

Resepti (Posteriorijakauman johtaminen
liitto- eli konjugaattiperheen tapauksessa.)

Ainekset: Priorijakauma ja uskottavuusfunktio

Ohjeet: 1) Kirjoita "priori x uskottavuus"

käyttämällä johdonmukaisia merkinlöjiä:
priorijakauman esitys pitää kirjoittaa saman
muuttujan (esim. θ) funktiona, jota käytetään
parametreille uskottavuusfunktiossa.

2) Kehitä saamaasi lauseketta muuttujan
 θ funktiona varamuunnosmerkinlöjien
avulla. Voit jättää pois termit, jotka eivät
riipu muuttujasta θ .













3) Tunnistaa lopputuloksesta posteriorijakauman
muoto (mistä parametrisesta perheestä se
tulee ja mitkä ovat ko. perheen parametrit).

4) Jos et tunnistanut jakaumaa, voi olla että
kyseessä ei ole liittojakaumadilanne, joten yritä
leikkiä jokin muu lähestymistapa.

Usein esiintyviä liittopriorita:

- beta-jakauma todennäköisyysparametreille
(binomiuskottavuus; geometrisesta jakaumasta
tai negatiivisesta binomijakaumasta saatuva
uskottavuusfunktio)
- gammajakauma positiivisille parametreille
(Poissonin jakauma (HT); eksponenttijakauma
ym.)
- normaali-jakauma (joissakin eikoistapauksissa)

Gammajakauman tiheysfunktioita eri parametrien arvoille. Tapaus $\alpha=1$ on eksponenttijakauma. Tiheysfunktioilla on moodi pisteessä $(\alpha-1)/\lambda$, mikäli $\alpha > 1$. Jakauman odotusarvo on α/λ ja varianssi on α/λ^2 .



Gamma-jakauma on jatkuva jakauma, jonka tiheysfunktio on muotoa

$$f(x) \propto x^{\alpha-1} e^{-\lambda x}, \quad x > 0,$$

missä $\alpha > 0$ ja $\lambda > 0$ ovat jakaumaperheen parametrit. Normalisointivakiolla Γ on

$$f(x) = \begin{cases} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}, & \text{kun } x > 0 \\ 0 & \text{muuten} \end{cases}$$

Yleisemmälle yhtä yleinen parametrointi:
 α ja $\beta = 1/\lambda$.

Esimerkki: eksponenttijakautuneet havainnot ja gammapriori. Olkoot $X_1, \dots, X_n \sim \text{Exp}(\theta)$ riippumattomasti, ehdolla θ , ja priori olkoon $\text{Gamma}(\alpha, \lambda)$ [α ja λ vakioita]. Tällöin posteriori $P(\theta | \underline{x})$ on

$$P(\theta | \underline{x}) \propto \underbrace{P(\theta)}_{\text{priori}} \underbrace{f_{\underline{x}}(\underline{x} | \theta)}_{\text{uskoettavuusfunktio}}$$

$$\propto \underbrace{\theta^{\alpha-1} e^{-\lambda \theta}}_{\substack{\text{muuttujan } \theta \\ \text{funktion;} \\ \text{jätettiin vakio pois}}} \prod_{i=1}^n \underbrace{\theta e^{-\theta x_i}}_{\substack{\text{parametriin } \theta; \\ x_i \text{ havaittu arvo on } x_i}}$$

$$\propto \theta^{\alpha+n-1} \exp\left(-\theta\left(\lambda + \sum_{i=1}^n x_i\right)\right), \quad \theta > 0$$

Täten \Rightarrow posteriorijakauma on $\text{Gamma}\left(\alpha+n, \lambda + \sum_{i=1}^n x_i\right)$

[Vrt. AS, jaksot 2,7]

16. Posteriorijakauma tunnistettua - mitä seuraavaksi?

Posteriorijakauma on täydellinen lausaus epävarmuudelle havainnon jälkeen. Jos se kuuluu johonkin yleisesti tunnettuun parametrisen perheeseen, mittää kertoa jakaumaperheen nimi sekä posteriorin parametrit ko. perheessä (näitä voidaan kutsua hyperparametreiksi jotta ne eivät menisi sekaisin tilastollisen mallin parametreien 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 parametri-avaruus; tässä $p(\theta | \underline{x})$ on posteriorijakauman f). Erityisesti parametriin 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 yksihuippuinen. Englanniksi käytetään nimityksiä "posterior mode" tai "maximum a posteriori estimate, MAP estimate."

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

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

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

Posteriorijakauman määrittäminen kuvaillessa useimmissa joko posteriorivarianssilla tai tämän kuvan neliöjunnelle 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 frekventistisen 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 ts. 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 häntään 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-tilastus-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 kerätyille aineistoille, niin suhteellisen osuus niille toistoille, joilla luottamusväli sisältää parametrin olisi noin $(1-\alpha)$ [tämä on oikea tulkinta].

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

[AS, jaksso 2.7 s. 38-39]

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

Käsittellään vielä yksi esimerkki lüttöjakaumien perustuvasta päättelystä. Oletamme, että havaintoja 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 :in 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 vakio-termi μ_1^2/σ_1^2 , eksponenttifunktion sisällä).

Kun tätä tulosta verrataan posteriorijakauman esitykseen polynomien $q(\theta)$ 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 sovittua merkintää.]

18. Epäaito priori [AS, s. 40-41]

Jos edellisen jaksun tilanteessa annetaan priorijakauman tallekuvuden $\gamma_0 = \frac{1}{\sigma_0^2}$ lähestyäkseen nollassa (eli varianssin σ_0^2 lähestyäkseen 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; [frequentistisessä tilastotieteessä keskiarvon otantajakauma $\bar{x} \sim N(\theta, \frac{1}{n} \sigma^2)$, kun $x_1, \dots, x_n \perp \perp \sim N(\theta, \sigma^2)$.]

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 talle määrää mitään reaaliakselin todennäköisyysjakaumaa.

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

Näihin liittyy se ongelma, että epäaidon priorin avulla laskettu 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?

Bayesläisessä tilastotieteessä kyseymyksellä 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 parametris arvoon liittyvä
 epävarmuus otetaan huomioon integroimalla θ
 pois parametris 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 $X_{n+1} \perp\!\!\!\perp \underline{X} \mid \theta$):

$$E[X_{n+1} \mid \underline{X} = \underline{x}] = \sum_{x_{n+1}} x_{n+1} f_{X_{n+1}}(x_{n+1} \mid \underline{X} = \underline{x})$$

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

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

$E[X_{n+1} \mid \theta]$ (tunnetaan käytännössä)

(Tässä pitää jotenkin pystyä perustelemaan summankäsen ja integraalin järjestyksen vaihto, mutta emme jää nyt pohtimaan tätä asiaa.)

Korkeampia momentteja saadaan lasketta 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 lasketta), 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

liitto-perheillä bayesläinen päättely onnistuu tiettyyn 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 satunnaisuusmuuttujien $\tilde{\theta}_1, \tilde{\theta}_2, \dots, \tilde{\theta}_N$ havaittuina arvoina, joista kukin on jakauman posteriorijakauman mukaisesti. Tällaisia simulointimenetelmiä käsitellään esim. Laskennallisen tilastotieteen kursseilla. Tämän jälkeen otosta t_1, \dots, t_N käsitellään data-analyysin keinoilla: esim. posterioriodotusarvoja 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 histogrammien tai kehittyneempien tiheysfunktion estimointimenetelmien avulla jne. Tällaiset menetelmät ovat suhteellisen uusia, ja niiden ansiosta voidaan käsitellä lähes mielivaltaisen monimutkaisia bayesläisiä tilastollisia malleja.