضي، الطبعة الثانية، العلوم، موسكو، 1983.
2. إيفتشينكو، ج. إ.، وميدفيدف، يو. إز، الإحصاء الرياضي، المدرسة العليا، موسكو، 1984.
3. جورمان، ب. إ.، نظرية الاحتمالات والإحصاء الرياضي، المدرسة العليا، موسكو، 1985.
4. كورولويوك، ه. ن.، نظرية الاحتمالات والإحصاء الرياضي، العلوم، موسكو، 1985.
5. بوروفكوف، أ. أ.، الإحصاء الرياضي: تقدير المعالم واختبار الفرضيات، العلوم، موسكو، 1984.
6. كليموف، ج. ب.، نظرية الاحتمالات والإحصاء الرياضي، جامعة موسكو، 1980.
7. كنيدينكا، ب. ف.، نظرية الاحتمالات، العلوم، موسكو، 1988.

ملحق الجداول الإحصائية

The Binomial Distribution جدول 1: توزيع ذي الحدين

$$P_n(m) = C_n^m P^m q^{n-m} \quad \text{جدول قيم الدالة:}$$

| | | <i>P</i> | | | | | | | | | | | |
|----------|----------|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|---|
| <i>n</i> | <i>m</i> | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | |
| 1 | 0 | .9900 | .9500 | .9000 | .8500 | .8000 | .7500 | .7000 | .6500 | .6000 | .5500 | .5000 | 1 |
| | 1 | .0100 | .0500 | .1000 | .1500 | .2000 | .2500 | .3000 | .3500 | .4000 | .4500 | .5000 | 0 |
| 2 | 0 | .9801 | .9025 | .8100 | .7225 | .6400 | .5625 | .4900 | .4225 | .3600 | .3025 | .2500 | 2 |
| | 1 | .0198 | .0950 | .1800 | .2550 | .3200 | .3750 | .4200 | .4550 | .4800 | .4950 | .5000 | 1 |
| | 2 | .0001 | .0025 | .0100 | .0225 | .0400 | .0625 | .0900 | .1225 | .1600 | .2025 | .2500 | 0 |
| 3 | 0 | .9703 | .8574 | .7290 | .6141 | .5120 | .4219 | .3430 | .2746 | .2160 | .1664 | .1250 | 3 |
| | 1 | .0294 | .1354 | .2430 | .3251 | .3840 | .4219 | .4410 | .4436 | .4320 | .4084 | .3750 | 2 |
| | 2 | .0003 | .0071 | .0270 | .0574 | .0960 | .1406 | .1890 | .2389 | .2880 | .3341 | .3750 | 1 |
| | 3 | .0000 | .0001 | .0010 | .0034 | .0080 | .0156 | .0270 | .0429 | .0640 | .0911 | .1250 | 0 |
| 4 | 0 | .9606 | .8145 | .6561 | .5220 | .4096 | .3164 | .2401 | .1785 | .1296 | .0915 | .0625 | 4 |
| | 1 | .0388 | .1715 | .2916 | .3685 | .4096 | .4219 | .4116 | .3845 | .3456 | .2995 | .2500 | 3 |
| | 2 | .0006 | .0135 | .0486 | .0975 | .1536 | .2109 | .2646 | .3105 | .3456 | .3676 | .3750 | 2 |
| | 3 | .0000 | .0005 | .0038 | .0115 | .0256 | .0469 | .0756 | .1115 | .1536 | .2005 | .2500 | 1 |
| | 4 | .0000 | .0000 | .0001 | .0005 | .0016 | .0039 | .0081 | .0150 | .0256 | .0410 | .0625 | 0 |
| 5 | 0 | .9510 | .7738 | .5905 | .4437 | .3277 | .2373 | .1681 | .1160 | .0778 | .0503 | .0312 | 5 |
| | 1 | .0480 | .2036 | .3280 | .3915 | .4096 | .3955 | .3602 | .3124 | .2592 | .2069 | .1562 | 4 |
| | 2 | .0010 | .0214 | .0729 | .1382 | .2048 | .2637 | .3087 | .3364 | .3456 | .3369 | .3125 | 3 |
| | 3 | .0000 | .0011 | .0081 | .0244 | .0512 | .0879 | .1323 | .1811 | .2304 | .2757 | .3126 | 2 |
| | 4 | .0000 | .0000 | .0004 | .0022 | .0064 | .0146 | .0284 | .0488 | .0768 | .1128 | .1562 | 1 |
| | 5 | .0000 | .0000 | .0000 | .0001 | .0003 | .0010 | .0024 | .0053 | .0102 | .0185 | .0312 | 0 |
| 6 | 0 | .9415 | .7351 | .5314 | .3771 | .2621 | .1780 | .1176 | .0754 | .0467 | .0277 | .0156 | 6 |
| | 1 | .0571 | .2321 | .3543 | .3993 | .3932 | .3560 | .3025 | .2437 | .1866 | .1359 | .0938 | 5 |
| | 2 | .0014 | .0305 | .0984 | .1762 | .2458 | .2966 | .3241 | .3280 | .3110 | .2780 | .2344 | 4 |
| | 3 | .0000 | .0021 | .0146 | .0415 | .0819 | .1318 | .1852 | .2355 | .2765 | .3032 | .3126 | 3 |
| | 4 | .0000 | .0001 | .0012 | .0055 | .0154 | .0330 | .0595 | .0951 | .1382 | .1861 | .2344 | 2 |
| | 5 | .0000 | .0000 | .0001 | .0004 | .0015 | .0044 | .0102 | .0205 | .0369 | .0609 | .0938 | 1 |
| | 6 | .0000 | .0000 | .0000 | .0000 | .0001 | .0002 | .0007 | .0018 | .0041 | .0083 | .0156 | 0 |
| 7 | 0 | .9321 | .6983 | .4783 | .3206 | .2097 | .1335 | .0824 | .0490 | .0280 | .0152 | .0078 | 7 |
| | 1 | .0659 | .2573 | .3720 | .3960 | .3670 | .3115 | .2471 | .1848 | .1306 | .0872 | .0647 | 6 |
| | 2 | .0020 | .0406 | .1240 | .2097 | .2753 | .3115 | .3177 | .2985 | .2613 | .2140 | .1641 | 5 |
| | 3 | .0000 | .0036 | .0230 | .0617 | .1147 | .1730 | .2269 | .2679 | .2903 | .2918 | .2734 | 4 |
| | 4 | .0000 | .0002 | .0026 | .0109 | .0287 | .0577 | .0972 | .1542 | .1935 | .2388 | .2734 | 3 |
| | 5 | .0000 | .0000 | .0002 | .0012 | .0043 | .0115 | .0250 | .0466 | .0774 | .1172 | .1641 | 2 |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | |
| | | <i>P</i> | | | | | | | | | | | |

تابع الجدول 1

p

| n | m | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | |
|----|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| 7 | 6 | .0000 | .0000 | .0000 | .0001 | .0004 | .0013 | .0036 | .0084 | .0172 | .0320 | .0547 | 1 |
| | 7 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0002 | .0006 | .0016 | .0037 | .0078 | 0 |
| 8 | 0 | .9227 | .6634 | .4305 | .2725 | .1678 | .1002 | .0576 | .0319 | .0168 | .0084 | .0039 | 8 |
| | 1 | .0746 | .2793 | .3826 | .3847 | .3355 | .2670 | .1977 | .1373 | .0896 | .0548 | .0312 | 7 |
| | 2 | .0026 | .0515 | .1488 | .2376 | .2936 | .3115 | .2965 | .2587 | .2090 | .1569 | .1094 | 6 |
| | 3 | .0001 | .0054 | .0331 | .0839 | .1468 | .2076 | .2541 | .2786 | .2787 | .2568 | .2188 | 5 |
| | 4 | .0000 | .0004 | .0046 | .0185 | .0459 | .0865 | .1361 | .1875 | .2322 | .2627 | .2734 | 4 |
| | 5 | .0000 | .0000 | .0004 | .0026 | .0092 | .0231 | .0467 | .0808 | .1239 | .1719 | .2188 | 3 |
| | 6 | .0000 | .0000 | .0000 | .0002 | .0011 | .0038 | .0100 | .0217 | .0413 | .0403 | .1094 | 2 |
| | 7 | .0000 | .0000 | .0000 | .0000 | .0001 | .0004 | .0012 | .0033 | .0079 | .0164 | .0312 | 1 |
| 8 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0002 | .0007 | .0017 | .0039 | 0 | |
| 9 | 0 | .9135 | .6302 | .3874 | .2316 | .1342 | .0751 | .0404 | .0207 | .0101 | .0046 | .0020 | 9 |
| | 1 | .0830 | .2985 | .3874 | .3679 | .3020 | .2253 | .1556 | .1004 | .0605 | .0339 | .0176 | 8 |
| | 2 | .0034 | .0629 | .1722 | .2597 | .3020 | .3003 | .2668 | .2162 | .1612 | .1110 | .0703 | 7 |
| | 3 | .0001 | .0077 | .0446 | .1069 | .1762 | .2336 | .2668 | .2716 | .2508 | .2119 | .1641 | 6 |
| | 4 | .0000 | .0006 | .0074 | .0283 | .0661 | .1168 | .1715 | .2194 | .2508 | .2600 | .2461 | 5 |
| | 5 | .0000 | .0000 | .0008 | .0050 | .0165 | .0389 | .0735 | .1181 | .1672 | .2128 | .2691 | 4 |
| | 6 | .0000 | .0000 | .0001 | .0006 | .0028 | .0087 | .0210 | .0424 | .0743 | .1160 | .1641 | 3 |
| | 7 | .0000 | .0000 | .0000 | .0000 | .0003 | .0012 | .0039 | .0098 | .0212 | .0407 | .0703 | 2 |
| | 8 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0004 | .0013 | .0035 | .0083 | .0176 | 1 |
| 9 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0003 | .0008 | .0020 | 0 | |
| 10 | 0 | .9044 | .5987 | .3487 | .1969 | .1074 | .0563 | .0282 | .0135 | .0060 | .0025 | .0010 | 10 |
| | 1 | .0914 | .3151 | .3874 | .3474 | .2684 | .1877 | .1211 | .0725 | .0403 | .0207 | .0098 | 9 |
| | 2 | .0042 | .0746 | .1937 | .2759 | .3020 | .2816 | .2336 | .1757 | .1209 | .0763 | .0439 | 8 |
| | 3 | .0001 | .0105 | .0574 | .1298 | .2013 | .2503 | .2668 | .2522 | .2150 | .1665 | .1172 | 7 |
| | 4 | .0000 | .0010 | .0112 | .0401 | .0881 | .1460 | .2001 | .2377 | .2508 | .2384 | .2051 | 6 |
| | 5 | .0000 | .0001 | .0015 | .0085 | .0264 | .0584 | .1029 | .1536 | .2007 | .2340 | .2461 | 5 |
| | 6 | .0000 | .0000 | .0001 | .0012 | .0055 | .0162 | .0368 | .0689 | .1115 | .1596 | .2051 | 4 |
| | 7 | .0000 | .0000 | .0000 | .0001 | .0008 | .0031 | .0090 | .0212 | .0425 | .0746 | .1172 | 3 |
| | 8 | .0000 | .0000 | .0000 | .0000 | .0001 | .0004 | .0014 | .0043 | .0106 | .0229 | .0439 | 2 |
| | 9 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0016 | .0042 | .0098 | 1 |
| 10 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0003 | .0010 | 0 | |
| 11 | 0 | .8953 | .5688 | .3138 | .1673 | .0859 | .0422 | .0198 | .0088 | .0036 | .0014 | .0005 | 11 |
| | 1 | .0995 | .3293 | .3836 | .3248 | .2362 | .1549 | .0932 | .0518 | .0266 | .0125 | .0064 | 10 |
| | 2 | .0050 | .0876 | .2131 | .2866 | .2953 | .2581 | .1998 | .1395 | .0887 | .0513 | .0269 | 9 |
| | 3 | .0002 | .0137 | .0710 | .1517 | .2215 | .2581 | .2588 | .2254 | .1774 | .1259 | .0606 | 8 |
| | 4 | .0000 | .0014 | .0158 | .0536 | .1107 | .1721 | .2201 | .2428 | .2365 | .2060 | .1611 | 7 |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | |

p

تابع الجدول 1

p

| <i>n</i> | <i>m</i> | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | | |
|----------|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|---|
| 11 | 5 | .0000 | .0001 | .0025 | .0132 | .0388 | .0803 | .1321 | .1830 | .2207 | .2360 | .2256 | 6 | |
| | 6 | .0000 | .0000 | .0003 | .0023 | .0097 | .0268 | .0566 | .0985 | .1471 | .1931 | .2256 | 5 | |
| | 7 | .0000 | .0000 | .0000 | .0003 | .0017 | .0064 | .0173 | .0379 | .0701 | .1128 | .1611 | 4 | |
| | 8 | .0000 | .0000 | .0000 | .0000 | .0002 | .0011 | .0037 | .0102 | .0234 | .0462 | .0806 | 3 | |
| | 9 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0018 | .0052 | .0126 | .0269 | 2 | |
| | 10 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0007 | .0021 | .0054 | 1 |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0005 | 0 |
| 12 | 0 | .8864 | .5404 | .2824 | .1422 | .0687 | .0317 | .0138 | .0057 | .0022 | .0008 | .0002 | 12 | |
| | 1 | .1074 | .3413 | .3766 | .3012 | .2062 | .1267 | .0712 | .0368 | .0174 | .0075 | .0029 | 11 | |
| | 2 | .0060 | .0988 | .2301 | .2924 | .2835 | .2323 | .1678 | .1088 | .0639 | .0339 | .0161 | 10 | |
| | 3 | .0002 | .0173 | .0852 | .1720 | .2362 | .2581 | .2397 | .1954 | .1419 | .0923 | .0537 | 9 | |
| | 4 | .0000 | .0021 | .0213 | .0683 | .1329 | .1936 | .2311 | .2367 | .2128 | .1700 | .1208 | 8 | |
| | 5 | .0000 | .0002 | .0038 | .0193 | .0532 | .1032 | .1585 | .2039 | .2270 | .2225 | .1934 | 7 | |
| | 6 | .0000 | .0000 | .0005 | .0040 | .0155 | .0401 | .0792 | .1281 | .1766 | .2124 | .2256 | 6 | |
| | 7 | .0000 | .0000 | .0000 | .0006 | .0033 | .0115 | .0291 | .0591 | .1009 | .1489 | .1934 | 5 | |
| | 8 | .0000 | .0000 | .0000 | .0001 | .0005 | .0024 | .0078 | .0199 | .0420 | .0762 | .1208 | 4 | |
| | 9 | .0000 | .0000 | .0000 | .0000 | .0001 | .0004 | .0015 | .0048 | .0125 | .0277 | .0637 | 3 | |
| | 10 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0008 | .0025 | .0068 | .0161 | 2 | |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0003 | .0010 | .0029 | 1 | |
| 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0002 | 0 | | |
| 13 | 0 | .8775 | .5133 | .2542 | .1209 | .0550 | .0238 | .0097 | .0037 | .0013 | .0004 | .0001 | 13 | |
| | 1 | .1152 | .3512 | .3672 | .2774 | .1787 | .1029 | .0540 | .0259 | .0113 | .0045 | .0016 | 12 | |
| | 2 | .0070 | .1109 | .2448 | .2937 | .2680 | .2059 | .1388 | .0836 | .0453 | .0220 | .0095 | 11 | |
| | 3 | .0003 | .0214 | .0997 | .1900 | .2457 | .2517 | .2181 | .1651 | .1107 | .0660 | .0349 | 10 | |
| | 4 | .0000 | .0028 | .0277 | .0838 | .1535 | .2097 | .2337 | .2222 | .1845 | .1350 | .0873 | 9 | |
| | 5 | .0000 | .0003 | .0055 | .0266 | .0691 | .1258 | .1803 | .2154 | .2214 | .1989 | .1571 | 8 | |
| | 6 | .0000 | .0000 | .0008 | .0063 | .0230 | .0559 | .1030 | .1546 | .1968 | .2169 | .2096 | 7 | |
| | 7 | .0000 | .0000 | .0001 | .0011 | .0058 | .0186 | .0442 | .0833 | .1312 | .1775 | .2095 | 6 | |
| | 8 | .0000 | .0000 | .0001 | .0001 | .0011 | .0047 | .0142 | .0336 | .0656 | .1088 | .1571 | 5 | |
| | 9 | .0000 | .0000 | .0000 | .0000 | .0001 | .0009 | .0034 | .0101 | .0243 | .0495 | .0873 | 4 | |
| | 10 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0022 | .0065 | .0162 | .0349 | 3 | |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0003 | .0012 | .0038 | .0095 | 2 | |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0015 | 1 | |
| 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | 0 | | |
| 14 | 0 | .8687 | .4877 | .2288 | .1028 | .0440 | .0178 | .0068 | .0024 | .0008 | .0002 | .0001 | 14 | |
| | 1 | .1229 | .3593 | .3559 | .2539 | .1539 | .0832 | .0467 | .0181 | .0073 | .0027 | .0009 | 13 | |
| | 2 | .0081 | .1220 | .2570 | .2912 | .2501 | .1802 | .1134 | .0634 | .0317 | .0141 | .0056 | 12 | |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | | |

p

تابع الجدول 1

p

| n | m | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | | |
|-----|-----|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| 14 | 3 | .0003 | .0250 | .1142 | .2056 | .2501 | .2402 | .1943 | .1366 | .0845 | .0462 | .0222 | 11 | |
| | 4 | .0000 | .0037 | .0349 | .0998 | .1720 | .2202 | .2290 | .2022 | .1549 | .1040 | .0611 | 10 | |
| | 5 | .0000 | .0004 | .0078 | .0352 | .0860 | .1468 | .1963 | .2178 | .2066 | .1701 | .1222 | 9 | |
| | 6 | .0000 | .0000 | .0013 | .0093 | .0322 | .0734 | .1262 | .1750 | .2066 | .2088 | .1833 | 8 | |
| | 7 | .0000 | .0000 | .0002 | .0019 | .0092 | .0280 | .0618 | .1082 | .1574 | .1952 | .2088 | 7 | |
| | 8 | .0000 | .0000 | .0000 | .0003 | .0020 | .0082 | .0232 | .0510 | .0918 | .1398 | .1833 | 6 | |
| | 9 | .0000 | .0000 | .0000 | .0000 | .0003 | .0018 | .0066 | .0183 | .0408 | .0762 | .1222 | 5 | |
| | 10 | .0000 | .0000 | .0000 | .0000 | .0000 | .0003 | .0014 | .0049 | .0136 | .0312 | .0611 | 4 | |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0010 | .0033 | .0083 | .0222 | 3 | |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0019 | .0058 | 2 |
| | 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0002 | .0009 | 1 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | 0 |
| | 15 | 0 | .8601 | .4633 | .2059 | .0874 | .0352 | .0134 | .0047 | .0016 | .0005 | .0001 | .0000 | 15 |
| | | 1 | .1003 | .3658 | .2432 | .2312 | .1319 | .0668 | .0305 | .0126 | .0047 | .0016 | .0005 | 14 |
| 2 | | .0092 | .1348 | .2869 | .2856 | .2309 | .1559 | .0916 | .0476 | .0219 | .0090 | .0032 | 13 | |
| 3 | | .0004 | .0307 | .1285 | .2184 | .2501 | .2252 | .1700 | .1110 | .0634 | .0318 | .0139 | 12 | |
| 4 | | .0000 | .0049 | .0428 | .1156 | .1876 | .2252 | .2186 | .1792 | .1268 | .0760 | .0417 | 11 | |
| 5 | | .0000 | .0006 | .0105 | .0449 | .1032 | .1681 | .2061 | .2123 | .1859 | .1404 | .0916 | 10 | |
| 6 | | .0000 | .0000 | .0019 | .0132 | .0430 | .0917 | .1472 | .1906 | .2066 | .1914 | .1527 | 9 | |
| 7 | | .0000 | .0000 | .0003 | .0030 | .0138 | .0393 | .0811 | .1319 | .1771 | .2013 | .1964 | 8 | |
| 8 | | .0000 | .0000 | .0000 | .0005 | .0035 | .0131 | .0348 | .0710 | .1181 | .1647 | .1964 | 7 | |
| 9 | | .0000 | .0000 | .0000 | .0001 | .0007 | .0034 | .0116 | .0298 | .0612 | .1048 | .1527 | 6 | |
| 10 | | .0000 | .0000 | .0000 | .0000 | .0001 | .0007 | .0030 | .0096 | .0245 | .0515 | .0916 | 5 | |
| 11 | | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0024 | .0074 | .0191 | .0417 | 4 | |
| 12 | | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0004 | .0016 | .0052 | .0139 | 3 | |
| 13 | | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0003 | .0010 | .0032 | 2 | |
| 14 | | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | 1 | |
| 15 | | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 0 | |
| 16 | 0 | .8515 | .4401 | .1853 | .0743 | .0281 | .0100 | .0033 | .0010 | .0003 | .0001 | .0000 | 16 | |
| | 1 | .1376 | .3706 | .3294 | .2097 | .1126 | .0536 | .0228 | .0087 | .0030 | .0009 | .0002 | 15 | |
| | 2 | .0104 | .1463 | .2745 | .2775 | .2111 | .1336 | .0732 | .0353 | .0150 | .0056 | .0018 | 14 | |
| | 3 | .0005 | .0359 | .1123 | .2285 | .2463 | .2079 | .1465 | .0888 | .0468 | .0215 | .0085 | 13 | |
| | 4 | .0000 | .0061 | .0514 | .1311 | .2001 | .2252 | .2040 | .1553 | .1014 | .0572 | .0278 | 12 | |
| | 5 | .0000 | .0008 | .0137 | .0555 | .1201 | .1802 | .2099 | .2008 | .1623 | .1123 | .0667 | 11 | |
| | 6 | .0000 | .0001 | .0028 | .0180 | .0550 | .1101 | .1649 | .1982 | .1983 | .1684 | .1222 | 10 | |
| | 7 | .0000 | .0000 | .0004 | .0045 | .0197 | .0524 | .1010 | .1524 | .1889 | .1969 | .1746 | 9 | |
| | 8 | .0000 | .0000 | .0001 | .0009 | .0055 | .0197 | .0487 | .0923 | .1417 | .1812 | .1964 | 8 | |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | | |

p

تابع الجدول 1

p

| <i>n</i> | <i>m</i> | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | |
|----------|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| 16 | 9 | .0000 | .0000 | .0000 | .0001 | .0012 | .0058 | .0185 | .0442 | .0840 | .1318 | .1746 | 7 |
| | 10 | .0000 | .0000 | .0000 | .0000 | .0002 | .0014 | .0056 | .0167 | .0392 | .0755 | .1222 | 6 |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0013 | .0049 | .0142 | .0337 | .0667 | 5 |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0011 | .0040 | .0115 | .0278 | 4 |
| | 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0008 | .0025 | .0085 | 3 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0018 | 2 |
| | 15 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0002 | 1 |
| | 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 0 |
| 17 | 0 | .8429 | .4181 | .1668 | .0631 | .0225 | .0075 | .0023 | .0007 | .0002 | .0000 | .0000 | 17 |
| | 1 | .1447 | .3741 | .3150 | .1893 | .0957 | .0426 | .0169 | .0060 | .0019 | .0005 | .0001 | 16 |
| | 2 | .0117 | .1575 | .2800 | .2673 | .1914 | .1136 | .0581 | .0260 | .0102 | .0035 | .0010 | 15 |
| | 3 | .0006 | .0415 | .1556 | .2359 | .2393 | .1893 | .1245 | .0701 | .0341 | .0144 | .0052 | 14 |
| | 4 | .0000 | .0076 | .0605 | .1457 | .2093 | .2209 | .1868 | .1320 | .0796 | .0411 | .0182 | 13 |
| | 5 | .0000 | .0010 | .0175 | .0668 | .1361 | .1914 | .2081 | .1849 | .1379 | .0875 | .0472 | 12 |
| | 6 | .0000 | .0001 | .0039 | .0236 | .0680 | .1276 | .1784 | .1991 | .1839 | .1432 | .0944 | 11 |
| | 7 | .0000 | .0000 | .0007 | .0065 | .0267 | .0668 | .1201 | .1685 | .1827 | .1841 | .1484 | 10 |
| | 8 | .0000 | .0000 | .0001 | .0014 | .0084 | .0279 | .0644 | .1134 | .1606 | .1883 | .1855 | 9 |
| | 9 | .0000 | .0000 | .0000 | .0003 | .0021 | .0093 | .0276 | .0511 | .1070 | .1540 | .1855 | 8 |
| | 10 | .0000 | .0000 | .0000 | .0000 | .0004 | .0025 | .0095 | .0263 | .0571 | .1008 | .1484 | 7 |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0026 | .0090 | .0242 | .0525 | .0944 | 6 |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0024 | .0081 | .0215 | .0472 | 5 |
| | 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0021 | .0068 | .0182 | 4 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0004 | .0016 | .0052 | 3 |
| | 15 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0003 | .0010 | 2 |
| | 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | 1 |
| 17 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 0 | |
| 18 | 0 | .8345 | .3972 | .1501 | .0536 | .0180 | .0056 | .0016 | .0004 | .0001 | .0000 | .0000 | 18 |
| | 1 | .1517 | .3763 | .3002 | .1704 | .0811 | .0338 | .0126 | .0042 | .0012 | .0003 | .0001 | 17 |
| | 2 | .0130 | .1683 | .2835 | .2566 | .1723 | .0958 | .0458 | .0180 | .0069 | .0022 | .0006 | 16 |
| | 3 | .0007 | .0473 | .1680 | .2406 | .2207 | .1704 | .1046 | .0547 | .0240 | .0095 | .0031 | 15 |
| | 4 | .0000 | .0093 | .0700 | .1592 | .2153 | .2130 | .1681 | .1104 | .0614 | .0291 | .0117 | 14 |
| | 5 | .0000 | .0014 | .0218 | .0787 | .1507 | .1988 | .2017 | .1664 | .1146 | .0666 | .0327 | 13 |
| | 6 | .0002 | .0002 | .0052 | .0301 | .0816 | .1436 | .1873 | .1941 | .1656 | .1181 | .0708 | 12 |
| | 7 | .0000 | .0000 | .0010 | .0081 | .0350 | .0620 | .1376 | .1792 | .1892 | .1557 | .1214 | 11 |
| | 8 | .0000 | .0000 | .0002 | .0022 | .0120 | .0376 | .0811 | .1327 | .1734 | .1884 | .1669 | 10 |
| | 9 | .0000 | .0000 | .0000 | .0004 | .0033 | .0139 | .0386 | .0794 | .1284 | .1694 | .1855 | 9 |
| | 10 | .0000 | .0000 | .0000 | .0001 | .0008 | .0042 | .0149 | .0385 | .0771 | .1248 | .1669 | 8 |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | |

p

تابع الجدول 1

p

| <i>n</i> | <i>m</i> | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | |
|----------|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| 18 | 11 | .0000 | .0000 | .0000 | .0000 | .0001 | .0010 | .0046 | .0151 | .0374 | .0742 | .1214 | 7 |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0012 | .0047 | .0145 | .0354 | .0708 | 6 |
| | 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0012 | .0045 | .0134 | .0327 | 5 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0011 | .0039 | .0117 | 4 |
| | 15 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0009 | .0031 | 3 |
| | 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0006 | 2 |
| | 17 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 1 |
| | 18 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 0 |
| 19 | 0 | .3262 | .3774 | .4351 | .4956 | .5644 | .6342 | .7011 | .7603 | .8101 | .8500 | .8800 | 19 |
| | 1 | .1583 | .3774 | .2852 | .1529 | .0535 | .0256 | .0083 | .0029 | .0008 | .0002 | .0000 | 18 |
| | 2 | .0144 | .1787 | .2852 | .2428 | .1540 | .0803 | .0358 | .0138 | .0046 | .0013 | .0003 | 17 |
| | 3 | .0008 | .0633 | .1795 | .2428 | .2182 | .1517 | .0869 | .0422 | .0175 | .0082 | .0018 | 16 |
| | 4 | .0000 | .0112 | .0798 | .1714 | .2182 | .2023 | .1491 | .0909 | .0467 | .0203 | .0074 | 15 |
| | 5 | .0000 | .0018 | .0266 | .0907 | .1636 | .2023 | .1916 | .1458 | .0933 | .0497 | .0222 | 14 |
| | 6 | .0000 | .0002 | .0069 | .0374 | .0955 | .1574 | .1916 | .1844 | .1451 | .0949 | .0518 | 13 |
| | 7 | .0000 | .0000 | .0014 | .0122 | .0443 | .0974 | .1525 | .1844 | .1797 | .1443 | .0961 | 12 |
| | 8 | .0000 | .0000 | .0002 | .0032 | .0166 | .0487 | .0981 | .1489 | .1797 | .1771 | .1442 | 11 |
| | 9 | .0000 | .0000 | .0000 | .0007 | .0051 | .0198 | .0514 | .0980 | .1464 | .1771 | .1762 | 10 |
| | 10 | .0000 | .0000 | .0000 | .0001 | .0013 | .0066 | .0220 | .0628 | .0976 | .1449 | .1762 | 9 |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0003 | .0018 | .0077 | .0233 | .0632 | .0970 | .1442 | 8 |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0000 | .0004 | .0022 | .0083 | .0237 | .0529 | .0961 | 7 |
| | 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0024 | .0086 | .0233 | .0618 | 6 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0024 | .0082 | .0222 | 5 |
| | 15 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0005 | .0022 | .0074 | 4 |
| | 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0018 | 3 |
| | 17 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0003 | 2 |
| | 18 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 1 |
| 19 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 0 | |
| 20 | 0 | .8179 | .3585 | .1216 | .0388 | .0115 | .0032 | .0008 | .0002 | .0000 | .0000 | .0000 | 20 |
| | 1 | .1652 | .3774 | .2702 | .1368 | .0576 | .0211 | .0058 | .0020 | .0005 | .0001 | .0000 | 19 |
| | 2 | .0159 | .1687 | .2852 | .2293 | .1369 | .0699 | .0278 | .0100 | .0031 | .0008 | .0002 | 18 |
| | 3 | .0010 | .0595 | .1901 | .2428 | .2054 | .1339 | .0716 | .0323 | .0123 | .0040 | .0011 | 17 |
| | 4 | .0000 | .133 | .0898 | .1821 | .2182 | .1897 | .1304 | .0738 | .0350 | .0138 | .0045 | 16 |
| | 5 | .0000 | .0022 | .0319 | .1028 | .1746 | .2023 | .1789 | .1272 | .0746 | .0365 | .0148 | 15 |
| | 6 | .0000 | .0003 | .0089 | .0454 | .1081 | .1686 | .1916 | .1712 | .1244 | .0746 | .0370 | 14 |
| | 7 | .0000 | .0000 | .0020 | .0160 | .0545 | .1124 | .1643 | .1944 | .1559 | .1221 | .0739 | 13 |
| 8 | .0000 | .0000 | .0004 | .0046 | .0222 | .0609 | .1144 | .1614 | .1797 | .1623 | .1201 | 12 | |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | |

p

تابع الجدول 1

p

| <i>n</i> | <i>m</i> | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | |
|----------|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| 20 | 9 | .0000 | .0000 | .0001 | .0011 | .0074 | .0271 | .0654 | .1158 | .1597 | .1771 | .1602 | 11 |
| | 10 | .0000 | .0000 | .0000 | .0002 | .0020 | .0099 | .0308 | .0686 | .1171 | .1593 | .1762 | 10 |
| | 11 | .0000 | .0000 | .0000 | .0000 | .0005 | .0030 | .0120 | .0336 | .0710 | .1185 | .1602 | 9 |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0001 | .0008 | .0039 | .0136 | .0355 | .0727 | .1201 | 8 |
| | 13 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0010 | .0045 | .0148 | .0366 | .0738 | 7 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0012 | .0049 | .0150 | .0370 | 6 |
| | 15 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0003 | .0013 | .0048 | .0148 | 5 |
| | 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0003 | .0013 | .0046 | 4 |
| | 17 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0011 | 3 |
| | 18 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | 2 |
| | 19 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 1 |
| 20 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | 0 | |
| 25 | 0 | .7778 | .2774 | .0718 | .0172 | .0038 | .0008 | .0001 | .0000 | .0000 | .0000 | .0000 | 25 |
| | 1 | .1964 | .3650 | .1994 | .0759 | .0236 | .0063 | .0014 | .0003 | .0000 | .0000 | .0000 | 24 |
| | 2 | .0238 | .2305 | .2659 | .1607 | .0708 | .0251 | .0074 | .0018 | .0004 | .0001 | .0000 | 23 |
| | 3 | .0018 | .0930 | .2265 | .2174 | .1358 | .0641 | .0243 | .0076 | .0018 | .0004 | .0001 | 22 |
| | 4 | .0001 | .0269 | .1384 | .2110 | .1867 | .1175 | .0572 | .0224 | .0071 | .0018 | .0004 | 21 |
| | 5 | .0000 | .0060 | .0646 | .1564 | .1960 | .1645 | .1030 | .0506 | .0199 | .0063 | .0018 | 20 |
| | 6 | .0000 | .0010 | .0239 | .0920 | .1633 | .1828 | .1472 | .0908 | .0442 | .0172 | .0053 | 19 |
| | 7 | .0000 | .0001 | .0072 | .0441 | .1108 | .1654 | .1712 | .1327 | .0800 | .0381 | .0143 | 18 |
| | 8 | .0000 | .0000 | .0018 | .0175 | .0623 | .1241 | .1651 | .1607 | .1200 | .0701 | .0322 | 17 |
| | 9 | .0000 | .0000 | .0004 | .0058 | .0294 | .0781 | .1336 | .1635 | .1511 | .1084 | .0609 | 16 |
| | 10 | .0000 | .0000 | .000 | .0016 | .0118 | .0417 | .0916 | .1409 | .1612 | .1419 | .0974 | 15 |
| | 11 | .0000 | .0000 | .0000 | .0004 | .0040 | .0189 | .0536 | .1034 | .1465 | .1583 | .1328 | 14 |
| | 12 | .0000 | .0000 | .0000 | .0000 | .0012 | .0074 | .0268 | .0650 | .1140 | .1511 | .1550 | 13 |
| 13 | .0000 | .0000 | .0000 | .0000 | .0003 | .0025 | .0115 | .0350 | .0760 | .1236 | .1550 | 12 | |
| 14 | .0000 | .0000 | .0000 | .0000 | .0000 | .0007 | .0042 | .0161 | .0434 | .0867 | .1328 | 11 | |
| 15 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0013 | .0064 | .0212 | .0520 | .0974 | 10 | |
| 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0004 | .0021 | .0088 | .0296 | .0609 | 9 | |
| 17 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0031 | .0115 | .0322 | 8 | |
| 18 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0009 | .0042 | .0143 | 7 | |
| 19 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0013 | .0063 | 6 | |
| 20 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0016 | 5 | |
| 21 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0004 | 4 | |
| 22 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | 3 | |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | |

p

تابع الجدول 1

P

| n | m | .01 | .05 | .10 | .15 | .20 | .25 | .30 | .35 | .40 | .45 | .50 | |
|-----|-----|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| 30 | 0 | .7397 | .2146 | .0424 | .0076 | .0012 | .0002 | .0000 | .0000 | .0000 | .0000 | .0000 | 30 |
| | 1 | .2242 | .3389 | .1413 | .0404 | .0093 | .0018 | .0003 | .0000 | .0000 | .0000 | .0000 | 29 |
| | 2 | .0328 | .2586 | .2277 | .1034 | .0337 | .0086 | .0018 | .0003 | .0000 | .0000 | .0000 | 28 |
| | 3 | .0031 | .1270 | .2361 | .1703 | .0785 | .0269 | .0072 | .0015 | .0003 | .0000 | .0000 | 27 |
| | 4 | .002 | .0451 | .1771 | .2028 | .1325 | .0604 | .0208 | .0056 | .0012 | .0002 | .0000 | 26 |
| | 5 | .0000 | .0124 | .1023 | .1861 | .1723 | .1047 | .0464 | .0157 | .0041 | .0008 | .0001 | 25 |
| | 6 | .0000 | .0027 | .0474 | .1368 | .1795 | .1455 | .0829 | .0363 | .0115 | .0029 | .0006 | 24 |
| | 7 | .0000 | .0005 | .0180 | .0628 | .1538 | .1662 | .1229 | .0652 | .0263 | .0061 | .0019 | 23 |
| | 8 | .0000 | .0001 | .0068 | .0420 | .1106 | .1593 | .1501 | .1009 | .0505 | .0181 | .0055 | 22 |
| | 9 | .0000 | .0000 | .0016 | .0181 | .0676 | .1298 | .1573 | .1328 | .823 | .0382 | .0133 | 21 |
| | 10 | .0000 | .0000 | .0004 | .0067 | .0355 | .0909 | .1416 | .1502 | .1152 | .656 | .0280 | 20 |
| | 11 | .0000 | .0000 | .0001 | .0022 | .0161 | .0551 | .1103 | .1471 | .1386 | .0976 | .0508 | 19 |
| | 12 | .0000 | .0000 | .0000 | .0006 | .0064 | .0291 | .0749 | .1254 | .1474 | .1265 | .0806 | 18 |
| | 13 | .0000 | .0000 | .0000 | .0001 | .0022 | .0134 | .0444 | .0936 | .1380 | .1433 | .1115 | 17 |
| | 14 | .0000 | .0000 | .0000 | .0000 | .0007 | .0054 | .0231 | .0611 | .1101 | .1323 | .1354 | 16 |
| | 15 | .0000 | .0000 | .0000 | .0000 | .0002 | .0019 | .0106 | .0351 | .0783 | .1242 | .1445 | 15 |
| | 16 | .0000 | .0000 | .0000 | .0000 | .0000 | .0006 | .0042 | .0177 | .0489 | .0953 | .1354 | 14 |
| | 17 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0015 | .0079 | .0289 | .0642 | .1115 | 13 |
| | 18 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0005 | .0031 | .0129 | .0379 | .0806 | 12 |
| | 19 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0010 | .0064 | .0196 | .0508 | 11 |
| | 20 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0003 | .0020 | .0068 | .0280 | 10 |
| | 21 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | .0034 | .0133 | 9 |
| | 22 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0002 | .0012 | .0055 | 8 |
| | 23 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0003 | .0019 | 7 |
| | 24 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | .0006 | 6 |
| | 25 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0000 | .0001 | 5 |
| | | .99 | .95 | .90 | .85 | .80 | .75 | .70 | .65 | .60 | .55 | .50 | |

P

جدول 2: توزيع بواسون *The Poisson Distribution*

$$P_m(t) \cdot 10^6 = \frac{\lambda^m}{m!} e^{-\lambda} \cdot 10^6 \quad \text{جدول قيم الدالة:}$$

| | | λ | | | | | | | | | | |
|----------|--------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|----------|--|
| m | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1.0 | m | |
| 0 | 904837 | 818731 | 740818 | 670320 | 606531 | 548812 | 496585 | 449329 | 406570 | 367879 | 0 | |
| 1 | 90484 | 163746 | 222245 | 268128 | 303265 | 329287 | 347610 | 359463 | 365913 | 367879 | 1 | |
| 2 | 4524 | 16375 | 33337 | 53626 | 75816 | 98786 | 121663 | 143785 | 164661 | 183940 | 2 | |
| 3 | 151 | 1092 | 3334 | 7150 | 12636 | 19757 | 28388 | 38343 | 49398 | 61313 | 63 | |
| 4 | 4 | 55 | 250 | 715 | 1580 | 2964 | 4968 | 7669 | 11115 | 15328 | 4 | |
| 5 | | 2 | 15 | 57 | 158 | 356 | 696 | 1227 | 2001 | 3066 | 5 | |
| 6 | | | 1 | 4 | 13 | 36 | 81 | 164 | 300 | 511 | 6 | |
| 7 | | | | | 1 | 3 | 8 | 19 | 39 | 73 | 7 | |
| 8 | | | | | | | 1 | 2 | 4 | 9 | 8 | |
| | | | | | | | | | | 1 | 9 | |
| m | 1.1 | 1.2 | 1.3 | 1.4 | 1.5 | 1.6 | 1.7 | 1.8 | 1.9 | 2.0 | m | |
| 0 | 332871 | 301194 | 272532 | 246597 | 223130 | 201897 | 182684 | 165299 | 149569 | 135335 | 0 | |
| 1 | 366158 | 361433 | 354291 | 345236 | 334695 | 323034 | 310562 | 297538 | 284180 | 270671 | 1 | |
| 2 | 201387 | 216860 | 230289 | 241665 | 251021 | 258428 | 263978 | 267784 | 269971 | 270671 | 2 | |
| 3 | 72842 | 86744 | 99792 | 112777 | 125510 | 137828 | 149587 | 160671 | 170982 | 180447 | 3 | |
| 4 | 20307 | 26023 | 32432 | 39472 | 47067 | 55131 | 63575 | 72302 | 81216 | 90224 | 4 | |
| 5 | 4467 | 6246 | 8432 | 11052 | 14120 | 17642 | 21615 | 26029 | 30862 | 36089 | 5 | |
| 6 | 819 | 1249 | 1827 | 2579 | 3530 | 4705 | 6124 | 7809 | 9773 | 12030 | 6 | |
| 7 | 129 | 214 | 339 | 516 | 756 | 1075 | 1487 | 2008 | 2653 | 3437 | 7 | |
| 8 | 18 | 32 | 55 | 90 | 142 | 215 | 316 | 452 | 630 | 859 | 8 | |
| 9 | 2 | 4 | 8 | 14 | 24 | 38 | 60 | 90 | 133 | 191 | 9 | |
| 10 | | 1 | 1 | 2 | 4 | 6 | 10 | 16 | 25 | 38 | 10 | |
| 11 | | | | | | 1 | 2 | 3 | 4 | 7 | 11 | |
| 12 | | | | | | | | | 1 | 1 | 12 | |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 2.1 | 2.2 | 2.3 | 2.4 | 2.5 | 2.6 | 2.7 | 2.8 | 2.9 | 3.0 | |
| 0 | 122456 | 110803 | 100259 | 90718 | 82085 | 74274 | 67206 | 60810 | 55023 | 49787 | 0 |
| 1 | 257159 | 243767 | 230595 | 217723 | 205212 | 193111 | 181455 | 170268 | 159567 | 149361 | 1 |
| 2 | 270016 | 268144 | 265185 | 261268 | 256516 | 251045 | 244964 | 238375 | 231373 | 224042 | 2 |
| 3 | 189012 | 196639 | 203308 | 209014 | 213763 | 217572 | 220468 | 222484 | 223660 | 224042 | 3 |
| 4 | 99231 | 108151 | 116902 | 125409 | 133602 | 141422 | 148816 | 155739 | 162154 | 168013 | 4 |
| 5 | 41677 | 47587 | 53775 | 60196 | 66801 | 73539 | 80360 | 87214 | 94049 | 100819 | 5 |
| 6 | 14587 | 17448 | 20614 | 24078 | 27834 | 31867 | 36162 | 40700 | 45457 | 50409 | 6 |
| 7 | 4376 | 5484 | 6773 | 8255 | 9941 | 11836 | 13948 | 16280 | 18832 | 21604 | 7 |
| 8 | 1149 | 1508 | 1947 | 2477 | 3106 | 3847 | 4708 | 5698 | 6827 | 8102 | 8 |
| 9 | 268 | 369 | 498 | 660 | 863 | 1111 | 1412 | 1773 | 2200 | 2701 | 9 |
| 10 | 56 | 81 | 114 | 158 | 216 | 289 | 381 | 496 | 638 | 810 | 10 |
| 11 | 11 | 16 | 24 | 35 | 49 | 68 | 94 | 126 | 168 | 221 | 11 |
| 12 | 2 | 3 | 5 | 7 | 10 | 15 | 21 | 29 | 41 | 55 | 12 |
| 13 | | 1 | 1 | 1 | 2 | 3 | 4 | 6 | 9 | 13 | 13 |
| 14 | | | | | | 1 | 1 | 1 | 2 | 3 | 14 |
| 15 | | | | | | | | | | 1 | 15 |
| | 3.1 | 3.2 | 3.3 | 3.4 | 3.5 | 3.6 | 3.7 | 3.8 | 3.9 | 4.0 | |
| 0 | 45049 | 40762 | 36883 | 33373 | 30197 | 27324 | 24724 | 22371 | 20242 | 18316 | 0 |
| 1 | 139653 | 130439 | 121714 | 113469 | 105691 | 98365 | 91477 | 85009 | 78943 | 73263 | 1 |
| 2 | 216461 | 208702 | 200829 | 192898 | 184959 | 177058 | 169233 | 161517 | 153940 | 146525 | 2 |
| 3 | 223677 | 222616 | 220912 | 218617 | 215785 | 212469 | 208720 | 204588 | 200122 | 195367 | 3 |
| 4 | 173350 | 178093 | 182252 | 185825 | 188812 | 191222 | 193066 | 194359 | 195119 | 195367 | 4 |
| 5 | 107477 | 113979 | 120286 | 126361 | 132169 | 137680 | 142869 | 147713 | 152193 | 156293 | 5 |
| 6 | 55530 | 60789 | 66158 | 71604 | 77098 | 82608 | 88102 | 93551 | 98925 | 104196 | 6 |
| 7 | 24592 | 27789 | 31189 | 34779 | 38549 | 42484 | 46568 | 50785 | 55115 | 59540 | 7 |
| 8 | 9529 | 11116 | 12865 | 14781 | 16865 | 19118 | 21538 | 24123 | 26869 | 29770 | 8 |
| 9 | 3282 | 3952 | 4717 | 5584 | 6559 | 7647 | 8854 | 10185 | 11643 | 13231 | 9 |
| 10 | 1018 | 1265 | 1557 | 1899 | 2296 | 2753 | 3276 | 3870 | 4541 | 5292 | 10 |
| 11 | 287 | 368 | 567 | 587 | 730 | 901 | 1102 | 1337 | 1610 | 1925 | 11 |
| 12 | 74 | 98 | 128 | 166 | 213 | 270 | 340 | 423 | 523 | 642 | 12 |
| 13 | 18 | 24 | 33 | 43 | 57 | 75 | 97 | 124 | 157 | 197 | 13 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 3.1 | 3.2 | 3.3 | 3.4 | 3.5 | 3.6 | 3.7 | 3.8 | 3.9 | 4.0 | |
| 14 | 4 | 6 | 8 | 11 | 14 | 19 | 26 | 34 | 44 | 56 | 14 |
| 15 | 1 | 1 | 2 | 2 | 3 | 5 | 6 | 9 | 11 | 15 | 15 |
| 16 | | | | 1 | 1 | 1 | 1 | 2 | 3 | 4 | 16 |
| 17 | | | | | | | | | 1 | 1 | 17 |
| | 4.1 | 4.2 | 4.3 | 4.4 | 4.5 | 4.6 | 4.7 | 4.8 | 4.9 | 5.0 | |
| 0 | 16573 | 14996 | 13569 | 12277 | 11109 | 10052 | 9095 | 8230 | 7447 | 6738 | 0 |
| 1 | 67948 | 62981 | 58345 | 54020 | 49990 | 46238 | 42748 | 39503 | 36488 | 33690 | 1 |
| 2 | 139293 | 132261 | 125441 | 118845 | 112479 | 106348 | 100457 | 94807 | 89396 | 84224 | 2 |
| 3 | 190368 | 185165 | 179799 | 174305 | 168718 | 163068 | 157383 | 151691 | 146014 | 140374 | 3 |
| 4 | 195127 | 194424 | 193184 | 191736 | 189808 | 187528 | 194925 | 182029 | 178867 | 175467 | 4 |
| 5 | 160004 | 163316 | 166224 | 168728 | 170827 | 172525 | 173830 | 174748 | 175290 | 175467 | 5 |
| 6 | 109336 | 114321 | 119127 | 123734 | 128120 | 132270 | 136167 | 139798 | 143153 | 146223 | 6 |
| 7 | 64040 | 68593 | 73178 | 7775 | 82363 | 86920 | 91426 | 95862 | 100207 | 104445 | 7 |
| 8 | 32820 | 36011 | 39333 | 42776 | 46329 | 49979 | 53713 | 57517 | 61377 | 65278 | 8 |
| 9 | 14951 | 16805 | 18793 | 20913 | 23165 | 25545 | 28050 | 30676 | 33416 | 36266 | 9 |
| 10 | 6130 | 7058 | 8081 | 9202 | 10424 | 11751 | 13184 | 14724 | 16374 | 18138 | 10 |
| 11 | 2285 | 2695 | 3159 | 3681 | 4264 | 4914 | 5633 | 6425 | 7294 | 8242 | 11 |
| 12 | 781 | 943 | 1132 | 1350 | 1599 | 1884 | 2206 | 2570 | 2978 | 3434 | 12 |
| 13 | 246 | 305 | 374 | 457 | 554 | 667 | 798 | 949 | 1123 | 1321 | 13 |
| 14 | 72 | 91 | 115 | 144 | 178 | 219 | 268 | 325 | 393 | 472 | 14 |
| 15 | 20 | 26 | 33 | 42 | 53 | 67 | 84 | 104 | 128 | 157 | 15 |
| 16 | 5 | 7 | 9 | 12 | 15 | 19 | 25 | 31 | 39 | 49 | 16 |
| 17 | 1 | 2 | 2 | 3 | 4 | 5 | 7 | 9 | 11 | 14 | 17 |
| 18 | | | 1 | 1 | 1 | 1 | 2 | 2 | 3 | 4 | 18 |
| 19 | | | | | | | | | 1 | 1 | 19 |
| | 5.1 | 5.2 | 5.3 | 5.4 | 5.5 | 5.6 | 5.7 | 5.8 | 5.9 | 6.0 | |
| 0 | 6097 | 5517 | 4992 | 4517 | 4087 | 3698 | 3346 | 3028 | 2739 | 2479 | 0 |
| 1 | 31093 | 28686 | 26455 | 24390 | 22477 | 20477 | 19072 | 17560 | 16163 | 14873 | 1 |
| 2 | 79288 | 74584 | 70107 | 65852 | 61812 | 57982 | 54355 | 50923 | 47680 | 44618 | 2 |
| 3 | 134790 | 129279 | 123856 | 118533 | 113323 | 108234 | 103275 | 98452 | 93771 | 89235 | 3 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 5.1 | 5.2 | 5.3 | 5.4 | 5.5 | 5.6 | 5.7 | 5.8 | 5.9 | 6.0 | |
| 4 | 171857 | 168063 | 164109 | 160020 | 155819 | 151528 | 147167 | 142775 | 138312 | 133853 | 4 |
| 5 | 175294 | 174785 | 173955 | 172821 | 171401 | 169711 | 167770 | 165596 | 163208 | 160623 | 5 |
| 6 | 149000 | 151480 | 153660 | 155539 | 157117 | 158397 | 159382 | 160076 | 160488 | 160623 | 6 |
| 7 | 108557 | 112528 | 116343 | 119987 | 123449 | 126717 | 129782 | 132635 | 135268 | 137677 | 7 |
| 8 | 69205 | 73143 | 77077 | 80991 | 84871 | 88702 | 92470 | 96160 | 99760 | 103258 | 8 |
| 9 | 39216 | 42261 | 45390 | 48595 | 51866 | 55192 | 58564 | 61970 | 65398 | 68838 | 9 |
| 10 | 20000 | 21976 | 24057 | 26241 | 28526 | 30908 | 33382 | 35943 | 38585 | 41303 | 10 |
| 11 | 9273 | 10388 | 11591 | 12882 | 14263 | 15735 | 17298 | 18952 | 20696 | 22529 | 11 |
| 12 | 3941 | 4502 | 5119 | 5797 | 6537 | 7343 | 8216 | 9160 | 10175 | 11264 | 12 |
| 13 | 1546 | 1801 | 2087 | 2408 | 2766 | 3163 | 3603 | 4087 | 4618 | 5199 | 13 |
| 14 | 563 | 669 | 790 | 929 | 1087 | 1265 | 1467 | 1693 | 1946 | 2228 | 14 |
| 15 | 191 | 232 | 279 | 334 | 398 | 472 | 557 | 655 | 766 | 891 | 15 |
| 16 | 61 | 75 | 92 | 113 | 137 | 165 | 199 | 237 | 282 | 334 | 16 |
| 17 | 18 | 23 | 29 | 36 | 44 | 54 | 67 | 81 | 98 | 118 | 17 |
| 18 | 5 | 7 | 8 | 11 | 14 | 17 | 21 | 26 | 32 | 39 | 18 |
| 19 | 1 | 2 | 2 | 3 | 4 | 5 | 6 | 8 | 10 | 12 | 19 |
| 20 | | | 1 | 1 | 1 | 1 | 2 | 2 | 3 | 4 | 20 |
| 21 | | | | | | | | 1 | 1 | 1 | 21 |
| | 6.1 | 6.2 | 6.3 | 6.4 | 6.5 | 6.6 | 6.7 | 6.8 | 6.9 | 7.0 | |
| 0 | 2243 | 2029 | 1836 | 1662 | 1503 | 1303 | 1360 | 1231 | 1114 | 1008 | 0 |
| 1 | 13682 | 12582 | 11569 | 10634 | 9772 | 8978 | 8247 | 7574 | 6954 | 6383 | 1 |
| 2 | 41729 | 39006 | 36441 | 34029 | 31760 | 29629 | 27628 | 25751 | 23990 | 22341 | 2 |
| 3 | 84848 | 80612 | 76527 | 72595 | 68814 | 65183 | 61702 | 58368 | 55178 | 52129 | 3 |
| 4 | 129393 | 124948 | 120530 | 116151 | 111822 | 107553 | 103351 | 99225 | 95182 | 91226 | 4 |
| 5 | 157860 | 154936 | 151868 | 148674 | 145369 | 141969 | 138490 | 134946 | 131351 | 127717 | 5 |
| 6 | 160491 | 160100 | 159561 | 158585 | 157483 | 156166 | 154648 | 152939 | 151053 | 149003 | 6 |
| 7 | 139856 | 141803 | 143515 | 144992 | 146234 | 147243 | 148020 | 148569 | 148895 | 149003 | 7 |
| 8 | 106640 | 109897 | 113018 | 115994 | 118815 | 121475 | 123967 | 126284 | 128422 | 130377 | 8 |
| 9 | 72278 | 75707 | 79113 | 82484 | 85811 | 89082 | 92286 | 95415 | 98457 | 101405 | 9 |
| 10 | 44090 | 46938 | 49841 | 52790 | 55777 | 58794 | 61832 | 64882 | 67935 | 70983 | 10 |
| 11 | 14450 | 26456 | 28545 | 30714 | 32959 | 35276 | 37661 | 40109 | 42614 | 45171 | 11 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 6.1 | 6.2 | 6.3 | 6.4 | 6.5 | 6.6 | 6.7 | 6.8 | 6.9 | 7.0 | |
| 12 | 12429 | 13669 | 14986 | 16381 | 17853 | 19402 | 21028 | 22728 | 24503 | 26350 | 12 |
| 13 | 5832 | 6519 | 7263 | 8064 | 8926 | 9850 | 10837 | 11889 | 13005 | 14188 | 13 |
| 14 | 2541 | 2887 | 3268 | 3687 | 4144 | 4644 | 5186 | 5774 | 6410 | 7094 | 14 |
| 15 | 1033 | 1193 | 1373 | 1573 | 1796 | 2043 | 2317 | 2618 | 2949 | 3311 | 15 |
| 16 | 394 | 462 | 540 | 629 | 730 | 843 | 970 | 1113 | 1272 | 1448 | 16 |
| 17 | 141 | 169 | 200 | 237 | 279 | 327 | 382 | 445 | 516 | 596 | 17 |
| 18 | 48 | 58 | 70 | 84 | 101 | 120 | 142 | 168 | 198 | 232 | 18 |
| 19 | 15 | 19 | 23 | 28 | 34 | 42 | 50 | 60 | 72 | 85 | 19 |
| 20 | 5 | 6 | 7 | 9 | 11 | 14 | 17 | 20 | 25 | 30 | 20 |
| 21 | 1 | 2 | 2 | 3 | 3 | 4 | 5 | 7 | 8 | 10 | 21 |
| 22 | | | 1 | 1 | 1 | 1 | 2 | 2 | 3 | 3 | 22 |
| 23 | | | | | | | | 1 | 1 | 1 | 23 |
| | 7.1 | 7.2 | 7.3 | 7.4 | 7.5 | 7.6 | 7.7 | 7.8 | 7.9 | 8.0 | |
| 0 | 825 | 747 | 676 | 611 | 553 | 500 | 453 | 410 | 371 | 335 | 0 |
| 1 | 5858 | 5375 | 4931 | 4523 | 4148 | 3803 | 3487 | 3196 | 2929 | 2684 | 1 |
| 2 | 20797 | 19352 | 18000 | 16736 | 15555 | 14453 | 13424 | 12464 | 11569 | 10735 | 2 |
| 3 | 49219 | 46444 | 43799 | 41282 | 38889 | 36614 | 34455 | 32407 | 30465 | 28626 | 3 |
| 4 | 87364 | 83598 | 79934 | 76372 | 72916 | 69567 | 66326 | 63193 | 60169 | 57252 | 4 |
| 5 | 124057 | 120382 | 116703 | 113031 | 109375 | 105742 | 102142 | 98581 | 95067 | 91604 | 5 |
| 6 | 146800 | 144458 | 141989 | 139405 | 136718 | 133940 | 131082 | 128156 | 125171 | 122138 | 6 |
| 7 | 148897 | 148586 | 148047 | 147371 | 146484 | 145421 | 144191 | 142802 | 141264 | 139587 | 7 |
| 8 | 132146 | 133727 | 135118 | 136318 | 137329 | 138150 | 138783 | 139232 | 139499 | 139587 | 8 |
| 9 | 104249 | 106982 | 109596 | 112084 | 114440 | 116660 | 118737 | 120668 | 122449 | 124077 | 9 |
| 10 | 74017 | 77027 | 80005 | 82942 | 85830 | 88661 | 91427 | 94121 | 96735 | 99262 | 10 |
| 11 | 47774 | 50418 | 53094 | 55797 | 58521 | 61257 | 63999 | 66740 | 69473 | 72190 | 11 |
| 12 | 28267 | 30251 | 32299 | 34408 | 36575 | 38796 | 41066 | 43381 | 45736 | 48127 | 12 |
| 13 | 15438 | 16754 | 18137 | 19586 | 21101 | 22681 | 24324 | 26029 | 27794 | 29616 | 13 |
| 14 | 7829 | 8616 | 9457 | 10353 | 11304 | 12312 | 13378 | 14502 | 15684 | 16924 | 14 |
| 15 | 3706 | 4136 | 4603 | 5107 | 5652 | 6238 | 6867 | 7541 | 8260 | 9026 | 15 |
| 16 | 1644 | 1861 | 2100 | 2362 | 2649 | 2963 | 3305 | 3676 | 4078 | 4513 | 16 |
| 17 | 687 | 788 | 902 | 1028 | 1169 | 1325 | 1497 | 1687 | 1895 | 2124 | 17 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 7.1 | 7.2 | 7.3 | 7.4 | 7.5 | 7.6 | 7.7 | 7.8 | 7.9 | 8.0 | |
| 18 | 271 | 315 | 366 | 423 | 487 | 559 | 660 | 731 | 832 | 944 | 18 |
| 19 | 101 | 119 | 141 | 165 | 192 | 224 | 259 | 300 | 346 | 397 | 19 |
| 20 | 36 | 43 | 51 | 61 | 72 | 85 | 100 | 117 | 137 | 159 | 20 |
| 21 | 12 | 15 | 18 | 21 | 26 | 31 | 37 | 43 | 51 | 61 | 21 |
| 22 | 4 | 5 | 6 | 7 | 9 | 11 | 13 | 15 | 18 | 22 | 22 |
| 23 | 1 | 2 | 2 | 2 | 3 | 4 | 4 | 5 | 6 | 8 | 23 |
| 24 | | | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 2 | 24 |
| 25 | | | | | | | | 1 | 1 | 1 | 25 |
| | 8.1 | 8.2 | 8.3 | 8.4 | 8.5 | 8.6 | 8.7 | 8.8 | 8.9 | 9.0 | |
| 0 | 304 | 275 | 249 | 225 | 203 | 184 | 167 | 151 | 136 | 123 | 0 |
| 1 | 2459 | 2252 | 2063 | 1889 | 1729 | 1583 | 1449 | 1326 | 1214 | 1111 | 1 |
| 2 | 9958 | 9234 | 8560 | 7933 | 7350 | 6808 | 6304 | 5836 | 5402 | 4998 | 2 |
| 3 | 26885 | 25539 | 23683 | 22213 | 20826 | 19517 | 18283 | 17120 | 16025 | 14994 | 3 |
| 4 | 54443 | 51740 | 49142 | 46648 | 44255 | 41961 | 39765 | 37664 | 35656 | 33737 | 4 |
| 5 | 88198 | 84854 | 81576 | 78368 | 75233 | 72174 | 69192 | 66289 | 63467 | 60727 | 5 |
| 6 | 119067 | 115967 | 112847 | 109716 | 106581 | 103449 | 100328 | 97224 | 94143 | 91090 | 6 |
| 7 | 137778 | 135848 | 133805 | 131659 | 129419 | 127094 | 124693 | 122224 | 119696 | 117116 | 7 |
| 8 | 139500 | 139244 | 138823 | 138242 | 137508 | 136626 | 135604 | 134446 | 133161 | 131756 | 8 |
| 9 | 125550 | 126866 | 128025 | 129026 | 129869 | 130554 | 131084 | 131682 | 131756 | 131756 | 9 |
| 10 | 101696 | 104031 | 106261 | 108382 | 110388 | 112277 | 114043 | 115684 | 117197 | 118580 | 10 |
| 11 | 74885 | 77550 | 80179 | 82764 | 85300 | 87780 | 90197 | 92547 | 94823 | 97020 | 11 |
| 12 | 50547 | 52993 | 55457 | 57935 | 60421 | 62909 | 65393 | 67868 | 70327 | 72765 | 12 |
| 13 | 31495 | 33426 | 35407 | 37435 | 39506 | 41617 | 43763 | 45941 | 48147 | 50376 | 13 |
| 14 | 18222 | 19578 | 20991 | 22461 | 23986 | 25565 | 27196 | 28877 | 30608 | 32384 | 14 |
| 15 | 9840 | 10703 | 11615 | 12578 | 13592 | 14657 | 15773 | 16941 | 18161 | 19431 | 15 |
| 16 | 4981 | 5485 | 6025 | 6604 | 7221 | 7878 | 8577 | 9318 | 10102 | 10930 | 16 |
| 17 | 2373 | 2646 | 2942 | 3263 | 3610 | 3985 | 4389 | 4823 | 5289 | 5786 | 17 |
| 18 | 1068 | 1205 | 1356 | 1523 | 1705 | 1904 | 2121 | 2358 | 2615 | 2893 | 18 |
| 19 | 455 | 520 | 593 | 673 | 763 | 862 | 971 | 1092 | 1225 | 1370 | 19 |
| 20 | 184 | 213 | 246 | 283 | 324 | 371 | 423 | 481 | 545 | 617 | 20 |
| 21 | 71 | 83 | 97 | 113 | 131 | 152 | 175 | 201 | 231 | 264 | 21 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 8.1 | 8.2 | 8.3 | 8.4 | 8.5 | 8.6 | 8.7 | 8.8 | 8.9 | 9.0 | |
| 22 | 26 | 31 | 37 | 43 | 51 | 59 | 69 | 81 | 93 | 108 | 22 |
| 23 | 9 | 11 | 13 | 16 | 19 | 22 | 26 | 31 | 36 | 42 | 23 |
| 24 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 11 | 13 | 16 | 24 |
| 25 | 1 | 1 | 2 | 2 | 2 | 3 | 3 | 4 | 5 | 6 | 25 |
| 26 | | | | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 26 |
| 27 | | | | | | | | | 1 | 1 | 27 |
| | 9.1 | 9.2 | 9.3 | 9.4 | 9.5 | 9.6 | 9.7 | 9.8 | 9.9 | 10.0 | |
| 0 | 112 | 101 | 91 | 83 | 75 | 68 | 61 | 55 | 50 | 45 | 0 |
| 1 | 1016 | 930 | 850 | 778 | 711 | 660 | 594 | 543 | 497 | 454 | 1 |
| 2 | 4624 | 4276 | 3954 | 3655 | 3378 | 3121 | 2883 | 2663 | 2459 | 2270 | 2 |
| 3 | 14025 | 13113 | 12256 | 11452 | 10696 | 9987 | 9322 | 8698 | 8114 | 7567 | 3 |
| 4 | 31906 | 30160 | 28496 | 26911 | 25403 | 23969 | 22606 | 21311 | 20082 | 18917 | 4 |
| 5 | 58069 | 55494 | 53002 | 50593 | 48266 | 46020 | 43855 | 41770 | 39763 | 37833 | 5 |
| 6 | 88072 | 85091 | 82154 | 79262 | 76421 | 73632 | 70899 | 68224 | 65609 | 63055 | 6 |
| 7 | 114493 | 111834 | 109147 | 106438 | 103714 | 100981 | 98246 | 95514 | 92790 | 90079 | 7 |
| 8 | 130236 | 128609 | 126883 | 125065 | 123160 | 121178 | 119123 | 117004 | 114827 | 112599 | 8 |
| 9 | 131683 | 131467 | 131113 | 130623 | 130003 | 129256 | 128388 | 127405 | 126310 | 125110 | 9 |
| 10 | 119832 | 120950 | 121935 | 122786 | 123502 | 124086 | 124537 | 124857 | 125047 | 125110 | 10 |
| 11 | 99133 | 101158 | 103090 | 104926 | 106661 | 108293 | 109819 | 111236 | 112542 | 113736 | 11 |
| 12 | 75176 | 77555 | 79895 | 82192 | 84440 | 86634 | 88770 | 90843 | 92847 | 94780 | 12 |
| 13 | 52623 | 54885 | 57156 | 59431 | 61706 | 63976 | 66236 | 68481 | 70707 | 72908 | 13 |
| 14 | 34205 | 36067 | 37968 | 39904 | 41872 | 43869 | 45892 | 47937 | 50000 | 52077 | 14 |
| 15 | 20751 | 22121 | 23540 | 25006 | 26519 | 28076 | 29677 | 31319 | 33000 | 34718 | 15 |
| 16 | 11802 | 12720 | 13683 | 14691 | 15746 | 16846 | 17992 | 19183 | 20419 | 21699 | 16 |
| 17 | 6318 | 6884 | 7485 | 8123 | 8799 | 9513 | 10266 | 11058 | 11891 | 12764 | 17 |
| 18 | 3194 | 3518 | 3867 | 4242 | 4644 | 5074 | 5532 | 6021 | 6540 | 7091 | 18 |
| 19 | 1530 | 1704 | 1893 | 2099 | 2322 | 2563 | 2824 | 3105 | 3408 | 3732 | 19 |
| 20 | 696 | 784 | 880 | 986 | 1103 | 1230 | 1370 | 1522 | 1687 | 1866 | 20 |
| 21 | 302 | 343 | 390 | 442 | 499 | 563 | 633 | 710 | 795 | 889 | 21 |
| 22 | 125 | 144 | 165 | 189 | 215 | 245 | 279 | 316 | 358 | 404 | 22 |
| 23 | 49 | 57 | 67 | 77 | 89 | 102 | 118 | 135 | 154 | 176 | 23 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 9.1 | 9.2 | 9.3 | 9.4 | 9.5 | 9.6 | 9.7 | 9.8 | 9.9 | 10.0 | |
| 24 | 19 | 22 | 26 | 30 | 35 | 41 | 48 | 55 | 64 | 73 | 24 |
| 25 | 7 | 8 | 10 | 11 | 13 | 16 | 18 | 22 | 25 | 29 | 25 |
| 26 | 2 | 3 | 3 | 4 | 5 | 6 | 7 | 8 | 10 | 11 | 26 |
| 27 | 1 | 1 | 1 | 1 | 2 | 2 | 2 | 3 | 4 | 4 | 27 |
| 28 | | | | | 1 | 1 | 1 | 1 | 1 | 1 | 28 |
| 29 | | | | | | | | | | 1 | 29 |
| | 10.1 | 10.2 | 10.3 | 10.4 | 10.5 | 10.6 | 10.7 | 10.8 | 10.9 | 11.0 | |
| 0 | 41 | 37 | 34 | 30 | 28 | 25 | 23 | 20 | 18 | 17 | 0 |
| 1 | 415 | 379 | 346 | 317 | 289 | 264 | 241 | 220 | 201 | 184 | 1 |
| 2 | 2095 | 1934 | 1784 | 1646 | 1518 | 1400 | 1291 | 1190 | 1097 | 1010 | 2 |
| 3 | 7054 | 6574 | 6125 | 5705 | 5313 | 4946 | 4603 | 4283 | 3984 | 3705 | 3 |
| 4 | 17811 | 16764 | 15773 | 14834 | 13946 | 13107 | 12313 | 11564 | 10856 | 10189 | 4 |
| 5 | 35979 | 34199 | 32492 | 30855 | 29287 | 27786 | 26350 | 24978 | 23667 | 22415 | 5 |
| 6 | 60565 | 58139 | 55777 | 53482 | 51252 | 49089 | 46991 | 44960 | 42995 | 41095 | 6 |
| 7 | 87387 | 84716 | 82072 | 79458 | 76878 | 74334 | 71830 | 69367 | 66949 | 64577 | 7 |
| 8 | 110326 | 108013 | 105668 | 103296 | 100902 | 98493 | 96072 | 93646 | 91218 | 88794 | 8 |
| 9 | 123810 | 122415 | 120931 | 119364 | 117720 | 116003 | 114219 | 112375 | 110475 | 108526 | 9 |
| 10 | 125048 | 124863 | 124559 | 124139 | 123606 | 122963 | 122215 | 121365 | 120418 | 119378 | 10 |
| 11 | 114817 | 115782 | 116633 | 117368 | 117987 | 118492 | 118882 | 119159 | 119323 | 119378 | 11 |
| 12 | 96637 | 98415 | 100110 | 101719 | 103239 | 104667 | 106003 | 107243 | 108386 | 109430 | 12 |
| 13 | 75080 | 77218 | 79318 | 81375 | 83385 | 85344 | 87248 | 89094 | 90877 | 92595 | 13 |
| 14 | 54165 | 56259 | 58355 | 60450 | 62539 | 64618 | 66683 | 68730 | 70754 | 72753 | 14 |
| 15 | 36471 | 38256 | 40071 | 41912 | 43777 | 45663 | 47567 | 49485 | 51415 | 53352 | 15 |
| 16 | 23022 | 24388 | 25795 | 27243 | 28729 | 30252 | 31810 | 33403 | 35026 | 36680 | 16 |
| 17 | 13678 | 14633 | 15629 | 16666 | 17744 | 18863 | 20022 | 21220 | 22458 | 23734 | 17 |
| 18 | 7675 | 8292 | 8943 | 9629 | 10351 | 11108 | 11902 | 12732 | 13600 | 14504 | 18 |
| 19 | 4080 | 4451 | 4848 | 5271 | 5720 | 6197 | 6703 | 7237 | 7802 | 8397 | 19 |
| 20 | 2060 | 2270 | 2497 | 2741 | 3003 | 3285 | 3586 | 3908 | 4252 | 4618 | 20 |
| 21 | 991 | 1103 | 1225 | 1357 | 1502 | 1658 | 1827 | 2010 | 2207 | 2419 | 21 |
| 22 | 455 | 511 | 573 | 642 | 717 | 799 | 889 | 987 | 1093 | 1210 | 22 |
| 23 | 200 | 227 | 257 | 290 | 327 | 368 | 413 | 463 | 518 | 578 | 23 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 10.1 | 10.2 | 10.3 | 10.4 | 10.5 | 10.6 | 10.7 | 10.8 | 10.9 | 11.0 | |
| 24 | 84 | 96 | 110 | 126 | 143 | 163 | 184 | 208 | 235 | 265 | 24 |
| 25 | 34 | 39 | 45 | 52 | 60 | 69 | 79 | 90 | 103 | 117 | 25 |
| 26 | 13 | 15 | 18 | 21 | 24 | 28 | 32 | 37 | 43 | 49 | 26 |
| 27 | 5 | 6 | 7 | 8 | 9 | 11 | 13 | 15 | 17 | 20 | 27 |
| 28 | 2 | 2 | 3 | 3 | 4 | 4 | 5 | 6 | 7 | 8 | 28 |
| 29 | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 2 | 3 | 3 | 29 |
| 30 | | | | | | 1 | 1 | 1 | 1 | 1 | 30 |
| | 11.1 | 11.2 | 11.3 | 11.4 | 11.5 | 11.6 | 11.7 | 11.8 | 11.9 | 12.0 | |
| 0 | 15 | 14 | 12 | 11 | 10 | 9 | 8 | 8 | 7 | 6 | 0 |
| 1 | 168 | 153 | 140 | 128 | 116 | 106 | 97 | 89 | 81 | 74 | 1 |
| 2 | 931 | 858 | 790 | 727 | 670 | 617 | 568 | 522 | 481 | 442 | 2 |
| 3 | 3445 | 3202 | 2976 | 2764 | 2568 | 2385 | 2214 | 2055 | 1907 | 1770 | 3 |
| 4 | 9559 | 8965 | 8406 | 7879 | 7382 | 6915 | 6476 | 6062 | 5674 | 5309 | 4 |
| 5 | 21221 | 20082 | 18997 | 17936 | 16979 | 16043 | 15153 | 14307 | 13504 | 12741 | 5 |
| 6 | 39259 | 37487 | 35778 | 34130 | 32544 | 31017 | 29549 | 28137 | 26782 | 254814 | 6 |
| 7 | 62253 | 59979 | 57755 | 55584 | 53465 | 51400 | 49388 | 47432 | 45530 | 43682 | 7 |
| 8 | 86376 | 83970 | 81579 | 79206 | 76856 | 74529 | 72231 | 69962 | 67725 | 65523 | 8 |
| 9 | 106531 | 104496 | 102427 | 100328 | 98204 | 96060 | 93900 | 91728 | 89548 | 87364 | 9 |
| 10 | 118249 | 117036 | 115743 | 114374 | 112935 | 111430 | 109863 | 108239 | 106562 | 104837 | 10 |
| 11 | 119324 | 119164 | 118899 | 118533 | 118068 | 117508 | 116854 | 116110 | 115281 | 114368 | 11 |
| 12 | 110375 | 111220 | 111964 | 112607 | 113149 | 113591 | 113933 | 114175 | 114320 | 114363 | 12 |
| 13 | 94243 | 95820 | 97322 | 98747 | 100093 | 101358 | 102538 | 103636 | 104647 | 105570 | 13 |
| 14 | 74721 | 76656 | 78553 | 80409 | 82219 | 83982 | 85694 | 87350 | 88950 | 90489 | 14 |
| 15 | 55294 | 57236 | 59177 | 61110 | 63035 | 64946 | 66841 | 68716 | 70567 | 72391 | 15 |
| 16 | 38360 | 40065 | 41793 | 43541 | 45306 | 47086 | 48877 | 50678 | 52484 | 54293 | 16 |
| 17 | 25047 | 26396 | 27780 | 29198 | 30648 | 32129 | 33639 | 35176 | 36739 | 38325 | 17 |
| 18 | 15446 | 16424 | 17440 | 18492 | 19581 | 20706 | 21865 | 23060 | 24288 | 25550 | 18 |
| 19 | 9023 | 9682 | 10372 | 11095 | 11852 | 12641 | 13465 | 14322 | 15212 | 16137 | 19 |
| 20 | 5008 | 5422 | 5860 | 6324 | 6815 | 7332 | 7877 | 8450 | 9051 | 9682 | 20 |
| 21 | 2647 | 2892 | 3153 | 3433 | 3732 | 4050 | 4388 | 4748 | 5129 | 5533 | 21 |
| 22 | 1336 | 1472 | 1620 | 1779 | 1951 | 2136 | 2334 | 2547 | 2774 | 3018 | 22 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 11.1 | 11.2 | 11.3 | 11.4 | 11.5 | 11.6 | 11.7 | 11.8 | 11.9 | 12.0 | |
| 23 | 645 | 717 | 796 | 882 | 975 | 1077 | 1187 | 1307 | 1435 | 1575 | 23 |
| 24 | 298 | 335 | 375 | 419 | 467 | 521 | 579 | 642 | 712 | 787 | 24 |
| 25 | 132 | 150 | 169 | 191 | 215 | 242 | 271 | 303 | 339 | 378 | 25 |
| 26 | 57 | 65 | 74 | 84 | 95 | 108 | 122 | 138 | 155 | 174 | 26 |
| 27 | 23 | 27 | 31 | 35 | 41 | 46 | 53 | 60 | 68 | 78 | 27 |
| 28 | 9 | 11 | 12 | 14 | 17 | 19 | 22 | 25 | 29 | 33 | 28 |
| 29 | 4 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 14 | 29 |
| 30 | 1 | 2 | 2 | 2 | 3 | 3 | 3 | 4 | 5 | 5 | 30 |
| 31 | | 1 | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 2 | 31 |
| 32 | | | | | | | | 1 | 1 | 1 | 32 |
| | 12.1 | 12.2 | 12.3 | 12.4 | 12.5 | 12.6 | 12.7 | 12.8 | 12.9 | 13.0 | |
| 0 | 6 | 5 | 5 | 4 | 4 | 3 | 3 | 3 | 2 | 2 | 0 |
| 1 | 67 | 61 | 56 | 51 | 47 | 42 | 39 | 35 | 32 | 29 | 1 |
| 2 | 407 | 374 | 344 | 317 | 291 | 268 | 246 | 226 | 208 | 191 | 2 |
| 3 | 1641 | 1522 | 1412 | 1309 | 1213 | 1124 | 1042 | 965 | 894 | 828 | 3 |
| 4 | 4966 | 4643 | 4341 | 4057 | 3791 | 3541 | 3307 | 3088 | 2882 | 2690 | 4 |
| 5 | 12017 | 11330 | 10679 | 10062 | 9477 | 8924 | 8400 | 7905 | 7436 | 6994 | 5 |
| 6 | 24233 | 23037 | 21892 | 20749 | 19744 | 18740 | 17781 | 16864 | 15988 | 15153 | 6 |
| 7 | 41889 | 40151 | 38467 | 36836 | 35258 | 33733 | 32259 | 30837 | 29464 | 28141 | 7 |
| 8 | 63358 | 61230 | 59142 | 57095 | 55091 | 53129 | 51212 | 49339 | 47511 | 45730 | 8 |
| 9 | 85181 | 83000 | 80828 | 78665 | 76515 | 74381 | 72266 | 70171 | 68100 | 66054 | 9 |
| 10 | 103069 | 101261 | 99418 | 97544 | 95644 | 93720 | 91777 | 89819 | 87849 | 85870 | 10 |
| 11 | 113376 | 112308 | 111168 | 109959 | 108686 | 107352 | 105961 | 104516 | 103023 | 101483 | 11 |
| 12 | 114321 | 114180 | 113947 | 113624 | 113215 | 112720 | 112142 | 111484 | 110749 | 109940 | 12 |
| 13 | 106406 | 107153 | 107811 | 108380 | 108860 | 109251 | 109554 | 109769 | 109897 | 109940 | 13 |
| 14 | 91965 | 93376 | 94720 | 95994 | 97197 | 98326 | 99381 | 100360 | 101263 | 102087 | 14 |
| 15 | 74185 | 75946 | 77670 | 79355 | 80997 | 82594 | 84143 | 85641 | 87086 | 88475 | 15 |
| 16 | 56103 | 57909 | 59709 | 61500 | 63279 | 65043 | 66788 | 68513 | 70213 | 71886 | 16 |
| 17 | 39932 | 41558 | 43201 | 44859 | 46529 | 48208 | 49895 | 51586 | 53279 | 54972 | 17 |
| 18 | 26843 | 28167 | 29521 | 30903 | 32312 | 33746 | 35204 | 36683 | 38183 | 39702 | 18 |
| 19 | 17095 | 18086 | 19111 | 20168 | 21258 | 22379 | 23531 | 24713 | 25925 | 27164 | 19 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 12.1 | 12.2 | 12.3 | 12.4 | 12.5 | 12.6 | 12.7 | 12.8 | 12.9 | 13.0 | |
| 20 | 10342 | 11033 | 11753 | 12504 | 13286 | 14099 | 14942 | 15816 | 16721 | 17657 | 20 |
| 21 | 5959 | 6409 | 6884 | 7383 | 7908 | 8459 | 9036 | 9640 | 10272 | 10930 | 21 |
| 22 | 3278 | 3554 | 3849 | 4162 | 4493 | 4845 | 5216 | 5609 | 6023 | 6459 | 22 |
| 23 | 1724 | 1885 | 2058 | 2244 | 2442 | 2654 | 2880 | 3122 | 3378 | 3651 | 23 |
| 24 | 869 | 958 | 1055 | 1159 | 1272 | 1393 | 1524 | 1665 | 1816 | 1977 | 24 |
| 25 | 421 | 468 | 519 | 575 | 636 | 702 | 774 | 852 | 973 | 1028 | 25 |
| 26 | 196 | 219 | 246 | 274 | 306 | 340 | 378 | 420 | 465 | 514 | 26 |
| 27 | 88 | 99 | 112 | 126 | 142 | 159 | 178 | 199 | 222 | 248 | 27 |
| 28 | 38 | 43 | 49 | 56 | 63 | 71 | 81 | 91 | 102 | 115 | 28 |
| 29 | 16 | 18 | 21 | 24 | 27 | 31 | 35 | 40 | 46 | 52 | 29 |
| 30 | 6 | 7 | 9 | 10 | 11 | 13 | 15 | 17 | 20 | 22 | 30 |
| 31 | 2 | 3 | 3 | 4 | 5 | 5 | 6 | 7 | 8 | 9 | 31 |
| 32 | 1 | 1 | 1 | 2 | 2 | 2 | 2 | 3 | 3 | 4 | 32 |
| 33 | | | | 1 | 1 | 1 | 1 | 1 | 1 | 2 | 33 |
| 34 | | | | | | | | | | 1 | 34 |
| | 13.1 | 13.2 | 13.3 | 13.4 | 13.5 | 13.6 | 13.7 | 13.8 | 13.9 | 14.0 | |
| 0 | 2 | 2 | 2 | 2 | 1 | 1 | 1 | 1 | 1 | 1 | 0 |
| 1 | 27 | 24 | 22 | 20 | 19 | 17 | 15 | 14 | 13 | 12 | 1 |
| 2 | 175 | 161 | 148 | 136 | 125 | 115 | 105 | 97 | 89 | 81 | 2 |
| 3 | 766 | 709 | 657 | 608 | 562 | 520 | 481 | 445 | 411 | 380 | 3 |
| 4 | 2510 | 2341 | 2183 | 2035 | 1897 | 1768 | 1648 | 1535 | 1429 | 1331 | 4 |
| 5 | 6575 | 6180 | 5807 | 5455 | 5123 | 4810 | 4514 | 4236 | 3974 | 3727 | 5 |
| 6 | 14356 | 13596 | 12872 | 12183 | 11526 | 10902 | 10308 | 9743 | 9206 | 8696 | 6 |
| 7 | 26867 | 25639 | 24458 | 23322 | 22230 | 21181 | 20173 | 19207 | 18280 | 17392 | 7 |
| 8 | 43994 | 42304 | 40661 | 39064 | 37512 | 36007 | 34547 | 33132 | 31762 | 30435 | 8 |
| 9 | 64036 | 62046 | 60088 | 58161 | 56269 | 54410 | 52588 | 50802 | 49054 | 47344 | 9 |
| 10 | 83887 | 81901 | 79916 | 77936 | 75963 | 73998 | 72046 | 70107 | 68185 | 66282 | 10 |
| 11 | 99901 | 98281 | 96626 | 94940 | 93227 | 91489 | 89730 | 87953 | 86162 | 84359 | 11 |
| 12 | 109059 | 108109 | 107094 | 106017 | 104880 | 103687 | 102441 | 101146 | 99804 | 98418 | 12 |
| 13 | 109898 | 109773 | 109566 | 109279 | 108914 | 108473 | 107957 | 107370 | 106713 | 105989 | 13 |
| 14 | 102833 | 103500 | 104087 | 104595 | 105024 | 105373 | 105644 | 105836 | 105951 | 105989 | 14 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----|
| | 13.1 | 13.2 | 13.3 | 13.4 | 13.5 | 13.6 | 13.7 | 13.8 | 13.9 | 14.0 | |
| 15 | 89807 | 91080 | 92291 | 93439 | 94522 | 95539 | 96488 | 97369 | 98181 | 98923 | 15 |
| 16 | 73530 | 75141 | 76717 | 78255 | 79753 | 81208 | 82618 | 83981 | 85295 | 86558 | 16 |
| 17 | 56661 | 58345 | 60019 | 61683 | 63333 | 64966 | 66580 | 68173 | 69741 | 71283 | 17 |
| 18 | 41237 | 42786 | 44348 | 45920 | 47500 | 49386 | 50675 | 52266 | 53856 | 55442 | 18 |
| 19 | 28432 | 29725 | 31043 | 32385 | 33750 | 35135 | 36539 | 37962 | 39400 | 40852 | 19 |
| 20 | 18623 | 19619 | 20644 | 21698 | 22781 | 23892 | 25030 | 26193 | 27383 | 28597 | 20 |
| 21 | 11617 | 12332 | 13074 | 13846 | 14645 | 15473 | 16329 | 17213 | 18125 | 19064 | 21 |
| 22 | 6917 | 7399 | 7904 | 8433 | 8987 | 9565 | 10168 | 10797 | 11452 | 12132 | 22 |
| 23 | 3940 | 4246 | 4571 | 4913 | 5275 | 5656 | 6057 | 6478 | 6921 | 7385 | 23 |
| 24 | 2151 | 2336 | 2533 | 2743 | 2967 | 3205 | 3457 | 3725 | 4008 | 4308 | 24 |
| 25 | 1127 | 1233 | 1348 | 1470 | 1602 | 1744 | 1895 | 2056 | 2229 | 2412 | 25 |
| 26 | 568 | 626 | 689 | 758 | 832 | 912 | 998 | 1091 | 1191 | 1299 | 26 |
| 27 | 275 | 306 | 340 | 376 | 416 | 459 | 507 | 558 | 613 | 674 | 27 |
| 28 | 129 | 144 | 161 | 180 | 201 | 223 | 248 | 275 | 305 | 337 | 28 |
| 29 | 58 | 66 | 74 | 83 | 93 | 105 | 117 | 131 | 146 | 163 | 29 |
| 30 | 25 | 29 | 33 | 37 | 42 | 47 | 53 | 60 | 68 | 76 | 30 |
| 31 | 11 | 12 | 14 | 16 | 18 | 21 | 24 | 27 | 30 | 34 | 31 |
| 32 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 13 | 15 | 32 |
| 33 | 2 | 2 | 2 | 3 | 3 | 4 | 4 | 5 | 6 | 6 | 33 |
| 34 | 1 | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 2 | 3 | 34 |
| 35 | | | | | | 1 | 1 | 1 | 1 | 1 | 35 |
| | 14.1 | 14.2 | 14.3 | 14.4 | 14.5 | 14.6 | 14.7 | 14.8 | 14.9 | 15.0 | |
| 0 | 1 | 1 | 1 | 1 | 1 | | | | | | 0 |
| 1 | 11 | 10 | 9 | 8 | 7 | 7 | 6 | 6 | 5 | 5 | 1 |
| 2 | 75 | 69 | 63 | 58 | 53 | 49 | 45 | 41 | 38 | 34 | 2 |
| 3 | 352 | 325 | 300 | 277 | 256 | 237 | 219 | 202 | 186 | 172 | 3 |
| 4 | 1239 | 1153 | 1073 | 999 | 929 | 864 | 803 | 747 | 694 | 645 | 4 |
| 5 | 3494 | 3275 | 3070 | 2876 | 2694 | 2523 | 2362 | 2211 | 2069 | 1936 | 5 |
| 6 | 8212 | 7752 | 7316 | 6902 | 6510 | 6139 | 5787 | 5454 | 5138 | 4839 | 6 |
| 7 | 16541 | 15726 | 14946 | 14199 | 13486 | 12804 | 12152 | 11530 | 10937 | 10370 | 7 |
| 8 | 29153 | 27913 | 26715 | 25559 | 24443 | 23367 | 22330 | 21331 | 20370 | 19444 | 8 |

تابع الجدول 2

| m | λ | | | | | | | | | | m |
|----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|----|
| | 14.1 | 14.2 | 14.3 | 14.4 | 14.5 | 14.6 | 14.7 | 14.8 | 14.9 | 15.0 | |
| 9 | 45673 | 44040 | 42447 | 40894 | 39380 | 37907 | 36472 | 35078 | 33723 | 32407 | 9 |
| 10 | 64399 | 62537 | 60700 | 58887 | 57101 | 55343 | 53614 | 51915 | 50247 | 48611 | 10 |
| 11 | 82547 | 80730 | 78910 | 77089 | 75270 | 73456 | 71648 | 69850 | 68062 | 66287 | 11 |
| 12 | 96993 | 95530 | 94034 | 92507 | 90951 | 89371 | 87769 | 86148 | 84510 | 82859 | 12 |
| 13 | 105200 | 104349 | 103437 | 102469 | 101446 | 100371 | 99247 | 98076 | 96862 | 95607 | 13 |
| 14 | 105951 | 105839 | 105654 | 105396 | 105069 | 104672 | 104209 | 103681 | 103089 | 102436 | 14 |
| 15 | 99594 | 100195 | 100723 | 101181 | 101567 | 101881 | 102125 | 102298 | 102402 | 102436 | 15 |
| 16 | 87768 | 88923 | 90021 | 91063 | 92045 | 92967 | 93827 | 94626 | 95361 | 96034 | 16 |
| 17 | 72795 | 74277 | 75724 | 77135 | 78509 | 79842 | 81133 | 82380 | 83581 | 84736 | 17 |
| 18 | 57023 | 58596 | 60158 | 61708 | 63243 | 64761 | 66259 | 67735 | 69187 | 70613 | 18 |
| 19 | 42317 | 43793 | 45277 | 46768 | 48264 | 49763 | 51263 | 52762 | 54257 | 55747 | 19 |
| 20 | 29834 | 31093 | 32373 | 33673 | 34992 | 36327 | 37678 | 39044 | 40422 | 41810 | 20 |
| 21 | 20231 | 21025 | 22045 | 23090 | 24161 | 25256 | 26375 | 27517 | 28680 | 29865 | 21 |
| 22 | 122838 | 13570 | 14329 | 15114 | 15924 | 16761 | 17623 | 18511 | 19424 | 20362 | 22 |
| 23 | 7870 | 8378 | 8909 | 9462 | 10039 | 10640 | 11264 | 11911 | 12584 | 13280 | 23 |
| 24 | 4624 | 4957 | 5308 | 5677 | 6065 | 6472 | 6899 | 7345 | 7812 | 8300 | 24 |
| 25 | 2608 | 2816 | 3036 | 3270 | 3518 | 3780 | 4057 | 4348 | 4656 | 4980 | 25 |
| 26 | 1414 | 1538 | 1670 | 1811 | 1962 | 2123 | 2294 | 2475 | 2668 | 2873 | 26 |
| 27 | 739 | 809 | 884 | 966 | 1054 | 1148 | 1249 | 1357 | 1473 | 1596 | 27 |
| 28 | 372 | 410 | 452 | 497 | 546 | 598 | 656 | 717 | 784 | 855 | 28 |
| 29 | 181 | 201 | 223 | 247 | 273 | 301 | 332 | 366 | 403 | 442 | 29 |
| 30 | 85 | 95 | 106 | 118 | 132 | 147 | 163 | 181 | 200 | 221 | 30 |
| 31 | 39 | 44 | 49 | 55 | 62 | 69 | 77 | 86 | 96 | 107 | 31 |
| 32 | 17 | 19 | 22 | 25 | 28 | 32 | 35 | 40 | 45 | 50 | 32 |
| 33 | 7 | 8 | 9 | 11 | 12 | 14 | 16 | 18 | 20 | 23 | 33 |
| 34 | 3 | 3 | 4 | 5 | 5 | 6 | 7 | 8 | 9 | 10 | 34 |
| 35 | 1 | 1 | 2 | 2 | 2 | 2 | 3 | 3 | 4 | 4 | 35 |
| 36 | | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 2 | 2 | 36 |
| 37 | | | | | | | | 1 | 1 | 1 | 37 |

The Poisson Distribution جدول 3: توزيع بواسون

$$g(k, \lambda) = \sum_{m=0}^k \frac{\lambda^m e^{-\lambda}}{m!}$$

جدول قيم الدالة:

| $\lambda \backslash k$ | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 |
|------------------------|----------|----------|----------|----------|----------|----------|
| 0 | 0.904837 | 0.818731 | 0.740818 | 0.670320 | 0.606531 | 0.548812 |
| 1 | 0.995321 | 0.982477 | 0.963063 | 0.938448 | 0.909796 | 0.878099 |
| 2 | 0.999845 | 0.998852 | 0.996390 | 0.992074 | 0.985612 | 0.977885 |
| 3 | 0.999996 | 0.999943 | 0.999724 | 0.999224 | 0.998248 | 0.997642 |
| 4 | 1.000000 | 0.999998 | 0.999974 | 0.999939 | 0.999828 | 0.999606 |
| 5 | 1.000000 | 1.000000 | 0.999999 | 0.999996 | 0.999986 | 0.999962 |
| 6 | 1.000000 | 1.000000 | 1.000000 | 1.000000 | 0.999999 | 0.999997 |
| 7 | 1.000000 | 1.000000 | 1.000000 | 1.000000 | 1.000000 | 1.000000 |

| $\lambda \backslash k$ | 0.7 | 0.8 | 0.9 | 1.0 | 2.0 | 3.0 |
|------------------------|----------|----------|----------|----------|----------|----------|
| 0 | 0.496585 | 0.449329 | 0.406570 | 0.367879 | 0.135335 | 0.049787 |
| 1 | 0.844195 | 0.808792 | 0.772483 | 0.735759 | 0.406006 | 0.199148 |
| 2 | 0.965858 | 0.952577 | 0.937144 | 0.919699 | 0.676677 | 0.423190 |
| 3 | 0.994246 | 0.990920 | 0.988542 | 0.981012 | 0.857124 | 0.647232 |
| 4 | 0.999214 | 0.998589 | 0.997657 | 0.996340 | 0.947348 | 0.815263 |
| 5 | 0.999909 | 0.999816 | 0.999658 | 0.999406 | 0.983437 | 0.916082 |
| 6 | 0.999990 | 0.999980 | 0.999958 | 0.999917 | 0.995467 | 0.966491 |
| 7 | 0.999998 | 0.999999 | 0.999997 | 0.999990 | 0.998904 | 0.988095 |
| 8 | 1.000000 | 1.000000 | 1.000000 | 0.999999 | 0.999763 | 0.996196 |
| 9 | | | | 1.000000 | 0.999954 | 0.998897 |
| 10 | | | | | 0.999992 | 0.999707 |
| 11 | | | | | 0.999999 | 0.999928 |
| 12 | | | | | 1.000000 | 0.999983 |
| 13 | | | | | | 0.999996 |
| 14 | | | | | | 0.999999 |
| 15 | | | | | | 1.000000 |

The Exponential Distribution جدول 4: التوزيع الأسي

$$f(x) = e^{-x}$$

جدول قيم الدالة:

| x | e^x | e^{-x} |
|------|--------|----------|
| 0.00 | 1.0000 | 1.0000 |
| 0.01 | 1.0101 | 0.9900 |
| 0.02 | 1.0202 | 0.9802 |
| 0.03 | 1.0305 | 0.9704 |
| 0.04 | 1.0408 | 0.9608 |
| 0.05 | 1.0513 | 0.9512 |
| 0.06 | 1.0618 | 0.9418 |
| 0.07 | 1.0725 | 0.9324 |
| 0.08 | 1.0833 | 0.9231 |
| 0.09 | 1.0942 | 0.9139 |
| 0.10 | 1.1052 | 0.9048 |
| 0.11 | 1.1163 | 0.8958 |
| 0.12 | 1.1275 | 0.8869 |
| 0.13 | 1.1388 | 0.8781 |
| 0.14 | 1.1503 | 0.9694 |
| 0.15 | 1.1618 | 0.8607 |
| 0.16 | 1.1735 | 0.8521 |
| 0.17 | 1.853 | 0.8437 |
| 0.18 | 1.1972 | 0.8353 |
| 0.19 | 1.2092 | 0.8270 |
| 0.20 | 1.2214 | 0.8187 |
| 0.21 | 1.2337 | 0.8106 |
| 0.22 | 1.2461 | 0.8025 |
| 0.23 | 1.2586 | 0.7945 |
| 0.24 | 1.2712 | 0.7866 |

| x | e^x | e^{-x} |
|------|---------|----------|
| 0.25 | 1.2840 | 0.7788 |
| 0.26 | 1.2969 | 0.7711 |
| 0.27 | 1.3100 | 0.7634 |
| 0.28 | 1.3231 | 0.7558 |
| 0.29 | 1.3364 | 0.7483 |
| 0.30 | 1.3499 | 0.7408 |
| 0.31 | 1.13634 | 0.7334 |
| 0.32 | 1.3771 | 0.7261 |
| 0.33 | 1.3910 | 0.7189 |
| 0.34 | 1.4049 | 0.7118 |
| 0.35 | 1.4191 | 0.7047 |
| 0.36 | 1.4333 | 0.6977 |
| 0.37 | 1.4477 | .06907 |
| 0.38 | 1.4623 | 0.6839 |
| 0.39 | 1.4770 | 0.6771 |
| 0.40 | 1.4918 | 0.6703 |
| 0.41 | 1.5068 | 0.6637 |
| 0.42 | 1.5220 | 0.6570 |
| 0.43 | 1.5373 | 0.6505 |
| 0.44 | 1.5527 | 0.6440 |
| 0.45 | 1.5683 | 0.6376 |
| 0.46 | 1.5683 | 0.6376 |
| 0.47 | 1.5841 | 0.6313 |
| 0.48 | 1.6000 | 0.6250 |
| 0.49 | 1.6161 | 0.6188 |

تابع جدول 4.

| x | e^x | e^{-x} |
|------|--------|----------|
| 0.50 | 1.6323 | 0.6126 |
| 0.51 | 1.6487 | 0.6065 |
| 0.52 | 1.6653 | 0.6005 |
| 0.53 | 1.6820 | 0.5945 |
| 0.54 | 1.6989 | 0.5886 |
| 0.55 | 1.7160 | 0.5827 |
| 0.56 | 1.7333 | 0.5769 |
| 0.57 | 1.7507 | 0.5712 |
| 0.58 | 1.7683 | 0.5655 |
| 0.59 | 1.7860 | 0.5599 |
| 0.60 | 1.8040 | 0.5543 |
| 0.61 | 1.8221 | 0.5488 |
| 0.62 | 1.8044 | 0.5434 |
| 0.63 | 1.8589 | 0.5379 |
| 0.64 | 1.8776 | 0.5326 |
| 0.65 | 1.8965 | 0.5273 |
| 0.66 | 1.9155 | 0.5220 |
| 0.67 | 1.9348 | 0.5169 |
| 0.68 | 1.9542 | 0.5117 |
| 0.69 | 1.9739 | 0.5066 |
| 0.70 | 2.0138 | 0.4966 |
| 0.71 | 2.0340 | 0.4916 |
| 0.72 | 2.0544 | 0.4868 |
| 0.73 | 2.0751 | 0.4819 |
| 0.74 | 2.0959 | 0.4771 |
| 0.75 | 2.1170 | 0.4724 |
| 0.76 | 2.1383 | 0.4677 |

| x | e^x | e^{-x} |
|------|--------|----------|
| 0.77 | 2.1598 | 0.4630 |
| 0.78 | 2.1815 | 0.4584 |
| 0.79 | 2.2034 | 0.4538 |
| 0.80 | 2.2255 | 0.4493 |
| 0.81 | 2.2479 | 0.4449 |
| 0.82 | 2.2705 | 0.4404 |
| 0.83 | 2.2933 | 0.4360 |
| 0.84 | 2.3164 | 0.4317 |
| 0.85 | 2.3396 | 0.4274 |
| 0.86 | 2.3632 | 0.4232 |
| 0.87 | 2.369 | 0.4190 |
| 0.88 | 2.4109 | 0.4148 |
| 0.89 | 2.4351 | 0.4107 |
| 0.90 | 2.4596 | 0.4066 |
| 0.91 | 2.4843 | 0.4025 |
| 0.92 | 2.5093 | 0.3985 |
| 0.93 | 2.5345 | 0.3946 |
| 0.94 | 2.5600 | 0.3906 |
| 0.95 | 2.5857 | 0.3867 |
| 0.96 | 2.6117 | 0.3829 |
| 0.97 | 2.6379 | 0.3791 |
| 0.98 | 2.6646 | 0.3753 |
| 0.99 | 2.6912 | 0.3716 |
| 1.00 | 2.7183 | 0.3679 |
| 1.05 | 2.8577 | 0.3499 |
| 1.10 | 3.0042 | 0.3329 |
| 1.15 | 3.1582 | 0.3166 |

تابع جدول 4

| x | e^x | e^{-x} |
|------|--------|----------|
| 1.20 | 3.3201 | 0.3012 |
| 1.25 | 3.4903 | 0.2865 |
| 1.30 | 3.6693 | 0.2725 |
| 1.35 | 3.8574 | 0.2592 |
| 1.40 | 4.0552 | 0.2466 |
| 1.45 | 2.631 | 0.2346 |
| 1.50 | 4.4817 | 0.2231 |
| 1.55 | 4.7115 | 0.2122 |
| 1.60 | 4.9530 | 0.2019 |
| 1.65 | 5.2070 | 0.1920 |
| 1.70 | 5.4739 | 0.1827 |
| 1.75 | 5.7546 | 0.1738 |
| 1.80 | 6.0496 | 0.1653 |
| 1.85 | 6.3598 | 0.1572 |
| 1.90 | 6.6859 | 0.1496 |
| 1.95 | 7.0287 | 0.1423 |
| 2.00 | 7.3891 | 0.1353 |
| 2.05 | 7.7679 | 0.1287 |
| 2.10 | 8.1662 | 0.1225 |
| 2.15 | 8.5849 | 0.1165 |
| 2.20 | 9.0250 | 0.1108 |
| 2.25 | 9.4877 | 0.1054 |
| 2.30 | 9.7942 | 0.1003 |
| 2.35 | 10.486 | 0.0954 |
| 2.40 | 11.023 | 0.0907 |
| 2.45 | 11.588 | 0.0863 |
| 2.50 | 12.182 | 0.0821 |

| x | e^x | e^{-x} |
|------|--------|----------|
| 2.55 | 12.807 | 0.0781 |
| 2.60 | 13.464 | 0.0743 |
| 2.65 | 14.154 | 0.0707 |
| 2.70 | 14.880 | 0.672 |
| 2.75 | 16.643 | 0.0639 |
| 2.80 | 16.445 | 0.0608 |
| 2.85 | 17.288 | 0.0578 |
| 2.90 | 18.174 | 0.0550 |
| 2.95 | 19.106 | 0.0523 |
| 3.00 | 10.086 | 0.0498 |
| 3.05 | 21.115 | 0.0474 |
| 3.10 | 22.198 | 0.0450 |
| 3.15 | 23.336 | 0.0429 |
| 3.20 | 24.533 | 0.0408 |
| 3.25 | 25.790 | 0.0388 |
| 3.30 | 27.113 | 0.0369 |
| 3.35 | 28.503 | 0.0351 |
| 3.40 | 29.964 | 0.0334 |
| 3.45 | 31.500 | 0.0317 |
| 3.50 | 33.115 | 0.0302 |
| 3.55 | 34.813 | 0.0287 |
| 3.60 | 36.598 | 0.0273 |
| 3.65 | 38.475 | 0.0260 |
| 3.70 | 40.447 | 0.0247 |
| 3.75 | 42.521 | 0.0235 |
| 3.80 | 44.701 | 0.0224 |
| 3.85 | 46.993 | 0.0213 |

تابع جدول 4

| x | e^x | e^{-x} |
|------|--------|----------|
| 4.60 | 99.484 | 0.0101 |
| 4.70 | 109.95 | 0.0091 |
| 4.80 | 121.15 | 0.0082 |
| 3.90 | 49.402 | 0.0202 |
| 3.95 | 51.935 | 0.0193 |
| 4.00 | 54.598 | 0.0183 |
| 4.10 | 60.340 | 0.0166 |
| 4.20 | 66.686 | 0.0150 |
| 4.30 | 73.700 | 0.0136 |
| 4.40 | 81.451 | 0.0123 |
| 4.50 | 90.017 | 0.0111 |


| x | e^x | e^{-x} |
|-------|---------|----------|
| 4.90 | 134.29 | 0.0074 |
| 5.00 | 148.41 | 0.0067 |
| 5.20 | 181.27 | 0.0055 |
| 5.40 | 221.41 | 0.0045 |
| 5.60 | 270.43 | 0.0037 |
| 5.80 | 330.30 | 0.0030 |
| 6.00 | 403.43 | 0.0025 |
| 7.00 | 1096.6 | 0.0009 |
| 8.00 | 2981.0 | 0.0003 |
| 9.00 | 8103.1 | 0.0001 |
| 10.00 | 22026.0 | 0.00005 |

جدول 5: التوزيع الطبيعي المعياري

The Standard Normal Distribution

$$\varphi(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}}$$

جدول قيم الدالة:



| z | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0 | 0.3989 | 0.3989 | 0.3989 | 0.3988 | 0.3986 | 0.3984 | 0.3982 | 0.3980 | 0.3977 | 0.3973 |
| 0.1 | 3970 | 3965 | 3961 | 3956 | 3951 | 3945 | 3939 | 3932 | 3925 | 3918 |
| 0.2 | 3910 | 3902 | 3894 | 3885 | 3876 | 3867 | 3857 | 3847 | 3836 | 3825 |
| 0.3 | 3814 | 3802 | 3790 | 3778 | 3765 | 3752 | 3739 | 3726 | 3712 | 3697 |
| 0.4 | 3683 | 3668 | 3653 | 3637 | 3621 | 3605 | 3589 | 3572 | 3555 | 3538 |
| 0.5 | 3521 | 3503 | 3485 | 3467 | 3448 | 3429 | 3410 | 3391 | 3372 | 3352 |
| 0.6 | 3332 | 3312 | 3292 | 3271 | 3251 | 3230 | 3209 | 3187 | 3166 | 3144 |
| 0.7 | 3123 | 3101 | 3079 | 3056 | 3034 | 3011 | 2989 | 2966 | 2943 | 2920 |
| 0.8 | 2897 | 2874 | 2850 | 2827 | 2803 | 2780 | 2756 | 2732 | 2709 | 2685 |
| 0.9 | 2661 | 2637 | 2613 | 2589 | 2565 | 2541 | 2516 | 2492 | 2568 | 2444 |
| 1.0 | 0.2420 | 0.2396 | 0.2371 | 0.2347 | 0.2323 | 0.2299 | 0.2275 | 0.2251 | 0.2227 | 0.2203 |
| 1.1 | 2179 | 2155 | 2131 | 2107 | 2083 | 2059 | 2036 | 2012 | 1989 | 1965 |
| 1.2 | 1942 | 1919 | 1895 | 1872 | 1849 | 1826 | 1804 | 1781 | 1758 | 1736 |
| 1.3 | 1714 | 1691 | 1669 | 1647 | 1626 | 1604 | 1582 | 1561 | 1539 | 1518 |
| 1.4 | 1497 | 1476 | 1456 | 1435 | 1415 | 1394 | 1374 | 1354 | 1334 | 1315 |
| 1.5 | 1295 | 1276 | 1257 | 1238 | 1219 | 1200 | 1182 | 1163 | 1145 | 1127 |
| 1.6 | 1109 | 1092 | 1074 | 1057 | 1040 | 1023 | 1006 | 9989 | 0973 | 0957 |
| 1.7 | 0940 | 0925 | 0909 | 0893 | 0878 | 0863 | 0848 | 0833 | 0818 | 0804 |
| 1.8 | 0790 | 0775 | 0761 | 0748 | 0734 | 0721 | 0707 | 0694 | 0681 | 0669 |
| 1.9 | 0656 | 0644 | 0632 | 0620 | 0608 | 0596 | 0584 | 0573 | 0562 | 0551 |
| 2.0 | 0.0540 | 0.0529 | 0.0519 | 0.0508 | 0.0498 | 0.0488 | 0.0478 | 0.0468 | 0.0459 | 0.0449 |
| 2.1 | 0440 | 0431 | 0422 | 0413 | 0404 | 0396 | 0387 | 0379 | 0371 | 0363 |
| 2.2 | 0355 | 0347 | 0339 | 0332 | 0325 | 0317 | 0310 | 0303 | 0297 | 0290 |
| 2.3 | 0283 | 0277 | 0270 | 0264 | 0258 | 0252 | 0246 | 0241 | 0235 | 0229 |


تابع جدول 5

| z | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 2.4 | 0224 | 0219 | 0213 | 0208 | 0203 | 0198 | 0194 | 0189 | 0184 | 0180 |
| 2.5 | 0175 | 0171 | 0167 | 0163 | 0158 | 0154 | 0151 | 0147 | 0143 | 0139 |
| 2.6 | 0136 | 0132 | 0129 | 0126 | 0122 | 0119 | 0116 | 0113 | 0110 | 0107 |
| 2.7 | 0104 | 0101 | 0099 | 0096 | 0093 | 0091 | 0088 | 0086 | 0084 | 0081 |
| 2.8 | 0079 | 0077 | 0075 | 0073 | 0071 | 0069 | 0067 | 0065 | 0063 | 0061 |
| 2.9 | 0060 | 0058 | 0056 | 0055 | 0053 | 0051 | 0050 | 0048 | 0047 | 0046 |
| 3.0 | 0.0044 | 0.0043 | 0.0042 | 0.0041 | 0.0039 | 0.0038 | 0.0037 | 0.0036 | 0.0035 | 0.0034 |
| 3.1 | 0033 | 0032 | 0031 | 0030 | 0029 | 0028 | 0027 | 0026 | 0025 | 0025 |
| 3.2 | 0024 | 0023 | 0022 | 0022 | 0021 | 0020 | 0020 | 0019 | 0018 | 0018 |
| 3.3 | 0017 | 0017 | 0016 | 0016 | 0015 | 0015 | 0014 | 0014 | 0013 | 0013 |
| 3.4 | 0012 | 0012 | 0012 | 0011 | 0011 | 0010 | 0010 | 0010 | 0009 | 0009 |
| 3.5 | 0009 | 0008 | 0008 | 0008 | 0008 | 0007 | 0007 | 0007 | 0007 | 0006 |
| 3.6 | 0006 | 0006 | 0006 | 0005 | 0005 | 0005 | 0005 | 0005 | 0005 | 0004 |
| 3.7 | 0004 | 0004 | 0004 | 0004 | 0004 | 0004 | 0003 | 0003 | 0003 | 0003 |
| 3.8 | 0003 | 0003 | 0003 | 0003 | 0003 | 0002 | 0002 | 0002 | 0002 | 0003 |
| 3.9 | 0002 | 0002 | 0002 | 0002 | 0002 | 0002 | 0002 | 0002 | 0001 | 0001 |
| 4.0 | 0.0001 | 0.0001 | 0.0001 | 0.0001 | 0.0001 | 0.0001 | 0.0001 | 0.0001 | 0.0001 | 0.0001 |
| 4.1 | 0.0001338 | | | | | | | | | |
| 4.5 | 0.0000160 | | | | | | | | | |
| 5.0 | 0.0000015 | | | | | | | | | |

جدول 6: التوزيع الطبيعي المعياري

The Standard Normal Distribution

$$\Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt \quad \text{جدول قيم الدالة:}$$



| z | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|--------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 0.0 | 0.5000 | .5040 | .5080 | .5120 | .5160 | .5199 | .5239 | .5279 | .5319 | .5359 |
| 0.1 | .5398 | .5438 | .5478 | .5517 | .5557 | .5596 | .5636 | .5675 | .5714 | .5753 |
| 0.2 | .5793 | .5832 | .5871 | .5910 | .5948 | .5987 | .6026 | .6064 | .6103 | .6141 |
| 0.3 | .6179 | .6217 | .6255 | .6293 | .6331 | .6368 | .6406 | .6443 | .6480 | .6517 |
| 0.4 | .6551 | .6591 | .6628 | .6664 | .6700 | .6736 | .6772 | .6808 | .6844 | .6879 |
| 0.5 | .6915 | .6950 | .6985 | .7019 | .7054 | .7088 | .7123 | .7157 | .7190 | .7221 |
| 0.6 | .7257 | .7291 | .7324 | .7357 | .7389 | .7422 | .7454 | .7480 | .7517 | .7549 |
| 0.7 | .7580 | .7611 | .7642 | .7672 | .7704 | .7734 | .7764 | .7794 | .7823 | .7852 |
| 0.8 | .7881 | .7910 | .7939 | .7967 | .7995 | .8023 | .8051 | .8078 | .8106 | .8133 |
| 0.9 | .8159 | .8186 | .8238 | .8238 | .8204 | .8289 | .8315 | .8340 | .8366 | .8389 |
| 1.0 | .8413 | .8438 | .8461 | .8485 | .8508 | .8531 | .8551 | .8577 | .8599 | .8621 |
| 1.1 | .8643 | .8665 | .8686 | .8708 | .8729 | .8749 | .8770 | .8790 | .8810 | .8830 |
| 1.2 | .8849 | .8869 | .8888 | .8907 | .8925 | .8944 | .8962 | .8980 | .8997 | .9015 |
| 1.3 | .9032 | .9049 | .9066 | .9082 | .9099 | .9115 | .9131 | .9147 | .9162 | .9177 |
| 1.4 | .9192 | .9207 | .9222 | .9236 | .9251 | .9265 | .9279 | .9292 | .9306 | .9319 |
| 1.5 | .9332 | .9345 | .9357 | .9370 | .9382 | .9394 | .9406 | .9418 | .9429 | .9441 |
| 1.6 | .9452 | .9463 | .9474 | .9484 | .9495 | .9505 | .9515 | .9525 | .9535 | .9545 |
| 1.7 | .9554 | .9564 | .9573 | .9582 | .9591 | .9599 | .9608 | .9616 | .9625 | .9633 |
| 1.8 | .9641 | .9649 | .9656 | .9664 | .9671 | .9678 | .9686 | .9693 | .9699 | .9706 |
| 1.9 | .9713 | .9719 | .9726 | .9732 | .9738 | .9744 | .9750 | .9756 | .9761 | .9767 |
| 2.0 | .9772 | .9778 | .9783 | .9788 | .9793 | .9798 | .9803 | .9808 | .9812 | .9817 |
| 2.1 | .9821 | .9826 | .9830 | .9834 | .9838 | .9842 | .9846 | .9850 | .9854 | .9857 |
| 2.2 | .9861 | .9864 | .9868 | .9871 | .9875 | .9878 | .9881 | .9884 | .9887 | .9890 |


تابع جدول 6

| z | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|----------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| 2.3 | .9893 | .9896 | .9898 | .9901 | .9904 | .9906 | .9909 | .9911 | .9913 | .9916 |
| 2.4 | .9918 | .9920 | .9922 | .9925 | .9927 | .9929 | .9931 | .9932 | .9934 | .9936 |
| 2.5 | .9938 | .9940 | .9941 | .9943 | .9945 | .9946 | .9948 | .9949 | .9951 | .9952 |
| 2.6 | .9953 | .9955 | .9956 | .9957 | .9959 | .9960 | .9961 | .9962 | .9963 | .9961 |
| 2.7 | .9965 | .9966 | .9967 | .9968 | .9969 | .9970 | .9971 | .9972 | .9973 | .9971 |
| 2.8 | .9974 | .9975 | .9976 | .9977 | .9977 | .9978 | .9979 | .9979 | .9980 | .9981 |
| 2.9 | .9981 | .9982 | .9982 | .9983 | .9984 | .9984 | .9985 | .9985 | .9986 | .9986 |
| 3.0 | .9987 | .9987 | .9987 | .9988 | .9988 | .9989 | .9989 | .9989 | .9990 | .9990 |
| 3.1 | .9990 | .9991 | .9991 | .9991 | .9992 | .9992 | .9992 | .9992 | .9993 | .9993 |
| 3.2 | .9993 | .9993 | .9994 | .9994 | .9994 | .9994 | .9994 | .9995 | .9995 | .9995 |
| 3.3 | .9995 | .9995 | .9995 | .9996 | .9996 | .9996 | .9996 | .9996 | .9996 | .9997 |
| 3.4 | .9997 | .9997 | .9997 | .9997 | .9997 | .9997 | .9997 | .9997 | .9997 | .9998 |
| 3.5 | .9998 | | | | | | | | | |
| 3.6 | .9998 | | | | | | | | | |
| 3.7 | .99989 | | | | | | | | | |
| 3.8 | .99993 | | | | | | | | | |
| 3.9 | .99995 | | | | | | | | | |
| 4.0 | .999968 | | | | | | | | | |
| 4.5 | .999997 | | | | | | | | | |
| 5.0 | .9999997 | | | | | | | | | |

جدول 7: التوزيع الطبيعي المعياري

The Standard Normal Distribution

$$U(z) = \frac{2}{\sqrt{2\pi}} \int_0^z e^{-\frac{t^2}{2}} dt = P(|Z| < z) \quad \text{جدول قيم الدالة:}$$



| z | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0 | 0.0000 | 0.0080 | 0.0160 | 0.0239 | 0.0319 | 0.0399 | 0.0478 | 0.0558 | 0.0638 | 0.0717 |
| 0.1 | 0.0797 | 0.0876 | 0.0955 | 0.1034 | 0.1113 | 0.1192 | 0.1271 | 0.1350 | 0.1428 | 0.1507 |
| 0.2 | 0.1585 | 0.1663 | 0.1741 | 0.1819 | 0.1897 | 0.1974 | 0.2051 | 0.2128 | 0.2205 | 0.2282 |
| 0.3 | 0.2358 | 0.2434 | 0.2510 | 0.2586 | 0.2661 | 0.2737 | 0.2812 | 0.2886 | 0.2960 | 0.3035 |
| 0.4 | 0.3108 | 0.3182 | 0.3255 | 0.3328 | 0.3401 | 0.3473 | 0.3545 | 0.3616 | 0.3688 | 0.3759 |
| 0.5 | 0.3829 | 0.3899 | 0.3969 | 0.4039 | 0.4108 | 0.4177 | 0.4245 | 0.4313 | 0.4381 | 0.4448 |
| 0.6 | 0.4515 | 0.4581 | 0.4647 | 0.4713 | 0.4778 | 0.4843 | 0.4907 | 0.4971 | 0.5035 | 0.5098 |
| 0.7 | 0.5161 | 0.5223 | 0.5285 | 0.5346 | 0.5407 | 0.5467 | 0.5527 | 0.5587 | 0.5646 | 0.5705 |
| 0.8 | 0.5763 | 0.5821 | 0.5878 | 0.5935 | 0.5991 | 0.6047 | 0.6102 | 0.6157 | 0.6211 | 0.6265 |
| 0.9 | 0.6319 | 0.6372 | 0.6424 | 0.6476 | 0.6528 | 0.6579 | 0.6629 | 0.6679 | 0.6729 | 0.6778 |
| 1.0 | 0.6827 | 0.6875 | 0.6923 | 0.6970 | 0.7017 | 0.7063 | 0.7109 | 0.7154 | 0.7199 | 0.7243 |
| 1.1 | 0.7287 | 0.7330 | 0.7373 | 0.7415 | 0.7457 | 0.7499 | 0.7540 | 0.7580 | 0.7620 | 0.7660 |
| 1.2 | 0.7699 | 0.7737 | 0.7775 | 0.7813 | 0.7850 | 0.7887 | 0.7923 | 0.7959 | 0.7994 | 0.8029 |
| 1.3 | 0.8064 | 0.8098 | 0.8132 | 0.8165 | 0.8198 | 0.8230 | 0.8262 | 0.8293 | 0.8324 | 0.8355 |
| 1.4 | 0.8385 | 0.8415 | 0.8444 | 0.8473 | 0.8501 | 0.8529 | 0.8557 | 0.8584 | 0.8611 | 0.8638 |
| 1.5 | 0.8664 | 0.8690 | 0.8715 | 0.8740 | 0.8764 | 0.8789 | 0.8812 | 0.8836 | 0.8859 | 0.8882 |
| 1.6 | 0.8904 | 0.8926 | 0.8948 | 0.8969 | 0.8990 | 0.9011 | 0.9031 | 0.9051 | 0.9070 | 0.9090 |
| 1.7 | 0.9109 | 0.9127 | 0.9146 | 0.9164 | 0.9181 | 0.9199 | 0.9216 | 0.9233 | 0.9249 | 0.9265 |
| 1.8 | 0.9281 | 0.9297 | 0.9312 | 0.9327 | 0.9342 | 0.9357 | 0.9371 | 0.9385 | 0.9399 | 0.9412 |
| 1.9 | 0.9426 | 0.9439 | 0.9451 | 0.9464 | 0.9476 | 0.9488 | 0.9500 | 0.9512 | 0.9523 | 0.9534 |
| 2.0 | 0.9545 | 0.9556 | 0.9566 | 0.9576 | 0.9586 | 0.9596 | 0.9606 | 0.9616 | 0.9625 | 0.9634 |
| 2.1 | 0.9643 | 0.9651 | 0.9660 | 0.9668 | 0.9676 | 0.9684 | 0.9692 | 0.9700 | 0.9707 | 0.9715 |
| 2.2 | 0.9722 | 0.9729 | 0.9736 | 0.9743 | 0.9749 | 0.9756 | 0.9762 | 0.9768 | 0.9774 | 0.9780 |
| 2.3 | 0.9786 | 0.9791 | 0.9797 | 0.9802 | 0.9807 | 0.9812 | 0.9817 | 0.9822 | 0.9827 | 0.9832 |

تابع جدول 7

| z | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
|-----|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 2.4 | 0.9836 | 0.9841 | 0.9845 | 0.9849 | 0.9853 | 0.9857 | 0.9861 | 0.9865 | 0.9869 | 0.9872 |
| 2.5 | 0.9876 | 0.9879 | 0.9883 | 0.9886 | 0.9889 | 0.9892 | 0.9895 | 0.9898 | 0.9901 | 0.9904 |
| 2.6 | 0.9907 | 0.9910 | 0.9912 | 0.9915 | 0.9917 | 0.9920 | 0.9922 | 0.9924 | 0.9926 | 0.9928 |
| 2.7 | 0.9931 | 0.9933 | 0.9935 | 0.9937 | 0.9939 | 0.9940 | 0.9942 | 0.9944 | 0.9946 | 0.9947 |
| 2.8 | 0.9949 | 0.9951 | 0.9952 | 0.9553 | 0.9955 | 0.9956 | 0.9958 | 0.9959 | 0.9960 | 0.9961 |
| 2.9 | 0.9963 | 0.9964 | 9965 | 0.9966 | 0.9967 | 0.9968 | 0.9969 | 0.9970 | 0.9971 | 0.9972 |
| 3.0 | 0.9973 | 0.9974 | 0.9975 | 0.9976 | 0.9976 | 0.9977 | 0.9978 | 0.9979 | 0.9979 | 0.9980 |
| 3.1 | 0.9981 | 0.9981 | 0.9982 | 0.9983 | 0.9983 | 0.9984 | 0.9984 | 0.9985 | 0.9985 | 0.9986 |
| 3.2 | 0.9986 | 0.9987 | 0.9987 | 0.9988 | 0.9988 | 0.9989 | 0.9989 | 0.9989 | 0.9990 | 0.9990 |
| 3.3 | 0.9990 | 0.9991 | 0.9991 | 0.9991 | 0.9992 | 0.9992 | 0.9992 | 0.9992 | 0.9993 | 0.9993 |
| 3.4 | 0.9993 | 0.9994 | 0.9994 | 0.9994 | 0.9994 | 0.9994 | 0.9995 | 0.9995 | 0.9995 | 0.9995 |
| 3.5 | 0.9995 | 0.9996 | 0.9996 | 0.9996 | 0.9996 | 0.9996 | 0.9996 | 0.9996 | 0.9997 | 0.9997 |
| 3.6 | 0.9997 | 0.9997 | 0.9997 | 0.9997 | 0.9997 | 0.9997 | 0.9997 | 0.9998 | 0.9998 | 0.9998 |
| 3.7 | 0.9998 | 0.9998 | 0.9998 | 0.9998 | 0.9998 | 0.9998 | 0.9998 | 0.9998 | 0.9998 | 0.9998 |
| 3.8 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 |
| 3.9 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 |
| 4.0 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 | 0.9999 |

95% فترة ثقة (θ_1, θ_2) من أجل المعلمة θ :


$$P_{\theta}(\theta_1 < \theta < \theta_2) = 0.95$$

| $n-k$ k | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| 0 | - - | 0.98 0.00 | 0.84 0.00 | 0.71 0.00 | 0.60 0.00 | 0.52 0.00 | 0.46 0.00 | 0.41 0.00 | 0.37 0.00 | 0.34 0.00 | 0.31 0.00 | 0.29 0.00 | 0.27 0.00 |
| 1 | 1.00 0.03 | 0.99 0.01 | 0.91 0.01 | 0.81 0.01 | 0.72 0.01 | 0.64 0.00 | 0.58 0.00 | 0.53 0.00 | 0.48 0.00 | 0.45 0.00 | 0.41 0.00 | 0.39 0.00 | 0.36 0.00 |
| 2 | 1.00 0.16 | 0.99 0.09 | 0.93 0.07 | 0.85 0.05 | 0.78 0.04 | 0.71 0.04 | 0.65 0.03 | 0.60 0.03 | 0.56 0.03 | 0.52 0.02 | 0.48 0.02 | 0.45 0.02 | 0.43 0.02 |
| 3 | 1.00 0.29 | 0.99 0.19 | 0.95 0.15 | 0.88 0.12 | 0.82 0.10 | 0.76 0.09 | 0.70 0.08 | 0.65 0.07 | 0.61 0.06 | 0.57 0.06 | 0.54 0.05 | 0.51 0.05 | 0.48 0.04 |
| 4 | 1.00 0.40 | 1.00 0.29 | 0.96 0.22 | 0.90 0.18 | 0.84 0.16 | 0.79 0.14 | 0.74 0.12 | 0.69 0.11 | 0.65 0.10 | 0.61 0.09 | 0.58 0.08 | 0.55 0.08 | 0.52 0.07 |
| 5 | 1.00 0.48 | 1.00 0.36 | 0.96 0.29 | 0.92 0.25 | 0.86 0.21 | 0.81 0.19 | 0.77 0.17 | 0.72 0.15 | 0.68 0.14 | 0.65 0.13 | 0.62 0.12 | 0.59 0.11 | 0.56 0.10 |
| 6 | 1.00 0.54 | 1.00 0.42 | 0.97 0.35 | 0.93 0.30 | 0.88 0.26 | 0.83 0.23 | 0.79 0.21 | 0.75 0.19 | 0.71 0.18 | 0.68 0.16 | 0.65 0.15 | 0.62 0.14 | 0.59 0.13 |
| 7 | 1.00 0.59 | 1.00 0.47 | 0.97 0.40 | 0.93 0.35 | 0.89 0.31 | 0.85 0.28 | 0.81 0.25 | 0.77 0.23 | 0.73 0.21 | 0.70 0.20 | 0.67 0.18 | 0.64 0.17 | 0.62 0.16 |
| 8 | 1.00 0.63 | 1.00 0.52 | 0.98 0.44 | 0.94 0.39 | 0.90 0.35 | 0.86 0.32 | 0.82 0.29 | 0.79 0.27 | 0.75 0.25 | 0.72 0.23 | 0.69 0.22 | 0.67 0.20 | 0.64 0.19 |
| 9 | 1.00 0.66 | 1.00 0.56 | 0.98 0.48 | 0.95 0.43 | 0.91 0.39 | 0.87 0.35 | 0.84 0.32 | 0.80 0.30 | 0.77 0.28 | 0.74 0.26 | 0.71 0.24 | 0.69 0.23 | 0.66 0.22 |
| 10 | 1.00 0.69 | 1.00 0.59 | 0.98 0.52 | 0.95 0.46 | 0.92 0.42 | 0.88 0.38 | 0.85 0.35 | 0.82 0.33 | 0.79 0.31 | 0.76 0.29 | 0.73 0.27 | 0.70 0.26 | 0.68 0.24 |
| 11 | 1.00 0.72 | 1.00 0.62 | 0.98 0.57 | 0.95 0.49 | 0.92 0.45 | 0.89 0.41 | 0.86 0.38 | 0.83 0.36 | 0.80 0.34 | 0.77 0.32 | 0.74 0.30 | 0.72 0.28 | 0.69 0.27 |
| 12 | 1.00 0.74 | 1.00 0.64 | 0.98 0.57 | 0.96 0.52 | 0.93 0.48 | 0.90 0.44 | 0.87 0.41 | 0.84 0.38 | 0.81 0.36 | 0.78 0.34 | 0.76 0.32 | 0.73 0.31 | 0.71 0.29 |

جدول 9: التوزيع الطبيعي المعياري

The Standard Normal Distribution

$$\alpha = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{z_{\alpha}} e^{-t^2/2} dt \quad \text{القيم الحرجة } z_{\alpha} \text{ للتوزيع:}$$




| α | z_{α} |
|----------|--------------|
| 0.50 | 0.000 |
| 0.51 | 0.025 |
| 0.52 | 0.050 |
| 0.53 | 0.075 |
| 0.54 | 0.100 |
| 0.55 | 0.126 |
| 0.56 | 0.151 |
| 0.57 | 0.176 |
| 0.58 | 0.202 |
| 0.59 | 0.228 |
| 0.60 | 0.253 |
| 0.61 | 0.279 |
| 0.62 | 0.305 |
| 0.63 | 0.332 |
| 0.64 | 0.358 |
| 0.65 | 0.385 |
| 0.66 | 0.412 |
| 0.67 | 0.440 |

| α | z_{α} |
|----------|--------------|
| 0.68 | 0.468 |
| 0.69 | 0.496 |
| 0.70 | 0.524 |
| 0.71 | 0.553 |
| 0.72 | 0.583 |
| 0.73 | 0.613 |
| 0.74 | 0.643 |
| 0.75 | 0.674 |
| 0.76 | 0.706 |
| 0.77 | 0.739 |
| 0.78 | 0.772 |
| 0.79 | 0.806 |
| 0.80 | 0.842 |
| 0.81 | 0.878 |
| 0.82 | 0.915 |
| 0.83 | 0.954 |
| 0.84 | 0.994 |
| 0.85 | 1.036 |

| α | z_{α} |
|----------|--------------|
| 0.86 | 1.080 |
| 0.87 | 1.126 |
| 0.88 | 1.175 |
| 0.89 | 1.227 |
| 0.90 | 1.282 |
| 0.91 | 1.341 |
| 0.92 | 1.405 |
| 0.93 | 1.476 |
| 0.94 | 1.555 |
| 0.95 | 1.645 |
| 0.96 | 1.751 |
| 0.97 | 1.881 |
| 0.98 | 2.054 |
| 0.99 | 2.326 |
| 0.999 | 3.090 |
| 0.9999 | 3.720 |
| 0.99999 | 4.265 |

$$\alpha = \int_{t_{\alpha, \nu}}^{\infty} \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi\nu} \Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{t^2}{\nu}\right)^{-\frac{\nu+1}{2}} dt \quad \text{قيم } t_{\alpha, \nu}$$



VALUES OF $t_{\alpha, \nu}$ *

| α ν | .10 | .05 | .025 | .01 | .005 | ν |
|-------------------|-------|-------|--------|--------|--------|-------|
| 1 | 3.078 | 6.314 | 12.706 | 31.821 | 63.657 | 1 |
| 2 | 1.886 | 2.920 | 4.303 | 6.965 | 9.925 | 2 |
| 3 | 1.638 | 2.353 | 3.182 | 4.541 | 5.841 | 3 |
| 4 | 1.533 | 2.132 | 2.776 | 3.747 | 4.604 | 4 |
| 5 | 1.476 | 2.015 | 2.571 | 3.365 | 4.032 | 5 |
| 6 | 1.440 | 1.943 | 2.447 | 3.143 | 3.707 | 6 |
| 7 | 1.415 | 1.895 | 2.365 | 2.998 | 3.499 | 7 |
| 8 | 1.397 | 1.860 | 2.306 | 2.896 | 3.355 | 8 |
| 9 | 1.383 | 1.833 | 2.262 | 2.821 | 3.250 | 9 |
| 10 | 1.372 | 1.812 | 2.228 | 2.764 | 3.169 | 10 |
| 11 | 1.363 | 1.796 | 2.201 | 2.718 | 3.106 | 11 |
| 12 | 1.356 | 1.782 | 2.179 | 2.681 | 3.055 | 12 |
| 13 | 1.350 | 1.771 | 2.160 | 2.650 | 3.012 | 13 |

تابع جدول 10


| α v | .10 | .05 | .025 | .01 | .005 | v |
|---------------|-------|-------|-------|-------|-------|------|
| 14 | 1.345 | 1.761 | 2.145 | 2.624 | 2.977 | 14 |
| 15 | 1.341 | 1.753 | 2.131 | 2.602 | 2.947 | 15 |
| 16 | 1.337 | 1.746 | 2.120 | 2.583 | 2.921 | 16 |
| 17 | 1.333 | 1.740 | 2.110 | 2.567 | 2.898 | 17 |
| 18 | 1.330 | 1.734 | 2.101 | 2.552 | 2.878 | 18 |
| 19 | 1.328 | 1.729 | 2.093 | 2.539 | 2.861 | 19 |
| 20 | 1.325 | 1.725 | 2.086 | 2.528 | 2.845 | 20 |
| 21 | 1.323 | 1.721 | 2.080 | 2.518 | 2.831 | 21 |
| 22 | 1.321 | 1.717 | 2.074 | 2.508 | 2.819 | 22 |
| 23 | 1.319 | 1.714 | 2.069 | 2.500 | 2.807 | 23 |
| 24 | 1.318 | 1.711 | 2.064 | 2.492 | 2.797 | 24 |
| 25 | 1.316 | 1.708 | 2.060 | 2.485 | 2.787 | 25 |
| 26 | 1.315 | 1.706 | 2.056 | 2.479 | 2.779 | 26 |
| 27 | 1.314 | 1.703 | 2.052 | 2.473 | 2.771 | 27 |
| 28 | 1.313 | 1.701 | 2.048 | 2.467 | 2.763 | 28 |
| 29 | 1.311 | 1.699 | 2.045 | 2.462 | 2.756 | 29 |
| inf. | 1.282 | 1.645 | 1.960 | 2.326 | 2.576 | inf. |

* This table is abridged from Table IV of R. A. Fisher, *Statistical Methods for Research Workers*, published by Oliver and Boyd, Ltd., Edinburgh, by permission of the author and publishers.

جدول 11: توزيع χ^2 *The Che-Square Distribution*

القيم الحرجة $\chi^2_{\alpha, v}$ للتوزيع:

$$\alpha = \int_{\chi^2_{\alpha, v}}^{\infty} f(\chi^2) d(\chi^2) = \frac{1}{2^{v/2} \Gamma(v/2)} \int_{\chi^2_{\alpha, v}}^{\infty} f(\chi^2) \chi^{v-2} e^{-\chi^2/2} d(\chi^2)$$



VALUES OF $\chi^2_{\alpha, v}$ *

| $\alpha \backslash v$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 |
|-----------------------|-----------|----------|----------|---------|---------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.995 | 0.0000393 | 0.000157 | 0.000982 | 0.00393 | 0.00982 | 0.0157 | 0.0201 | 0.0244 | 0.0287 | 0.0330 | 0.0373 | 0.0416 | 0.0459 | 0.0502 | 0.0545 | 0.0588 | 0.0631 | 0.0674 | 0.0717 | 0.0760 |
| 0.99 | 0.000157 | 0.000613 | 0.00243 | 0.00599 | 0.0118 | 0.0177 | 0.0236 | 0.0295 | 0.0354 | 0.0413 | 0.0472 | 0.0531 | 0.0590 | 0.0649 | 0.0708 | 0.0767 | 0.0826 | 0.0885 | 0.0944 | 0.1003 |
| 0.975 | 0.000982 | 0.00393 | 0.0157 | 0.0393 | 0.0768 | 0.1143 | 0.1518 | 0.1893 | 0.2268 | 0.2643 | 0.3018 | 0.3393 | 0.3768 | 0.4143 | 0.4518 | 0.4893 | 0.5268 | 0.5643 | 0.6018 | 0.6393 |
| 0.95 | 0.00393 | 0.0118 | 0.0393 | 0.0938 | 0.1883 | 0.2828 | 0.3773 | 0.4718 | 0.5663 | 0.6608 | 0.7553 | 0.8498 | 0.9443 | 1.0388 | 1.1333 | 1.2278 | 1.3223 | 1.4168 | 1.5113 | 1.6058 |
| 0.05 | 3.841 | 5.991 | 7.815 | 9.488 | 11.070 | 12.832 | 14.548 | 16.264 | 17.980 | 19.696 | 21.412 | 23.128 | 24.844 | 26.560 | 28.276 | 29.992 | 31.708 | 33.424 | 35.140 | 36.856 |
| 0.025 | 5.024 | 7.378 | 9.348 | 11.143 | 12.832 | 14.548 | 16.264 | 17.980 | 19.696 | 21.412 | 23.128 | 24.844 | 26.560 | 28.276 | 29.992 | 31.708 | 33.424 | 35.140 | 36.856 | 38.572 |
| 0.01 | 6.635 | 9.210 | 11.345 | 13.277 | 15.086 | 16.919 | 18.752 | 20.585 | 22.418 | 24.251 | 26.084 | 27.917 | 29.750 | 31.583 | 33.416 | 35.249 | 37.082 | 38.915 | 40.748 | 42.581 |
| 0.005 | 7.879 | 10.597 | 12.838 | 14.860 | 16.750 | 18.640 | 20.530 | 22.420 | 24.310 | 26.200 | 28.090 | 29.980 | 31.870 | 33.760 | 35.650 | 37.540 | 39.430 | 41.320 | 43.210 | 45.100 |
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 |

تابع جدول 11

| $\alpha \backslash v$ | 0.995 | 0.99 | 0.975 | 0.95 | 0.05 | 0.025 | 0.01 | 0.005 | v |
|-----------------------|-------|--------|--------|--------|--------|--------|--------|--------|-----|
| 6 | .676 | .872 | 1.237 | 1.635 | 12.592 | 14.449 | 16.812 | 18.548 | 6 |
| 7 | .989 | 1.239 | 1.690 | 2.167 | 14.067 | 16.013 | 18.475 | 20.278 | 7 |
| 8 | 1.344 | 1.646 | 2.180 | 2.733 | 15.507 | 17.535 | 20.090 | 21.955 | 8 |
| 9 | 1.735 | 2.088 | 2.700 | 3.325 | 16.919 | 19.023 | 21.666 | 23.589 | 9 |
| 10 | 2.156 | 2.558 | 3.247 | 3.940 | 18.307 | 20.483 | 23.209 | 25.188 | 10 |
| 11 | 2.603 | 3.053 | 3.816 | 4.575 | 19.675 | 21.920 | 24.725 | 26.757 | 11 |
| 12 | 3.074 | 3.571 | 4.404 | 5.226 | 21.026 | 23.337 | 26.217 | 28.300 | 12 |
| 13 | 3.565 | 4.107 | 5.009 | 5.892 | 22.362 | 24.736 | 27.688 | 29.819 | 13 |
| 14 | 4.075 | 4.660 | 5.629 | 6.571 | 23.685 | 26.119 | 29.141 | 31.319 | 14 |
| 15 | 4.601 | 5.229 | 6.262 | 7.261 | 24.996 | 27.488 | 30.578 | 32.801 | 15 |
| 16 | 5.142 | 5.812 | 6.908 | 7.962 | 26.296 | 28.845 | 32.000 | 34.267 | 16 |
| 17 | 5.697 | 6.408 | 7.564 | 8.672 | 27.587 | 30.191 | 33.409 | 35.718 | 17 |
| 18 | 6.265 | 7.015 | 8.231 | 9.390 | 28.869 | 31.526 | 34.805 | 37.156 | 18 |
| 19 | 6.844 | 7.633 | 8.907 | 10.117 | 30.144 | 32.852 | 36.191 | 38.582 | 19 |
| 20 | 7.434 | 8.260 | 9.591 | 10.851 | 31.410 | 34.170 | 37.566 | 39.997 | 20 |
| 21 | 8.034 | 8.897 | 10.283 | 11.591 | 32.671 | 35.479 | 38.932 | 41.401 | 21 |
| 22 | 8.643 | 9.542 | 10.982 | 12.338 | 33.924 | 36.781 | 40.289 | 42.796 | 22 |
| 23 | 9.260 | 10.196 | 11.689 | 13.091 | 35.172 | 38.076 | 41.638 | 44.181 | 23 |

تابع جدول 11

| $\alpha \backslash v$ | 0.995 | 0.99 | 0.975 | 0.95 | 0.05 | 0.025 | 0.01 | 0.005 | v |
|-----------------------|--------|--------|--------|--------|--------|--------|--------|--------|-----|
| 24 | 9.886 | 10.856 | 12.401 | 13.848 | 36.415 | 39.364 | 42.980 | 45.558 | 24 |
| 25 | 10.520 | 11.524 | 13.120 | 14.611 | 37.652 | 40.646 | 44.314 | 46.928 | 25 |
| 26 | 11.160 | 12.198 | 13.844 | 15.379 | 38.885 | 41.923 | 45.642 | 48.290 | 26 |
| 27 | 11.808 | 12.879 | 14.573 | 16.151 | 40.113 | 43.194 | 46.963 | 49.645 | 27 |
| 28 | 12.461 | 13.565 | 15.308 | 16.928 | 41.337 | 44.461 | 48.278 | 50.993 | 28 |
| 29 | 13.121 | 14.256 | 16.047 | 17.708 | 42.557 | 45.722 | 49.588 | 52.336 | 29 |
| 30 | 13.787 | 14.953 | 16.791 | 18.493 | 43.773 | 46.979 | 50.892 | 53.672 | 30 |


* This table is based on Table 8 of *Biometrika Tables for Statisticians, Volume I*, by permission of the *Biometrika* trustees.

The F Distribution

F توزيع : 12 جدول

$$\alpha = \int_{F_{\alpha, v_1, v_2}}^{\infty} \frac{\Gamma\left(\frac{u_1 + u_2}{2}\right)}{\Gamma\left(\frac{u_1}{2}\right) \Gamma\left(\frac{u_2}{2}\right)} \left(\frac{u_1}{u_2}\right)^{\frac{u_1}{2}} y^{\frac{u_1}{2} - 1} \left(1 + \frac{u_1}{u_2} y\right)^{-\frac{1}{2}(u_1 + u_2)} dy$$

القيم المرحية F_{α, v_1, v_2} للتوزيع :



VALUES OF $F_{.01, v_1, v_2}$ *

v_1 = Degrees of freedom for numerator

v_2 = Degrees of freedom for denominator

| $v_2 \backslash v_1$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 15 | 20 | 24 | 30 | 40 | 60 | 120 | ∞ |
|----------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----------|
| 1 | 4.051 | 5.000 | 5.403 | 5.625 | 5.764 | 5.859 | 5.928 | 5.982 | 6.023 | 6.056 | 6.106 | 6.157 | 6.209 | 6.235 | 6.261 | 6.287 | 6.313 | 6.339 | 6.366 |
| 2 | 98.5 | 99.0 | 99.2 | 99.2 | 99.3 | 99.3 | 99.4 | 99.4 | 99.4 | 99.4 | 99.4 | 99.4 | 99.4 | 99.5 | 99.5 | 99.5 | 99.5 | 99.5 | 99.5 |
| 3 | 34.1 | 30.8 | 29.5 | 28.7 | 28.2 | 27.9 | 27.7 | 27.5 | 27.3 | 27.2 | 27.1 | 26.9 | 26.7 | 26.6 | 26.5 | 26.4 | 26.3 | 26.2 | 26.1 |

تابع جدول 12

| $V_1 \backslash V_2$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 15 | 20 | 24 | 30 | 40 | 60 | 120 | ∞ |
|----------------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|----------|
| 4 | 21.2 | 18.0 | 16.7 | 16.0 | 15.5 | 15.2 | 15.0 | 14.8 | 14.7 | 14.5 | 14.4 | 14.2 | 14.0 | 13.9 | 13.8 | 13.7 | 13.7 | 13.6 | 13.5 |
| 5 | 16.3 | 13.3 | 12.1 | 11.4 | 11.0 | 10.7 | 10.5 | 10.3 | 10.2 | 10.1 | 9.89 | 9.72 | 9.55 | 9.47 | 9.38 | 9.29 | 9.20 | 9.11 | 9.02 |
| 6 | 13.7 | 10.9 | 9.78 | 9.15 | 8.75 | 8.47 | 8.26 | 8.10 | 7.98 | 7.87 | 7.72 | 7.56 | 7.40 | 7.31 | 7.23 | 7.14 | 7.06 | 6.97 | 6.88 |
| 7 | 12.2 | 9.55 | 8.45 | 7.85 | 7.46 | 7.19 | 6.99 | 6.84 | 6.72 | 6.62 | 6.47 | 6.31 | 6.16 | 6.07 | 5.99 | 5.91 | 5.82 | 5.74 | 5.65 |
| 8 | 11.3 | 8.65 | 7.59 | 7.01 | 6.63 | 6.37 | 6.18 | 6.03 | 5.91 | 5.81 | 5.67 | 5.52 | 5.36 | 5.28 | 5.20 | 5.12 | 5.03 | 4.95 | 4.86 |
| 9 | 10.6 | 8.02 | 6.99 | 6.42 | 6.06 | 5.80 | 5.61 | 5.47 | 5.35 | 5.26 | 5.11 | 4.96 | 4.81 | 4.73 | 4.65 | 4.57 | 4.48 | 4.40 | 4.31 |
| 10 | 10.0 | 7.56 | 6.55 | 5.99 | 5.64 | 5.39 | 5.20 | 5.06 | 4.94 | 4.85 | 4.71 | 4.56 | 4.41 | 4.33 | 4.25 | 4.17 | 4.08 | 4.00 | 3.91 |
| 11 | 9.65 | 7.21 | 6.22 | 5.67 | 5.32 | 5.07 | 4.89 | 4.74 | 4.63 | 4.54 | 4.40 | 4.25 | 4.10 | 4.02 | 3.94 | 3.86 | 3.78 | 3.69 | 3.60 |
| 12 | 9.33 | 6.93 | 5.95 | 5.41 | 5.06 | 4.82 | 4.64 | 4.50 | 4.39 | 4.30 | 4.16 | 4.01 | 3.86 | 3.78 | 3.70 | 3.62 | 3.54 | 3.45 | 3.36 |
| 13 | 9.07 | 6.70 | 5.74 | 5.21 | 4.86 | 4.62 | 4.44 | 4.30 | 4.19 | 4.10 | 3.96 | 3.82 | 3.66 | 3.59 | 3.51 | 3.43 | 3.34 | 3.25 | 3.17 |
| 14 | 8.86 | 6.51 | 5.56 | 5.04 | 4.70 | 4.46 | 4.28 | 4.14 | 4.03 | 3.94 | 3.80 | 3.66 | 3.51 | 3.43 | 3.35 | 3.27 | 3.18 | 3.09 | 3.00 |
| 15 | 8.68 | 6.36 | 5.42 | 4.89 | 4.56 | 4.32 | 4.14 | 4.00 | 3.89 | 3.80 | 3.67 | 3.52 | 3.37 | 3.29 | 3.21 | 3.13 | 3.05 | 2.96 | 2.87 |
| 16 | 8.53 | 6.23 | 5.29 | 4.77 | 4.44 | 4.20 | 4.03 | 3.89 | 3.78 | 3.69 | 3.55 | 3.41 | 3.26 | 3.18 | 3.10 | 3.02 | 2.93 | 2.84 | 2.75 |
| 17 | 8.40 | 6.11 | 5.19 | 4.67 | 4.34 | 4.10 | 3.93 | 3.79 | 3.68 | 3.59 | 3.46 | 3.31 | 3.16 | 3.08 | 3.00 | 2.92 | 2.83 | 2.75 | 2.65 |
| 18 | 8.29 | 6.01 | 5.09 | 4.58 | 4.25 | 4.01 | 3.84 | 3.71 | 3.60 | 3.51 | 3.37 | 3.23 | 3.08 | 3.00 | 2.92 | 2.84 | 2.75 | 2.66 | 2.57 |
| 19 | 8.18 | 5.93 | 5.01 | 4.50 | 4.17 | 3.94 | 3.77 | 3.63 | 3.52 | 3.43 | 3.30 | 3.15 | 3.00 | 2.92 | 2.84 | 2.76 | 2.67 | 2.58 | 2.49 |
| 20 | 8.10 | 5.85 | 4.94 | 4.43 | 4.10 | 3.87 | 3.70 | 3.56 | 3.46 | 3.37 | 3.23 | 3.09 | 2.94 | 2.86 | 2.78 | 2.69 | 2.61 | 2.52 | 2.42 |
| 21 | 8.02 | 5.78 | 4.87 | 4.37 | 4.04 | 3.81 | 3.64 | 3.51 | 3.40 | 3.31 | 3.17 | 3.03 | 2.88 | 2.80 | 2.72 | 2.64 | 2.55 | 2.46 | 2.36 |
| 22 | 7.95 | 5.72 | 4.82 | 4.31 | 3.99 | 3.76 | 3.59 | 3.45 | 3.35 | 3.26 | 3.12 | 2.98 | 2.83 | 2.75 | 2.67 | 2.58 | 2.50 | 2.40 | 2.31 |
| 23 | 7.88 | 5.66 | 4.76 | 4.26 | 3.94 | 3.71 | 3.54 | 3.41 | 3.30 | 3.21 | 3.07 | 2.93 | 2.78 | 2.70 | 2.62 | 2.54 | 2.45 | 2.35 | 2.26 |

تابع جدول 12

| $V_1 \backslash V_2$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 15 | 20 | 24 | 30 | 40 | 60 | 120 | ∞C |
|----------------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|
| 24 | 7.82 | 5.61 | 4.72 | 4.22 | 3.90 | 3.67 | 3.50 | 3.36 | 3.26 | 3.17 | 3.03 | 2.89 | 2.74 | 2.66 | 2.58 | 2.49 | 2.40 | 2.31 | 2.21 |
| 25 | 7.77 | 5.57 | 4.68 | 4.18 | 3.86 | 3.63 | 3.46 | 3.32 | 3.22 | 3.13 | 2.99 | 2.85 | 2.70 | 2.62 | 2.53 | 2.45 | 2.36 | 2.27 | 2.17 |
| 30 | 7.56 | 5.39 | 4.51 | 4.02 | 3.70 | 3.47 | 3.30 | 3.17 | 3.07 | 2.98 | 2.84 | 2.70 | 2.55 | 2.47 | 2.39 | 2.30 | 2.21 | 2.11 | 2.01 |
| 40 | 7.31 | 5.18 | 4.31 | 3.83 | 3.51 | 3.29 | 3.12 | 2.99 | 2.89 | 2.80 | 2.66 | 2.52 | 2.37 | 2.29 | 2.20 | 2.11 | 2.02 | 1.92 | 1.80 |
| 60 | 7.08 | 4.98 | 4.13 | 3.65 | 3.34 | 3.12 | 2.95 | 2.82 | 2.72 | 2.63 | 2.50 | 2.35 | 2.20 | 2.12 | 2.03 | 1.94 | 1.84 | 1.73 | 1.60 |
| 120 | 6.85 | 4.79 | 3.95 | 3.48 | 3.17 | 2.96 | 2.79 | 2.66 | 2.56 | 2.47 | 2.34 | 2.19 | 2.03 | 1.95 | 1.86 | 1.76 | 1.66 | 1.53 | 1.38 |
| ∞C | 6.63 | 4.61 | 3.78 | 3.32 | 3.02 | 2.80 | 2.64 | 2.51 | 2.41 | 2.32 | 2.18 | 2.04 | 1.88 | 1.79 | 1.70 | 1.59 | 1.47 | 1.32 | 1.00 |

* This table is reproduced from M. Merrington and C. M. Thompson, "Tables of percentage points of the inverted beta (F) distribution," *Biometrika*, Vol. 33 (1943), by permission of the *Biometrika* trustees.

جدول 12 : توزيع F

قيم الدالة $F_{0.05, v_1, v_2}$:

$$\alpha = \int_{F_{0.05, v_1, v_2}}^{\infty} F_{v_1, v_2}(y) dy =$$

$$= \left(\frac{u_1}{u_2} \right)^{\frac{v_1}{2}} \frac{\Gamma\left(\frac{u_1 + u_2}{2}\right)}{\Gamma\left(\frac{u_1}{2}\right) \Gamma\left(\frac{u_2}{2}\right)} \int_{F_{0.05, v_1, v_2}}^{\infty} y^{\frac{v_1}{2}-1} \left(1 + \frac{u_1}{u_2} y\right)^{-\frac{(u_1 + u_2)}{2}} dy$$

VALUES OF $F_{0.05, u_1, u_2}$ *

u_1 = Degrees of freedom for numerator

u_2 = Degrees of freedom for denominator

| $v_2 \backslash v_1$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 15 | 20 | 24 | 30 | 40 | 60 | 120 | ∞ |
|----------------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|----------|
| 1 | 161 | 200 | 216 | 225 | 230 | 234 | 237 | 239 | 241 | 242 | 244 | 246 | 248 | 249 | 250 | 251 | 252 | 253 | 254 |
| 2 | 18.5 | 19.0 | 19.2 | 19.2 | 19.3 | 19.3 | 19.4 | 19.4 | 19.4 | 19.4 | 19.4 | 19.4 | 19.4 | 19.5 | 19.5 | 19.5 | 19.5 | 19.5 | 19.5 |
| 3 | 10.1 | 9.55 | 9.28 | 9.12 | 9.01 | 8.94 | 8.89 | 8.85 | 8.81 | 8.79 | 8.74 | 8.70 | 8.66 | 8.64 | 8.62 | 8.59 | 8.57 | 8.55 | 8.53 |
| 4 | 7.71 | 6.94 | 6.59 | 6.39 | 6.26 | 6.16 | 6.09 | 6.04 | 6.00 | 5.96 | 5.91 | 5.86 | 5.80 | 5.77 | 5.75 | 5.72 | 5.69 | 5.66 | 5.63 |

تایع جدول 12

| $V_1 \backslash V_2$ | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 12 | 15 | 20 | 24 | 30 | 40 | 60 | 120 | ∞ |
|----------------------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|------|----------|
| 24 | 4.26 | 3.40 | 3.01 | 2.78 | 2.62 | 2.51 | 2.42 | 2.36 | 2.30 | 2.25 | 2.18 | 2.11 | 2.03 | 1.98 | 1.94 | 1.89 | 1.84 | 1.79 | 1.73 |
| 25 | 4.24 | 3.39 | 2.99 | 2.76 | 2.60 | 2.49 | 2.40 | 2.34 | 2.28 | 2.24 | 2.16 | 2.09 | 2.01 | 1.96 | 1.92 | 1.87 | 1.82 | 1.77 | 1.71 |
| 30 | 4.17 | 3.32 | 2.92 | 2.69 | 2.53 | 2.42 | 2.33 | 2.27 | 2.21 | 2.16 | 2.09 | 2.01 | 1.93 | 1.89 | 1.84 | 1.79 | 1.74 | 1.68 | 1.62 |
| 40 | 4.08 | 3.23 | 2.84 | 2.61 | 2.45 | 2.34 | 2.25 | 2.18 | 2.12 | 2.08 | 2.00 | 1.92 | 1.84 | 1.79 | 1.74 | 1.69 | 1.64 | 1.58 | 1.51 |
| 60 | 4.00 | 3.15 | 2.76 | 2.53 | 2.37 | 2.25 | 2.17 | 2.10 | 2.04 | 1.99 | 1.92 | 1.84 | 1.75 | 1.70 | 1.65 | 1.59 | 1.53 | 1.47 | 1.39 |
| 120 | 3.92 | 3.07 | 2.68 | 2.45 | 2.29 | 2.18 | 2.09 | 2.02 | 1.96 | 1.91 | 1.83 | 1.75 | 1.66 | 1.61 | 1.55 | 1.50 | 1.43 | 1.35 | 1.25 |
| ∞ | 3.84 | 3.00 | 2.60 | 2.37 | 2.21 | 2.10 | 2.01 | 1.94 | 1.88 | 1.83 | 1.75 | 1.67 | 1.57 | 1.52 | 1.46 | 1.39 | 1.32 | 1.22 | 1.00 |

* This table is reproduced M. Merington and C. M. Thompson, "Tables of percentage points of the inverted bats (F) distribution," Biometrika, Vol. 33 (1943), by permission of the Biometrika trustees.

