

SF1914/SF1916: SANNOLIKHETSTEORI OCH
STATISTIK
FÖRELÄSNING 9
INFERENSTEORI – KONSTEN ATT DRA
SLUTSATSER.
PUNKSKATTNINGAR OCH DERAS
EGENSKAPER.

Tatjana Pavlenko

21 september 2018



PLAN FÖR DAGENS FÖRELÄSNING

- ▶ Inledning: skillnaden mellan sannolikhets teori och statistisk inferens (Kap. 11.1-11.2).
- ▶ Punktskattningar, egenskaper hos en skattning (Kap. 11.3)
- ▶ Skattning av väntevärde och varians (Kap. 11.4)
- ▶ Objektiva metoder att ta fram skattningar: MK- och ML-skattningar (Kap. 11.5)



INLEDNING

- ▶ I *sannolighetsteorin* har vi arbetat med stokastiska variabler vars fördelningar och deras parametrar varit *kända*. Utgående från en given sannolikhetsmodell, vill man bestämma sannolikheter för olika intressanta händelser.
- ▶ I *statistikteorin* är förhållandet det omvända; vi har en samling av mätvärden (data) från någon fördelning vars parametrar i regel är okända, vi vill använda mätvärdena för att uppskatta de okända parametrarna på något bra sätt.

Utmaningen är att omsätta data till kunskap!

- ▶ I dagens tillämpningar träffar man ofta stora mängder av (komplexa) data.



- ▶ Most everyone now has heard one of the hottest terms today – *big data*. Big data is a big deal, especially in such data-intensive industries as cybersecurity, finance, healthcare, marketing, transportation, energy, and others. And, many of us are already familiar with the 3V's of big data – volume, velocity, and variety of data. But, the key question is,

“How do we extract big knowledge from big data?”

- ▶ The new breed of analytics specialists need to have a combination of skills including statistical techniques, applied mathematical methods, advanced machine learning algorithms, data visualization, and business and communications skills.

Cited from the book *Big Data and Business Analytics* (Taylor Francis, 2013) by J. Liebowitz, the Orkand Endowed Chair in Management and Technology at University of Maryland University College.



- ▶ Vi antar att vi har ett *stickprov*, x_1, \dots, x_n som är en samling observationer (uppmätta värden) av stokastiska variabler X_1, \dots, X_n genom experiment. Fördelningen för X beror av en- eller flerdimensionell *okänd* parameter θ .
- ▶ Parametern kan ta värden i ett *parameterrum*, bet. Ω_θ , (t. ex. $\Omega_\theta = (0, \infty)$ om vi vet att $\theta > 0$).
- ▶ I allmänhet antas X_1, \dots, X_n oberoende och likafördelade, dvs kommer från samma $F_X(x)$.
- ▶ Syftet är att *skatta* den okända fördelningsparametern θ med hjälp av *funktion* av data.



1. Opinionsundersökning (se Ex i Kap. 11.2) :
 - ▶ 1000 personer väljes på måfå ur en stor population, t.ex. Sveriges befolkning (vid halvårsskiftet i år var Sveriges folkmängd 9 793 172 personer, SCB).
 - ▶ En fråga som ska besvaras med *Ja* eller *Nej* ställs. Resultat: 350 personer svarat *Ja*. Data: $x = 350$. Uppskatta andelen *Ja*-svarare $\theta = p$ i hela populationen.
2. Uppskatta medelhastigheten hos hela populationen bilar som passerar korsningen: $\theta = \mu = E(X)$.
 X_i är hastighet hos bil i . Data: $x_1 = 65, x_2 = 50, \dots, x_{78} = 56$.
3. Hur stor är den förväntade andelen fortkörare?
 $\theta = p = P(X > 50)$. Data: $y = 41$.

- ▶ **Def.** En *punktskattning* θ^* av en parameter θ är en funktion av data (x_1, \dots, x_n) som ger ett värde i parametertrum Ω_θ , detta värde ges av

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

- ▶ **Viktigt!**

- ▶ Mätdata (x_1, \dots, x_n) ses som utfall av s. v. (X_1, \dots, X_n) .
- ▶ Punktskattningen $\theta_{obs.}^*$ ses som ett utfall (en observation) av den s.v. $\theta^*(X_1, \dots, X_n)$.
- ▶ Om ny mätdata erhålls så får vi ett nytt utfall $\theta_{obs.}^*$ av den s.v. $\theta^*(X_1, \dots, X_n)$.
- ▶ Funktionen $\theta^*(X)$ av motsvarande s. v. $X = (X_1, \dots, X_n)$ kallas för *skattare av θ* . $\theta^*(X)$ är också en s. v. med t. ex. fördelning, väntevärde och varians.
- ▶ Skilj på θ som är en parameter, dvs okänt tal, och θ^* som är dess skattning. Skattningen varierar med stickprovet, det gör inte θ !
- ▶ *Tokning*: Fördelning för $\theta^*(X)$ talar om vad skattningen kunde blivit istället, om vi gjort om experiment, t ex mäter hastighet hos 78 nya bilar.



Önskvärda egenskaper: fördelningen för en s.v. $\theta^*(X)$ har inte något systematiskt fel. Detta kan preciseras i följande

- ▶ **Def.** En punktskattning θ_{obs}^* är väntevärdesriktig om

$$E(\theta^*) = \theta$$

för varje $\theta \in \Omega_\theta$.

Ex på tavlan!



Önskvärda egenskaper:

- ▶ intuitivt, skattningen bör bli *bättre* då man ökar antalet observationer (mätdata) skattningen baseras på. För att tydligare markera att skattningarna beror an n betecknar vi nu stickprovsvariabeln med $\theta_n^*(X)$.
- ▶ Fördelning av $\theta_n^*(X)$ koncentreras mer och mer kring det rätta värdet θ då n växer. Detta kan preciseras i följande

- ▶ **Def.** Om för varje fixt $\theta \in \Omega_\theta$ och för varje givet $\varepsilon > 0$

$$P(|\theta_n^* - \theta| > \varepsilon) \rightarrow 0$$

då stickprovsstorleken $n \rightarrow \infty$ sägs θ_{obs}^* vara *konsistent*.

- ▶ *Tolkning:* för ett stort stickprov är det troligt att punktskattningen ligger nära det rätta värdet θ .

Ex på tavlan!



Önskvärda egenskaper:

- ▶ som koncentrationsmått/spridningsmått för stickprovsvariabeln θ^* används ofta variansen, $V(\theta^*)$. Vid val mellan två olika väntevärdesriktiga skattningar föredrar man en som har *liten spridning*, vilket leder oss till följande

- ▶ **Def.** Om θ^* och $\hat{\theta}$ är två skattningar väntevärdesriktiga och

$$V(\theta^*) \leq V(\hat{\theta})$$

för alla $\theta \in \Omega_\theta$, med strikt olikhet för något $\theta \in \Omega_\theta$, sägs θ^* vara *effektivare* än $\hat{\theta}$.

- ▶ *Tolkning:* Man väljer den väntevärdesriktiga skattningen som har *lägst varians!* Detta kallas för den *effektivaste skattningen*.

Ex på tavlan!



Ett sätt att samtidigt ta hänsyn till både *systematsikt* fel (*bias* på engelska), $E(\theta^*) - \theta$, och *slumpmässigt* fel är att studera *medelkvadratfel*.

- ▶ **Def.** En skattnings medelkvadratfel (MSE, Mean Square Error) är

$$\text{MSE} = E((\theta^* - \theta)^2).$$

- ▶ Medelkvadratfel kan skrivas som (se def 11.4 på s. 248 i Blom)

$$\text{MSE} = V(\theta^*) + (E(\theta^*) - \theta)^2,$$

dvs som summan av skattningens varians och kvadraten på systematsikt fel.



$$\text{MSE} = V(\theta^*) + (E(\theta^*) - \theta)^2.$$

- ▶ För väntevärdesriktig skattning är systematsikt fel lika med noll, $E(\theta^*) - \theta = 0$. Detta innebär att för väntevärdesriktiga skattningar har vi

$$\text{MSE} = V(\theta^*).$$

- ▶ Obs! När vi talar om väntevärde (varians) för en punktskattning är det väntevärde (varians) för en *skattare*, dvs för s.v. $\theta^*(X)$. Vi skriver $E(\theta^*)$ ist. för omständigare $E(\theta^*(X))$, och $V(\theta^*)$ ist. för omständigare $V(\theta^*(X))$.



Låt x_1, \dots, x_n vara mätdata som ses som observationer av oberoende s.v X_1, \dots, X_n vilkas fördelning har väntevärde μ och variansen σ^2 , dvs

$$E(X_i) = \mu \quad \text{och} \quad V(X_i) = \sigma^2 \quad \text{för alla} \quad i = 1, \dots, n.$$

- ▶ Syftet är att skatta de okända parametrar μ och σ^2 med hjälp av x_1, \dots, x_n .
- ▶ Vi använder *stickprovsmedelvärde* och *stickprovsvarians*

$$\mu_{obs.}^* = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad (\sigma^2)_{obs.}^* = s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

som är naturliga (intuitiva) skattningar för μ och σ^2 och ofta har bra teoretiska egenskaper.

- ▶ **Sats:** \bar{x} och s^2 är väntevärdesriktiga och konsistenta skattningar för μ resp. σ^2 .



- ▶ Hittills har vi använt intuition för att konstruera skattningar. Det finns mer rationella sätt att ta fram skattningar för parametrar i olika fördelningar. En av dessa är

Maximum likelihood-, ML-metoden: man väljer som skattningen ett värde, sådant att sannolikhet för den givna mätdatan maximeras.

- ▶ **Def.** Funktionen

$$L(\theta) = \begin{cases} p_{X_1, \dots, X_n}(x_1, \dots, x_n; \theta) & \text{diskreta fallet} \\ f_{X_1, \dots, X_n}(x_1, \dots, x_n; \theta) & \text{kontinuerliga fallet} \end{cases}$$

kallas för *likekihood-funktionen* (förf. *L*-funktionen).

- ▶ *Tolkning av ML-metoden:* I *L*-funktionen låter man argumentet θ variera inom Ω_θ och ser efter för vilket värde på argumentet $L(\theta)$ maximeras. Detta värde tas som ML-skattning av parametern θ .




- ▶ **Def.** Det värde θ_{obs}^* , för vilket $L(\theta)$ antar sitt största värde inom Ω_θ kallas för maximum-likelihood-skattningen (ML-skattningen) av θ .
- ▶ Om x_1, \dots, x_n är utfall av oberoende, *likaförelade* s.v. X_1, \dots, X_n så får vi

$$L(\theta) = \begin{cases} \prod_{i=1}^n p_X(x_i; \theta) & \text{diskr. fallet} \\ \prod_{i=1}^n f_X(x_i; \theta) & \text{kont. fallet} \end{cases}$$

- ▶ Produktformen av $L(\theta)$ gör att maximeringen kan bli besvärlig. Det är lämpligt att i stället maximera $\ln L(\theta)$, *log-likelihood-funktion*, som ger en summa och maximeringen förenklas. Logaritmen är en monotont växande funktion, så $L(\theta)$ och $\ln L(\theta)$ antar maximum i samma punkt.
- ▶ Ex på tavla!

MAXIMUM-LIKELIHOOD-METODEN (FORTS.)



FIGUR: Plot av log-likelihood-funktionen för Ex om opinionsundersökning.