

SF1901: Sannolikhetslära och statistik

Föreläsning 9.

Statistik: statistiska inferensproblem, maximum likelihood, minsta kvadrat

Jan Grandell & Timo Koski

15.02.2016



- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):

- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):
 - A) opinionsundersökning

- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):
 - A) opinionsundersökning
 - B) Hur får man ett svar på en fråga som man inte ställt?

Sammanfattning

- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):
 - A) opinionsundersökning
 - B) Hur får man ett svar på en fråga som man inte ställt?
- Bonus Enigma



Sammanfattning

- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):

- A) opinionsundersökning
- B) Hur får man ett svar på en fråga som man inte ställt?

Bonus Enigma

- C) serienummerproblemet även känt som 'the German tank problem'.



Sammanfattning

- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):

- A) opinionsundersökning
- B) Hur får man ett svar på en fråga som man inte ställt?

Bonus Enigma

- C) serienummerproblemet även känt som 'the German tank problem'.
- D) mätvärden med brus (ex. ljusets hastighet; Newcomb-Michelson)



Sammanfattning

- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):

- A) opinionsundersökning
- B) Hur får man ett svar på en fråga som man inte ställt?

Bonus Enigma

- C) serienummerproblemet även känt som 'the German tank problem'.
 - D) mätvärden med brus (ex. ljusets hastighet; Newcomb-Michelson)
- Sedan definierar vi begrepp som punktskattning och stickprovsvariabel, och inför krav på deras prestanda.




- Vi inleder med några exempel på statistiska *inferensproblem* (inferens= slutledning):

- A) opinionsundersökning
- B) Hur får man ett svar på en fråga som man inte ställt?

Bonus Enigma

- C) serienummerproblemet även känt som 'the German tank problem'.
- D) mätvärden med brus (ex. ljusets hastighet; Newcomb-Michelson)
- Sedan definierar vi begrepp som punktskattning och stickprovsvariabel, och inför krav på deras prestanda.
- Vi inför två systematiska metoder för systematisk konstruktion av punktskattningar: *maximum-likelihood* och *minsta kvadrat* och tillämpar på exemplen A) -D).



Probability: Given the information in the pail, what is in your hand?



Statistics: Given the information in your hand, what is in the pail?

Statistisk Inferens: Data $\rightarrow$ Kunskap. Ett citat:

Inference is the problem of turning data into knowledge, where knowledge often is expressed in terms of entities that are not present in the data per se but are present in models that one uses to interpret the data.

Committee on the Analysis of Massive Data: *Frontiers in Massive Data Analysis*. The National Academies Press, Washington D.C., 2013, sid.3.

A) Inledande om opinionsundersökning: punktskattning

Vi väljer 1000 personer ur en 'stor' population (t.ex. Sveriges befolkning). De ska svara 'JA' eller 'NEJ' till en fråga (t.ex. om medlemskap i militäralliansen NATO).

Ponera nu att

$$x = 350 \quad \text{svarat JA}$$


Vi vill veta proportionen JA-sägare i HELA populationen, dvs. punktskatta proportionen JA-sägare i HELA populationen.

En skattning av p :

$$p_{obs}^* = \frac{x}{1000} \Rightarrow p_{obs}^* = 35\%$$

Hur stor är osäkerheten i denna skattning?





A) Inledande diskussion: modell för skattning

$p_{obs}^* = \frac{x}{1000} = 0.35$. Hur stor är osäkerheten i denna skattning? Vi använder oss av en sannolikhetsmodell.

URNMODELL: p = andelen JA-svar i populationen. X = antalet JA-svar när vi frågar 1000 individer. N = populationens storlek, t.ex. $N = 7,3$ miljoner svenskar över 15 år (enligt SCB var Sveriges befolkning 9 182 927 invånare på nyårsafton 2007)¹.

Vi har att

$$X \in \text{Hyp}(N, 1000, p)$$

¹http://www.scb.se/templates/pressinfo__227515.asp

A) Inledande diskussion: modell för skattning

Vi återkallar i minnet

Sats

Om X är $\text{Hyp}(N, n, p)$ -fördelad med $n/N \leq 0.1$ så är X approximativt $\text{Bin}(n, p)$ -fördelad.

Då kan vi utan stor förlust ta

$$X \in \text{Bin}(1000, p)$$

Vi uppfattar $x = 350$ som ett utfall av X . Vi kallar

$$p^* = \frac{X}{1000}$$

en *stickprovsvariabel*. $p_{obs}^* = \frac{x}{1000} = 0.35$ är ett utfall av p^*



A) Inledande diskussion: modell för skattning

$$X \in \text{Bin}(1000, p)$$

Vi vet att $E(X) = 1000 \cdot p$, $V(X) = 1000 \cdot p \cdot (1 - p)$. Detta ger

$$E(p^*) = E\left(\frac{X}{1000}\right) = \frac{1}{1000} E(X) = \frac{1}{1000} \cdot 1000 \cdot p = p.$$

$$V(p^*) = V\left(\frac{X}{1000}\right) = \frac{1}{1000^2} V(X) = \frac{1}{1000^2} \cdot 1000 \cdot p(1 - p) = \frac{p(1 - p)}{1000}.$$

Svårigheten är att de ovanstående uttrycken beror på den okända (parameter) p som vi vill skatta!



A) Inledande diskussion: medelfelet för skattning

$$E(p^*) = p, \quad V(p^*) = \frac{p(1-p)}{1000}.$$

$$D(p^*) = \sqrt{V(p^*)} = \sqrt{\frac{p(1-p)}{1000}}$$

Vår skattning av osäkerhet i skattningen är då *medelfelet*

$$d(p^*) = \sqrt{\frac{p_{obs}^*(1-p_{obs}^*)}{1000}} = \sqrt{\frac{0.35(1-0.35)}{1000}} \approx 0.015 = 1.5\%$$

B) Hur får man ett svar på en fråga som man inte ställt?

Det föregående bygger på antagandet att intervjuobjekten svarar ärligt. Ibland frågan är s.a.s. 'känslig', så att svaret 'Ja' kan vara stigmatiserande. Således kan man inte förvänta sig enbart ärliga svar.

B) Hur får man ett svar på en fråga som man inte ställt?

Man vill undersöka andelen p av personer i en stor population med en viss egenskap som ger svaret 'Ja' till en känslig fråga. (Exempel: "Har Du under det senaste året använt narkotika?").

En randomiserad undersökning:

För att få ökad personlig sekretess (och mer korrekt undersökningsresultat) lät man de tillfrågade dra ett kort. Med sannolikheten $2/3$ skulle de dra ett kort av typ I som säger de skall svara (ärligt: Ja/Nej) på den känsliga frågan och med sannolikheten $1/3$ skulle de dra kort av typ II som säger att de skall svara (ärligt: Ja/Nej) på en irrelevant fråga (T.ex. är den sista siffran i ditt personnummer ett jämnt tal?). Denna lottning fick den utfrågade själv utföra utan att visa resultatet till andra.

Antag att du genomförde denna undersökning och fick 40% Ja-svar. Vad är p = andelen individer som t.ex. under det senaste året använt narkotika?



B) Hur får man ett svar på en fråga som man inte ställt?

Låt $\lambda =$ sannolikheten för svaret 'Ja'. $p = P(\text{svar:Ja} \mid \text{kort typ I})$. Vi antar att det är lika sannolikt med Ja och Nej till den irrelevanta frågan.

Lagen om total sannolikhet ger:

$$\begin{aligned}\lambda &= P(\text{svar:Ja} \mid \text{kort typ I}) P(\text{kort I}) + P(\text{svar:Ja} \mid \text{kort typ II}) P(\text{kort II}) \\ &= p \cdot \frac{2}{3} + \frac{1}{2} \frac{1}{3}\end{aligned}$$

D.v.s

$$p = \frac{3\lambda}{2} - \frac{3}{2} \cdot \frac{1}{6} = \frac{3\lambda}{2} - \frac{1}{4}.$$

B) Hur får man ett svar på en fråga som man inte ställt?

$$p^* = \frac{3\lambda^*}{2} - \frac{1}{4}.$$

Med $\lambda_{\text{obs}}^* = 0.40$ fås

$$p_{\text{obs}}^* = 1.5 \cdot 0.4 - 0.25 = 0.35.$$



B) λ^*

$\lambda^* = \frac{X}{n}$, där X är antalet Ja-svar i den randomiserade undersökningen och n är antalet deltagare i samma undersökning. $X \in \text{Bin}(n, \lambda)$. Då fås

$$\begin{aligned} V(p^*) &= V(1.5 \cdot \lambda^* - 0.25) = \\ &= 1.5^2 V(\lambda^*) = 2.25 \cdot \frac{1}{n^2} V(X) = \\ &= 2.25 \cdot \frac{1}{n} \lambda \cdot (1 - \lambda). \\ &= 2.25 \cdot \frac{1}{n} \left(\frac{2p}{3} + \frac{1}{6} \right) \cdot \left(\frac{5}{6} - \frac{2p}{3} \right). \end{aligned}$$

B) En svårighet med detta:

$$p = \frac{3\lambda}{2} - \frac{1}{4}.$$

Med $\lambda_{\text{obs}}^* = 0.15$ fås

$$p_{\text{obs}}^* = 1.5 \cdot 0.15 - 0.25 = -0.025$$

Ett uppenbarligen orimligt resultat !



C) German tank problem (1)

During World War II, the Germans tried to make a complete tabulation of how much they were producing, but reports from individual factories were often late and not always reliable. British and U.S. statisticians working for military intelligence were keenly interested in estimating German war production (especially the production of Mark V German tanks (Panther)), too, but they could hardly ask the German factories to send them reports. Instead, they based their estimates on the manufacturing serial numbers of captured equipment (specifically the tank gearboxes). These numbers were consecutive and didn't vary - because that was a rational system in terms of maintenance and spare parts. These serial numbers provided a sample that was very small, but reliable.

The challenge is to choose a good estimator for the total number of tanks.



C) German tank problem (2)

Detta är även känt som 'the serial number problem'. Vi kan renodla det enligt följande:


Någon har levererat oss heltalen $x_1, x_2, \dots, x_n$, som är slumpmässiga stickprov från mängden av heltal

$$\{1, 2, 3, \dots, N\}$$

där N är okänt.

Uppgiften (uppgiften för statistisk inferens) är att skatta N på basis av $x_1, x_2, \dots, x_n$. (forts.)





Enigma & Good-Turings punktskattning

Enigma var en portabel krypteringsmaskin som användes av Nazitysklands väpnade styrkor både före och under andra världskriget. Britterna hade lyckats i att kapa åt sig Kenngruppenbuch (KG), en sekretessbelagd bok som innehöll i en slumpmässig ordning varje ord med tre bokstäver. Ett sådant ord, dagligen plockat ur en sida i KG enligt vissa instruktioner, ingick i krypteringsnyckeln för krigsmarinens meddelanden per enigma.



De omständliga detaljerna i denna procedur genomgås i

<http://users.telenet.be/d.rijmenants/en/enigmaproc.htm>

35

Spalte 081*)

	A	B	C	D	E	F	G	H	I	J	K	L
1	T	F	Q	B	D	X	K	P	F	Q	D	X
2	V	U	Q	P	C	J	B	F	U	Q	P	C
3	Y	Q	B	X	K	P	F	Q	D	X	K	P
4	C	Q	U	Y	D	C	O	Q	C	D	F	T
5	D	X	F	G	Y	Z	H	F	T	Q	Y	Z
6	O	G	U	H	D	Q	X	K	P	F	Q	D
7	B	Q	U	K	P	F	Q	D	X	K	P	F
8	X	B	Q	U	K	P	F	Q	D	X	K	P
9	Z	D	G	W	H	X	K	P	F	Q	D	X
10	Y	U	L	R	N	B	J	J	K	A	X	G
11	U	L	Y	N	Z	A	B	B	Z	R	T	O
12	D	Y	W	H	W	G	H	T	R	C	H	L
13	D	M	K	Y	P	R	D	X	K	P	F	Q
14	E	O	Y	L	C	P	A	N	G	B	R	Q
15	P	O	H	D	U	Z	G	J	Q	K	F	B
16	L	H	O	G	U	T	N	D	W	M	T	Q
17	F	Q	T	H	E	X	A	C	L	T	O	N
18	O	T	A	P	W	L	X	O	A	O	Z	J
19	O	X	D	R	H	D	R	U	L	B	Q	B
20	O	O	F	B	D	G	H	C	M	L	T	G
21	X	N	O	D	B	Q	W	B	U	N	K	G
22	W	M	G	T	O	D	G	J	E	F	L	A
23	W	R	U	R	V	W	A	M	X	F	N	G
24	L	W	Y	W	G	A	B	F	Y	J	L	X
25	L	W	Y	M	D	V	O	F	R	L	X	C
26	L	P	V	W	A	O	X	J	R	A	F	U
27	D	H	Q	G	M	J	Y	M	N	G	V	O
28	W	Q	Z	P	D	K	R	X	Z	P	Y	V
29	Z	B	X	R	F	Y	F	G	J	Y	T	F
30	Z	V	D	U	A	Y	W	F	L	F	T	W
31	T	Y	C	Z	P	Y	W	O	D	X	C	B
32	O	G	H	T	D	J	C	V	W	D	C	Z
33	G	Q	L	O	Z	F	T	W	L	Y	C	W
34	H	Y	X	O	P	Z	X	Q	Z	Z	N	Y
35	G	W	T	O	P	A	Q	V	K	H	M	V
36	L	E	Q	O	C	F	R	G	T	X	W	C
37	D	L	X	F	A	U	O	R	J	Y	Q	W
38	C	O	P	L	B	G	N	E	W	A	C	K
39	X	N	B	U	G	Z	N	B	V	R	P	O
40	J	N	K	O	M	C	O	R	D	M	X	O
41	C	T	Z	B	X	P	D	K	W	H	Q	E
42	T	R	D	P	X	B	T	M	G	H	F	K
43	Y	N	B	Z	Q	Y	F	Y	J	O	G	H
44	J	G	U	B	V	O	H	E	X	L	C	P
45	W	J	M	D	P	Y	Z	T	B	J	H	W
46	T	J	F	N	L	U	B	M	J	P	Z	W
47	O	W	H	P	M	B	T	V	Z	U	C	Y
48	H	P	Z	N	B	G	N	V	M	W	N	F

*) Die Gruppen haben im Teil II, Gruppenschlüssel, die Bezeichnungen L.F.H.

Col. 1



KTH Matematik

Enigma

Alan Turing & gruppen hade stickprov av ord med tre bokstäver, som använts av ubåtskaptenerna i meddelanden som tidigare forcerats. Turing antog att dessa fartygschefer ofta plockade samma ord som tidigare.



Bundesarchiv, Bild 101I-640-4022-92A
Foto: Dietrich (März 1941)

<http://commons.wikimedia.org/wiki/File:Bundesarchiv>

Enigma: Good-Turings punktskattning

Turing ville skatta sannolikheten att den nya nyckelns ord är ett av dem, som redan använts, och fördelningen för alla observerade ord.

Relativ frekvens visade sig inte fungera, Turing byggde sin skattning på storleksfördelningen (size distribution) $\{N_r\}$, där N_r är antalet ord som förekommer r gånger bland de forcerade orden (med tre bokstäver). Då är totalantalet ord $N = \sum_{r=1} rN_r$.

Enigma: Good-Turings punktskattning

p_r (= sannolikheten för ett ord som setts r gånger) skattas av

$$\hat{p}_r = \frac{(r+1) \cdot N_{r+1}}{N \cdot N_r}.$$

I.J. Good förfinade detaljerna, d.v.s algoritmen genom en funktion $S(N_r)$. Denna skattning får sägas vara rätt så icke-intuitiv. Det skulle ta oss för långt att gå vidare med detta.

Med dessa skattningar kunde Turing designa *statistiska test* för att reducera antalet initiella inställningar som checkades av den av honom konstruerade maskinen (datorn?, kallad bombe) för att hitta Enigmas dagliga inställning.



D) Mätning av ljusets hastighet


Exempel

För bestämning av ljusets hastighet (nu accepterad som $c = 299792458(\leftrightarrow \theta)$ m per sekund), utvecklade Simon Newcomb (1835 – 1909, astronom och matematiker vid U.S. Navy) och Albert Abraham Michelson (1852 1931, fysiker , året 1907s nobelpristagare i fysik) en optisk utrustning som bestod av en fast sfärisk spegel, placerad vid foten av Washington Monument (Washington D.C.) och en roterande spegel och en optisk lins vid nuvarande Fort Myer. Genom att reglera spegelns rotation, mäta avståndet mellan monumentet och Fort Myer, avståndet mellan en ljuskälla och den roterande spegeln, och förskjutningen mellan den skickade ljusstrålen och den reflekterade ljusstrålen, kan ljusets hastighet bestämmas (per en formel).

Det finns många källor till mätfel i detta.



D) Mätning av ljusets hastighet: utrustningen (lite moderniserad)



D) Mätning av ljusets hastighet

Exempel


De exakta tekniska detaljerna för hur dessa mätningar gjordes redovisas i R.J. MacKay & R.W. Oldford : Statistical Method and the Speed of Light. *Statistical Science*, vol. 15, 2000, pp. 254–278.

W.E. Cater & M.S. Carter: The Newcomb-Michelson Velocity of Light Experiments. *Eos, Transactions, American Geophysical Union*, vol 83, 2002, pp. 405–410.

D) Mätning av ljusets hastighet

Exempel

Newcomb-Michelsons data är differenserna från 24,800 ns. (Addera 299,800 för att få svaret i km/s.) Histogrammet för 66 differenser är enligt



figuren:

D) Mätning av ljusets hastighet

Exempel

Newcomb-Michelsons svar blev 299860 km/s. Det intressanta för eftervärldens statistiker är inte svaret utan hur data hanterades och mätfel och systematiska fel eliminerades med statistiska metoder.



Punktskattning **Modell**

Vi uppfattar mätvärdena ($= \theta + \text{mätfel}$), som utfall av n st. oberoende och lika fördelade s.v. $X_1, X_2, \dots, X_n$ med $E(X_i) = \theta$ och $V(X_i) = \sigma^2$. En *punktskattning* θ_{obs}^* av θ är en funktion av mätvärdena:

$$\theta_{\text{obs}}^* = \theta^*(x_1, \dots, x_n).$$

När vill vill analysera en skattning ersätter vi observationerna med de underliggande stokastiska variablerna. Vi säger då att

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

är en *stickprovsvariabel*.

Stickprovsvariabeln är själv en stokastisk variabel, vars fördelning beror av fördelningen för $X_1, X_2, \dots, X_n$ och därmed av θ .



Om vi inte använder någon statistisk teori så väljer vi antagligen

$$\theta_{\text{obs}}^* = \bar{x} = \frac{1}{n} \sum x_i.$$

För motsvarande stickprovsvariabel $\theta^* = \bar{X}$ gäller (liksom tidigare konstaterats) att

$$E(\theta^*) = E(\bar{X}) = \theta$$

och

$$V(\theta^*) = V(\bar{X}) = \sigma^2 / n.$$

Vi har en uppsättning data

$$x_1, x_2, \dots, x_n$$

som ses som utfall av s.v.

$$X_1, X_2, \dots, X_n.$$

Dessa variabler antages vara oberoende och likafördelade och deras gemensamma fördelning beror av en okänd parameter θ , t.ex. $N(\theta, \sigma)$, $Po(\theta)$, $N(\theta_1, \theta_2)$, osv.

- En punktskattning θ_{obs}^* av θ är en funktion $\theta^*(x_1, \dots, x_n)$

- En punktskattning θ_{obs}^* av θ är en funktion $\theta^*(x_1, \dots, x_n)$
- och motsvarande stickprovsvariabel θ^* är $\theta^*(X_1, \dots, X_n)$

- En punktskattning θ_{obs}^* av θ är en funktion $\theta^*(x_1, \dots, x_n)$
- och motsvarande stickprovsvariabel θ^* är $\theta^*(X_1, \dots, X_n)$
- Exemplet A) ovan:

$$p_{obs}^* = \frac{350}{1000} = 0.35$$

är en punktskattning.

$$p^* = \frac{X}{1000}, \quad X \in \text{Bin}(1000, p)$$

är motsvarande stickprovsvariabel.

Vad menas med en bra skattning?

Vi ger tre kriterier:

Definition

- 1) En punktskattning θ_{obs}^* av θ är väntevärdesriktig om $E(\theta^*(X_1, \dots, X_n)) = \theta$.

Vad menas med en bra skattning?

Vi ger tre kriterier:

Definition

- 1) En punktskattning θ_{obs}^* av θ är väntevärdesriktig om $E(\theta^*(X_1, \dots, X_n)) = \theta$.
- 2) En punktskattning θ_{obs}^* av θ är konsistent om $P(|\theta^*(X_1, \dots, X_n) - \theta| > \varepsilon) \rightarrow 0$ då $n \rightarrow \infty$.

Vad menas med en bra skattning?

Vi ger tre kriterier:

Definition

- 1) En punktskattning θ_{obs}^* av θ är väntevärdesriktig om $E(\theta^*(X_1, \dots, X_n)) = \theta$.
- 2) En punktskattning θ_{obs}^* av θ är konsistent om $P(|\theta^*(X_1, \dots, X_n) - \theta| > \varepsilon) \rightarrow 0$ då $n \rightarrow \infty$.
- 3) Om θ_{obs}^* och θ_{obs}^{**} är väntevärdesriktiga skattningar av θ så säger man att θ_{obs}^* är effektivare än θ_{obs}^{**} om $V(\theta^*(X_1, \dots, X_n)) < V(\theta^{**}(X_1, \dots, X_n))$.

A) Proportionen JA-sägare & Good-Turing



$$X \in \text{Bin}(1000, p)$$

$$p^* = \frac{X}{1000}, \quad E(p^*) = p.$$

Således är p_{obs}^* väntevärdesriktig.

- Good-Turings punktskattning är inte väntevärdesriktig, men felet, även kallat bias, är litet.



Skattning av väntevärdet μ

Sats

Stickprovsmedelvärdet $\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$ som skattning av väntevärdet μ är

- 1) Väntevärdesriktig;
- 2) Konsistent;
- 3) Ej nödvändigtvis effektiv, dvs. den effektivaste möjliga skattningen.

Bevis.

- 1) $E(\bar{X}) = \mu$.
- 2) $V(\bar{X}) = \sigma^2 / n$ och stora talens lag gäller.
- 3) Det finns motexempel (den intresserade hänvisas till Blom et al.)



KTH Matematik

Sats

Stickprovsvariansen $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ som skattning av σ^2 är

- 1) Väntevärdesriktig;
- 2) Konsistent;
- 3) Ej nödvändigtvis effektiv.

1) används ofta som motivering för att man dividerar med $n - 1$, men det är en dålig motivering, eftersom man oftast vill skatta σ . s som skattning av σ är dock ej väntevärdesriktig.

Maximum-likelihood-metoden: Likelihoodfunktion

Antag att X_i har täthetsfunktionen $f_X(x, \theta)$, θ okänd.

Vi ska nu studera en systematisk metod att hitta skattningar. Idén är att skatta θ så att utfallet blir så "troligt" som möjligt.

Definition

$$L(\theta) = f_{X_1}(x_1, \theta) \cdot \dots \cdot f_{X_n}(x_n, \theta)$$

kallas *Likelihood-funktionen*.

Observera att likelihoodfunktionen betraktas som en funktion av θ , inte av $x_1, \dots, x_n$.



$$L(\theta) = f_{X_1}(x_1, \theta) \cdot \dots \cdot f_{X_n}(x_n, \theta)$$

Definition

Det värde θ_{obs}^ för vilket $L(\theta)$ antar sitt största värde kallas ML-skattningen av θ .*

För stora stickprov är denna skattning i allmänhet mycket bra.

Maximum-likelihood-metoden för $\text{Bin}(1000, p)$

Låt oss återkalla i minnet den inledande diskussionen A) om skattning av proportionen JA-sägare i en stor population. Vi har observerat $x = 350$ och tar detta som ett utfall av X med

$$X \in \text{Bin}(1000, p)$$

Då är likelihoodfunktionen för p

$$L(p) = p_X(x) = \binom{1000}{x} p^x (1-p)^{1000-x}$$

Vi bildar *loglikelihoodfunktionen* $\ln L(p)$, dvs.

$$\ln L(p) = \ln \binom{1000}{x} + x \ln p + (1000 - x) \ln 1 - p$$



Maximum-likelihood-metoden för $\text{Bin}(1000, p)$

För att maximera $L(p)$ kan vi ekvivalent maximera

$$\ln L(p) = \ln \binom{1000}{x} + x \ln p + (1000 - x) \ln 1 - p$$

För detta deriverar vi $\ln L(p)$ m.a.p. p

$$\frac{d}{dp} \ln L(p) = x \frac{1}{p} - (1000 - x) \frac{1}{1 - p}$$

och löser $\frac{d}{dp} \ln L(p) = 0$ m.a.p. p .

$$x \frac{1}{p} - (1000 - x) \frac{1}{1 - p} = 0 \Leftrightarrow x \frac{1}{p} = (1000 - x) \frac{1}{1 - p}$$


$$\Leftrightarrow (1 - p)x = p(1000 - x) \Leftrightarrow x - px = p1000 - px$$

dvs. maximum likelihood - skattningen är

$$p_{obs}^* = \frac{x}{1000} = \frac{350}{1000} = 0.35.$$



Plot av loglikelihoodfunktionen $\ln L(p)$ för $\text{Bin}(1000, p)$ med $x = 350$



$$\ln L(p) = \ln \binom{1000}{350} + 350 \ln p + (1000 - 350) \ln 1 - p, \quad 0 < p < 1$$

B) Ny metod: Hur får man ett svar på en fråga som man inte ställt?

Man vill undersöka andelen p av personer som svarar ja p en känslig fråga. (Exempel: "Har Du under det senaste året använt narkotika?").

En ny randomiserad undersökning:

Vi har en kortlek med n =jämmt tal kort. De tillfrågade drar var sitt kort **utan återläggning**. $n/2$ kort ger instruktionen att de skall svara (ärligt: Ja/Nej) på den känsliga frågan och $n/2$ kort säger att de skall blankt svara Ja. Alla drar sitt kort och visar inte resultatet till andra.

X = antalet Ja-svar. Vi vet att det finns minst $n/2$ Ja-svar. Då är $Y = X - \frac{n}{2} \in \text{Bin}(\frac{n}{2}, p)$, med den okända proportionen p som förut. Då är

$$p^* = \frac{Y}{\frac{n}{2}}$$

enligt ovan maximum likelihood skattning av p , väntevärdesriktig och effektiv. Dessutom gäller $0 \leq p^* \leq 1$!



Exempel

X_i är $N(\theta, \sigma)$, dvs.

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

Vi kan t.ex. ha

mätvärde = θ + slumpmässigt normalfördelat mätfel

$$X_i = \theta + \sigma Z_i, \quad Z_i \in N(0, 1), \quad i = 1, 2, \dots, n$$

Vi observerar $x_1, \dots, x_n$. Då fås

$$L(\theta) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_1-\theta}{\sigma}\right)^2} \dots \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x_n-\theta}{\sigma}\right)^2} = \frac{1}{\sigma^n (2\pi)^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n \left(\frac{x_i-\theta}{\sigma}\right)^2}$$



Maximum-likelihood-metoden (Exempel D))

Vi antar att σ är känt.

$$\ln L(\theta) = -\ln(\sigma^n (2\pi)^{n/2}) - \frac{1}{2\sigma^2} \sum_1^n (x_i - \theta)^2$$

$$\frac{d \ln L(\theta)}{d\theta} = \frac{1}{2\sigma^2} \sum_1^n 2(x_i - \theta).$$

$$\frac{d \ln L(\theta)}{d\theta} = 0$$

ger

$$\sum_1^n x_i = n\theta,$$

dvs.

$$\theta_{\text{obs}}^* = \bar{x}.$$

I detta fall är θ_{obs}^* *effektiv*!




Maximum-likelihood-metoden Exempel: $\sigma = 3$

$$\ln L(\theta) = -\log(3^{10} \cdot (2\pi)^{10/2}) - \frac{1}{2 \cdot 3^2} \sum_{i=1}^{10} (x_i - \theta)^2$$

$$x_1 = 3.28 \quad x_2 = -0.21 \quad x_{31} = 3.69 \quad x_4 = -2.15 \quad x_5 = 3.38$$

$$x_6 = 3.89 \quad x_7 = 3.14 \quad x_8 = -1.04 \quad x_9 = 0.96 \quad x_{10} = 3.33$$

$$\bar{x} = 1.83$$



Om vi inte känner fördelningen helt kan inte ML-metoden användas. Ibland ger den även upphov till svåra beräkningsproblem. Man kan då gå tillväga på följande sätt:

Låt $x_1, \dots, x_n$ vara ett stickprov från en fördelning med $E(X) = \mu(\theta)$ där $\mu(\theta)$ är en *känd* funktion av en *okänd* parameter θ .

Sätt $Q(\theta) = \sum_{i=1}^n (x_i - \mu(\theta))^2$ och minimera $Q(\theta)$ map. θ . Lösningen θ_{obs}^* till detta problem kallas *MK-skattningen* av θ .

$$Q(\theta) = \sum_{i=1}^n (x_i - \mu(\theta))^2$$

$$\frac{d}{d\theta} Q(\theta) = 2 \sum_{i=1}^n (x_i - \mu(\theta)) \cdot \left(-\frac{d}{d\theta} \mu(\theta) \right)$$

$$\frac{d}{d\theta} Q(\theta) = 0 \Leftrightarrow -2 \frac{d}{d\theta} \mu(\theta) \sum_{i=1}^n (x_i - \mu(\theta)) = 0$$

$$\Leftrightarrow \sum_{i=1}^n (x_i - \mu(\theta)) = 0 \Leftrightarrow \sum_{i=1}^n x_i - n\mu(\theta) = 0$$

$$\mu(\theta) = \frac{1}{n} \sum_{i=1}^n x_i$$

Ifall den inversa funktionen $\mu^{-1}(\theta)$ existerar ges MK-skattningen θ_{obs}^* av

$$\theta_{obs}^* = \mu^{-1} \left(\frac{1}{n} \sum_{i=1}^n x_i \right) = \mu^{-1}(\bar{x})$$

Minsta-kvadrat-metoden

$x_1, x_2, \dots, x_n$ utfall av s.v. $X_1, X_2, \dots, X_n$, $X_i \in U(0, \theta)$. Kursens formelsamling eller en enkel härledning ger

$$E(X_i) = \frac{\theta}{2}, \quad V(X_i) = \frac{\theta^2}{12}$$

dvs. vi tar $\mu(\theta) = \frac{\theta}{2}$ i $Q(\theta) = \sum_{i=1}^n (x_i - \mu(\theta))^2$, dvs.

$$Q(\theta) = \sum_{i=1}^n \left(x_i - \frac{\theta}{2}\right)^2$$

MK-skattningen θ^* ges enligt ovan av

$$\theta_{obs}^* = \mu^{-1}(\bar{x}) = 2\bar{x}$$



Minsta-kvadrat-metoden

$$\theta_{obs}^* = \mu^{-1}(\bar{x}) = 2\bar{x}$$

Denna punktskattning är väntevärdesriktig:

$$E(\theta^*) = 2E(\bar{X}) = 2\frac{\theta}{2} = \theta$$

och konsistent (Tjebysjovs olikhet)

$$\begin{aligned} V(\theta^*) &= V(2\bar{X}) = 4\frac{1}{n^2} \cdot n\frac{\theta^2}{12} \\ &= \frac{\theta^2}{3n}. \end{aligned}$$



C) German tank problem (3)

θ = total number of tanks (true population value)

n = number of tanks captured

m = largest serial number of the captured tanks

The following *estimator* (= *stickprovsvariabel* i vår terminologi) was invented and used by statisticians in the the WW II allied military intelligence² :

$$\theta^* = [(n+1)/n]m \leftrightarrow \theta^* = m + (m/n)$$

which is interpreted as adding the average size of the gap to the highest serial number.

C) German tank problem (4)

Betrakta ett fiktivt exempel³. Antag att vi har $n = 15$ och att serienumren är

5 10 15 20 25 30 35 40 45 50 55 60 65 70 75

så att $m = 75$. Då ger formeln ovan *punktskattningen*

$$\theta_{\text{obs}}^* = 75 + (75/15) = 80$$

Vi kommer nedan att tolka stickprovsvariabeln $\theta^* = m + (m/n)$ som en för väntevärdesriktighet korrigerad maximum-likelihood-skattning av θ i $U(0, \theta)$ med n observationer !

³http://en.wikipedia.org/wiki/German_tank_problem

Maximum likelihood för θ i $U(0, \theta)$

$x_1, x_2, \dots, x_n$ utfall av s.v. $X_1, X_2, \dots, X_n$, $X_i \in U(0, \theta)$. Vad är maximum likelihood skattningen av θ ?

$$f_X(x) = \begin{cases} \frac{1}{\theta} & \text{för } 0 \leq x \leq \theta \\ 0 & \text{annars.} \end{cases}$$

$$L(\theta) = f_{X_1}(x_1, \theta) \cdot \dots \cdot f_{X_n}(x_n, \theta) =$$

och eftersom $x \geq \theta \Rightarrow f_X(x) = 0$

$$= \begin{cases} \frac{1}{\theta^n} & \text{för } \theta \geq \max(x_1, x_2, \dots, x_n) \\ 0 & \text{annars.} \end{cases}$$

$L(\theta)$ är en avtagande funktion av θ och detta ger (utan derivering)

$$\theta_{obs}^{ML} = \max(x_1, x_2, \dots, x_n).$$



Korrigerad maximum likelihood i $U(0, \theta)$

$X_1, X_2, \dots, X_n, X_i \in U(0, \theta)$. Maximum likelihood skattningen av θ är

$$\theta_{obs}^{ML} = \max(x_1, x_2, \dots, x_n).$$

Man kan checka (Blom et.al. sid. 258) att den korrigerade skattningen

$$\frac{n+1}{n} \theta_{obs}^{ML}$$

är väntevärdesriktig, konsistent samt effektivare än minst-kvadrat skattningen.



C) Korrigerad maximum likelihood i $U(0, \theta)$ & the German tank problem (5)

Den korrigerade skattningen

$$\frac{n+1}{n} \theta_{obs}^{ML} = \max(x_1, x_2, \dots, x_n) + \frac{\max(x_1, x_2, \dots, x_n)}{n}$$

är ingenting annat än den ovan framlagda skattningen i C) 'the German tank problem'. MEN: vi har då gett oss in på en kontinuerlig approximation av det ursprungliga problemet, dvs. vi har approximerat en likformig sannolikhetsfunktion på heltalen $\{1, 2, \dots, \theta\}$ med en likformig täthet på $(0, \theta)$. Detta låter sig göras om θ är stort.

Exakt räknat kan man visa för det diskreta problemet att


$$\theta_{obs}^* = \max(x_1, x_2, \dots, x_n) + \frac{\max(x_1, x_2, \dots, x_n)}{n} - 1$$

är en väntevärdesriktig och effektiv skattning.



C) Simulerad korrigerad maximum likelihood & the German tank problem (6)

Vi drar hundra gånger tio värden $x_1, x_2, \dots, x_{10}$ ur $1, 2, \dots, \theta$ med $\theta = 245$ med hjälp av slumpfelsgeneratorn *unidrnd* i MATLAB Statistics toolbox. Sedan tar vi maximum $y_i = \max(x_1, x_2, \dots, x_{10})$, $i = 1, \dots, 100$ för vart och ett av dessa hundra sampel och bildar $\theta_{obs \text{ nr } i}^* = y_i + y_i/10$. Histogrammet för de hundra θ_{obs}^* syns i bilden. $\theta_{obs}^* = 250.64$.



C) German tank problem (7)

By using the formula $\theta^* = \theta^{ML} + (\theta^{ML}/n)$, statisticians reportedly estimated that the Germans produced 246 tanks per month between June 1940 and September 1942. At that time, standard intelligence estimates had believed the number was at around 1,400. After the war, the allies captured German production records of the Ministry, which was in charge of Germany's war production, showing that the true number of tanks produced in those three years was 245 per month, almost exactly what the statisticians had calculated, and less than one fifth of what standard intelligence had thought likely, and were more accurate and timely than Germany's own estimates.

Emboldened, the allies attacked the western front in 1944 and overcame the Panzers on their way to Berlin. And so it was that statisticians won the war - in their own estimation, at any rate. Even Alan Turing is acknowledged as one made victory possible.



C) German tank problem (8): lätt tillgängliga referenser

- G. Davies: How a statistical formula won the war.
The Guardian, Thursday July 20 2006

<http://www.guardian.co.uk/world/2006/jul/20/secondworldwar.tvandradio>

- Robert Matthews: Hidden truths.
New Scientist 23 May 1998

<http://www.newscientist.com/article/mg15821355.000-hidden-truths.html>



Definition

$$(1) \underline{\sum_{i=1}^n x_i = x_1 + x_2 + \dots + x_n.}$$

Sats

$$(2) \quad \underline{\sum_{i=1}^n a \cdot x_i = a \sum_{i=1}^n x_i}.$$

Bevis. Definitionen (1) ger $\sum_{i=1}^n a \cdot x_i = ax_1 + ax_2 + \dots + ax_n$
 $= a(x_1 + x_2 + \dots + x_n) = a \sum_{i=1}^n x_i.$

Exempel: $x_i = 1, i = 1, \dots, n$

$$\sum_{i=1}^n ax_i = a \sum_{i=1}^n 1 = a(1 + 1 + \dots + 1) = a \cdot n.$$

Sats

$$(3) \quad \underline{\sum_{i=1}^n (x_i + y_i) = \sum_{i=1}^n x_i + \sum_{i=1}^n y_i.}$$

Bevis. Definition (1) ger

$$\begin{aligned} \sum_{i=1}^n (x_i + y_i) &= (x_1 + y_1) + (x_2 + y_2) + \dots + (x_n + y_n) \\ &= x_1 + x_2 + \dots + x_n + y_1 + y_2 + \dots + y_n = \sum_{i=1}^n x_i + \sum_{i=1}^n y_i. \end{aligned}$$

Bilaga: räkneoperationer med summor

Sats

$$(4) \quad \underline{\sum_{i=1}^n (ax_i + by_i) = a \sum_{i=1}^n x_i + b \sum_{i=1}^n y_i}$$

Bevis. Detta fås av (3) och (2).

Sats

$$(5) \quad \underline{\sum_{i=1}^n (x_i + y_i)^2 = \sum_{i=1}^n x_i^2 + 2 \sum_{i=1}^n x_i y_i + \sum_{i=1}^n y_i^2.}$$

Bevis. Använd $(x_i + y_i)^2 = x_i^2 + 2x_i y_i + y_i^2$ och (4) samt (2) med $a = 2$.