

[Vrt. AS, jaksot 2,7]

16. Posteriorijakauma tunnustettu - mitä seuraavaksi?

Posteriorijakauma on täydellinen lausaus epävarmuudelle havainnon jälkeen. Jos se kuuluu johonkin yleisesti tunnettuun parametrisen perheeseen, riittää kertoa jakaumaperheen nimi sekä posteriorin parametrit ko. perheessä (näitä voidaan kutsua hyperparametreiksi jotta ne eivät menisi sekaisin tilastollisen mallin parametri(en) kanssa).

Usein kuitenkin posterioria tahdotaan kuvaila joidenkin tunnuslukujen avulla. Jos g on parametriavaruudessa määritelty funktio, niin $g(\theta)$:n posterioriodotusarvo on

$$E[g(\theta) | \underline{x} = \underline{x}] \quad \left[\begin{array}{l} \text{pedanttisemmin} \\ = \\ E[g(\tilde{\theta}) | \underline{x} = \underline{x}] \end{array} \right]$$

$$= \int g(\theta) p(\theta | \underline{x}) d\theta$$

(integraalin tilalla on summa, jos parametri on diskreetti; integrointijoukko \equiv parametriavaruus; tässä $p(\theta | \underline{x})$ on posteriorijakauman f). Erityisesti parametrin posterioriodotusarvo on

$$E[\theta | \underline{x} = \underline{x}] \quad \left[= E[\tilde{\theta} | \underline{x} = \underline{x}] \right] = \int \theta p(\theta | \underline{x}) d\theta$$

Valinnalla $g(\theta) = \theta^2$ saadaan posteriorijakauman toinen momentti $E[\theta^2 | \underline{x} = \underline{x}]$, ja näistä saadaan posteriorijakauman varianssi eli posteriorivarianssi

$$\text{Var}(\theta | \underline{x} = \underline{x}) \quad \left[= \text{Var}[\tilde{\theta} | \underline{x} = \underline{x}] \right]$$

$$= E[\theta^2 | \underline{x} = \underline{x}] - \{E[\theta | \underline{x} = \underline{x}]\}^2$$

Posteriorijakauman sijaintia kuvaavia tunnuslukuja:

- posterioriodotusarvo (engl. posterior mean, posterior expectation) lienee yleisin
- posteriorimoodia (eli posteriorijakauman moodia) voidaan käyttää silloin, kun posteriorijakauman tiheys on yksikuippuinen. Englanniksi käytetään nimityksiä "posterior mode" tai "maximum a posteriori estimate, MAP estimate."

Normaalijakaumalle odotusarvo = moodi. Muille jakaumille näin ei välttämättä ole:

$$\text{Beta}(\alpha, \beta): \text{odotusarvo} = \frac{\alpha}{\alpha + \beta}; \text{ moodi} = \frac{\alpha - 1}{\alpha + \beta - 2} \quad (\text{kun } \alpha, \beta > 1)$$

$$\text{Gamma}(\alpha, \lambda): \text{odotusarvo} = \frac{\alpha}{\lambda}; \text{ moodi} = \frac{\alpha - 1}{\lambda} \quad (\text{kun } \alpha > 1)$$

Posteriorijakauman hajontaa kuvaillaan useimmiten joko posteriorivarianssilla tai tämän luvun neliöjuurelle eli posteriorikeskihajonnalla.

Bayeslaisessa päätelyssä voidaan laskea myös muotoa

$$P(\theta \in A | \underline{X} = \underline{x}) = P(\tilde{\theta} \in A | \underline{X} = \underline{x}) \\ = \int_A P(\theta | \underline{x}) d\theta$$

olevia todennäköisyyksiä (joita feleventistisen paradigman puitteissa ei saa edes ajatella!). Voidaan suoraan kysyä (posteriori-) todennäköisyyttä sille, että $\theta > \theta_1$ tai $\theta_1 < \theta < \theta_2$. Voidaan myös etsiä posteriorivälejä eli bayeslaisia luottamusvälejä t_α . Etsiä luvut θ_1 ja θ_2 siten, että

$$P(\theta_1 \leq \tilde{\theta} \leq \theta_2 | \underline{X} = \underline{x}) = 1 - \alpha,$$

jossa α on annettu luku, esim. 0.05.

[engl. credible interval, posterior (probability) interval, Bayesian confidence interval, ...]

Tällaisen välin päätepisteet voidaan valita esim., niin, että posteriorijakauman molempiin häntiin jää saman verran todennäköisyysmassaa, eli päätepisteet θ_1 ja θ_2 voidaan määrittää ehdosta

$$P(\theta < \theta_1 | \underline{X} = \underline{x}) = \frac{\alpha}{2} \quad \text{ja} \quad P(\theta > \theta_2 | \underline{X} = \underline{x}) = \frac{\alpha}{2}.$$

Nämä pisteet ovat hyvin määritellyjä, mikäli posteriorijakauma on jatkuva jakauma (mikä on päätelyssä tyypillisin tilanne). Esim. beta-, normaali- tai gammajakaumalle nämä pisteet voidaan laskea sopivalla tietokoneohjelmalla, [Esim. R-tilasto-ohjelmistossa funktioilla $qbeta()$, $qnorm()$, $qgamma()$.]

Varoitus: termi "luottamusväli" (ilman lisämääreitä) on frekventistisen tilastotieteen käsite. Usea tilastotieteen soveltaja ajattelee, että luottamustasolla $(1-\alpha)$ lasketun luottamusväli sisältää parametrin arvon todennäköisyydellä $(1-\alpha)$, mikä on täysin väärä tulkinta; aineistosta lasketun luottamusväli joko sisältää tai ei sisällä parametrin arvoa, mutta jos luottamusvälejä laskettaisiin uusille, samasta tilanteesta keätyille aineistoille, niin suhteellinen osuus niille tistoille, joilla luottamusväli sisältäisi parametrin olisi noin $(1-\alpha)$ [tämä on oikea tulkinta].

Bayesläisen lähestymistavan väliestimaatin oikea tulkinta on sitä vastoin jumi se, että väli sisältää parametrin arvon todennäköisyydellä $(1-\alpha)$, kun todennäköisyyden ymmärretään tarkoittavan ehdollista todennäköisyyttä sen jälkeen, kun aineisto on havaittu.

[AS, jaksot 2.7 s. 38-39]

17. Odotusarvon estimointi Bayes-menetelmällä -
normaalijakautunut otos ja varianssi tunnettu

Käsitellään vielä yksi esimerkki lüttojakaumien perustuvasta päättelystä. Oletamme, että havainnot ja vastaavat satunnaismuuttujat ovat ehdollisesti riippumattomia ehdolla parametri ja että $X_i \sim N(\theta, \sigma^2)$, $i=1, \dots, n$ (ehdolla θ).

Priorijakaumaksi otamme normaalijakauman $N(\mu_0, \sigma_0^2)$. Posteriorijakauman tiheysfunktio on

$$P(\theta | \underline{x}) \propto P(\theta) f_{\underline{X}}(\underline{x} | \theta)$$

$$\left[= \frac{1}{\sqrt{2\pi} \sigma_0} \exp\left(-\frac{1}{2} \frac{(\theta - \mu_0)^2}{\sigma_0^2}\right) \prod_{i=1}^n \frac{1}{\sqrt{2\pi} \sigma} \exp\left(-\frac{1}{2} \frac{(x_i - \theta)^2}{\sigma^2}\right) \right]$$

$$\propto \exp\left(-\frac{1}{2} q(\theta)\right)$$

jossa eksponenttifunktion sisällä oleva θ :n kvadrattinen funktio on

$$q(\theta) = \frac{(\theta - \mu_0)^2}{\sigma_0^2} + \sum_{i=1}^n \frac{(\theta - x_i)^2}{\sigma^2}$$

$$= \theta^2 \left[\frac{1}{\sigma_0^2} + \frac{n}{\sigma^2} \right]$$

$$- 2\theta \left[\frac{\mu_0}{\sigma_0^2} + \frac{1}{\sigma^2} \sum x_i \right] + \kappa_1,$$

jossa κ_1 on θ :n funktiona ajateltuna vakio (se tietenkin riippuu aineistosta sekä vakioista $\mu_0, \sigma_0^2, \sigma^2$). Huomaa, että tästä additiivisesta vakiosta tulee multiplikatiivinen eksponenttifunktion soveltamisen jälkeen, ts.

$$\exp\left(-\frac{1}{2} q(\theta)\right) = \exp\left(-\frac{1}{2} (g(\theta) + \kappa_1)\right)$$

$$= e^{-\frac{1}{2} \kappa_1} \exp\left(-\frac{1}{2} g(\theta)\right) \propto \exp\left(-\frac{1}{2} g(\theta)\right)$$

Toisaalta, normaalijakauman $N(\mu_1, \sigma_1^2)$ tf on, θ in funktiona ilmaistuna

$$\frac{1}{\sqrt{2\pi} \sigma_1} \exp\left(-\frac{1}{2} \frac{(\theta - \mu_1)^2}{\sigma_1^2}\right) \\ \propto \exp\left(-\frac{1}{2} \left[\frac{1}{\sigma_1^2} \theta^2 - 2 \frac{\mu_1}{\sigma_1^2} \theta \right]\right)$$

(jossa jätettiin kirjoittamatta θ :sta riippumaton vakioterimi μ_1^2/σ_1^2 , eksponenttifunktion sisällä).

Kun tätä tulosta verrataan posteriorijakauman esitykseen polynomien $g(\theta)$ avulla, huomataan että posteriorijakauma on normaalijakauma $N(\mu_1, \sigma_1^2)$, jossa

$$\begin{cases} \frac{1}{\sigma_1^2} = \frac{1}{\sigma_0^2} + \frac{n}{\sigma^2} \\ \frac{\mu_1}{\sigma_1^2} = \frac{\mu_0}{\sigma_0^2} + \frac{1}{\sigma^2} \sum_{i=1}^n x_i \end{cases}$$

Tästä lasketaan helposti ensin $\frac{1}{\sigma_1^2}$, sitten σ_1^2 ja lopulta $\mu_1 = \sigma_1^2 \left(\frac{\mu_0}{\sigma_0^2} + \frac{1}{\sigma^2} \sum x_i \right)$.

Huomautus: Bayesläisen tilastotieteen johdoissa kannattaa usein ajatella, että normaalijakauman parametrit ovat odotusarvo μ sekä ns. tarkkuus, joka määrittää varianssin käänteislukuna, $\psi = \frac{1}{\sigma^2}$. Päivityskaava priorijakauman ja uskottavuusfunktion tarkkuusparametreille on yleisin kertainen:

$$\psi_1 = \psi_0 + n\psi \quad \left[\psi_1 = \frac{1}{\sigma_1^2}, \psi_0 = \frac{1}{\sigma_0^2}, \psi = \frac{1}{\sigma^2} \right]$$

Varianssiparametreille saadaan hankalampi kaava -

$$\sigma_1^2 = \frac{1}{\frac{1}{\sigma_0^2} + \frac{n}{\sigma^2}}$$

[Toisin kuin varianssille, tarkkuusparametreille ei ole yhtä yleisesti sorittua merkintää.]

18. Epäaito priori [AS, s. 40-41]

Jos edellisen jaksun tilanteessa annetaan priorijakauman tallekkouden $\gamma_0 = \frac{1}{\sigma_0^2}$ lähestyy nollaa (eli varianssin σ_0^2 lähestyy ääretöntä), niin rajalla posteriorijakaumaksi saadaan

$$N(\bar{x}, \frac{1}{n} \sigma^2) \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

Tämä on siis rajalla saatava θ in posteriorijakauma, kun havainnot on annettu; [frekventistisessä tilastotieteessä keskiarvon otantajakauma $\bar{X} \sim N(\theta, \frac{1}{n} \sigma^2)$, kun $X_1, \dots, X_n \perp \sim N(\theta, \sigma^2)$.]

Samaan tulokseen päädyttäisiin ottamalla (formaalisti) priorijakauman lausekkeeksi $h(\theta) \equiv 1$ ja soveltamalla Bayesin kaava (ts. kertolaskukaavaa). Nyt kuitenkin $\int_{-\infty}^{\infty} h(\theta) d\theta = \infty$

eikä funktio $h(\theta)$ tämän talleia määrää mitään reaaliakselin todennäköisyysjakaumaa.

Varsinkin aikaisemmin suorittien tällaisten epäaitojen priorien (engl. improper prior) käyttöä.

Näihin liittyy se ongelma, että epäaidon priorin avulla lasketun posteriori saattaa joskus olla epäaito (ts. myös sen integraali saattaa olla ääretön), jolloin se ei määrää mitään todennäköisyysjakaumaa.

Mm. tästä syystä epäaitojen priorien käyttö on vähenemässä, eikä niiden käyttöä voi suositella ainakaan vasta-alkajille.

19. disää ennustamisesta

Havainnot: $\underline{X} = (X_1, \dots, X_n)$ (satunnaismuuttujina)
 $\underline{x} = (x_1, \dots, x_n)$ (havaitut arvot)

Tulevaisuudessa tehtävä uusi havainto: X_{n+1} (satunnaismuuttuja). Mitä voimme sanoa X_{n+1} :n jakaumasta havaintojen perusteella?

Bayeslaisessa tilastotieteessä kysymyksellä on yksikäsitteinen ratkaisu: X_{n+1} :n jakauma havaintojen jälkeen on sen ennustejakauma,

$$f_{X_{n+1}}(x_{n+1} | \underline{X} = \underline{x}) = \int f_{\tilde{\theta}, X_{n+1}}(\theta, x_{n+1} | \underline{X} = \underline{x}) d\theta$$
$$= \int \underbrace{f_{\tilde{\theta}}(\theta | \underline{X} = \underline{x})}_{\text{posteriori} \equiv p(\theta | \underline{x})} f_{X_{n+1}}(x_{n+1} | \tilde{\theta} = \theta, \underline{X} = \underline{x}) d\theta$$

Huomaa, että parametrisen arvoon liittyvä epävarmuus otetaan huomioon integroimalla θ pois parametrisen ja uuden havainnon yhteisjakaumasta ehdolla havainnot [näin siirrytään yhteisjakaumasta reuna-jakaumaan!].

Usein oletetaan, että $\underline{X} \perp\!\!\!\perp X_{n+1} | \theta$ eli että uusi havainto ja jo tehdyt havainnot ovat ehdollisesti riippumattomia. Tällöin

$f_{X_{n+1}}(x_{n+1} | \tilde{\theta} = \theta, \underline{X} = \underline{x}) = f_{X_{n+1}}(x_{n+1} | \tilde{\theta} = \theta)$,
ja viimeinen jakauma on tunnettu tehtävän spesifikaation perusteella.

Jos $X_{n+1} \perp\!\!\!\perp \underline{X} \mid \theta$, niin on siis

$$f_{X_{n+1}}(x_{n+1} \mid \underline{X} = \underline{x}) = \int p(\theta \mid \underline{x}) f_{X_{n+1}}(x_{n+1} \mid \theta) d\theta.$$

Tämän integraalin voi usein laskea liittäjakaumien tilanteessa. Ennustejakauman momentteja voi usein laskea helposti seuraavalla periaatteella.

Ennustejakauman odotusarvo eli ehdollinen odotusarvo $E[X_{n+1} \mid \underline{X} = \underline{x}]$ voidaan laskea seuraavalla kaavalla (kun X_{n+1} :llä on diskreetti jakauma ja $X_{n+1} \perp\!\!\!\perp \underline{X} \mid \theta$):

$$\begin{aligned} E[X_{n+1} \mid \underline{X} = \underline{x}] &= \sum_{x_{n+1}} x_{n+1} f_{X_{n+1}}(x_{n+1} \mid \underline{X} = \underline{x}) \\ &= \sum_{x_{n+1}} x_{n+1} \int p(\theta \mid \underline{x}) f_{X_{n+1}}(x_{n+1} \mid \theta) d\theta \\ &= \int p(\theta \mid \underline{x}) \underbrace{\sum_{x_{n+1}} x_{n+1} f_{X_{n+1}}(x_{n+1} \mid \theta)}_{E[X_{n+1} \mid \theta]} d\theta \end{aligned}$$

(tunnetaan
käytännössä)

(Tässä pitää jotenkin pystyä perustelevaan summauksen ja integroinnin järjestyksen vaihto, mutta emme jää nyt pohtimaan tätä asiaa.)

Korkeampia momentteja saadaan laskettua samalla tavalla, esim.

$$E[X_{n+1}^2 \mid \underline{X} = \underline{x}] = \int p(\theta \mid \underline{x}) \underbrace{E[X_{n+1}^2 \mid \theta]}_{\text{tyypillisesti tunnetaan}} d\theta$$

jolloin ennustejakauman varianssi saadaan selville (mikäli integraalit saadaan laskettua), sillä

$$\text{Var}(X_{n+1} \mid \underline{X} = \underline{x}) = E[X_{n+1}^2 \mid \underline{X} = \underline{x}] - \{E[X_{n+1} \mid \underline{X} = \underline{x}]\}^2$$

20. Bayes - päättelyn laskentaa

liittoperheillä bayesläinen päättely onnistuu tietyyn rajaan asti, mutta jos jotakin mallissa muutetaan, niin tyypillisesti liitto-ominaisuus katoaa.

Nykyään Bayes - päättelyn laskentamenetelmät perustuvat tyypillisesti satunnaisuuden simulointiin tietokoneella eli ns. Monte Carlo -menetelmien käyttöön. Ne perustuvat sille ajatukselle, että koska posteriorijakauma on todennäköisyysjakauma, niin sitä voidaan (yrittää) simuloida, eli tietokoneella voidaan laskea arvoja t_1, t_2, \dots, t_N (N voi olla hyvin suuri), joita voidaan käytännössä pitää sellaisten satunnaismuuttujien $\tilde{\theta}_1, \tilde{\theta}_2, \dots, \tilde{\theta}_N$ havaittuina arvoina, joista kukin on jakauman posteriorijakauman mukaisesti. Tällaisia simulointimenetelmiä käsitellään esim. Laskennallisen tilastotieteen kursilla. Tämän jälkeen otosta t_1, \dots, t_N käsitellään data-analyysin keinoilla: esim. posteriori odotusarvoja voidaan arvioida kaavoilla

$$E[\tilde{\theta} | \underline{x} = \underline{x}] \approx \frac{1}{N} \sum_{i=1}^N t_i$$

$$E[g(\tilde{\theta}) | \underline{x} = \underline{x}] \approx \frac{1}{N} \sum_{i=1}^N g(t_i),$$

posteriorijakauman tiheysfunktioita voidaan arvioida histogrammin tai kehittyneempien tiheysfunktion estimointimenetelmien avulla jne. Tällaiset menetelmät ovat suhteellisen uusia, ja niiden ansiosta voidaan käsitellä lähes mielivaltaisen monimutkaisia bayesläisiä tilastollisia malleja.