

# MNOŽICE ZAUPANJA, NAPOVEDNE MNOŽICE

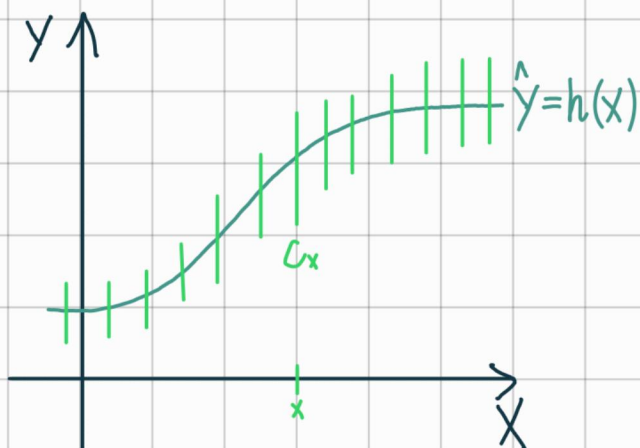
Spet: Opazimo  $X$ , zanimiva nas  $Y$ .

Želimo sklepati  $Y_{\min} < Y < Y_{\max}$ .  
 $\parallel$   $\parallel$   
 $h_{\min}(x)$   $h_{\max}(x)$

Če je  $Y = y = q(\theta)$  deterministična količina, temu pravimo interval zaupanja, sicer pa je to napovedni model.


$$\forall \theta \in \Theta: P_{\theta}(Y_{\min} < Y < Y_{\max}) \geq 1 - \alpha$$

Splošneje lahko sklepamo, da je  $Y \in C_x$ , kjer je  $C_x, x \in \dots$ , nabor nekih množic.



Ideje za konstrukcijo:

1) Celovit pogled:



$$C = \{(x, y) ; y \in C_x\}$$

$$P_{\theta}((X, Y) \in C) \geq 1 - \alpha$$

$\Downarrow$   
 $\approx$   
 $\rightarrow$

2) Mera razhajanja:

$\rho(x, y)$  ... mera razhajanja

$$C = \{(x, y) ; \rho(x, y) < c_{\alpha}\}$$

Če imamo srečo, če  $\rho$  pivotna funkcija, kar pomeni, da se porazdelitev slučajne spremenljivke  $\rho(X, Y)$  ne spreminja s  $\theta$ .


Tedaj lahko  $c_{\alpha}$  dobimo kot minimalni  $c$ , za katerega je  $P_{\theta}(\rho(X, Y) \leq c) \geq 1 - \alpha$ .

Tedaj je tudi  $P_{\theta}(\rho(X, Y) \leq c_{\alpha}) \geq 1 - \alpha$ , čisto pa tudi  $P_{\theta}(\rho(X, Y) < c_{\alpha}) \geq 1 - \alpha$ .

3) Uporaba točkovnih napovedi/cenilk:

$$\rho(x, y) = |h(x) - y|$$

Kjer je  $\hat{y} = h(x)$  napoved za  $Y$ .



Splošneje lahko vzamemo  $\rho(x, y) = d(h(x), y)$ .

Ponovimo standardni primer:

Opazimo  $X_1, X_2, \dots, X_n \sim N(\mu, \sigma^2)$  neodvisne.

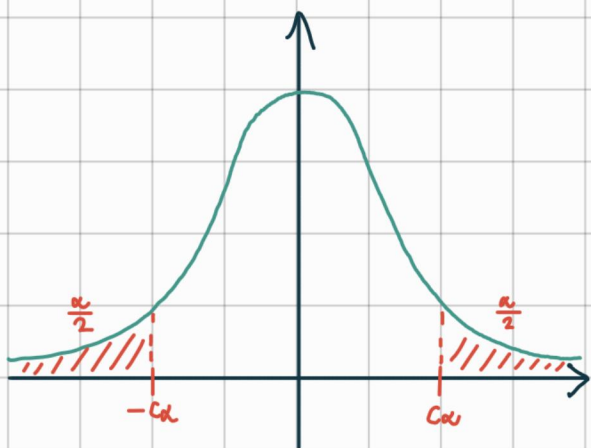
Recimo, da poznamo  $\sigma$  in ocenjujemo  $\mu$ .

Za oceno  $\hat{\mu} = \bar{X}$  dobimo:

$$\rho((x_1, x_2, \dots, x_n), \mu) = \left| \frac{x_1 + x_2 + \dots + x_n}{n} - \mu \right|$$

To je pivotna funkcija, ker je  $\rho((X_1, X_2, \dots, X_n), \mu) = |\bar{X} - \mu|$  in  $\bar{X} - \mu \sim N(0, \frac{\sigma^2}{n})$ , ne glede na  $\mu = \theta$ .

$$c_\alpha := \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \frac{\sigma}{\sqrt{n}}$$



$$\bar{X} - c_\alpha < \mu < \bar{X} + c_\alpha$$

Napovedni interval za  $X_{n+1} \sim N(\mu, \sigma^2)$ , neodvisne od  $X_1, X_2, \dots, X_n$ :

$$\left. \begin{array}{l} \bar{X} - \mu \sim N\left(0, \frac{\sigma^2}{n}\right) \\ X_{n+1} - \mu \sim N(0, \sigma^2) \end{array} \right\} \text{neodvisni}$$

$$\Rightarrow X_{n+1} - \bar{X} \sim N(0, (1 + \frac{1}{n})\sigma^2)$$

Torej je napovedni interval:

$$\bar{X} - c_{\alpha}^{\text{nap}} < X_{n+1} < \bar{X} + c_{\alpha}^{\text{nap}}$$

$$c_{\alpha}^{\text{nap}} = \Phi^{-1}(1 - \frac{\alpha}{2}) \sigma \sqrt{1 + \frac{1}{n}}$$

Kaj pa, če  $\sigma$  ne poznamo?

Iz primera 7.14 vemo, da je  $\frac{\bar{X} - \mu}{\hat{\sigma}_+} \sqrt{n} \sim \text{Student}(n-1)$ , ne glede na  $\mu$  in  $\sigma$ .

Interval zaupanja bo zdaj spet  $\bar{X} - c_{\alpha} < \mu < \bar{X} + c_{\alpha}$ , kjer pa bo:

$$c_{\alpha} = F_{\text{Student}(n-1)}^{-1}(1 - \frac{\alpha}{2}) \frac{\hat{\sigma}_+}{\sqrt{n}}$$

Podobno dobimo tudi napovedni interval, kjer je:

$$c_{\alpha}^{\text{nap}} := F_{\text{Student}(n-1)}^{-1}(1 - \frac{\alpha}{2}) \hat{\sigma}_+ \sqrt{1 + \frac{1}{n}}$$

#### 4) Uporaba verjetja:

Deluje le za  $Y = y = g(\theta)$ , torej za količine, ki jih ne modeliramo kot slučajne.

Deluje dobro za veliko neodvisnih in enako porazdeljenih vrednosti.

Za verjetje sicer ni nujno, da so opažanja NEP, če pa imamo NEP, pa verjetje še toliko bolj pomaga.

Spomnimo se izreka 6.4:

Za cenilko  $\hat{Y}$  po metodi največjega verjetja velja  $MSE_{\theta}(\hat{Y}|y) \sim \frac{\nabla g(\theta)^T (F_1(\theta))^{-1} \nabla g(\theta)}{n}$ .

Torej, več kot imamo informacij, manjša je napaka.

Izrek 8.1: Naj bo  $\hat{\theta}$  cenilka za  $\theta^* \in \Theta \subseteq \mathbb{R}^n$  po metodi največjega verjetja na podlagi neodvisnih in enako porazdeljenih opažanj  $X_1, \dots, X_n$  (kjer je nedvoumno definirana, sicer pa poljubna).

Naj bo  $\theta^* \in \Theta$  in  $F_1(\theta^*)$  obrnljiva. Tedaj pod podobnimi dodatnimi pogoji kot za izrek 6.4 velja:

$$\sqrt{n}(\hat{\theta} - \theta^*) \xrightarrow[n \rightarrow \infty]{d, P_{\theta^*}} N(0, (F_1(\theta^*))^{-1})$$

Nadalje, naj bo še  $g: \Theta \rightarrow \mathbb{R}$  dovolj gladka funkcija ter  $y^* = g(\theta^*)$  in  $\hat{y} = g(\hat{\theta})$ . Če definiramo:

$$RMSE^* := \left( \frac{(\nabla g(\theta^*))^T (F_1(\theta^*))^{-1} \nabla g(\theta^*)}{n} \right)^{1/2}$$

$$\hat{RMSE} := \left( \frac{(\nabla g(\hat{\theta}))^T (F_1(\hat{\theta}))^{-1} \nabla g(\hat{\theta})}{n} \right)^{1/2}$$

Velja še:

$$\frac{\hat{y} - y^*}{RMSE^*} \xrightarrow[n \rightarrow \infty]{d, P_{\theta^*}} N(0, 1)$$

$$\frac{\hat{y} - y^*}{\hat{RMSE}} \xrightarrow[n \rightarrow \infty]{d, P_{\theta^*}} N(0, 1)$$

Če je torej  $\hat{y} = g(\hat{\theta}) = h(x_1, \dots, x_n)$  in  $\hat{RMSE} = s(x_1, \dots, x_n)$ , potem je  $\rho(x_1, \dots, x_n; y) = \frac{h(x_1, \dots, x_n) - y}{s(x_1, \dots, x_n)}$  asimptotično prista funkcija.

Dokaz (ideje):

$$\nabla l(\theta | x_1, \dots, x_n) \stackrel{NEP}{=} \sum_{i=1}^n \nabla l_1(\theta | x_i)$$

Uporabimo večrazsežni CLT za vsoto  $\sum_{i=1}^n \nabla l_1(\theta | x_i)$ .

Cenilka  $\hat{Y}$  je približno linearna funkcija vsote  $\sum_{i=1}^n \nabla l_1(\theta^* | x_i)$ .

Uporabimo izrek o konvergenci slučajnih spremenljivk (trditev 2.21) in izrek Slutkega za deljenje (trditev 2.28).

⇒ Dobimo asimptotično eksakten interval zaupanja:

$$\hat{y} - \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \hat{RMSE} < Y < \hat{y} + \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \hat{RMSE} \in O\left(\frac{1}{\sqrt{n}}\right)$$

## PREIZKUŠANJE DOMNEV, TESTIRANJE HIPOTEZ

Včasih imamo o  $\theta$  kakšno "idejo". Imenujemo jo ničelna domneva oziroma hipoteza in jo označujemo s  $H_0$ .

Primer: "Kovanec je pošten"

$$\theta = P(\text{pade glava}) \in [0, 1]$$

$$H_0: \theta = \frac{1}{2}$$

$H_0$  je v splošnem  $\theta \in \Theta_0 \subseteq \Theta$ .

Negaciji ničelne domneve  $H_0$  pravimo alternativna domneva ali hipoteza in jo označimo s  $H_1$ .

Če je opažanje preveč neskladno s  $H_0$ , to domnevo zavrnilo in sprejmemo  $H_1$ . Če pa opažanje ni neskladno, pa ne rečemo nič.

Torej do zmote po definiciji pride samo, če  $H_0$  zavrnilo, čeprav velja.

Zato želimo  $H_0$  zavrniti v čim več primerih, ko ne drži (in hkrati v čim manj primerih, ko ne drži).

Moč preizkusa je funkcija:

$$\begin{aligned} \Theta \setminus \Theta_0 &\longrightarrow [0, 1] \\ \theta &\longmapsto P_\theta(H_0 \text{ zavrnemo}) \end{aligned}$$

Za  $\theta \in \Theta_0$  pa zahtevamo:

$$P_\theta(H_0 \text{ zavrnemo}) \square \overset{\text{stopnja tveganja}}{\alpha}$$

Kjer je  $\square$  ena izmed relacij:

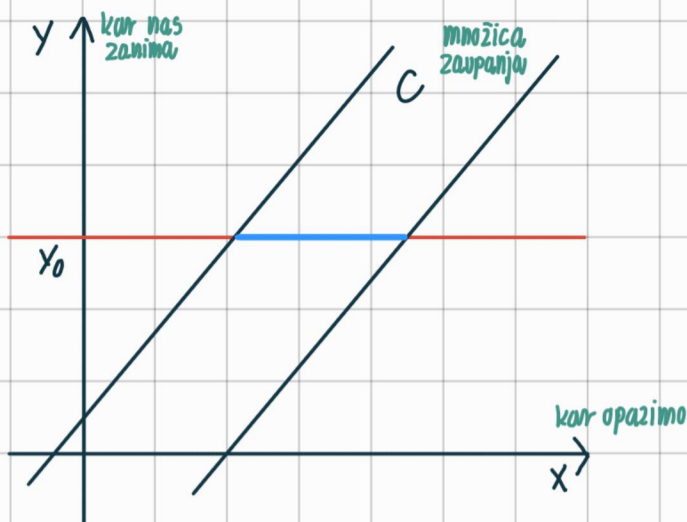
- = (eksakten)
- $\approx$  (aproksimativen)
- $\xrightarrow{n \rightarrow \infty}$  (asimptotičen)
- $\leq$  (konservativen)

$\alpha$  imenujemo stopnja tveganja ali značilnosti preizkusa (significance level).

Zveza z množicami zaupanja:

Vsaka domneva  $\theta \in \Theta_0$  je za primerno karakteristiko  $y = g(\theta)$  ekvivalentna domnevi  $y = y_0$ , na primer  $g(\theta) = 1(\theta \in \Theta_0)$ ,  $y_0 = 1$ .

Opazka 8.2: Nabor preizkusov domnev  $H_0: y = y_0$  za vse možne  $y_0$  je ekvivalenten množici zaupanja za  $Y$ :



Domnevo  $y = y_0$  zavrneemo za  $x$ , ki so izven  $C$ .

$\Rightarrow$  Če imamo nabor preizkusov za  $Y$ , pogledamo navpične preseke s  $C$ .

$$H_0: y = y_0 \text{ zavrneemo} \Leftrightarrow (X, y_0) \notin C \Leftrightarrow y_0 \in C_x$$

$$\Leftrightarrow \rho(X, y_0) \geq C_\alpha$$

$\uparrow$  mera razhajanja
 $\uparrow$  kritična vrednost

Primer: Opazimo  $S \sim \text{Bin}(n, \theta)$ , kjer je  $n$  znan,  $\theta$  pa nas zanima.

$$\hat{\theta} = \frac{s}{n} \quad (\text{delež uspehov})$$

$$\Rightarrow \rho(s, \theta) = \left| \frac{s}{n} - \theta \right|$$

Hočemo, da je to pivotna funkcija, torej da ima stabilno porazdelitev.

$$\frac{s}{n} - \theta = \hat{\theta} - \theta \stackrel{\text{CLT}}{\sim} N\left(0, \frac{\theta(1-\theta)}{n}\right)$$

Ker  $\theta$  tukaj nastopa, to ni pivotna funkcija. Niti blizu temu ni.

Lahko pa  $\theta$  v varianci nadomestimo z oceno  $\hat{\theta}$  in dobimo Waldov interval zaupanja:

$$\hat{\theta} - \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}} < \theta < \hat{\theta} + \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \sqrt{\frac{\hat{\theta}(1-\hat{\theta})}{n}}$$

(Abraham Wald, 1902-1950)

Izkaže se, da je to slab interval, saj nam diskretnost dela težave.

$H_0: \theta = \theta_0$  zavrtnemo proti  $H_1: \theta \neq \theta_0$ , če velja:

$$|\hat{\theta} - \theta_0| \geq \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \sqrt{\frac{\theta(1-\theta)}{n}}$$

Naravnješa in tudi boljša različica preizkusa pa je, da  $H_0: \theta = \theta_0$  zavrtnemo, če velja:

$$|\hat{\theta} - \theta_0| \geq \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \sqrt{\frac{\theta_0(1-\theta_0)}{n}}$$

To vodi v izboljšano množico zaupanja:

$$C = \left\{ (s, \theta) ; \left| \frac{s}{n} - \theta \right| < \underbrace{\Phi^{-1}\left(1 - \frac{\alpha}{2}\right)}_{=: z} \sqrt{\frac{\theta(1-\theta)}{n}} \right\}$$

Pri danem  $s$  oziroma  $\hat{\theta} = \frac{s}{n}$  dobimo:

$$\frac{2n\hat{\theta} + z^2 - \sqrt{4nz^2\hat{\theta}(1-\hat{\theta}) + z^4}}{2(n+z^2)} < \theta < \frac{2n\hat{\theta} + z^2 + \sqrt{4nz^2\hat{\theta}(1-\hat{\theta}) + z^4}}{2(n+z^2)}$$

To je Wilsonov interval zaupanja.

(Edwin Bidwell Wilson, 1879-1964)

Ta interval ima boljšo pokritost.

V splošnem lahko konstrukcijo množice zaupanja za karakteristiko  $y$  izboljšamo tako, da vzamemo:

$$C = \left\{ (x, y) ; \rho(x, y) < C_\alpha(y) \right\}$$

Tukaj ni nujno, da je  $\rho$  pivotna. Dovolj je že, da je porazdelitev  $\rho(X, y)$  pri vsakem  $\theta$  natanko določena z  $y = g(\theta)$ .

Včasih nas skrbijo odstopanja le v eno smer:

$H_0: y = y_0$  preizkušamo proti  $H_1^+: y > y_0$  ali  $H_1^-: y < y_0$ .

Primer: Loterija trdi, da vsaka druga srečka zadane.

Opazimo  $S \sim \text{Bin}(n, \theta)$ . Postavimo  $\theta_0 = \frac{1}{2}$  in dobimo  $H_0: \theta = \theta_0$   
in  $H_1^-: \theta < \theta_0$ .


Če je  $n$  dovolj velik, pri  $H_0$  velja  $S \sim N(n\theta_0, \sqrt{n\theta_0(1-\theta_0)})$ .

$$\hat{\theta} = \frac{S}{n} \sim N\left(\theta_0, \sqrt{\frac{\theta_0(1-\theta_0)}{n}}\right)$$


$$\Rightarrow \frac{\hat{\theta} - \theta_0}{\sqrt{\frac{\theta_0(1-\theta_0)}{n}}} \sim N(0, 1)$$

$$\Rightarrow H_0 \text{ zavrnamo, če je } \frac{\hat{\theta} - \theta_0}{\sqrt{\frac{\theta_0(1-\theta_0)}{n}}} \leq -\Phi^{-1}(1-\alpha) = \Phi^{-1}(\alpha).$$

Enostransko območje zavrnitve:



Dvostransko območje zavrnitve:



## PREIZKUŠANJE Z RAZMERJEM VERJETIJ

$$LR = \frac{\sup_{\theta \in \Theta_1} L(\theta|X)}{\sup_{\theta \in \Theta_0} L(\theta|X)} \quad (\text{likelihood ratio})$$

$H_0: \theta \in \Theta_0$  zavrnamo, če je  $LR \geq c_\alpha$ .

Prag  $c_\alpha$  določimo skladno s stopnjo tveganja  $\alpha$ .

(Samuel Stanley Wilks, 1906-1964)

Izrek 8.3 (Wilksov izrek):

Naj bodo  $X_1, X_2, \dots$  pri vsaki verjetnostni meri  $P_\theta, \theta \in \Theta$ , neodvisne in enako porazdeljene slučajne spremenljivke,  $\Theta$  naj bo gladka mnogoterost dimenzije  $p$ ,  $\Theta_0 \subseteq \Theta$  pa podmnogoterost dimenzije  $q$ . Obe naj bosta brez roba. Pod določenimi dodatnimi pogoji gre tedaj  $2 \ln LR \xrightarrow{n \rightarrow \infty} \chi^2(p-q)$  pri vseh  $P_\theta, \theta \in \Theta_0$ .

Dokaz opustimo.

Wilksov preizkus:

$H_0: \theta \in \Theta_0$  zavrnemo, če je  $2 \ln LR \geq F_{\chi^2(p-q)}^{-1}(1-\alpha)$ .

Primer:  $P_\theta = \begin{pmatrix} a_0 & a_1 & \dots & a_p \\ \theta_0 & \theta_1 & \dots & \theta_p \end{pmatrix}$

$\underline{\theta} = (\theta_0, \theta_1, \dots, \theta_p)$

$\Theta = \{ \underline{\theta} \in \mathbb{R}^{p+1} ; \theta_0, \theta_1, \dots, \theta_p > 0, \sum_{j=1}^p \theta_j = 1 \}$

Za fiksne  $\pi_0, \pi_1, \dots, \pi_p$  preizkusimo:

$H_0: \theta_0 = \pi_0, \theta_1 = \pi_1, \dots, \theta_p = \pi_p$

Opazimo:

$$\underbrace{X_1, X_2, \dots, X_p}_{\text{nezavisne}} \sim \begin{pmatrix} a_0 & a_1 & \dots & a_p \\ \theta_0 & \theta_1 & \dots & \theta_p \end{pmatrix}$$

$$\ln LR = \sup_{\theta \in \Theta} \sum_{i=1}^n \ell_1(\theta | X_i) - \sup_{\theta \in \Theta_0} \sum_{i=1}^n \ell_1(\theta | X_i)$$

$$\ell_1(\theta | x) = \begin{cases} \ln \theta_0 & ; x = a_0 \\ \ln \theta_1 & ; x = a_1 \\ \vdots & \\ \ln \theta_p & ; x = a_p \end{cases}$$

$$= \sum_{j=0}^p \ln \theta_j \cdot 1(x = a_j)$$

$$\begin{aligned} \ell(\theta_0, \theta_1, \dots, \theta_p | X_1, X_2, \dots, X_n) &= \sum_{i=1}^n \sum_{j=0}^p \ln \theta_j \cdot 1(X_i = a_j) \\ &= \sum_{j=0}^p \ln \theta_j \underbrace{\sum_{i=1}^n 1(X_i = a_j)}_{N_j - \text{frekvencija vrednosti } a_j} \end{aligned}$$

$$\text{Lagrange: } F = \sum_{j=0}^p N_j \ln \theta_j - \lambda \sum_{j=0}^p \theta_j$$

$$\frac{\partial F}{\partial \theta_j} = \frac{N_j}{\theta_j} - \lambda = 0$$

$$\hat{\theta}_j = \frac{N_j}{\lambda}$$

$$\sum_{j=0}^p \hat{\theta}_j = 1 \Rightarrow \lambda = \sum_{j=0}^p N_j = n$$

$$\sup_{\theta \in \Theta} \ell(\theta_0, \theta_1, \dots, \theta_p | X_1, X_2, \dots, X_n) = \sum_{j=0}^p N_j \ln \hat{\theta}_j$$

$$\sup_{\theta \in \Theta_0} \ell(\theta_0, \theta_1, \dots, \theta_p | X_1, X_2, \dots, X_n) = \sum_{j=0}^p N_j \ln \pi_j$$

$$2 \ln LR = 2 \sum_{j=0}^p N_j \ln \frac{\hat{\theta}_j}{\pi_j} = 2 \sum_{j=0}^p N_j \ln \frac{N_j}{n \pi_j}$$

$\tilde{N}_j = n \pi_j$  so pričakovane frekvence.

Minimalni pogoji za legitimnost:

$$H_j: \tilde{N}_j > 5$$

Tedaj bo porazdelitev  $2 \ln LR$  vsaj približno blizu  $\chi^2(p)$ .

Opazka 8.4: Izkaže se:

$$2 \ln LR \approx \sum_{j=0}^p \frac{(N_j - \tilde{N}_j)^2}{\tilde{N}_j}$$

To je Pearsonov preizkus.

(Karl Pearson, 1857-1936)

