

## 10 Bayes-päätelyn alkeita

- Jos parametrin arvo on kiinnitetty, niin havaintosatunnaisvektorin jakauma mallinnetaan bayesiläisessä päätelyssä täysin samalla tavalla kuin frekventistisessä päätelyssä.
- Frekventistisessä lähestymistavassa parametri on kiinteä (ts. ei-satunnainen) mutta tuntematon.
- Bayesiläisessä lähestymistavassa parametria käsitellään satunnaisena suureena.
- Tämä ehkä vähäiseltä tuntuva ero johtaa suuriin eroihin laskutekniikoissa ja tulosten tulkinnoissa.
- **Bayesiläisessä päätelyssä kaikki on toisin** kuin frekventistisessä.

## 10.1 Todennäköisyyslaskentaa

- Oletamme hiljaisesti, että osamäärien nimittäjät ovat esitettävissä kaavoissa erisuuria kuin nolla.
- Olkoot  $A$  ja  $B$  tapahtumia. Jos tiedämme (täsmälleen sen), että  $B$  on sattunut, niin tapahtuman  $A$  todennäköisyys lasketaan **ehdollisen todennäköisyyden** kaavalla

$$P(A | B) = \frac{P(A \cap B)}{P(B)}. \quad (1)$$

- Ehdollisen todennäköisyyden kaavasta saadaan todennäköisyyksien **kertolaskukaava**

$$P(A \cap B) = P(B) P(A | B) = P(A) P(B | A). \quad (2)$$

- Tästä nähdään kaava

$$P(A | B) = \frac{P(A) P(B | A)}{P(B)}. \quad (3)$$

# Kokonaistodennäköisyyden kaava

Jos tapahtumat  $A_1, \dots, A_M$  ovat jokin perusjoukon ositus ts.

- joukot  $A_i$  ovat erillisiä: jos  $i \neq j$ , niin  $A_i \cap A_j = \emptyset$ .
- niiden yhdiste on koko perusjoukko,

niin  $P(B)$  voidaan laskea (todennäköisyyden additiivisuuden perusteella) seuraavasti,

$$\begin{aligned} P(B) &= P(\cup_{i=1}^M (B \cap A_i)) = \sum_{i=1}^M P(B \cap A_i) \\ &= \sum_{i=1}^M P(A_i) P(B | A_i) \end{aligned}$$

Kun *kokonaistodennäköisyyden* kaavaa käytetään kaavassa (3) saadaan *Bayesin kaava*

$$P(A_k | B) = \frac{P(A_k) P(B | A_k)}{\sum_{i=1}^M P(A_i) P(B | A_i)} \quad (4)$$

johon bayesiläinen päättely perustuu diskreetin parametrin ja diskreetin havaintovektorin tapauksessa.

# Samat kaavat uudestaan

- Käsitellään kahden diskreetin satunnaismuuttujan (tai satunnaisvektorin)  $\tilde{\theta}$  ja  $\mathbf{Y}$  yhteisjakaumaa, jonka määrää niiden yhteispistetodennäköisyysfunktio

$$f_{\tilde{\theta}, \mathbf{Y}}(\theta, \mathbf{y}) = P(\tilde{\theta} = \theta, \mathbf{Y} = \mathbf{y}) = P(\{\tilde{\theta} = \theta\} \cap \{\mathbf{Y} = \mathbf{y}\}). \quad (5)$$

- Satunnaismuuttujan  $\tilde{\theta}$  mahdolliset arvot ovat  $\theta_1, \theta_2, \dots$
- Satunnaisvektorin  $\mathbf{Y}$  mahdolliset arvot ovat  $\mathbf{y}_1, \mathbf{y}_2, \dots$
- Yhteispistetodennäköisyysfunktion arvoja ja muiden pistetodennäköisyysfunktioiden arvoja lasketaan jatkossa sellaisissa pisteissä  $(\theta, \mathbf{y})$ , joiden  $\theta$ -koordinaatti on jokin  $\tilde{\theta}$  mahdollisista arvoista ja  $\mathbf{y}$ -koordinaatti on jokin  $\mathbf{Y}$ :n mahdollisista arvoista.

- $p(\theta)$  on satunnaismuuttujan  $\tilde{\theta}$  reunajakauman pntf, eli

$$p(\theta) = P(\tilde{\theta} = \theta)$$

- $f(\mathbf{y} | \theta)$  on satunnaisvektorin  $\mathbf{Y}$  pntf, kun  $\tilde{\theta} = \theta$ , eli

$$f(\mathbf{y} | \theta) = P(\mathbf{Y} = \mathbf{y} | \tilde{\theta} = \theta).$$

- $p(\theta | \mathbf{y})$  on satunnaismuuttujan  $\tilde{\theta}$  pntf, kun  $\mathbf{Y} = \mathbf{y}$ , eli

$$p(\theta | \mathbf{y}) = P(\tilde{\theta} = \theta | \mathbf{Y} = \mathbf{y})$$

- $f(\mathbf{y})$  on satunnaisvektorin  $\mathbf{Y}$  reunajakauman pntf, eli

$$f(\mathbf{y}) = P(\mathbf{Y} = \mathbf{y})$$

# Reunajakaumat yhteisjakaumasta

Satunnaismuuttujien  $\tilde{\theta}$  ja  $\mathbf{Y}$  reunapistetodennäköisyysfunktiot saadaan niiden yhteispistetodennäköisyysfunktioista kokonaistodennäköisyyden kaavalla, nimittäin

$$p(\theta) = P(\tilde{\theta} = \theta) = \sum_{\mathbf{y}} P(\tilde{\theta} = \theta, \mathbf{Y} = \mathbf{y}) = \sum_{\mathbf{y}} f_{\tilde{\theta}, \mathbf{Y}}(\theta, \mathbf{y}) \quad (6)$$

$$f(\mathbf{y}) = P(\mathbf{Y} = \mathbf{y}) = \sum_{\theta} f_{\tilde{\theta}, \mathbf{Y}}(\theta, \mathbf{y}). \quad (7)$$

# Yhteisjakauma reunajakaumasta ja ehdollisesta jakaumasta

Todennäköisyyksien kertolaskukaavan (2) mukaan yhteispistetodennäköisyysfunktio voidaan jakaa tekijöihin molemmilla seuraavista tavoista

$$f_{\tilde{\theta}, \mathbf{Y}}(\theta, \mathbf{y}) = p(\theta) f(\mathbf{y} | \theta) = f(\mathbf{y}) p(\theta | \mathbf{y}). \quad (8)$$



# Bayesin kaava

- Bayesin kaava tapahtuman  $\tilde{\theta} = \theta$  todennäköisyydelle ehdolla  $\mathbf{Y} = \mathbf{y}$  saadaan ratkaistua edellisestä identiteetistä, nimittäin

$$p(\theta | \mathbf{y}) = \frac{p(\theta) f(\mathbf{y} | \theta)}{f(\mathbf{y})}. \quad (9)$$

- Bayesiläisessä päättelyssä parametria pidetään satunnaismuuttujana  $\tilde{\theta}$  joka saa jonkin arvon parametriavaruudessa  $\Theta$ .
- Jos aineiston otantajakauma on diskreetti ja parametriavaruus on diskreetti, niin bayesiläinen päättely perustuu suoraan Bayesin kaavaan.

# Priorista posterioriin

- Ennen (lat. *a priori*) havaintojen tekoa parametrilla on ns. **priorijakauma** (engl. *prior distribution*) eli jakauma, jonka ptnf on  $p(\theta)$ .
- Seuraavaksi tehdään havainto  $\mathbf{Y} = \mathbf{y}$ .
- Bayesiläinen päättely tarkoittaa sitä, että havaintojen jälkeen (lat. *a posteriori*) priorikäsitys päivitetään siirtymällä havaintoja vastaavaan ehdolliseen jakaumaan.
- Ennakkokäsitys päivitetään Bayesin kaavalla havaintojen jälkeiseksi käsitykseksi käyttämällä hyväksi priorijakaumaa ja havaintoja vastaavaa uskottavuusfunktiota  $f(\mathbf{y} | \theta)$ .
- Tulos on parametrin **posteriorijakauma** (engl. *posterior distribution*), eli parametrin ehdollinen jakauma  $p(\theta | \mathbf{y})$  ehdolla  $\mathbf{Y} = \mathbf{y}$ .

# Avainkaava: posteriori $\propto$ priori $\times$ uskottavuus

- Merkintä  $\propto$  tarkoittaa verrannollisuutta: posteriori on vakio kertaa priorin ja uskottavuusfunktion tulo, kun lausekkeita ajatellaan muuttujan  $\theta$  funktiona.
- Ts. kalvon otsikossa väitetään, että

$$p(\theta | \mathbf{y}) = C p(\theta) f(\mathbf{y} | \theta), \quad \text{kaikilla } \theta, \quad (10)$$

ja tämän on totta, sillä

$$C = \frac{1}{f(\mathbf{y})} = \frac{1}{\sum_{\theta=0}^N p(\theta) f(\mathbf{y} | \theta)}$$

- Verrannollisuusvakio  $C$  toki riippuu havainnoista  $\mathbf{y}$ , mutta muuttujan  $\theta$  funktiona ajateltuna se on vakio.

# Bayesiläisen ja frekventistisen ajattelun ero

- Bayesiläisessä analyysissä havaintoja vastaavalle satunnaisvektorille kiinnitetään sen havaittu arvo, ja sitten pohditaan eri parametrin arvojen todennäköisyyksiä.
- Frekventistisessä analyysissä parametri on kiinteä, ja todennäköisyyyslaskentaa käytetään aineistoa vastaavan satunnaisvektorin jakauman ja siitä johdettujen tunnuslukujen jakaumien johtamiseen erilaisilla hypoteettisilla parametrin arvoilla.
- Useimmat frekventistisen tilastotieteen käsitteet perustuvat sellaisten potentiaalisten aineistojen ominaisuuksien pohtimiseen, joita ei kokeessa havaittu.

# Algoritmi: posteriori priorista ja uskottavuudesta

Voimme ajatella, että bayesiläisessä analyysissä diskreetin parametrin tapauksessa lasketaan priorin ja uskottavuuden tulo kaikilla mahdollisilla parametrin arvoilla, jonka jälkeen tulos normalisoidaan pistetodennäköisyysfunktioiksi.

1 Laske

$$s = \sum_{\theta} p(\theta) f(\mathbf{y} | \theta). \quad (11)$$

2 Laske

$$p(\theta | \mathbf{y}) = \frac{p(\theta) f(\mathbf{y} | \theta)}{s}, \quad \theta \in \Theta. \quad (12)$$

## 10.2 Pallot kulhossa: diskreetti parametri

- Kulhossa on  $N$  palloa:  $\theta$  valkoista ja  $N - \theta$  mustaa.
- Valkoisten pallojen lukumäärä  $0 \leq \theta \leq N$  on tuntematon. Palloja nostetaan satunnaisesti ja palauttaen  $n$  kertaa.
- Oletetaan nyt, että luontoäiti on laittanut pallot kulhoon sillä tavalla, että hän ensin arpoi valkoisten pallojen lukumääräksi  $\theta$  yhden luvuista  $0, 1, \dots, N$  siten, että kaikki vaihtoehdot ovat yhtä todennäköisiä. Sen jälkeen hän laittoi kulhoon  $\theta$  valkoista ja  $N - \theta$  mustaa palloa.
- Lopuksi pallojen poiminta tuottaa jonkin jonon  $\mathbf{y} = (y_1, y_2, \dots, y_n)$  onnistumisia (valkoinen pallo:  $y_i = 1$ ) tai epäonnistumisia (musta pallo:  $y_i = 0$ ).

# Kohti posteriorijakaumaa

- Vastaavien satunnaismuuttujien  $Y_1, \dots, Y_n$  yhteispistetodennäköisyysfunktio tunnetaan, jos  $\theta$  tunnetaan, sillä se on

$$f(\mathbf{y} \mid \theta) = \left(\frac{\theta}{N}\right)^{t(\mathbf{y})} \left(1 - \frac{\theta}{N}\right)^{n-t(\mathbf{y})}, \quad (13)$$

jossa  $t(\mathbf{y}) = \sum_i y_i$  on onnistumisten lukumäärä.

- Kun nyt on havaittu tietty jono  $\mathbf{y}$  niin sitten kysytään, millä todennäköisyydellä kulhossa on  $\theta$  kappaletta valkoisia palloja.
- Kun tähän kysymykseen vastataan kaikilla mahdollisilla parametrin  $\theta$  arvoilla  $0, 1, \dots, N$ , saadaan tuloksena posteriorijakauma.

- Ennen havaintoja satunnaismuuttujan  $\tilde{\theta}$  jakauma eli priorijakauma on tilanteen kuvauksen perusteella diskreetti tasajakauma, jonka pistetodennäköisyysfunktio on

$$p(\theta) = \frac{1}{N+1}, \quad \theta = 0, 1, \dots, N.$$

- **Esimerkki:** Kulhossa on  $N = 5$  palloa ja nostoja tehdään  $n = 7$  ja tulokset ovat  $\mathbf{y} = (1, 0, 0, 0, 1, 0, 0)$ , eli onnistumisia on  $x = 2$  kappaletta. Lasketaan R:llä priorin ja uskottavuusfunktion tulo, ja normalisoidaan se posteriorijakaumaksi.



# Priori ja uskottavuusfunktio

```
N <- 5
n <- 7
x <- 2
param.space <- 0:N
print(prior <- rep(1, N + 1)/(N + 1))

## [1] 0.1667 0.1667 0.1667 0.1667 0.1667 0.1667

print(likelihood <- (param.space/N)^x * (1 - param.space/N)^(n -
  x))


## [1] 0.0000000 0.0131072 0.0124416 0.0036864 0.0002048 0.0000000
```

# Posteriori

```
h <- prior * likelihood
posterior <- h/sum(h)
names(posterior) <- as.character(param.space)
print(posterior)

##          0          1          2          3          4          5
## 0.000000 0.445217 0.422609 0.125217 0.006957 0.000000

plot(param.space, posterior, "h")
```



- Tasaisesti priorista seuraa se, että posteriorijakauma on yhtä kuin uskottavuusfunktio normalisoituna todennäköisyysjakaumaksi.
- Havaintojen jälkeen parametrin todennäköisin arvo on 1, mutta arvo 2 on lähes yhtä todennäköinen.
- Huomaa, että nyt on paikallaan puhua parametrin todennäköisyydestä (ennen ja jälkeen havaintojen teon); enää ei tarvitse puhua esim. uskottavuudesta.

## 10.3 Priorin ja posteriorin tulkitseminen epävarmuuden kuvauksina

- Edellisen jakson laskuissa ei ole mitään kiistanalaista, vaan ne seuraavat suoraan todennäköisyyslaskennan sääntöjen avulla tilanteen kuvauksesta.
- Kuitenkin bayesiläistä päättelyä pidettiin tilastotieteilijöiden piirissä yleisesti ainakin 1920–1960 luvuilla vanhentuneena ja suorastaan tuomittavana tapana lähestyä tilastollisen päättelyn ongelmia.
- Nykypäivänä tilastotieteen ammattilehdissä suurin osa artikkeleista käyttää tavalla tai toisella bayesiläistä lähestymistapaa.
- Yritän tässä jaksossa valottaa, mikä asia bayesiläisessä päättelyssä aikanaan aiheutti tämän voimakkaan vastustuksen.

# Mikä bayesiläisessä lähestymistavassa arvelutti

- Bayesiläistä lähestymistapaa sovelletaan myös tilanteissa, joissa parametrin arvoa ei määrää satunnaismekanismi.
- Tällöin priorijakauma ei kuvaa todellista arpomista, vaan se pitää ymmärtää kvantitatiivisena kuvauksena soveltajan epävarmuudesta parametrin todellisesta arvosta ennen havaintojen tekemistä.
- Posteriorijakauman tulkinnaiksi tulee puolestaan se, että se on kvantitatiivinen kuvaus epävarmuudesta parametrin todellisesta arvosta, kun havainnot on otettu huomioon.

# Kiistan ydin

- Kiistan ydin oli siinä, että frekventistisen tilastotieteen perustajat eivät hyväksyneet sitä ajatusta, että todennäköisyysjakauma saataisiin tulkita **subjektiivisena** epävarmuuden kuvauksena.
- Heidän mielestään todennäköisyyden käsite oli **objektiivinen**, ja sitä saadaan käyttää ainoastaan sellaisissa tilanteissa, jossa jotakin koetta (jossakin mielessä) toistetaan useita kertoja.
- Nykyaikana bayesiläisessä päättelyssä lähes aina käytetään todennäköisyyden subjektiivista tulkintaa epävarmuuden kvantitatiivisena kuvauksena silloin, kun puhutaan parametrin todennäköisyysjakaumasta. Tätä ajatusta ei nykyään enää koeta ongelmallisena.

# Bayesiläinen päättely on subjektiivista

- Posteriorijakauma on tällöin tietenkin subjektiivinen, sillä se riippuu siitä, minkälaista priorijakaumaa kyseinen subjekti pitää hyvänä kuvauksena omasta epävarmuudestaan.
- Priorijakaumalla on voimakas vaikutus posteriorijakaumaan, mikäli otoskoko on pieni.
- Jos otoskoko on suuri, niin tällöin erilaisilla järkevillä prioreilla saavutetaan lähes samanlainen posteriorijakauma.
- Oskoon kasvaessa järkevien soveltajien subjektiiviset posteriorijakaumat alkavat siis muistuttaa yhä enenevässä määrin toisiaan.

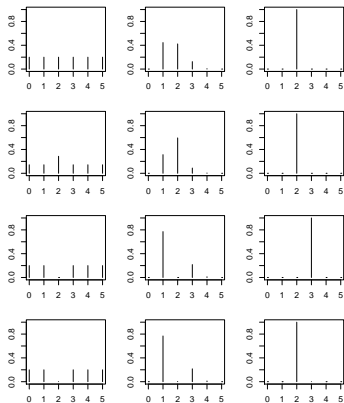
# Henkilöiden A, B, C ja D posteriorit

Kohta näytetään posteriorijakaumat pallot kulhossa -tilanteessa: ensin seitsemän noston (2 onnistumista) ja sitten 300 noston (133 onnistumista) jälkeen.

- A:n priorijakauma on tasajakauma arvoilla  $0, 1, \dots, 5$ .
- B:n ennakkokäsitys tukee kahden pallon vaihtoehtoa. B:n priorijakauman mukaan valkoisten pallojen lukumäärä 2 on kaksi kertaa todennäköisempi kuin muut, jotka puolestaan ovat keskenään yhtä todennäköisiä.
- C on dogmaattinen kahden pallon teorian vastustaja. C:n ennakkokäsityksen mukaan arvo 2 on täysin mahdoton, ja kaikki muut mahdollisuudet ovat yhtä todennäköisiä.
- D vastustaa kiivaasti kahden pallon teoriaa. D:n ennakkokäsityksen mukaan arvolla 2 on todennäköisyys  $1/1000$ , ja kaikki muut arvot ovat keskenään yhtä todennäköisiä.



# Tulokset kuvana



# Tulosten tulkintaa

- Otoskoolla  $n = 7$  posteriorijakaumat riippuvat vahvasti kunkin henkilön priorikäsityksistä, mutta henkilöt C ja D ovat käytännössä yhtä mieltä eri valkoisten pallojen lukumäärän todennäköisyyksistä.
- Otoskoolla  $n = 300$  kaikkien muiden henkilöiden paitsi C:n posteriorikäsitykset ovat käytännössä yhtenevät.
- C sulkee omalla priorin valinnallaan kokonaan pois sen mahdollisuuden, että valkoisia palloja voisi kulhossa olla kaksi.
- Tämän takia C:n posterioritodennäköisyys kahdelle valkoiselle pallolle on aina nolla riippumatta lainkaan siitä, mitä havaintoja saadaan.
- Nyt aineisto todistaa otoskoolla  $n = 300$  vahvasti sen puolesta, että valkoisia palloja olisi kulhossa todellisuudessa kaksi kappaletta, ja henkilöt A, B ja D ovat käytännössä täysin vakuuttuneita tästä asiasta.

Sellaista dogmaattista priorin valintaa (kuten C:n priorin), joka sulkee kokonaan pois jonkin järkevä osan parametriavaruudesta voidaan pitää bayesiläisen päättelyn pelisääntöjen vastaisena.

## 10.4 Nasta purkissa: jatkuva parametri

- Tässä tilanteessa binomikokeen onnistumistodennäköisyydellä on jokin arvo avoimelta väliltä  $(0, 1)$ .
- Jos tämä arvo  $\theta$  tunnetaan, niin havaintosatunnaisvektorin pistetodennäköisyysfunktio on

$$f(\mathbf{y} \mid \theta) = \theta^{t(\mathbf{y})} (1 - \theta)^{n-t(\mathbf{y})},$$

kun  $\mathbf{y} = (y_1, \dots, y_n)$  on jono nollia tai ykkösiä, ja  $t(\mathbf{y}) = \sum_i y_i$  on onnistumisten lukumäärä  $n$  toistossa.

- Nyt parametriavaruus on jatkuva, ja tämä tuo mukanaan uusia teknisiä ongelmia.

# Jatkuvasti jakautunut parametri

- Parametri  $\tilde{\theta}$  on nyt jatkuvasti jakautunut satunnaismuuttuja, jonka arvot kuuluvat parametriavaruuteen  $\Theta = (0, 1)$ .
- Ennen havaintojen tekoa soveltajan pitää onnistua kuvaamaan oma epävarmuutensa parametrin arvoista priorijakaumalla, jonka tiheysfunktioita merkitsemme

$$p(\theta), \quad \theta \in \Theta.$$

- Havaintojen jälkeen siirrytään tarkastelemaan parametrin ehdollista tiheysfunktioita eli sen posteriorijakaumaa.

# Jatkuvassa tapauksessa summaus korvataan integroinnilla

- Suuri osa jakson 10.1 kaavoista pitää sellaisenaan paikkansa myös tässä uudessa tilanteessa, mutta summaus pitää korvata integroinnilla.
- Yhteisjakauma voidaan esittää funktion

$$f_{\tilde{\theta}, \mathbf{Y}}(\theta, \mathbf{y}) = p(\theta) f(\mathbf{y} | \theta)$$

avulla.

- Se on muuttujan  $\theta$  suhteen tiheysfunktio ja muuttujan  $\mathbf{y}$  suhteen pistetodennäköisyysfunktio, ts. todennäköisyyksiä lasketaan integroimalla muuttujan  $\theta$  suhteen ja summaamalla muuttujan  $\mathbf{y}$  suhteen.

# Bayesin kaava

- Bayesin kaava saa muodon

$$p(\theta | \mathbf{y}) = \frac{p(\theta) f(\mathbf{y} | \theta)}{f(\mathbf{y})}.$$

- Nyt normalisointivakio  $f(\mathbf{y})$  pitää laskea integroimalla,

$$f(\mathbf{y}) = \int_0^1 p(\theta) f(\mathbf{y} | \theta) d\theta.$$

- Tätä integraalia ei yleisesti ottaen osata laskea analyyttisesti.
- Posteriorijakauman tiheysfunktion kuva voidaan piirtää käyttämällä verrannollisuustulosta

$$p(\theta | \mathbf{y}) \propto p(\theta) f(\mathbf{y} | \theta),$$

mikäli tyydytään siihen, että  $y$ -akselin skaala jää selvittämättä.

## 10.5 Liittojakauma eli konjugaattijakauma

- Joillekin uskottavuusfunktioille on mahdollista löytää sellainen parametrinen perhe jakaumia, että mikäli priorijakauma valitaan kyseisestä perheestä, niin myös posteriorijakauma kuuluu samaan perheeseen.
- Binomikokeen uskottavuusfunktioille beeta-jakaumat muodostavat tällaisen perheen.
- Tämä voidaan ilmaista sanomalla, että beeta-jakauma on binomiuskottavuuden **liittopriori** (engl. *conjugate prior*) tai että havaintosatunnaisvektorin otantajakauma ja priorijakauma ovat toistensa liittojakaumia.



# Priorin päivittäminen posterioriksi

- Mikäli tutkijan ennakkokäsitys parametrarvosta voidaan esittää jollakin liittoperheen jakaumalla, niin tällöin posteriorijakauma saadaan laskettua johtamalla päivityskaavat, joilla priorijakauman parametrit päivitetään posteriorijakauman parametreiksi.
- Kutsutaan näitä liittojakaumaperheen parametreja selvyiden vuoksi hyperparametreiksi, jotta ne saadaan erotettua tilastollisen mallin parametrasta  $\theta$ .

# Beeta-jakauma

- Beeta-jakauma on jatkuva jakauma, jonka tiheysfunktio on muotoa

$$g(x) \propto x^{\alpha-1} (1-x)^{\beta-1}, \quad \text{kun } 0 < x < 1, \quad (14)$$

missä  $\alpha > 0$  ja  $\beta > 0$  ovat jakaumaperheen parametrit.

- Tämä lauseke määrittelee yksikäsitteisesti tietyn todennäköisyysjakauman, jonka tiheysfunktio saadaan selville jakamalla lauseke sen välin  $(0, 1)$  yli lasketulla integraalilla, sillä tiheysfunktion integraalin koko satunnaismuuttujan arvoalueen yli täytyy olla yksi.

# Beeta-jakauman normalisointivakio

- Kaavassa (14) merkitsemättä jätetty normalisointivakio saadaan ns. Eulerin beetafunktion

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

avulla (jossa  $B$  on iso beeta-kirjain).

- Beeta-jakauman tiheysfunktion täydellinen kaava on

$$g(x) = \begin{cases} \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, & \text{kun } 0 < x < 1, \\ 0 & \text{muuten.} \end{cases} \quad (15)$$

- Erityisesti valinnoilla  $\alpha = 1$  ja  $\beta = 1$  saadaan välin  $(0, 1)$  tasajakauma.

# Beeta-jakauman $Be(\alpha, \beta)$ ominaisuuksia

- Jakaumaa noudattavan satunnaismuuttujan  $X$  arvot ovat välillä  $(0, 1)$ .
- Sen odotusarvo ja varianssi saadaan laskettua tunnetuilla kaavoilla

$$EX = \frac{\alpha}{\alpha + \beta}, \quad \text{var } X = \frac{\alpha \beta}{(\alpha + \beta)^2 (\alpha + \beta + 1)}. \quad (16)$$

- Jakauman moodi (eli tiheysfunktion maksimipiste) on

$$\frac{\alpha - 1}{\alpha + \beta - 2},$$

mikäli  $\alpha > 1$  ja  $\beta > 1$  (muilla parametrinarvoilla jakaumalla ei ole hyvin määriteltyä moodia).

Tarkistetaan nyt, että beeta-jakauma on binomiuskottavuuden liittopriori. Priorin hyperparametrit ovat  $\alpha, \beta > 0$  ja onnistumisia havaitaan  $k$  kappaletta. Tarkistuksen voi tehdä kahdella erilaisella tavalla.

## Tapa 2: verrannollisuustarkastelu

Muuttujan  $\theta$  funktiona posteriorijakauman tiheys on verrannollinen priorijakauman tiheyden ja uskottavuusfunktion tuloon, joten välillä  $0 < \theta < 1$  pätee verrannollisuus

$$\begin{aligned} p(\theta | \mathbf{y}) &\propto p(\theta) f(\mathbf{y} | \theta) \\ &= \theta^{\alpha-1} (1 - \theta)^{\beta-1} \theta^k (1 - \theta)^{n-k} \\ &= \theta^{\alpha+k-1} (1 - \theta)^{\beta+n-k-1}. \end{aligned}$$

Vertaamalla tulosta kaavaan (14) nähdään, että posteriorijakauma on beeta-jakauma

$$\text{Be}(\alpha + k, \beta + n - k),$$

sillä ainoa todennäköisyysjakauma, jonka kantaja on  $(0, 1)$  ja jonka tiheysfunktio on verrannollinen johdettuun funktioon on tämä beeta-jakauma.

## 10.6 Posteriorijakauman yhteenvetoja

- Kun posteriorijakauma on selvitetty, niin siitä voidaan lopuksi laskea tiettyjä yhteenvetoja.
- Jos posteriorijakauma on ennestään tuttu yksinkertainen jakauma, niin tämä vaihe voidaan sivuuttaa.

# Posteriorijakauman keskikohdan luonnehdinta

- Posteriorijakauman keskikohtaa voidaan luonnehtia parametrin posterioriodotusarvolla eli binomikokeen tapauksessa luvulla

$$E[\tilde{\theta} | \mathbf{y}] = \int_0^1 \theta p(\theta | \mathbf{y}) d\theta.$$

- Beeta-jakaumalle tulos voidaan lukea suoraan beeta-jakauman odotusarvon kaavasta (16), kun siihen sijoitetaan posteriorijakauman hyperparametrit, jotka ovat binomikokeessa

$$\alpha_1 = \alpha + k, \quad \beta_1 = \beta + n - k.$$

- Vastaavasti voidaan laskea posteriorimoodi eli posteriorijakauman moodi.
- Posterioriodotusarvoa ja posteriorimoodia voidaan ajatella bayesiläisinä piste-estimaatteina.



- Posteriorijakauman keskittyneisyyttä voidaan kuvailla esim. laskemalla parametrin posteriorivarianssi eli posteriorijakauman varianssi.

# Bayesiläinen luottamusväli

- Mikäli posteriorijakauman kvantiilifunktion  $q(u)$  arvoja osataan laskea, niin sen jälkeen parametriavaruudesta löytyy helposti väli  $[L, U]$ , jolle

$$P(L \leq \tilde{\theta} \leq U \mid \mathbf{Y} = \mathbf{y}) = 1 - \alpha$$

millä tahansa annetulla  $0 < \alpha < 1$ .

- Eräs tällainen väli saadaan jakamalla virhetodennäköisyys  $\alpha$  tasan alemman ja ylemmän jakauman hännän kesken valitsemalla

$$L = q(\alpha/2), \quad U = q(1 - \alpha/2).$$

- Liittojakaumien tilanteessa tarvittava kvantiilifunktio löytyy valmiina tilastollisista ohjelmistoista.
- Tällaista väliä voidaan kutsua tason  $1 - \alpha$  todennäköisyysväliksi tai bayesiläiseksi luottamusväliksi.

# Bayesiläinen hypoteesintestaus

- Mikäli ollaan kiinnostuneita muotoa

$$\tilde{\theta} \in A$$

olevasta hypoteesista, niin sen todennäköisyys havainnon jälkeen voidaan (periaatteessa) laskea integroimalla posteriorijakauman tiheysfunktiota

$$P(\tilde{\theta} \in A) = \int_A p(\theta | \mathbf{y}) d\theta.$$

- Jos posteriorijakauman kertymäfunktio osataan laskea ja jos  $A$  on väli, niin välin  $A$  posterioritodennäköisyys saadaan laskemalla kertymäfunktion arvot välin päätepisteissä sekä laskemalla suuremman arvon ja pienemmän arvon erotus.
- Vastahypoteesin  $\tilde{\theta} \notin A$  todennäköisyys havainnon jälkeen saadaan sitten vähentämällä luvusta yksi tarkasteltavan hypoteesin todennäköisyys.

# Bayesiläinen hypoteesintestaus liittojakaumien tilanteessa

- Jos käytetään uskottavuusfunktion liittoprioria, niin posteriorijakauman kertymäfunktio löytyy valmiiksi toteutettuna tilastollisista ohjelmistoista.

- Koska parametria käsitellään satunnaismuuttujana, niin päästään puhumaan parametrin todennäköisyyksistä tai parametrin todennäköisyysjakaumasta tai kyseisen jakauman ominaisuuksista havainnon tekemisen jälkeen.
- Johdot ovat periaatteessa täysin suoraviivaisia ja niissä tarvitaan ainoastaan todennäköisyyslaskentaa, eikä mitään sen ulkopuolisia periaatteita.
- Monimutkaisten tilastollisten mallien yhteydessä vaadittavat laskut ovat kuitenkin liian hankalia analyttisesti suoritettaviksi.

## 10.7 Bayesiläisen päättelyn laskentamenetelmiä

Posteriorijakauma saadaan selvitettyä kaavojen avulla seuraavissa tilanteissa.

- 1 Jos parametri on diskreetti ja sillä on äärellinen määrä mahdollisia arvoja.
- 2 Jos käytetään priorijakaumaa, joka kuuluu uskottavuusfunktion liittoperheeseen.

Muissa tapauksissa ei saada johdettua käyttökelpoisia analyttisiä kaavoja.

# Monte Carlo -menetelmä bayesiläiseissä laskennassa

- Nykyään bayesiläinen analyysi tehdään tietokoneen avulla.
- Laskentamenetelmät perustuvat tyypillisesti satunnaisuuden simulointiin tietokoneen avulla eli ns. Monte Carlo -menetelmiin.
- Perustana on se ajatus, että koska posteriorijakauma on todennäköisyysjakauma, niin sitä voidaan yrittää simuloida tietokoneella.
- On kehitetty menetelmiä, joissa lasketaan suuri määrä arvoja  $t_1, \dots, t_N$ , joita voidaan pitää sellaisten satunnaismuuttujien  $\tilde{\theta}_1, \dots, \tilde{\theta}_N$  havaittuina arvoina, joista kukin on jakautunut posteriorijakauman mukaisesti.
- Tämän jälkeen otosta  $t_1, \dots, t_N$  käsitellään data-analyysin keinoin.

# Mitä kaikkia asioita voidaan selvittää, jos käytössä on otos posteriorijakaumasta

- Posterioriodotusarvoa voidaan arvioida vastaavilla otoskeskiarvoilla,

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

- Parametrille voidaan muodostaa bayesiläisiä luottamusvälejä otoksesta laskettujen kvantiilipisteiden avulla.
- Posteriorijakauman pistetodennäköisyysfunktioita voidaan arvioida vastaavilla suhteellisilla frekvensseillä (diskreetin parametrin tapauksessa).
- Posteriorijakauman tiheysfunktioita voidaan arvioida esim. histogrammilla (jatkuvan parametrin tapauksessa).
- Mielivaltaisen parametrin funktion  $g(\tilde{\theta})$  posteriorijakauman ominaisuuksia (esim. posterioriodotusarvoa tai posteriorijakaumaa) voidaan selvittää otoksesta  $g(t_1), \dots, g(t_N)$  aivan samoilla menetelmillä.



# Bayesiläisen päättelyn laskentamentelmistä

- Tällaiset menetelmät ovat suhteellisen uusia: intensiivinen kehitysvaihe alkoi 1980-luvun lopulla.
- Niiden ansiosta nykyään on mahdollista analysoida lähes mielivaltaisen monimutkaisia bayesiläisiä tilastollisia malleja.