

8. Todennäköisyyslaskentaa

Emmen bayesläisen päättelyn käsittelyä
kertaamme ehdolliseen todennäköisyyteen
liittyviä kalkyyliä. [AS, jaksot 1.4;
TNI, jaksot 1.7 ja 1.10] [ASE Arjas-Sirén]
[TNI ≡ P. Tuominen: Todennäköisyyslaskenta I]

Olkoot A ja B tapahtumia. Oletetaan, että
 $P(B) > 0$ ja että tiedämme, että B on sattunut
(mutta emme tiedä mitään muuta). Miten tällöin
pitää määritellä A:n tn? Vastaus: pitää
laskea A:n todennäköisyys ehdolla B, eli

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

[TNI, määr. 1.7.1]

Olkoot $P(A) > 0$ ja $P(B) > 0$. Ehdollisen tn:n
määritelmästä saadaan (todennäköisyyksien)
kerrolaskukaava eli ketjusääntö:

$$P(A \cap B) = P(B) P(A|B) = P(A) P(B|A)$$

Tästä voidaan ratkaista toimen ehdollisista
todennäköisyyksistä, $P(B|A)$, jos $P(A|B)$,
 $P(A)$ ja $P(B)$ tunnetaan:

$$P(B|A) = \frac{P(B) P(A|B)}{P(A)}$$


Olkoon B_1, B_2, \dots, B_M jokin perusjoukon Ω ("varman tapahtuman") ositus ts.

- joukot B_i ovat pistevieraita
- niiden yhdiste $\bigcup_{j=1}^M B_j = \Omega$

Oletetaan, että tunnetaan

- tr:t $P(B_k)$, $k=1, \dots, M$
- ehdolliset tr:t $P(A|B_k)$, $k=1, \dots, M$

Havaitaan, että tapahtuma A sattuu. Miten lasketaan tämän tiedon valossa tapahtumien B_k todennäköisyydet $P(B_k|A)$?



Ratkaisu:

$$P(B_k|A) = \frac{P(B_k \cap A)}{P(A)} = \frac{P(B_k) P(A|B_k)}{P(A)}$$

Miten lasketaan $P(A)$? Ratkaisu:

A voidaan osittaa pistevieraisiin paloihin $A \cap B_i$, $i=1, \dots, M$, joten (todennäköisyyden additiivisuus:)

$$\begin{aligned} P(A) &= P(A \cap B_1) + \dots + P(A \cap B_M) \\ &= P(B_1) P(A|B_1) + \dots + P(B_M) P(A|B_M) \end{aligned}$$

Tämä on kokonais-todennäköisyyden kaava.

Nyt saadaan Bayesin kaava:

$$P(B_k|A) = \frac{P(B_k) P(A|B_k)}{\sum_{i=1}^M P(B_i) P(A|B_i)}$$

Laskemista helpottava huomio:

Bayesin kaava voidaan esittää verrannollisuus-
tuloksena

$$P(B_k|A) \propto P(B_k) P(A|B_k) =: q_k$$

Tämä tarkoittaa sitä, että

$$P(B_k|A) = \kappa q_k = \kappa P(B_k) P(A|B_k)$$

jossa $\kappa = 1/P(A)$ on muuttujasta k
riippumaton vakio. Tämä vakio voidaan
määrittää siitä ehdosta, että

$$1 = \sum_k P(B_k|A) = \kappa \sum q_k$$

$$\Rightarrow \frac{1}{\kappa} = \sum q_k = \sum P(B_k) P(A|B_k) = P(A)$$

Miksi sitten on ilmeistä, että $\sum_k P(B_k|A) = 1$?

Vastaus 1: asia näkee Bayesin kaavasta!

Vastaus 2: ehdollinen tn $B \mapsto P(B|A)$ on
todennäköisyysmitta ja (B_k) on Ω :n
ositus, Tn:n additiivisuuden nojalla

$$1 = P(\Omega|A) = \sum_k P(B_k|A).$$

Bayesläisessä tilastotieteessä

- $P(B_k)$, $k=1, \dots, M$ on priori-jakauma
[lat. a priori \equiv ennen (havaintoa)]
- A vasten havaintoa
- $k \mapsto P(A|B_k)$ on uskottavuusfunktio
- $P(B_k|A)$, $k=1, \dots, M$ on posteriori-jakauma
[lat. a posteriori = (havainnon) jälkeen]

Resepti (Priorista ja uskottavuusfunktionista posterioriin; diskreetti tapaus, äärellinen arvovoukko)

Aineleset: Priorijakauma ja uskottavuusfunktio

Ohjeet: 1) Laske luvut q_k kertomalla
priori \times uskottavuus, eli

$$q_k = P(B_k) \cdot P(A|B_k)$$

2) Laske summa $s = \sum q_k$.

3) Posteriorijakauma on

$$P(B_k|A) = q_k / s.$$

Esimerkkejä: les. AS esim. 1.1 ja 1.2

Esim 1.1 : $M=2$

$$P(B_1) = 0,001 \quad P(B_2) = 0,999$$

$$P(A|B_1) = 0,997 \quad P(A|B_2) = 0,015$$

$$q_1 = 0,001 \times 0,997 \quad q_2 = 0,999 \times 0,015$$

$$s = q_1 + q_2 = 0,015982$$

$$P(B_1|A) = \frac{q_1}{s} \approx 0,062 \quad P(B_2|A) = \frac{q_2}{s} \approx 0,938$$

Suurin osa työstä kuluu siihen, että tilanteen selostuksesta ymmärretään, mikä on priorii ja mikä uskottavuusfunktio. Varsinaisen laskun on helppo.

[Vnt. AS: jakso 1.3]

9. Bayesläinen päättely: parametri satunnaismuuttujana

Frekventistisessä päättelyssä parametri on tuntematon, mutta kiinteä suure (kiinteä \equiv deterministinen \equiv ei-satunnainen). Tämän takia frekventistisessä tilastotieteessä

parametriarvunudessa ei ole määriteltyä todennäköisyysjakaumaa, ja kaikelle todennäköisyyttä koskevat lauseumat [esim. luottamusvälin luottamustaso] pitää ajatella niin, että aineisto tulkitaan niissä satunnaiseksi, jotta saataisiin konkreettinen tulkinta, voidaan ajatella, että alkuperäistä koetta toistetaan vastaavissa oloissa hyvin monta kertaa, ja sitten lasketaan lauseisen tapahtuman suhteellinen frekvenssi toistoissa (\Rightarrow frekventistinen päättely).

Bayesläisessä päättelyssä toimitaan toisin:

- parametri ajatellaan satunnaismuuttujaksi
- havainnot ja vastaavalle satunnaisvektorille \underline{X} formuloidaan sen ehdollinen todennäköisyysjakauma ehdolla parametri
- kun havainnot \underline{x} on saatu, satunnaisvektorille \underline{X} kääritetään arvo $\underline{X} = \underline{x}$
- päättelyn tulos on parametrin posteriorijakauma, joka laskeetaan Bayesin kaavalle:

$$\text{posteriori} \propto \text{priori} \times \text{uskottavuus}$$

Tarkastellaan ensin diskreettiä tapusta, jossa satunnaisen parametrien K arvo kuuluu johonkin äärelliseen joukkoon S_K , ja havaintovektoriin

$$\underline{x} = (x_1, x_2, \dots, x_n)$$

arvo kuuluu johonkin äärelliseen joukkoon $S_{\underline{x}} \subset \mathbb{R}^n$.

Ptnf (pistetodennäköisyysfunktio)
 $k \mapsto P(K=k)$ on priorijakauma

Ehdollinen ptnf

$$\underline{x} \mapsto P(\underline{x} = \underline{x} \mid K=k) \quad \underline{x} \in S_{\underline{x}}, \quad k \in S_K$$

on aineiston otanta jakauma ehdolla $K=k$.

Yhdessä nämä kaksi funktiota spesifioivat parametrien ja havaintovektoriin \underline{x} yhteisjakautumaa, sillä (kertolaskukaava!)

$$P(K=k, \underline{x} = \underline{x}) = P(K=k) P(\underline{x} = \underline{x} \mid K=k)$$

Nämä kaksi funktiota määrittelevät bayesläisen tilastollisen mallin; malli $M^* [AS]$.

Kun havaintovektoriin \underline{x} arvo \underline{x} havaitaan, niin sen jälkeen kaikelle tiedo parametrien K jakaumasta sisältyy sen posteriorijakaumaan

$$k \mapsto P(K=k \mid \underline{x} = \underline{x})$$

$$\propto \underbrace{P(K=k)}_{\text{priori}} \underbrace{P(\underline{x} = \underline{x} \mid K=k)}_{\text{uskottavuusfunktio}}$$

Uskottavuusfunktio on $k \mapsto P(\underline{x} = \underline{x} \mid K=k)$, jossa aineistoa vastaavalle satunnaisvektorille \underline{x} on kiinnitetty sen havaittu arvo \underline{x} .

Esimerkki: mustat ja valkeiset pallot kurlhossa:

N palloa, joista K (parametri) valkeista ja $N-K$ mustaa. Paimitaan palloja satunnaisesti palauttaen.

$$X_i = \begin{cases} 1, & \text{jos } i:\text{s nostettu pallo on valkoinen} \\ 0, & \text{jos } i:\text{s nostettu pallo on musta} \end{cases}$$

$$P(\underline{X} = \underline{x} \mid K = k)$$

$$= P(X_1 = x_1, \dots, X_n = x_n \mid K = k)$$

$$= \left(\frac{k}{N}\right)^{x_1} \left(1 - \frac{k}{N}\right)^{1-x_1} \dots \left(\frac{k}{N}\right)^{x_n} \left(1 - \frac{k}{N}\right)^{1-x_n}$$

$$= \left(\frac{k}{N}\right)^{T(\underline{x})} \left(1 - \frac{k}{N}\right)^{n - T(\underline{x})}$$

jossa $T(\underline{x}) = \sum_{i=1}^n x_i =$ nostettujen valkeisten lkm
 $n - T(\underline{x}) =$ nostettujen mustien lkm

$$\frac{k}{N} = P(\text{"nostetaan valkoinen"} \mid K = k)$$

$$1 - \frac{k}{N} = P(\text{"nostetaan musta"} \mid K = k)$$

Huomautus: satunnaisuuttajat X_1, \dots, X_n ovat ehdollisesti riippumattomia ehdolla $K = k$, eli ne ovat riippumattomia niiden ehdollisessa yhteisjakaumassa, sillä

$$P(\underline{X} = \underline{x} \mid K = k) = \prod_{i=1}^n P(X_i = x_i \mid K = k)$$

$$P(X_i = x_i \mid K = k) = \left(\frac{k}{N}\right)^{x_i} \left(1 - \frac{k}{N}\right)^{1-x_i}$$

Ne eivät (yleensä) ole marginaalisesti riippumattomia eli riippumattomia (reuna-) yhteisjakaumassa

$$P(\underline{X} = \underline{x}) = \sum_k P(K = k, \underline{X} = \underline{x}) = \sum_k P(K = k) P(\underline{X} = \underline{x} \mid K = k)$$

joka ei yleensä faktoroidu reunajakaumien tuloksi.

Kun havitaan, että $\underline{X} = \underline{x}$, sen jälkeen laskeaan posteriorijakauma

$$P(K=k | \underline{X} = \underline{x}) = \frac{P(K=k) P(\underline{X} = \underline{x} | K=k)}{\sum_i P(K=i) P(\underline{X} = \underline{x} | K=i)}$$

[kin funktiona]

$$\propto P(K=k) P(\underline{X} = \underline{x} | K=k)$$

"Pallot kulhossa" -esimerkeissä riittää tuntee nostettujen valkeisten pallojen lkm $T(\underline{x})$, sillä tämä tunnusluku kertoo havainnoista kaiken tarvittavan (se on ns. tyhjentävä tunnusluku): uskottavuusfunktion $P(\underline{X} = \underline{x} | K=k)$ arvot voidaan laskea heti, kun $T(\underline{x})$ tiedetään.

Mitä parametrien satunnaisuus tarkoittaa?

Yksi mahdollisuus: K on oikeasti poimittu jostakin jakaumasta, ja sitten kulho on täytetty.

Toinen mahdollisuus: pidän valkeisten pallojen lukumäärää satunnaismuuttujana, koska en tiedä mikä arvo sillä on. Tässä todennäköisyyden subjektiivisessa tulkinnaassa priorijakauma kuvaa kvantitatiivisesti subjektiivista (etiim. mielen tai siunon) epävarmuuden parametrien arvosta. Havainnon teon jälkeen tämän epävarmuuden ilmaisee posteriorijakauma, joka saadaan laskettua Bayesin kaavalla.

Bayeslaisessa tilastotieteessä käytetään yleensä tätä subjektiivista tulkeintaa.

10. Kalluuyliä pistetodennäköisyysfunktioille

Tarkastellaan diskreettejä sm:ia (sm = satunnaismuuttuja), X, Y, K , joista kukin voi saada vain äärellisen määrän eri arvoja; arvojoukot S_X, S_Y, S_K äärellisiä joukkoja. Oletetaan epäoleellisten vaihtelujen välttämiseksi, että

$$P(X=x, Y=y, K=k) > 0 \quad \forall x \in S_X, y \in S_Y, k \in S_K$$

Tällöin kaiteki alla käytetyt ehdolliset tnt:t ovat hyvin määritellyjiä. Jatkossa jätetään ehdot $x \in S_X, y \in S_Y, k \in S_K$ kirjoittamatta.

Marginalisointi, eli miten siirrytään yhteisjakaumasta reuna-jakaumaan:

$$P(X=x, Y=y) = \sum_k P(X=x, Y=y, K=k)$$

(todennäköisyyden additiivisuus!)

$$P(X=x) = \sum_y P(X=x, Y=y)$$

$$= \sum_y \sum_k P(X=x, Y=y, K=k)$$

jne. Yhteenveto:

Yhteis-ptnf:stä (ptnf = pistetodennäköisyys-funktio) saadaan reuna-ptnf summaamalla siitä tarpeeton muuttuja tai tarpeettomat muuttujat pois.

Ehdollinen ptnf \equiv ehdollinen tn. Esim.

$$P(X=x | Y=y) = \frac{P(X=x, Y=y)}{P(Y=y)}$$

Kertolaskukaava (eli -sääntö)

$$\begin{aligned} P(X=x, Y=y) &= P(X=x) P(Y=y | X=x) \\ &= P(Y=y) P(X=x | Y=y) \end{aligned}$$

(on sama asia kuin ehdollisen ptnfin määrittelmä.)

Riippumattomuus: $X \perp Y$, jos

$$P(X=x, Y=y) = P(X=x) P(Y=y) \quad \forall x, y$$

Jos $X \perp Y$, niin $P(Y=y) = P(Y=y | X=x)$ kaikilla x, y , ja $P(X=x) = P(X=x | Y=y)$ kaikilla x, y . Tämä seuraa riippumattomuuden määrittelmästä sekä kertolaskukaavasta.

Marginalisointi onnistuu samalla tavalla myös ehdolliselle yhteis-ptnf:lle:

$$P(X=x | K=k) = \sum_y P(X=x, Y=y | K=k)$$

(ehdollinen tn $B \mapsto P(B | K=k)$ on additiivinen!)

Ehdollinen riippumattomuus: $X \perp Y | K$, eli

X ja Y ovat riippumattomia ehdolla K , jos ne ovat riippumattomia ehdollisessa yhteisjakaumassa

$$P(X=x, Y=y | K=k) \quad \forall k$$

ts. jos

$$P(X=x, Y=y | K=k) = P(X=x | K=k) P(Y=y | K=k)$$

$$\forall x, y, k$$

Vaihtoehtoinen luonneldinta ehdolliselle riippumattomuudelle (HT):

$$X \perp\!\!\!\perp Y \mid K, \text{ jos}$$

$$P(X=x \mid Y=y, K=k) = P(X=x \mid K=k)$$

tai

$$P(Y=y \mid X=x, K=k) = P(Y=y \mid K=k)$$

$$\forall x, y, k$$

Huomautus: nämä kaikkii kaavat pätevät myös, jos X onkin (diskreetti) satunnaisvektori, esim.

$$X = \underline{X} = (X_1, X_2, \dots, X_n)$$

tai Y on (diskreetti) satunnaisvektori tai K on (diskreetti) satunnaisvektori.

Lisäksi nämä kaavat yleistyvät myös jatkuvien jakaumien tapauksiin, jolloin summien sijasta pitää laskea integraaleja. Palautamme jatkuvan tapaukseen myöhemmin.

11. Ennustaminen: mikä pallo seuraavaksi?

[AS: jakso 1.5]

Pallot kulhossa: olemme havainneet

$$\underline{x} = \underline{x} \text{ eli } x_1 = x_1, x_2 = x_2, \dots, x_n = x_n$$

Millä todennäköisyydellä seuraava nosto tuottaa valkeisen pallon, eli $x_{n+1} = 1$?

Tähän kysymykseen on hankala antaa vastauksia frekventistisen paradigman perusteissa; voitaisiin yrittää ennustaa sijoittamalla parametriin K järkevä frekventistinen estimaatti kaavaan K/N ts. ennuste olisi \hat{K}/N . Tällöin täysin sivuutetaan se ongelma, että K :n estimointiin liittyy epävarmuutta.

Bayeslaisessa paradignassa ennustaminen on periaatteessa suoraviivaista: pitää tukeutua ennuste- eli predikttiivisiin todennäköisyyttä

$$P(x_{n+1} = 1 \mid \underline{x} = \underline{x})$$

Tämä tapa ottaa huomioon parametrin estimointiin liittyvän epävarmuuden!

Miten ennuste todennäköisyys laskeetaan?

Yksinkertaisin tapa on hyvädyntää ehdollista riippumattomuutta. Kun $K=k$, on

$$\begin{aligned} & P(\underline{X} = \underline{x}, X_{m+1} = x_{m+1} \mid K = k) \\ &= \left(\frac{k}{N}\right)^{x_1} \left(1 - \frac{k}{N}\right)^{1-x_1} \dots \left(\frac{k}{N}\right)^{x_m} \left(1 - \frac{k}{N}\right)^{1-x_m} \left(\frac{k}{N}\right)^{x_{m+1}} \left(1 - \frac{k}{N}\right)^{1-x_{m+1}} \\ &= P(\underline{X} = \underline{x} \mid K = k) P(X_{m+1} = x_{m+1} \mid K = k) \end{aligned}$$

Siis $\underline{X} \perp\!\!\!\perp X_{m+1} \mid K$.

Nyt

$$\begin{aligned} & P(X_{m+1} = x_{m+1} \mid \underline{X} = \underline{x}) \\ &= \sum_k P(X_{m+1} = x_{m+1}, K = k \mid \underline{X} = \underline{x}) \quad (\text{marginalisointi}) \\ &= \sum_k P(K = k \mid \underline{X} = \underline{x}) P(X_{m+1} = x_{m+1} \mid \underline{X} = \underline{x}, K = k) \\ & \quad \quad \quad (\text{kertolaskukaava}) \\ &= \sum_k P(K = k \mid \underline{X} = \underline{x}) P(X_{m+1} = x_{m+1} \mid K = k) \\ & \quad \quad \quad (\text{sillä } \underline{X} \perp\!\!\!\perp X_{m+1} \mid K) \end{aligned}$$

Tässä siis summatetaan posteriorin $P(K=k \mid \underline{X}=\underline{x})$ kertaa uuden havainnon X_{m+1} ehdollinen tn,

$$P(X_{m+1} = x_{m+1} \mid K = k) = \begin{cases} \frac{k}{N}, & \text{jos } x_{m+1} = 1 \\ 1 - \frac{k}{N}, & \text{jos } x_{m+1} = 0 \end{cases}$$

Ennustejakauma on tietenkin p.tnf, eli

$$\underbrace{P(X_{m+1} = 0 \mid \underline{X} = \underline{x})}_{\geq 0} + \underbrace{P(X_{m+1} = 1 \mid \underline{X} = \underline{x})}_{\geq 0} = 1$$

joten riittää laskea toinen tapauksesta $x_{m+1}=1$ tai $x_{m+1}=0$

12. Kertolaskukaava jälleen kerran

Edellä sovellettiin kertolaskukaavaa ehdollisille yhteis-ptnf:oilte. Sen mukaan ehdollinen yhteis-ptnf voidaan jakaa tekiijöihin samalla periaatteella kuin ei-ehdollinen yhteis-ptnf, ts.

$P(X=x, Y=y | K=k) = P(X=x | K=k) P(Y=y | X=x, K=k)$
aina, kun x, y ja k ovat diskreettien satunnaismuuttujien tai -vektorien mahdollisia arvoja ja kein kyseiset ehdolliset tnt ovat hyvin määriteltäjiä. Tämän tuloksen voi perustella tarkistamalla identiteettiä

$P(A \cap B | C) = P(A | C) P(B | A \cap C)$
(kun kyseiset ehdolliset tnt ovat hyvin määriteltäjiä). Tämän jälkeen samastetaan

$A = \{X=x\}$, $B = \{Y=y\}$, $C = \{K=k\}$
ja huomataan kaavojen yhtäpitäisyys. Tätä varten pitää tietenkin huomata, että pilken tapahtumien välillä \cap -merkeissä $P(\cdot | \cdot)$ tarkoittaa sitä, että kaikille pilkulla erotetut tapahtumat sattuvat, eli pilken \equiv tapahtumien leikkaus.

Kertolaskusääntö saadaan helposti yleistettyä myös useammalle kuin kahdelle tapahtumalle; nimittäin pätee

$$P(A_1 \cap A_2 \cap \dots \cap A_n) =$$

$$P(A_1) P(A_2 | A_1) \dots P(A_n | A_1 \cap A_2 \cap \dots \cap A_{n-1})$$

(mikäli kaikille ehdolliset tnt ovat hyvin määriteltäjiä). Tästä saadaan kertolaskukaava yhteis-ptnf:oilte.

Analoginen tulos pätee myös ehdollisille tnt:ille sekä ehdollisille yhteis-ptnf:oilte.

Esimerkiksi: pallot kulhossa, ilman takaisinpanoa.

Kulhossa on aluksi N palloa, joista K (parametri) on valkeista. Poimimme palloja kulhosta palauttamatta nostettuja palloja kulhoon. Miten lasketaan otantajakauma

$$P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n | K = k),$$

kun $n < N$?

Vastaus: käytetään kertolaskukaavaa:

$$\begin{aligned} & P(X_1 = x_1, X_2 = x_2, \dots, X_n = x_n | K = k) \\ &= P(X_1 = x_1 | K = k) \\ &\quad \times P(X_2 = x_2 | X_1 = x_1, K = k) \\ &\quad \times \dots \\ &\quad \times P(X_n = x_n | X_1 = x_1, X_2 = x_2, \dots, X_{n-1} = x_{n-1}, K = k) \end{aligned}$$

Kukin termeistä on helppo järjkeillä pitämällä kirjaa siitä, kuinka monta palloa kulhossa on jäljellä ja kuinka monta niistä on valkeista silloin, kun kyseinen ehto on voimassa.

Esim.
$$P(X_1 = x_1 | K = k) = \begin{cases} \frac{k}{N}, & \text{kun } x_1 = 1 \\ 1 - \frac{k}{N}, & \text{kun } x_1 = 0 \end{cases}$$

$$P(X_2 = 1 | X_1 = 0, K = k) = \begin{cases} \frac{k}{N-1}, & \text{kun } 0 \leq k \leq N-1 \\ 0, & \text{kun } k = N \end{cases}$$

$$P(X_2 = 1 | X_1 = 1, K = k) = \begin{cases} \frac{k-1}{N-1}, & \text{kun } 1 \leq k \leq N \\ 0, & \text{kun } k = 0 \end{cases}$$

Komplementtitapahtuman $X_2 = 0$ ehdollinen löytö tieteen kaavalla

$$P(X_2 = 0 | X_1 = x_1, K = k) = 1 - P(X_2 = 1 | X_1 = x_1, K = k)$$

Tätä menetelmää on helppo jatkaa eteenpäin. (HT)

Huom. Tässä esimerkissä ei päde s. 39 positiivisuusoletus. Tästä syystä ehdollisen t:n määritelmiä laajennettiin.

Huomaa, että edellä tapahtumat $\{X_1=0, K=N\}$ sekä $\{X_1=1, K=0\}$ ovat mahdottomia (niiden tn on nolla). Käytin konventiota

$$P(B|A) = \begin{cases} \frac{P(A \cap B)}{P(A)} & , \text{ kun } P(A) > 0 \\ 0 & , \text{ kun } P(A) = 0 \end{cases}$$

Tällöin kertolaskusääntö pysyy voimassa:

1) jos $P(A) > 0$, niin

$$P(A) P(B|A) = P(A) \frac{P(A \cap B)}{P(A)} = P(A \cap B)$$

2) jos $P(A) = 0$, niin

$$P(A) P(B|A) = 0 \cdot 0 = 0,$$

mutta toisaalta $A \cap B \subset A$, joten

$$0 \leq P(A \cap B) \leq P(A) = 0,$$

joten kertolaskusääntö on voimassa.

Tämä päättely yleistyy ehdolliselle tn:lle sekä min joukon leikekaarelle, joten otantajakauema (tai uskottavuusfunktio) voidaan tässäkin tapauksessa laskea kertolaskusäännöllä.

Posteriorijakauma saadaan Bayesin kaavalle

$$P(K=k | \underline{X} = \underline{x}) = \frac{1}{P(\underline{X} = \underline{x})} P(K=k) P(\underline{X} = \underline{x} | K=k),$$

eikä sen kohdalla jouduta samaanlaisiin vaikeuksiin, sillä järkevissä bayesläisissä malleissa $P(\underline{X} = \underline{x}) > 0$;

$P(K=k | \underline{X} = \underline{x})$ häviää niillä k , joilla havaittu \underline{x} on mahdoton.

[$P(\underline{X} = \underline{x})$ olisi nolla, jos $P(K=k, \underline{X} = \underline{x})$ olisi identtisesti nolla havaitulle \underline{x} . Tällainen havainto \underline{x} olisi mallin mukaan mahdoton, joten malli ei voisi olla järkviä todellisuuden keveys.]

13. Ehdolliset jakaumat yleisemmässä tapauksessa

Tähän asti ehdolliset jakaumat on käsitelty suoraan ehdollisen tilan määritelmän avulla. Nyt siirrymme käsittelemään tilannetta, jossa mukana on jatkuvasti jakaantuneita muuttujia.

Hyvä uutinen: kaavat näyttävät samalta kuin ennen, kun summan tilalle kirjoitetaan tarvittaessa integraali.

~~Huono~~ uutinen: niitä integraaleja harvois osataan laskea analyttisesti.

Hyvä uutinen: joissakin tapauksissa integraalit osataan laskea nopean silmäilyn jälkeen (liitto- eli konjugaattijakaumat).

Kun havainto ja parametri ovat diskreettejä satunnaismuuttujia, niin bayesläinen päättely palautuu kertolaskukaavaan,

$$\begin{aligned} f_{X,Y}(x,y) &= f_X(x) f_Y(y | X=x) \\ &= f_Y(y) f_X(x | Y=y), \end{aligned}$$

jossa pntf:öitä merkittiin

$$f_{X,Y}(x,y) = P(X=x, Y=y) \quad f_X(x) = P(X=x)$$

$$f_Y(y | X=x) = P(Y=y | X=x) \text{ jne.}$$

Sopivasti tulkittuna tämä kaava säilyy voimassa kaikissa jatkossa iteen tulevissa tilanteissa.

Epäoleellisten vaikeuksien välttämiseksi teemme positiivisuusoletuksen: tarkastelemme sellaisia yhteisjakaumia, joille

$$f_{X,Y}(x,y) > 0 \Leftrightarrow (f_X(x) > 0 \text{ ja } f_Y(y) > 0)$$

ja vain sellaisia (x,y) , joille $f_{X,Y}(x,y) > 0$.

Tapaus: X diskreetti, Y jatkuva

$f_X(x) = P(X=x)$ on X :n reuna-ptnf.

$f_Y(y | X=x)$ on Y :n tf (tiheysfunktio) ehdolla $X=x$:

$$P(a \leq Y \leq b | X=x) = \int_a^b f_Y(y | X=x) dy$$

kaikilla $a \leq b$

$f_Y(y)$ on Y :n reuna-tf:

$$P(a \leq Y \leq b) = \int_a^b f_Y(y) dy$$

$f_X(x | Y=y)$ on X :n ptnf ehdolla $Y=y$.

Näiden välillä on yhteyksiä:

$$\begin{aligned} f_{X,Y}(x,y) &= f_X(x) f_Y(y | X=x) \\ &= f_Y(y) f_X(x | Y=y) \end{aligned}$$

kaikilla x, y

Yhteisjakauman esityksestä $f_{X,Y}(x,y)$ saadaan todennäköisyyksiä summamalla x :n suhteen ja integroimalla y :n suhteen:

$$P(X \in A, Y \in B) = \sum_{x \in A} \int_B f_{X,Y}(x,y) dy$$

kaikilla (järjellillä) joukoilla $A, B \subset \mathbb{R}$

Marginalisointi:

$$\begin{aligned} f_X(x) &= \int f_{X,Y}(x,y) dy \\ f_Y(y) &= \sum_x f_{X,Y}(x,y) \end{aligned}$$

[Määrätty integraali
joukon $S_Y = \{y: f_Y(y) > 0\}$
yli.]

Seuraus: jos jompikumpi yhteisjakauman faktoroinneista tunnetaan, niin niistä toinen pystytään (periaatteessa) laskemaan:

$$f_Y(y | X=x) = \frac{f_Y(y) f_X(x | Y=y)}{f_X(x)}$$

$$f_X(x | Y=y) = \frac{f_X(x) f_Y(y | X=x)}{f_Y(y)}$$

Tapaus: (X, Y) :llä jatkuva yhteisjakauma

$f_X(x)$ on X :n reuna-tf

$f_Y(y|X=x)$ on Y :n tf ehdolla $X=x$

$f_Y(y)$ on Y :n reuna-tf

$f_X(x|Y=y)$ on X :n tf

$f_{X,Y}(x,y)$ on parin (X,Y) yhteis-tf.

Näiden välillä on yhteyksiä:

$$\begin{aligned} f_{X,Y}(x,y) &= f_X(x) f_Y(y|X=x) \\ &= f_Y(y) f_X(x|Y=y) \text{ kaikilla } x,y. \end{aligned}$$

Yhteis-tf:stä saadaan todennäköisyyksiä integroimalla kummankin muuttujan suhteen:

$$\begin{aligned} P(X \in A, Y \in B) &= \iint_{A \times B} f_{X,Y}(x,y) dx dy \\ &= \int_A \left(\int_B f_{X,Y}(x,y) dy \right) dx \\ &= \int_B \left(\int_A f_{X,Y}(x,y) dx \right) dy \end{aligned}$$

(tasointegraali voidaan palauttaa iteroiduksi integraaliksi).

Marginalisointi:

$$f_X(x) = \int_{\mathbb{R}} f_{X,Y}(x,y) dy$$

$$f_Y(y) = \int_{\mathbb{R}} f_{X,Y}(x,y) dx$$

Seuraus: jos jompikumpi yhteis-tf:n funktioista tunnetaan, niin se toinen pystytään (periaatteessa) laskemaan.

Huomautus: jos Y :lläi on jatkuva jakauma, niin arvoa $f_X(x|Y=y)$ ei voida suoraan ajatella ehdollisena todennäköisyytenä, mutta se voidaan tulkita raja-arvojen kautta.

jos X diskreetti, Y jatkuva, niin

$$P(X=x | y \leq Y \leq y+h) \xrightarrow{h \rightarrow 0^+} f_X(x | Y=y)$$

(ainakin joillakin jatkuvuusoletuksilla).

Jos (X, Y) :lläi on jatkuva yhteisjakauma, niin kaikilla $a \leq b$ pätee

$$P(a \leq X \leq b | y \leq Y \leq y+h) \xrightarrow{h \rightarrow 0^+} \int_a^b f_X(x | Y=y) dx$$

(ainakin joillakin jatkuvuusoletuksilla).

Tilastotieteessä havainnot tehdään vain jollakin tarkkuudella, ja tällöin käytännössä approksimoidaan tämän tapaisia suureita vastaavien ehdollisten jakaumien avulla.

Yhteenveto: jokaisessa tapauksessa (ketolaskukaava)
 $f_{X,Y}(x,y) = f_X(x) f_Y(y|X=x) = f_Y(y) f_X(x|Y=y)$

Marginalisointi:

$$f_X(x) = \begin{cases} \sum_y f_{X,Y}(x,y), & Y \text{ diskreetti} \\ \int f_{X,Y}(x,y) dy, & Y \text{ jatkuva} \end{cases}$$

$$f_Y(y) = \begin{cases} \sum_x f_{X,Y}(x,y), & X \text{ diskreetti} \\ \int f_{X,Y}(x,y) dx, & X \text{ jatkuva} \end{cases}$$

$$\left. \begin{matrix} f_X(x) \\ f_X(x|Y=y) \end{matrix} \right\} \text{ on } \begin{cases} \text{ptnf, jos } X \text{ diskreetti} \\ \text{tf, jos } X \text{ jatkuva} \end{cases}$$

$$\left. \begin{matrix} f_Y(y) \\ f_Y(y|X=x) \end{matrix} \right\} \text{ on } \begin{cases} \text{ptnf, jos } Y \text{ diskreetti} \\ \text{tf, jos } Y \text{ jatkuva} \end{cases}$$

Huomautus 1) $\int p(x) dx$ on ei-negatiivinen ja sen summa koko avaruuden yli on yksi.

2) $\int f$ on ei-negatiivinen ja sen integraali koko avaruuden yli on yksi.

Ehdollinen jakauma verrannollisuusmerkin avulla:
Jos Y lle on jatkuva jakauma, niin

$$f_Y(y | X=x) = \frac{1}{f_X(x)} f_Y(y) f_X(x | Y=y)$$

[y:n funktiona]

$$\propto f_Y(y) f_X(x | Y=y)$$

Tässä tarvittava normalisointivakio on

$f_X(x)$ saa selville normalisoimalla tulon tiheysfunktioiksi:

$$f_X(x) = \int f_Y(y) f_X(x | Y=y) dy$$

(Vastava tarkastelu onnistuu tietenkin myös silloin, kun Y lle on diskreetti jakauma.)

Kirjallisuudesta löytyy monenlaisia merkintöjä yhteis- reuna- ja ehdollisille jakaumille.

Usein käytetään merkintöjä

$$f_X(x), f_Y(y), f_{X|Y}(x|y), f_{Y|X}(y|x), f_{X,Y}(x,y)$$

Bayesläisen päättelyn yhteydessä on tavainomaista jättää alaindeksit kirjoittamatta. Tällöin merkinnät voisivat olla $f(x), f(y), f(x|y), f(y|x), f(x,y)$.

Aloitteijan on näitä merkintöjä vaikea ymmärtää, sillä esim. $f(x|y)$ voi, asiayhteydestä riippuen, tarkoittaa joko

- funktiota $(x,y) \mapsto f_X(x | Y=y)$
- funktiota $x \mapsto f_X(x | Y=y)$ jollakin kiinteällä y
- funktiota $y \mapsto f_X(x | Y=y)$ jollakin kiinteällä x
- arvoa $f_X(x | Y=y)$ kiinteillä (x,y) .

Tästä huolimatta tällainen genereninen notaatio ei (taitavasti käytettynä) yleensä johda sekaannukseen.

14. Nasta lasipurkeissa: jatkuva parametri

[AS: jaksot 1.6]

Nastaa helistetään lasipurkeissa ja sen jälkeen rekisteröidään, laskeutuu se selälle vai kyljelle. Koetta toistetaan yhteensä n kertaa.

$$X_i = \begin{cases} 1, & \text{jos nastaa tulee selälle } i\text{nnellä } i\text{toistolla} \\ 0, & \text{— " — kyljelle — " —} \end{cases}$$

Valitaan parametriksi välillä $(0,1)$ oleva reaaliluku θ , joka on t'n sille, että nastaa päättyy selälle.

Voisimme periaatteessa selvittää θ :n arvon melkivaltaisen tarkasti tekemällä riittäin pitkin koesarjan (mutta jossain vaiheessa jokin menisi rikki: nastaa, lasipurkki tai helistäjän leäsi).

Emme tunnne θ :n arvoa (tällä kertaa kukaan ei oikeasti tunnne sitä), joten pidämme sitä satunnaismuuttujana. Huomautus: kirjaltaisten kirjainten ja parametrien kohdalla käytetään usein samaa symbolia (esim. θ) sekä satunnaismuuttujalle että sen (potentiaaliseen) arvolle. Tehdään [toisin kuin AS, ks. s. 20] kuitenkin selvyyden vuoksi merkintäsoinnus:

$\tilde{\theta}$ on parametri ymmärrettynä satunnaismuuttujana

θ on $\tilde{\theta}$:n (potentiaalinen) arvo.

Emmoleikkäisyytämme parametrin arvosta kuvaa jokin välillä $(0,1)$ määritelty jatkuva jakauma, jonka tiheysfunktio on

$$f_{\tilde{\theta}}(\theta) =: P(\theta), \quad 0 < \theta < 1$$

Jos parametrin arvo θ tunnetaan, niin aivan ilmeisesti havaintovektorin otantajakauma on

$$\begin{aligned} P(\underline{X} = \underline{x} \mid \tilde{\theta} = \theta) &= P(\underline{X} = \underline{x} \mid \theta) \quad [\text{merkintä}] \\ &= \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} = \theta^{T(\underline{x})} (1-\theta)^{n-T(\underline{x})} \end{aligned}$$

jossa

$$T(\underline{x}) = \sum_{i=1}^n x_i$$

Posteriorijakauma on jatkuva jakauma, jonka ff

$$\begin{aligned} P(\theta \mid \underline{X} = \underline{x}) &:= f_{\tilde{\theta}}(\theta \mid \underline{X} = \underline{x}) \\ &= \frac{1}{f_{\underline{X}}(\underline{x})} P(\theta) P(\underline{X} = \underline{x} \mid \theta) \end{aligned}$$

$$\propto P(\theta) P(\underline{X} = \underline{x} \mid \theta) \quad \left[\begin{array}{l} \theta\text{-in funktiona,} \\ 0 < \theta < 1 \end{array} \right]$$

Tässä verannollisuustuloksessa tarvittava normalisointivakio $f_{\underline{X}}(\underline{x})$ saadaan laskeaksesi integraaliksi

$$f_{\underline{X}}(\underline{x}) = \int_0^1 P(\theta) P(\underline{X} = \underline{x} \mid \theta) d\theta$$

(mutta tämä voi olla käytännössä vaikea laskea.)

15. Liittojakauma eli konjugaattijakauma

Joillekin uskottavuusfunktioille on mahdollista löytää parametrisen perhe jakaumia siten, että mikäli priorijakauma valitaan kysyisestä perheestä, niin myös posteripriorijakauma kuuluu kysyiseen perheeseen. Nasta laajurleissa -esimerleissä päädyttiin ns. binomiuskottavuuteen (binomikekeen uskottavuusfunktion), ja tälle uskottavuusfunktiole beta-jakaumat muodostavat tällaisen mukavan jakaumaperheen. Tällöin sanotaan, että beta-jakauma on binomiuskottavuuden liittopriori (conjugate prior) tai että otantajakauma ja priorijakauma ovat toistensa liittojakaumia.

Beta-jakauma on jatkuva jakauma, jonka tiheysfunktio on muotoa

$$f(x) \propto x^{\alpha-1} (1-x)^{\beta-1}, \quad 0 < x < 1,$$
 missä $\alpha > 0$ ja $\beta > 0$ ovat jakaumaperheen parametrit. Merkitsemättä jätetty normalisointivakio on

$$B(\alpha, \beta) = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx.$$

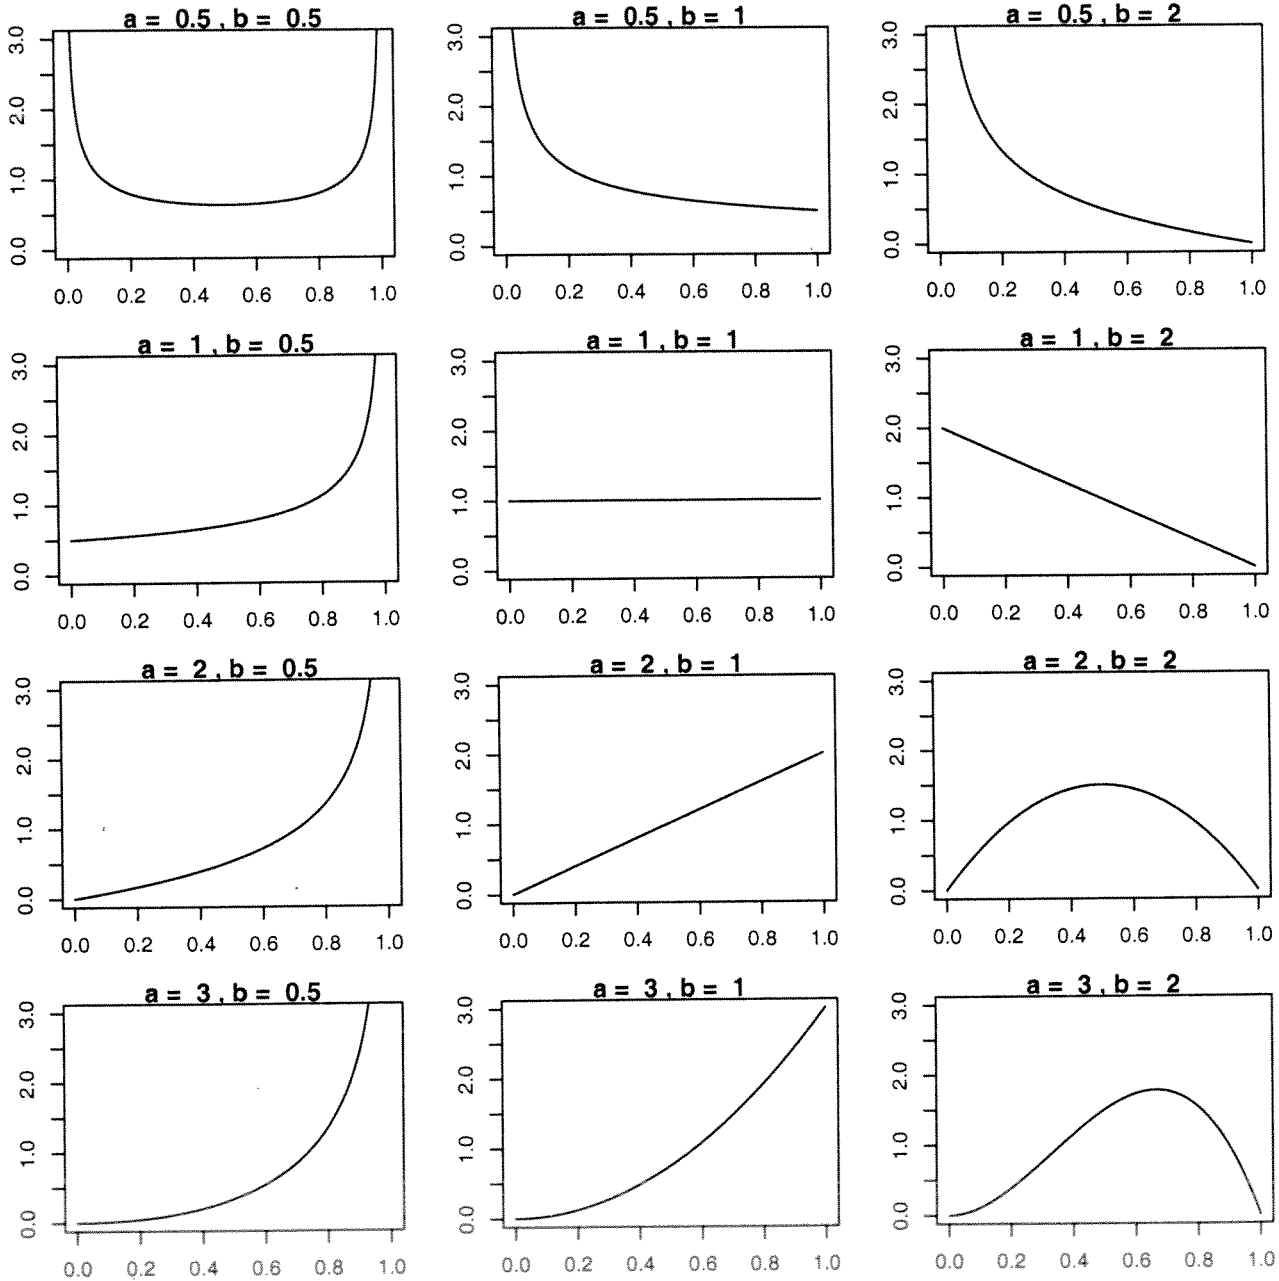
Tämä on ns. (Eulerin) beta-funktio (ja "B" on iso beta-kujain). Ts. tiheysfunktion täydellinen kaava on (mielivaltaisilla $\alpha, \beta > 0$)

$$f(x) = \begin{cases} \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, & 0 < x < 1 \\ 0, & \text{muuten.} \end{cases}$$

Useimmiten riittää tietää tiheysfunktion muoto, $f(x) \propto x^{\alpha-1} (1-x)^{\beta-1}, 0 < x < 1$; toisinaan tarvitaan normalisointivakion lauseketta.

Beta-jakauman tiheysfunktioita esi parametriarvoilla.
Tapaus $\alpha = \beta = 1$ on välin $(0,1)$ tasajakauma, $Tas(0,1)$.

Tiheysfunktiolla on moodi pisteessä $\frac{\alpha-1}{\alpha+\beta-2}$, mikäli $\alpha, \beta > 1$. Jakauman odotusarvo on $\alpha/(\alpha+\beta)$ kaikilla $\alpha, \beta > 0$.



Beta-funktion arvot voidaan laskea, jos osataan laskea (Eulerin) gammafunktion $\Gamma(\cdot)$ arvoja sillä voidaan osoittaa, että

$$B(\alpha, \beta) = \frac{\Gamma(\alpha) \Gamma(\beta)}{\Gamma(\alpha + \beta)}, \quad \alpha, \beta > 0$$

jossa Γ -funktio voidaan määritellä kaavalla

$$\Gamma(x) = \int_0^{\infty} x^{t-1} e^{-x} dx, \quad \text{kun } x > 0$$

Voidaan osoittaa, että $\Gamma(1) = 1$ ja että

$$\Gamma(x+1) = x \Gamma(x) \quad \text{kaikilla } x > 0,$$

mistä helposti päätellään, että $\Gamma(n) = (n-1)!$, kun $n \geq 1$ on kokonaisluku.

Cun ja näitä kaavoja ei tarvitse opetella tenttiä varten ulkoa, vaan ne annetaan tehtäväpaperissa, mikäli niitä tarvitaan.

Tarkistetaan, että beta-jakauma on binomiuskohtisuuden lüttojakauma. Priorin parametrit ovat $\alpha, \beta > 0$.

Tapa 1) Lasketaan normalisointivakio $f_{\underline{x}}(\underline{x}) = P(\underline{X} = \underline{x})$.

$$P(\underline{X} = \underline{x}) = \int_0^1 p(\theta) P(\underline{X} = \underline{x} | \theta) d\theta$$

$$= \int_0^1 \frac{1}{B(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} \theta^{T(\underline{x})} (1-\theta)^{n-T(\underline{x})} d\theta$$

[Kirjoitettiin beta-tiheys käyttämällä muuttujana θ :a, sekä binomikeskeen uskottavuus]

$$= \frac{1}{B(\alpha, \beta)} \int_0^1 \theta^{\alpha+T(\underline{x})-1} (1-\theta)^{\beta+n-T(\underline{x})-1} d\theta$$

$$= \frac{B(\alpha+T(\underline{x}), \beta+n-T(\underline{x}))}{B(\alpha, \beta)},$$

joten

$$p(\theta | \underline{X} = \underline{x}) = \frac{p(\theta) P(\underline{X} = \underline{x} | \theta)}{P(\underline{X} = \underline{x})}$$

= " = beta-jakauman tiheys,
jonka parametrit ovat $\alpha+T(\underline{x})$ ja $\beta+n-T(\underline{x})$

Tavassa 1) satun laskun varrella helposti virheitä.
Tulos on paljon helpompaa johtaa seuraavalla tavalla:

Tapa 2) θ :n funktiona
posteriori \propto priori \times uskottavuus,
joten

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

$$\propto \theta^{\alpha-1} (1-\theta)^{\beta-1} \theta^{T(\underline{x})} (1-\theta)^{n-T(\underline{x})}$$

[Kirjoitettiin $p(\theta)$ (θ :n funktiona!)
sekä uskottavuusfunktio, mutta jätettiin
kirjoittamatta vakiot, jotka eivät riipu
 θ :n arvosta]

$$\propto \theta^{\alpha+T(\underline{x})-1} (1-\theta)^{\beta+n-T(\underline{x})-1}, \quad 0 < \theta < 1$$

Nyt huomataan, että (ainoa!) jatkuva jakauma,
jonka tf on (normalisointivakiota vaille) tämän
näköinen on beta-jakauma, jonka parametrit
ovat $\alpha + T(\underline{x})$ ja $\beta + n - T(\underline{x})$.

Tässä $T(\underline{x})$ on "onnistumisten" $X_i = 1$ lkm, ja
 $n - T(\underline{x})$ on "epäonnistumisten" $X_i = 0$ lkm
missä toistossa, jotka ovat ehdollisesti riippumattomia
ehdolla θ [tai pedanttisemmin ilmaistena: ehdolla
 $\tilde{\theta} = \theta$].

Resepti (Posteriorijakauman johtaminen
liitto- eli konjugaattiperheen tapauksessa.)

Ainekset: Priorijakauma ja uskottavuusfunktio

Ohjeet: 1) Kirjoita "priori x uskottavuus"

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

2) Kehitä saamaasi lauseketta muuttujan
 θ funktiona varamuunnosmerkintöiden
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 liittojakaumatilanne, joten yritä
leikkiä jokin muu lähestymistapa.

Usein esiintyviä liittoprosentteja:

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

Gammajakauman tiheysfunktioita eri parametrien arvoilla. 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. Normalisointivakion kanssa f on

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

Yksinkertaisempi parametri: α ja $\beta = 1/\lambda$.

Esimerkki: eksponenttijakautuneet havainnot ja gamma-priori. 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

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

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

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

Täten \Rightarrow posteriorijakauma on

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