

1. Tyhjentävä tunnusluku (sufficient statistics)

Olkoon $(P(X = x|\theta) : \theta \in \Theta)$ todennäköisyysmalli havainnolle X . Datan funktio $T(X)$ on Tyhjentävä tunnusluku jos ehdollinen todennäköisyys (ehdollinen tiheysfunktio)

$$P(X = x|T(X) = t, \theta) = p(X = x|T(X) = t)$$

ei riipu tuntemattomasta θ :sta

Silloin uskottavuusfunktio faktorisoituu

$$P(X = x|\theta) =$$
$$P(X = x|T(X) = T(x))P(T(X) = T(x)|\theta)$$

Esimerkki: Heitetaan kolikkoa n -kertaa, olkoon $Y_i = \mathbf{1}$ (i -tulos on kruunu). Oletamme että kolikon heitot ovat riippumattomia ja samoin jakautuneita (independent and uniformly distributed, i.i.d), tuntemattomalla kruunun todennäköisyydellä $\theta \in [0, 1]$.

$$P(Y_1, \dots, Y_n | \theta) = \prod_{i=1}^n P(Y_i | \theta) = \prod_{i=1}^n \theta^{Y_i} (1 - \theta)^{(1 - Y_i)} = \theta^{X_n} (1 - \theta)^{n - X_n}$$

jossa $X_n = T(Y_1, \dots, Y_n) = (Y_1 + \dots + Y_n)$ on tyhjentävä tunnusluku.

$$\begin{aligned}
P(X_n = x|\theta) &= \\
&\sum_{y_i \in \{0,1\} : \sum_{i=1}^n y_i = x} P(Y_1 = y_1, \dots, Y_n = y_n | \theta) \\
&= \theta^x (1 - \theta)^{n-x} \#\{y \in \{0, 1\}^n : \sum_{i=1}^n y_i = x\} \\
&= \binom{n}{x} \theta^x (1 - \theta)^{n-x}
\end{aligned}$$

Tyhjentävyydenperiaate Olkoon Y data ja $T(Y)$ tyhjentävä tunnusluku. Olkoon y ja y' havaintojen arvoja joilla $T(y) = T(y')$. Tilastollinen päättely θ :sta datan $\{Y = y\}$ ja $\{Y = y'\}$ perustella johtaa samoihin tuloksiin. Sekä frequentistisessä että Bayeslaisessa ajattelutavassa hyväksytään tyhjentävyyden periaatetta.

Uskottavuuden periaate (Likelihood principle)

Olkoon $X \sim p(x|\theta)$ ja $\tilde{X} \sim \tilde{p}(\tilde{x}|\theta)$, kaksi kokeetta samoilla tuntematomalla parametrilla θ .

Jos joillakin kokeiden tuloksella $\{X = x\}$ ja $\{\tilde{X} = \tilde{x}\}$

$$p(X = x|\theta) = C\tilde{p}(\tilde{X} = \tilde{x}|\theta) \quad \forall \theta$$

jossa $C = C(x, \tilde{x})$ ei riipu θ :sta, silloin kokeiden tulokset $\{X = x\}$ ja $\{\tilde{X} = \tilde{x}\}$ ovat yhtä informatiivisia θ :stä ja johtavat samaan päättelyyn.

Uskottavuusfunktio $\theta \mapsto p(X = x|\theta)$ modulo normalisointivakiota sisältää koko havainnon $\{X = x\}$:n informaatiota tuntemattomasta parametrasta θ .
Esimerkiksi, suurimman uskottavuuden (maximum likelihood, ML) estimaattori noudattaa uskottavuuden periaatetta:

$$\begin{aligned}\hat{\theta}_{ML} &= \arg \max_{\theta} p(X = x|\theta)p(\tilde{X} = \tilde{x}|\theta) \\ &= \arg \max_{\theta} C(x, \tilde{x})p(\tilde{X} = \tilde{x}|\theta) \\ &= \arg \max_{\theta} p(\tilde{X} = \tilde{x}|\theta)\end{aligned}$$

Kuitenkin, kun suurimman uskottavuuteen estimattoriin liitetään frekventistiset luottamusvälit, rikotaan uskottavuuden periaatetta.

Esimerkki

Koe I:

Heitetaan kolikkoa n kertaa, jossa kruunun todennäköisyys on tuntematon parametri $\theta \in [0, 1]$. Olkon satunnaismuuttuja $X_n =$ kruunujen määrä Uskottavuusfunktio on

$$p(X_n = x|\theta) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$

Koe I:

Heitetaan kolikkoa n kertaa, jossa kruunun todennäköisyys on tuntematon parametri $\theta \in [0, 1]$. Olkon satunnaismuuttuja $X_n =$ kruunujen määrä Uskottavuusfunktio on

$$p(X_n = x|\theta) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}$$

Koe II:

heitetaan samaa kolikkoa jolla on edelleen tuntematon todennäköisyys parametri $\theta \in [0, 1]$, niin kauan kun saadan x -kruunuja. Olkoon satunnaismuuttuja

$N_x =$ heittojen määrä . N_x on x -geometristen satunnaismuuttujen muuttujen konvoluutio, negatiivinen binomialinen jakauma. x on otoskoko ja uskottavuusfunktio on

$$\tilde{P}(N_x = n|\theta) = \binom{n-1}{x-1} \theta^x (1 - \theta)^{n-x}$$

Tämä seuraa koska kun $x = 1$, N_1 on geometrisesti jakautunut parametrilla θ ,

$$\tilde{P}(N_1 = n_1 | \theta) = (1 - \theta)^{(n_1-1)} \theta$$

ja kun $N_0 = 0$

$$\begin{aligned} \tilde{P}(N_1 = n_1, N_2 - N_1 = n_2, \dots, N_x - N_{x-1} | \theta) &= \\ \prod_{i=1}^x \tilde{P}(N_i - N_{i-1} = n_i | \theta) &= \\ (1 - \theta)^{(n_1-1)} \theta \times (1 - \theta)^{(n_2-1)} \theta \times (1 - \theta)^{(n_x-1)} \theta &= \\ = (1 - \theta)^{\sum_{i=1}^x (n_i-1)} \theta^{\sum_{i=1}^x n_i} &= \\ (1 - \theta)^{(n-x)} \theta^x & \end{aligned}$$

jossa $n = n_1 + n_2 + \dots + n_x$.

Koska $N_x = \sum_{i=1}^x (N_i - N_{i-1})$,

$$\begin{aligned}\tilde{P}(N_x = n|\theta) &= \\ &\sum_{n_i: \sum_{i=1}^x n_i = n} P(N_1 = n_1, N_2 - N_1 = n_2, \dots, N_x - N_{x-1}|\theta) \\ &(1 - \theta)^{(n-x)} \theta^x \# \left\{ (n_1, \dots, n_x) : \sum_{i=1}^x n_i = n \right\} \\ &= (1 - \theta)^{(n-x)} \theta^x \binom{n-1}{x-1}\end{aligned}$$

Oletetaan että kokeessa I) olemme saaneet $X_n = x$, jossa n on otoskoko, ja kokeessa II) olemme saaneet $N_x = n$ jossa x . Havainnot $\{X_n = x\}$ kokeessa (I) ja $\{N_x = n\}$ kokeessa (II) sisältävät samaa informaatiota θ :sta ja kun noudataan uskottavuus-periaatetta joudutaan samaan päättelyyn.

Tässä tapauksessa Suurimman uskottavuuden estimaattorit ovat (I) : $\hat{\theta}_n = \frac{X_n}{n} = \frac{x}{n}$, ja (II) : $\hat{\theta}_x = \frac{x}{N_x} = \frac{x}{n}$. molemmissa tapauksissa.

Laskemme *ML*-estimattorien varianssija:

$$I) : E_{\theta_0}(X_n) = \theta_0 n, \quad \text{Var}_{\theta_0}(X_n) = \frac{\theta_0(1 - \theta_0)}{n}$$

Asymptottisesti, suurten lukujen laista

$$\hat{\theta}_n = \frac{X_n}{n} \rightarrow \theta_0 \quad \text{kun } n \rightarrow \infty$$

P_{θ_0} -todennäköisyydellä 1, ja
ja keskeisestä raja-arvolauseesta

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathcal{N}(0, \theta_0(1 - \theta_0))$$

jakauman konvergenssin mielessä.

$$II) E_{\theta_0}(N_x) = \frac{x}{\theta_0}, \quad \text{Var}_{\theta_0}(N_x) = x \frac{(1-\theta)}{\theta^2}$$

Suurten lukujen laista seuraa

$$\frac{N_x}{x} \rightarrow \frac{1}{\theta_0} \quad \text{kun } x \rightarrow \infty$$

\tilde{P}_{θ_0} -todennäköisyydellä 1, ja keskeisestä raja-arvolauseesta

$$\sqrt{x} \left(\frac{N_x}{x} - \frac{1}{\theta_0} \right) \xrightarrow{d} \mathcal{N} \left(0, \frac{1-\theta}{\theta^2} \right) \quad \text{kun } x \rightarrow \infty$$

jakauman mielessä.

Palautan mieleen delta-menetelmaa: jos

$$\sqrt{x}(\widehat{\psi}_x - \psi_0) \xrightarrow{d} \mathcal{N}(0, \sigma^2)$$

ja $\psi \mapsto \theta = f(\psi)$ jossa f on sileä, seuraa estimattorille
 $\widehat{\theta}_x := f(\widehat{\psi}_x)$

$$\sqrt{x}(\widehat{\theta}_x - \theta_0) = \sqrt{x}(f(\widehat{\psi}_x) - f(\psi_0)) \xrightarrow{d} \mathcal{N}(0, f'(\psi_0)^2 \sigma^2)$$

jossa $\theta_0 := f(\psi_0)$

Kun $f(x) = 1/x$, Delta menetelmällä seuraa

$$\begin{aligned}\sqrt{x}(f(N_x/x) - f(1/\theta_0)) &= \sqrt{x}(x/N_x - \theta_0) = \\ \sqrt{x}(\hat{\theta}_x - \theta_0) &\xrightarrow{d} \mathcal{N}\left(0, f'(\psi_0)^2 \frac{(1 - \theta_0)}{\theta_0^2}\right) \\ &= \mathcal{N}\left(0, (1 - \theta_0)\theta_0^2\right)\end{aligned}$$

Kun otoskoot n ja x ovat tarpeeksi suuret, saadan frequentistiset α -luottamustason luottamusvälit

Koe I): Kun $X_n = x$, $\hat{\theta}_n = x/n$

$$\theta_0 \sim \hat{\theta}_n \pm q_\alpha \sqrt{\frac{\hat{\theta}_n(1 - \hat{\theta}_n)}{n}}$$

Koe II): Kun $N_x = n$, $\hat{\theta}_x = x/n$

$$\theta_0 \sim \hat{\theta}_n \pm q_\alpha \sqrt{\frac{(1 - \hat{\theta}_x)\hat{\theta}_x^2}{x}}$$

Vaikka suurimman uskottavuuden estimointi on sopusoinnissa uskottavuus periaatteen kanssa, frequentistiset luottamusvälit eivät ole !

Bayesin ratkaisu

Oletamme tasainen prior $p(\theta) = 1$ kun $\theta \in [0, 1]$, $p(\theta) = 0$ muuten

Posteriori jakauma on

Koe I:

$$\begin{aligned} p(\theta|X_n = x) &= \frac{p(X_n = x|\theta)p(\theta)}{\int_0^1 p(X_n = x|\vartheta)p(\vartheta) d\vartheta} \\ &= \frac{\binom{n}{x} \theta^x (1 - \theta)^{n-x}}{\binom{n}{x} \int_0^1 \vartheta^x (1 - \vartheta)^{n-x} d\vartheta} \\ &= \frac{1}{\text{Beta}(x + 1, n - x + 1)} \theta^x (1 - \theta)^{n-x} \end{aligned}$$

jossa

$$\text{Beta}(a, b) := \int_0^1 \vartheta^{a-1} (1 - \vartheta)^{b-1} d\vartheta$$

on Beta funktio. Siis a posteriori ehdolla $X_n = x$ θ on

Koe II:

$$\begin{aligned} p(\theta | N_x = n) &= p(\theta | N_x = n) \\ &= \frac{p(N_x = n | \theta) p(\theta)}{\int_0^1 p(N_x = n | \vartheta) p(\vartheta) d\vartheta} \\ &= \frac{\binom{n-1}{x-1} \theta^x (1 - \theta)^{n-x}}{\binom{n-1}{x-1} \int_0^1 \vartheta^x (1 - \vartheta)^{n-x} d\vartheta} \\ &= \frac{1}{\text{Beta}(x + 1, n - x + 1)} \theta^x (1 - \theta)^{n-x} \end{aligned}$$

on θ :n ehdollinen jakauma ehdolla $N_x = n$.

Koska Bayesin kaavassa käytetään vain uskottavuusfunktion arvo data pisteissä, seuraa että Bayeslainen tilastotiede on sopusoinnissa uskottavuusperiaatteen kanssa.

Yleisemmin, oletetaan että heitetaan kolikkoita tietyn satunnaisen pysähdysstrategia mukaan:

Kokeensunnittelija määrää jonoa pysähdystodennäköisyyksiä $q_k(Y_1, \dots, Y_k) : \{0, 1\}^k \rightarrow [0, 1]$, jossa $k \in \mathbb{N}$. Koska θ on tuntematon koesuunnittelijalle, pysähdystodennäköisyydet eivät riipu parametrasta θ .

Jos koe on jatkanut k -heiton asti, todennäköisyydellä $q_k(Y_1, \dots, Y_k)$ datan kerääminen loppuu siihen. Myös alussa todennäköisyydellä q_0 päätetään kerätäänkö ollenkaan dataa.

Jos data ei kerätä, $N = 0$

Koska θ on tuntematon koesuunnittelijalle määrää pysähdys-todennäköisyydet $q_k(Y_1, \dots, Y_k)$.

Silloin $\text{data} = (N, Y_1, \dots, Y_N)$, jossa N on satunnainen, uskottavuusfunktiolla

$$\begin{aligned} P(N = n, Y_1 = y_1, \dots, Y_n = y_n | \theta) &= q_0 \quad \text{jos } n = 0, \text{ muuten} \\ &= \left\{ (1 - q_0) \left(\prod_{k=1}^{n-1} (1 - q_k(y_1, \dots, y_k)) \right) \times q_n(y_1, \dots, y_n) \right\} \times \\ &\times \left\{ \prod_{i=1}^n \theta^{y_i} (1 - \theta)^{1-y_i} \right\} \\ &= C(n, y_1, \dots, y_n) \theta^{x_n} (1 - \theta)^{n-x_n} \end{aligned}$$

jossa $x_n = y_1 + \dots + y_n$. Huomataan satunnaispari (N, X_N) on tyhjentävä tunnusluku. Kun noudataan uskottavuuden periaatetta tilastollinen päättely riippuu vain kerätystä datasta, eikä datan-keräämisen strategiasta

Edellisessä esimerkissä käytettiin pysähdysstrategiat

$q_k(y_1, \dots, y_k) = \mathbf{1}(k = n)$ ja vastaavasti

$q_k(y_1, \dots, y_k) = \mathbf{1}(y_1 + \dots + y_k = x)$ jossa n , ja vastaavasti x kiinnitettiin. Frekventtiset luottamusvälit ja p -arvot riippuvat ei pelkään kerätystä datasta mutta myös etukäteen sovitusta pysähdysstrategiasta.

Miten jos jostakin syystä joudutaan poikkeamaan etukäteen sovitusta pysähdysstrategiasta ? Silloin uusi pysähdystodennäköisyys on tuntematon, ja ei pysty enää laskemaan ML-estimattorin varianssi, frekventtiset luottamusvälit ja p -arvot.

Lääketieteellisessä tutkimuksessa tämä on aiheuttanut ja aiheuttaa (aivan turhaan, jos hyväksytään uskottavuuden periaattetta) eettisiä kysymyksiä: kun testataan uusia lääkkeitä, ja joudutaan poikeamaan protokollasta joidenkin potilaiden suhteen, koko koetutkimuksen aineisto sattaa tulla frekventisen tilastotieteen näkökulmasta kelvottomaksi, koska p -arvot ei pysty enää laskemaan. Toisaalta, lääkärit ovat velvollisia antamaan yksittäisille potilaille jokaisessa vaiheessa parhasta mahdollista hoitoa protokollan huolimatta.

Delta-menetelmästä

Delta menetelmä perustuu Taylorin kaavaan:

Kun $\hat{\theta}_n \xrightarrow{P_{\theta_0}} \theta_0$ kun $n \uparrow \infty$ $\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} \mathcal{N}(0, \sigma^2)$, jos
funktio f on derivoituva $\hat{f}(\theta_n) \xrightarrow{P_{\theta_0}} f(\theta_0)$

$$\begin{aligned}\sqrt{n}(f(\hat{\theta}_n) - f(\theta_0)) &= \\ f'(\theta_0)\sqrt{n}(\hat{\theta}_n - \theta_0) &+ n^{-1/2} \frac{1}{2} f''(\theta_n^*) (\sqrt{n}(\hat{\theta}_n - \theta_0))^2 \\ &\xrightarrow{d} \mathcal{N}(0, f'(\theta_0)^2 \sigma^2)\end{aligned}$$

Kun $n \uparrow \infty$, $\theta_n^* \xrightarrow{P_{\theta_0}} \theta_0$ ja toisen asteen jäännöstermi suppenee kohti nollaan P_{θ_0} :n mielessä.