

9 Moniulotteinen jakauma

- Moniulotteisella satunnaisvektorilla voi olla useampi kuin kaksi komponenttia.
- Sen jakaumaa kuvaillaan samaan tapaan kuin kaksiulotteisen satunnaisvektorin jakaumaa.
- Suurin osa tämän luvun ideoista on ennestään tuttuja, eikä tuttuja tuloksia enää perustella uudestaan.
- Tilastotieteilijä tarvitsee moniulotteisia jakaumia sen takia, että hän voisi määritellä ja analysoida tilastollisia malleja.

Moniulotteisuudesta johtuvia uusia asioita

- Reunajakauma voidaan määritellä mille tahansa komponenttien osajoukolle.
- Ehdollisia jakaumia voidaan laskea ehdollistamalla millä tahansa komponenttien osajoukolla.
- Ehdollinen riippumattomuus on käsite, joka ei ole mielekäs kuin vasta dimensioissa kolmesta eteenpäin.
- Moniulotteisten jakaumien havainnollistaminen on hankalaa. Kuvien piirtäminen ei onnistu korkeissa dimensioissa, vaan niiden sijasta pitää luottaa kaavojen manipulointiin.

9.1 Satunnaisvektori

- Jos X_1, \dots, X_n ovat samalla perusjoukolla Ω määriteltyjä satunnaismuuttujia, niin $\mathbf{X} = (X_1, \dots, X_n)$ on n -ulotteinen satunnaisvektori (lyh. sv).
- Ts. satunnaisvektori on kuvaus $\Omega \rightarrow \mathbb{R}^n$ siten, että

$$\mathbf{X}(\omega) = (X_1(\omega), \dots, X_n(\omega)) = \begin{bmatrix} X_1(\omega) \\ \vdots \\ X_n(\omega) \end{bmatrix}$$

Diskreetisti jakautunut satunnaisvektori

- Jos kaikki satunnaisvektorin \mathbf{X} komponentit X_i ovat diskreettejä sm:ia, niin sen ptnf eli sm:ien X_i yhteispistetodennäköisyysfunktio (yptnf) on

$$f_{\mathbf{X}}(\mathbf{x}) = P(\mathbf{X} = \mathbf{x}) = P(X_1 = x_1, \dots, X_n = x_n). \quad (1)$$

- Jos $g(\mathbf{X})$ on sv:n \mathbf{X} reaaliarvoinen muunnos, niin sen odotusarvo saadaan kaavalla (tiedostamattoman tilastotieteilijän laki diskreetissä tapauksessa).

$$Eg(\mathbf{X}) = \sum_{\mathbf{x}} g(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}), \quad (2)$$

mikäli kyseinen summa suppenee itseisesti

Jatkuvasti jakautunut satunnaisvektori

- Satunnaisvektorilla \mathbf{X} on jatkuva jakauma, mikäli sillä on tiheysfunktio $f_{\mathbf{X}}$.
- Tämä tarkoittaa sitä, että

$$P(\mathbf{X} \in B) = \int_B f_{\mathbf{X}} = \int_B f_{\mathbf{X}}(\mathbf{x}) \, d\mathbf{x}, \quad \text{kaikilla } B \subset \mathbb{R}^n. \quad (3)$$

- Tällöin sen komponenteilla X_1, \dots, X_n on jatkuva yhteisjakauma, ja tiheysfunktioita

$$f_{X_1, \dots, X_n}(x_1, \dots, x_n) = f_{\mathbf{X}}(\mathbf{x}), \quad \mathbf{x} = (x_1, \dots, x_n)$$

kutsutaan sm:ien X_1, \dots, X_n yhteistiheysfunktioiksi.

Kuinka n -kertainen integraali lasketaan

Edellä kyseessä on n -kertainen integraali,

$$\int_B f_{\mathbf{X}}(\mathbf{x}) \, d\mathbf{x} = \int \cdots \int 1_B(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}) \, dx_1 \cdots dx_n,$$

joka voidaan laskea **iteroituna integraalina** käyttämällä mielivaltaista integrointijärjestystä.

Tiedostamattoman tilastotieteilijän laki jatkuvassa tapauksessa

- Jos $g(\mathbf{X})$ on sv sv:n \mathbf{X} reaaliarvoinen muunnos, niin sen odotusarvo saadaan kaavalla

$$Eg(\mathbf{X}) = \int g(\mathbf{x}) f_{\mathbf{X}}(\mathbf{x}) d\mathbf{x} \quad (4)$$

mikäli kyseinen integraali suppenee itseisesti.

- Tämä integraali voidaan laskea iteroituna integraalina käyttäen mielivaltaista integrointijärjestystä.
- Kun integrointijoukkoa ei merkitä näkyviin, tarkoitetaan koko avaruuden (tässä \mathbb{R}^n) yli laskettua integraalia.
- Jos dimensio $n \geq 2$, niin tämä merkintä ei sekaannu **määrämättömän integraalin** (engl. *indefinite integral*) merkinnän kanssa, sillä määrämättömän integraalin käsitettä käytetään vain dimensiossa yksi.

Ytf:n ja ykf:n välinen yhteys

- Jatkuvan (yhteis)jakauman tapauksessa ykf on

$$F_{\mathbf{X}}(\mathbf{x}) = \int_{s_1=-\infty}^{x_1} \cdots \int_{s_n=-\infty}^{x_n} f_{\mathbf{X}}(s_1, \dots, s_n) ds_1 \cdots ds_n.$$

- Kun tätä funktiota derivoidaan osittain jokaisen argumenttinsa suhteen, nähdään että

$$\frac{\partial^n F_{\mathbf{X}}(x_1, \dots, x_n)}{\partial x_1 \cdots \partial x_n} = f_{\mathbf{X}}(x_1, \dots, x_n),$$

ainakin niissä pisteissä (x_1, \dots, x_n) , joissa $f_{\mathbf{X}}$ on jatkuva.

- Voidaan osoittaa, että tämä funktio kelpaa jatkuvasti jakautuneen sv:n tiheysfunktioksi (kun se jatketaan mielivaltaisesti niissä pisteissä, joissa ko. derivaatta ei ole olemassa).

Diskreetin ja jatkuvan sv:n yhteisjakauma

- Jos \mathbf{X} on diskreetti sv, ja \mathbf{Y} on jatkuvasti jakautunut sv, ja ne on määritelty samalla perusjoukolla Ω , niin silloin niiden yhteisjakauma voidaan esittää funktiolla

$$f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) = f_{\mathbf{X}}(\mathbf{x}) f_{\mathbf{Y}|\mathbf{X}}(\mathbf{y} | \mathbf{x}),$$

jossa $f_{\mathbf{X}}$ on sv:n \mathbf{X} reunajakauman (yhteis-)ptnf, ja $f_{\mathbf{Y}|\mathbf{X}}(\mathbf{y} | \mathbf{x})$ on sv:n \mathbf{Y} ehdollinen (yhteis-)tf ehdolla $\mathbf{X} = \mathbf{x}$.

- Jos $g(\mathbf{X}, \mathbf{Y})$ on reaaliarvoinen sm, niin sen odotusarvo saadaan kaavalla

$$Eg(\mathbf{X}, \mathbf{Y}) = \sum_{\mathbf{x}} \int g(\mathbf{x}, \mathbf{y}) f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) d\mathbf{y}, \quad (5)$$

mikäli kyseinen odotusarvo on olemassa.

9.2 Odotusarvovektori ja kovarianssimatriisi

Asetamme seuraavat määritelmät, mikäli kyseessä olevat odotusarvot ovat olemassa.

- Satunnaisvektorin $\mathbf{X} = (X_1, \dots, X_n)$ **odotusarvo** tai **odotusarvovektori** on n -komponenttinen vakiovektori

$$E\mathbf{X} = E(\mathbf{X}) = (EX_1, \dots, EX_n) = \begin{bmatrix} EX_1 \\ \vdots \\ EX_n \end{bmatrix}.$$

Satunnaismatriisin odotusarvo

- Dimensioltaan $m \times n$ olevan satunnaismatriisin $\mathbf{Z} = [Z_{ij}]$ **odotusarvo** tai **odotusarvomatriisi** on se $m \times n$ -vakiomatriisi, jonka alkio (i, j) on alkion Z_{ij} odotusarvo, ts.

$$E\mathbf{Z} = E \begin{bmatrix} Z_{11} & Z_{12} & \dots & Z_{1n} \\ Z_{21} & Z_{22} & \dots & Z_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ Z_{m1} & Z_{m2} & \dots & Z_{mn} \end{bmatrix} = \begin{bmatrix} EZ_{11} & EZ_{12} & \dots & EZ_{1n} \\ EZ_{21} & EZ_{22} & \dots & EZ_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ EZ_{m1} & EZ_{m2} & \dots & EZ_{mn} \end{bmatrix}.$$

Kahden satunnaisvektorin kovarianssi

- Satunnaisvektorien $\mathbf{X} = (X_1, \dots, X_n)$ ja $\mathbf{Y} = (Y_1, \dots, Y_k)$ (välinen) **kovarianssi** on $n \times k$ -matriisi

$$\begin{aligned} \text{cov}(\mathbf{X}, \mathbf{Y}) &= E[(\mathbf{X} - E\mathbf{X})(\mathbf{Y} - E\mathbf{Y})^T] \\ &= \begin{bmatrix} \text{cov}(X_1, Y_1) & \text{cov}(X_1, Y_2) & \dots & \text{cov}(X_1, Y_k) \\ \text{cov}(X_2, Y_1) & \text{cov}(X_2, Y_2) & \dots & \text{cov}(X_2, Y_k) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(X_n, Y_1) & \text{cov}(X_n, Y_2) & \dots & \text{cov}(X_n, Y_k) \end{bmatrix}. \end{aligned}$$

- $\text{cov}(\mathbf{X}, \mathbf{Y})$ on matriisi, joka sisältää kaikkien parien (X_i, Y_j) kovarianssit $\text{cov}(X_i, Y_j)$.
- Mikäli $\text{cov}(\mathbf{X}, \mathbf{Y}) = \mathbf{0}$, niin sanotaan, että satunnaisvektorit \mathbf{X} ja \mathbf{Y} eivät korreloi eli että ne ovat *korreloimattomat* (engl. *uncorrelated*).

Satunnaisvektorin kovarianssimatriisi

- Satunnaisvektorin $\mathbf{X} = (X_1, \dots, X_n)$ **kovarianssimatriisi** on $n \times n$ -matriisi

$$\begin{aligned} \text{Cov}(\mathbf{X}) &= \text{cov}(\mathbf{X}, \mathbf{X}) = E[(\mathbf{X} - E\mathbf{X})(\mathbf{X} - E\mathbf{X})^T] \\ &= \begin{bmatrix} \text{cov}(X_1, X_1) & \text{cov}(X_1, X_2) & \dots & \text{cov}(X_1, X_n) \\ \text{cov}(X_2, X_1) & \text{cov}(X_2, X_2) & \dots & \text{cov}(X_2, X_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(X_n, X_1) & \text{cov}(X_n, X_2) & \dots & \text{cov}(X_n, X_n) \end{bmatrix}. \end{aligned}$$

- Satunnaisvektorin kovarianssimatriisi on symmetrinen ja sen päälävistäjällä on komponenttisatunnaismuuttujien varianssit.
- Näissä merkinnöissä $\text{Cov}()$ on yhden argumentin funktio, ja $\text{cov}(,)$ on kahden argumentin funktio.

- Määritelmästä seuraa suoraan, että

$$E(\mathbf{Z}^T) = (E\mathbf{Z})^T. \quad (6)$$

- Laskusääntö

$$E[\mathbf{AZB} + \mathbf{C}] = \mathbf{A}(E\mathbf{Z})\mathbf{B} + \mathbf{C}, \quad (7)$$

on voimassa kun \mathbf{Z} on satunnaismatriisi ja \mathbf{A} , \mathbf{B} ja \mathbf{C} ovat vakiomatriiseja, joiden dimensiot ovat sellaiset, että lauseke on määritelty.

- Ts. vakiomatriisit saadaan vetää ulos odotusarvosta, jos ne sijaitsevat matriisitulossa äärimmäisenä vasemmalla tai äärimmäisenä oikealla.

Riippumattomuus

- Mikäli \mathbf{Y} ja \mathbf{Z} ovat satunnaisvektoreita, ja $\mathbf{G}(\mathbf{Y})$ ja $\mathbf{H}(\mathbf{Z})$ ovat matriisiarvoisia lausekkeita, niin

$$\mathbf{Y} \perp\!\!\!\perp \mathbf{Z} \quad \Rightarrow \quad \mathbf{G}(\mathbf{Y}) \perp\!\!\!\perp \mathbf{H}(\mathbf{Z}). \quad (8)$$

- Matriisilausekkeiden riippumattomuus tarkoittaa sitä, että kaikki matriisin $\mathbf{G}(\mathbf{Y})$ komponentit ovat riippumattomia kaikista matriisin $\mathbf{H}(\mathbf{Z})$ komponenteista.
- Riippumattomien satunnaisvektorien funktiot ovat keskenään riippumattomia.
- Koska tämä asia pätee matriisiarvoisille funktioille, se pätee tietenkin myös vektori- tai skalaariarvoisille funktioille.

Riippumattomien satunnaismatriisien tulon odotusarvo

Riippumattomuudesta ja matriisikertolaskun määritelmästä seuraa, että

$$\mathbf{Y} \perp\!\!\!\perp \mathbf{Z} \quad \Rightarrow \quad E[\mathbf{G}(\mathbf{Y}) \mathbf{H}(\mathbf{Z})] = E[\mathbf{G}(\mathbf{Y})] E[\mathbf{H}(\mathbf{Z})] \quad (9)$$

mikäli dimensiot ovat matriisitulossa $\mathbf{G}(\mathbf{Y}) \mathbf{H}(\mathbf{Z})$ yhteensopivat ja mikäli odotusarvot ovat olemassa.

Kahden satunnaisvektorin kovarianssin ominaisuuksia

- Jos $\mathbf{X} \perp \mathbf{Y}$, ja \mathbf{X} on m -komponenttinen ja \mathbf{Y} on n -komponenttinen, niin

$$\text{cov}(\mathbf{X}, \mathbf{Y}) = \mathbf{0}_{m \times n}.$$

- Sv:ien \mathbf{X} ja \mathbf{Y} kovarianssi voidaan laskea myös kaavalla

$$\text{cov}(\mathbf{X}, \mathbf{Y}) = E[\mathbf{X}\mathbf{Y}^T] - (E\mathbf{X})(E\mathbf{Y})^T.$$

- Jos $\mathbf{v} \in \mathbb{R}^m$ on vakiovektori, ja \mathbf{X} on n -komponenttinen sv, niin

$$\text{cov}(\mathbf{v}, \mathbf{X}) = \mathbf{0}_{m \times n}, \quad \text{cov}(\mathbf{X}, \mathbf{v}) = \mathbf{0}_{n \times m}.$$

- $\text{cov}(\mathbf{X}, \mathbf{Y}) = \text{cov}(\mathbf{Y}, \mathbf{X})^T$.
- Jos \mathbf{X}_1 , \mathbf{X}_2 ja \mathbf{Y} ovat satunnaisvektoreita, niin

$$\begin{aligned}\text{cov}(\mathbf{X}_1 + \mathbf{X}_2, \mathbf{Y}) &= \text{cov}(\mathbf{X}_1, \mathbf{Y}) + \text{cov}(\mathbf{X}_2, \mathbf{Y}), \\ \text{cov}(\mathbf{Y}, \mathbf{X}_1 + \mathbf{X}_2) &= \text{cov}(\mathbf{Y}, \mathbf{X}_1) + \text{cov}(\mathbf{Y}, \mathbf{X}_2).\end{aligned}$$

- Jos \mathbf{A} ja \mathbf{B} ovat vakiomatriiseja ja \mathbf{v} ja \mathbf{w} ovat vakiovektoreja, niin

$$\text{cov}(\mathbf{A}\mathbf{X} + \mathbf{v}, \mathbf{B}\mathbf{Y} + \mathbf{w}) = \mathbf{A} \text{cov}(\mathbf{X}, \mathbf{Y}) \mathbf{B}^T. \quad (10)$$

Erityisesti

$$\text{Cov}(\mathbf{A}\mathbf{X} + \mathbf{v}) = \mathbf{A} \text{Cov}(\mathbf{X}) \mathbf{A}^T. \quad (11)$$

Esimerkki: summan kovarianssimatriisi

- Jos satunnaisvektorit \mathbf{X} ja \mathbf{Y} ovat samanpituisia, niin

$$\begin{aligned}\text{Cov}(\mathbf{X} + \mathbf{Y}) &= \text{cov}(\mathbf{X} + \mathbf{Y}, \mathbf{X} + \mathbf{Y}) \\ &= \text{cov}(\mathbf{X}, \mathbf{X} + \mathbf{Y}) + \text{cov}(\mathbf{Y}, \mathbf{X} + \mathbf{Y}) \\ &= \text{cov}(\mathbf{X}, \mathbf{X}) + \text{cov}(\mathbf{X}, \mathbf{Y}) + \text{cov}(\mathbf{Y}, \mathbf{X}) + \text{cov}(\mathbf{Y}, \mathbf{Y}) \\ &= \text{Cov}(\mathbf{X}) + \text{Cov}(\mathbf{Y}) + \text{cov}(\mathbf{X}, \mathbf{Y}) + \text{cov}(\mathbf{Y}, \mathbf{X}).\end{aligned}$$

- Jos \mathbf{X} ja \mathbf{Y} eivät korreloi, niin $\text{cov}(\mathbf{X}, \mathbf{Y}) = \mathbf{0}$ ja $\text{cov}(\mathbf{Y}, \mathbf{X}) = \mathbf{0}$.
- Korreloimattomille satunnaisvektoreille summan kovarianssimatriisi on summattavien satunnaisvektoreiden kovarianssimatriisien summa. Tämä pitää erityisesti paikkansa riippumattomille satunnaisvektoreille.

Neliömatriisin mahdollisia ominaisuuksia

Neliömatriisi \mathbf{B} on

- **säännöllinen** eli **kääntyvä** eli **ei-singulaarinen**, jos sillä on olemassa käänteismatriisi \mathbf{B}^{-1} ;
- **symmetrinen**, jos $\mathbf{B}^T = \mathbf{B}$;
- **positiivisesti semidefiniitti**, jos $\mathbf{v}^T \mathbf{B} \mathbf{v} \geq 0$ kaikilla \mathbf{v} ;
- **positiivisesti definiitti**, jos $\mathbf{v}^T \mathbf{B} \mathbf{v} > 0$ kaikilla $\mathbf{v} \neq 0$.

Definiittisyys ja ominaisarvot

- On olemassa matriiseja, joiden kaikki alkiot ovat positiivisia, mutta jotka eivät ole positiivisesti semidefiniittejä, kuten esim.

$$\mathbf{B} = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}.$$

Valitsemalla $\mathbf{v} = (-1, 1)$ saadaan $\mathbf{v}^T \mathbf{B} \mathbf{v} = -2$.

- Definiittisyyden voi käsittää helposti ominaisarvojen etumerkkien avulla (mikäli ominaisarvot ovat tuttu käsite):
 - Symmetrinen matriisi \mathbf{B} on positiivisesti semidefiniitti jos ja vain jos kaikki sen ominaisarvot ovat suurempia tai yhtä kuin nolla.
 - Symmetrinen matriisi \mathbf{B} on positiivisesti definiitti jos ja vain jos kaikki sen ominaisarvot ovat aidosti suurempia kuin nolla.

Satunnaisvektorin kovarianssimatriisin definiittisyys

Lause

- Sv:n \mathbf{X} kovarianssimatriisi on symmetrinen ja positiivisesti semidefiniitti matriisi.
- Jos se ei ole positiivisesti definiitti, niin sv:n \mathbf{X} komponenttien välillä on lineaarisia sidosehtoja, eli \mathbf{X} saa todennäköisyydellä yksi arvoja vain tietyltä kiinteältä hypertasolta.
- *Seuraus:* Jos $\text{Cov } \mathbf{X}$ ei ole positiivisesti definiitti, niin \mathbf{X} :llä ei voi olla jatkuva jakauma, sillä hypertaso on alempiulotteisena pintana nollamittainen.
- Huomaa analogia satunnaismuuttujan Z varianssin $\text{var}(Z)$ ominaisuuksien kanssa.

- Kovarianssimatriisin symmetrisyys seuraa sen määritelmästä.
- Positiivinen semidefiniittisyys seuraa siitä, että

$$\begin{aligned}\mathbf{v}^T \text{Cov}(\mathbf{X})\mathbf{v} &= \mathbf{v}^T E[(\mathbf{X} - E\mathbf{X})(\mathbf{X} - E\mathbf{X})^T] \mathbf{v} \\ &= E[\mathbf{v}^T (\mathbf{X} - E\mathbf{X})(\mathbf{X} - E\mathbf{X})^T \mathbf{v}] = E \left[\left(\mathbf{v}^T (\mathbf{X} - E\mathbf{X}) \right)^2 \right] \geq 0,\end{aligned}$$

sillä ei-negatiivisen sm:n odotusarvo on ei-negatiivinen.

- Jos kovarianssimatriisi ei ole positiivisesti definiitti, niin on olemassa $\mathbf{v} \neq \mathbf{0}$ siten, että

$$0 = \mathbf{v}^T \text{Cov}(\mathbf{X})\mathbf{v} = E \left[\left(\mathbf{v}^T (\mathbf{X} - E\mathbf{X}) \right)^2 \right],$$

joten todennäköisyydellä yksi on

$$\mathbf{v}^T (\mathbf{X} - E\mathbf{X}) = 0.$$

9.3 Ehdolliset jakaumat, kertolaskusääntö ja ehdollinen odotusarvo

- Tarkastellaan sv:ia \mathbf{Z} , jonka r ensimmäistä koordinaattia muodostavat sv:n \mathbf{X} ja loput s koordinaattia sv:n \mathbf{Y} ,

$$\mathbf{Z} = (\mathbf{X}, \mathbf{Y}) = (X_1, \dots, X_r, Y_1, \dots, Y_s).$$

- Ehdolliset jakaumat $\mathbf{Y} \mid (\mathbf{X} = \mathbf{x})$ ja $\mathbf{X} \mid (\mathbf{Y} = \mathbf{y})$ hallitaan tutuilla kaavoilla:

$$f_{\mathbf{Y}|\mathbf{X}}(\mathbf{y} \mid \mathbf{x}) = \frac{f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y})}{f_{\mathbf{X}}(\mathbf{x})}, \quad f_{\mathbf{X}|\mathbf{Y}}(\mathbf{x} \mid \mathbf{y}) = \frac{f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y})}{f_{\mathbf{Y}}(\mathbf{y})}.$$

- Miten reunajakaumien tiheydet lasketaan? Pitääkö kaikkien komponenttien olla joko disreettejä tai jatkuvia?

Diskreettejä vai jatkuvia komponentteja?

- Oletamme, että sv:n $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$ yhteisjakauman esittää tiheys

$$f_{\mathbf{Z}}(\mathbf{z}) = f_{\mathbf{X}, \mathbf{Y}}(\mathbf{x}, \mathbf{y}), \quad \mathbf{z} = (\mathbf{x}, \mathbf{y}).$$

- Sallimme sen tilanteen, että jotkut \mathbf{Z} :n koordinaatit ovat diskreettejä sm:ia ja loppuilla on jatkuva yhteisjakauma.

Marginalisointi: yhteisjakaumasta reunajakaumaan

- Osavektorin \mathbf{X} :n reunajakauman esittää tiheys $f_{\mathbf{X}}$, joka saadaan summaamalla pois tiheydestä $f_{\mathbf{X},\mathbf{Y}}$ sv:n \mathbf{Y} diskreetit komponentit ja integroimalla pois sen jatkuvat komponentit.
- Merkintöjä väärinkäyttämällä,

$$f_{\mathbf{X}}(\mathbf{x}) = \int f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) \, d\mathbf{y}, \quad (12)$$

missä integraalimerkki tarkoittaa summaamista diskreettien komponenttien kohdalla.

- \mathbf{X} :n jakauma saadaan **marginalisoimalla** yhteisjakaumasta.
- Vastaavasti $f_{\mathbf{Y}}$ saadaan kaavalla

$$f_{\mathbf{Y}}(\mathbf{y}) = \int f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) \, d\mathbf{x}.$$

Marginalisointi, kun komponentit ovat hajan vektorissa \mathbf{Z}

- Edellä marginalisoitiin satunnaisvektorin $\mathbf{Z} = (\mathbf{X}, \mathbf{Y})$ yhteisjakaumasta joko ensimmäisten komponenttien \mathbf{X} tai viimeisten komponenttien \mathbf{Y} reunajakauma.
- Se tilanne, missä pitää reunajakauma pitää etsiä mielivaltaiselle osajoukolle \mathbf{Z} :n komponentteja saadaan palautettua edelliseen tilanteeseen permutoimalla koordinaatteja.
- Menettely selviää esimerkistä.

Esimerkki kahden muuttujan reunajakauman laskemisesta nejän muuttujan yhteisjakaumasta

- Olkoot U ja V diskreettejä sm:ia ja (X, Y) jatkuvasti jakautunut sv. Yhteisjakauman esittää tiheys

$$f_{U,V,X,Y}(u, v, x, y)$$

- Etsitään komponenttien V ja Y reunajakauma (ts. niiden yhteisjakauma).
- Jotta päästäisiin soveltamaan em. kaavoja, permutoidaan V ja Y ensimmäisiksi

$$f_{V,Y,U,X}(v, y, u, x) = f_{U,V,X,Y}(u, v, x, y),$$

(kaikilla kyseeseen tulevilla arvoilla u, v, x, y).

- Tämän jäkeen vektori (U, V) on ensimmäisenä, joten

$$f_{V,Y}(v, y) = \sum_u \int f_{V,Y,U,X}(v, y, u, x) dx.$$

Esimerkki jatkuu

- Nyt muistetaan, että $f_{V,Y,U,X}(v, y, u, x)$ on sama asia kuin $f_{U,V,X,Y}(u, v, x, y)$.
- Siispä sm:ien V ja Y yhteisjakauman esittää tiheys

$$f_{V,Y}(v, y) = \sum_u \int f_{U,V,X,Y}(u, v, x, y) dx,$$

- Käytännön laskuissa siirryttäisiin suoraan viimeiseen vaiheeseen ilman välissä esitettyjä permutointivälivaiheita.
- Diskreetit komponentit yksinkertaisesti marginalisoidaan pois summaamalla ja jatkuvat komponentit integroimalla.

- Kertolaskusääntö (eli ketjusääntö) on voimassa, eli

$$f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) = f_{\mathbf{X}}(\mathbf{x}) f_{\mathbf{Y}|\mathbf{X}}(\mathbf{y} | \mathbf{x}) = f_{\mathbf{Y}}(\mathbf{y}) f_{\mathbf{X}|\mathbf{Y}}(\mathbf{x} | \mathbf{y}).$$

- Kertolaskusääntöä voidaan iteroida. Oletetaan, että $\mathbf{S} = (\mathbf{U}, \mathbf{V})$. Tällöin

$$f_{\mathbf{U},\mathbf{V}}(\mathbf{u}, \mathbf{v}) = f_{\mathbf{U}}(\mathbf{u}) f_{\mathbf{V}|\mathbf{U}}(\mathbf{v} | \mathbf{u}),$$

minkä takia

$$f_{\mathbf{U},\mathbf{V},\mathbf{Y}}(\mathbf{u}, \mathbf{v}, \mathbf{y}) = f_{\mathbf{U}}(\mathbf{u}) f_{\mathbf{V}|\mathbf{U}}(\mathbf{v} | \mathbf{u}) f_{\mathbf{Y}|\mathbf{U},\mathbf{V}}(\mathbf{y} | \mathbf{u}, \mathbf{v}).$$

Lisää kertolaskusäännöstä

- Kertolaskusäännön soveltamista voidaan jatkaa, kunnes ollaan päästy skalaarikomponentteihin asti.
- Esimerkiksi neljän sm:n U, V, X, Y tiheys voidaan esittää muodossa

$$f_{U,V,X,Y}(u, v, x, y) = f_U(u) f_{V|U}(v | u) f_{X|U,V}(x | u, v) f_{Y|X,U,V}(y | x, u, v).$$

- Kertolaskusääntöä voidaan soveltaa yhtä hyvin käyttämällä jotakin muuta sm:ien permutaatiota.

Kertolaskusääntö pätee myös ehdollisille jakaumille

- Esim.

$$\begin{aligned}f_{\mathbf{U},\mathbf{V}|\mathbf{Y}}(\mathbf{u},\mathbf{v} | \mathbf{y}) &= \frac{f_{\mathbf{U},\mathbf{V},\mathbf{Y}}(\mathbf{u},\mathbf{v},\mathbf{y})}{f_{\mathbf{Y}}(\mathbf{y})} = \frac{f_{\mathbf{U},\mathbf{Y}}(\mathbf{u},\mathbf{y})}{f_{\mathbf{Y}}(\mathbf{y})} \frac{f_{\mathbf{U},\mathbf{V},\mathbf{Y}}(\mathbf{u},\mathbf{v},\mathbf{y})}{f_{\mathbf{U},\mathbf{Y}}(\mathbf{u},\mathbf{y})} \\ &= f_{\mathbf{U}|\mathbf{Y}}(\mathbf{u} | \mathbf{y}) f_{\mathbf{V}|\mathbf{U},\mathbf{Y}}(\mathbf{v} | \mathbf{u},\mathbf{y}).\end{aligned}$$

- Ensimmäinen tekijä on komponentin \mathbf{U} reunajakauma ehdollisessa yhteisjakaumassa (ehtona $\mathbf{Y} = \mathbf{y}$) ja toisena tekijänä komponentin \mathbf{V} ehdollinen jakauma ehdolla $\mathbf{U} = \mathbf{u}$ (kun edelleen ehdollistetaan arvolla $\mathbf{Y} = \mathbf{y}$).

Marginalisointi ehdollisesta yhteisjakaumasta

- Ehdollisen jakauman reunajakauman voi laskea marginalisoimalla tuttuun tapaan ehdollista yhteisjakaumaa.
- Esim.

$$\begin{aligned}f_{\mathbf{U}|\mathbf{Y}}(\mathbf{u} | \mathbf{y}) &= \frac{f_{\mathbf{U},\mathbf{Y}}(\mathbf{u}, \mathbf{y})}{f_{\mathbf{Y}}(\mathbf{y})} = \frac{1}{f_{\mathbf{Y}}(\mathbf{y})} \int f_{\mathbf{U},\mathbf{V},\mathbf{Y}}(\mathbf{u}, \mathbf{v}, \mathbf{y}) \, d\mathbf{v} \\ &= \int f_{\mathbf{U},\mathbf{V}|\mathbf{Y}}(\mathbf{u}, \mathbf{v} | \mathbf{y}) \, d\mathbf{v}.\end{aligned}$$

Merkintöjä mielellään yksinkertaistetaan

- Kun jakaumien välisiä yhteyksiä johdetaan tähän tapaan kertolaskukaavan ja marginalisoinnin kautta, niin **tiheysfunktioiden alaindeksit jätetään usein kirjoittamatta**, koska ne selviävät tiheysfunktion argumenteista.
- Muussa tapauksessa kaikki argumentit joudutaan kirjoittamaan kahteen kertaan: alaindekseissä esiintyvät satunnaismuuttujat (tai -vektorit) ja funktion argumentteina niiden mahdolliset arvot.
- Tämä merkintöjen väärinkäyttö ei johda sekaannukseen, kunhan pidetään mielessä, että esim. $f(x)$, $f(y)$, $f(x | y)$ ja $f(y | x)$ ovat tyypillisesti kaikki eri funktioita.

Ehdollistaminen satunnaisvektorin kiinteällä arvolla

- Satunnaisvektorin $\mathbf{g}(\mathbf{X}, \mathbf{Y})$ ehdollinen odotusarvo(vektori) ehdolla $\mathbf{X} = \mathbf{x}$ määritellään siten, että se on satunnaisvektorin $\mathbf{g}(\mathbf{x}, \mathbf{Y})$ odotusarvovektori, kun \mathbf{Y} :n jakaumana käytetään ehdollista jakaumaa $f_{\mathbf{Y}|\mathbf{X}}(\cdot | \mathbf{x})$.
- Merkintöjä väärinkäyttämällä

$$E(\mathbf{g}(\mathbf{X}, \mathbf{Y}) | \mathbf{X} = \mathbf{x}) = \int \mathbf{g}(\mathbf{x}, \mathbf{y}) f_{\mathbf{Y}|\mathbf{X}}(\mathbf{y} | \mathbf{x}) d\mathbf{y}.$$

- Tässä integraalimerkki voi tarkoittaa summausta joidenkin vektorin \mathbf{y} komponenttien suhteen.

Ehdollistaminen satunnaisvektorilla

- Jos ehdollistetaan satunnaisvektorilla \mathbf{X} , niin satunnaisvektori $E(\mathbf{g}(\mathbf{X}, \mathbf{Y}) \mid \mathbf{X})$ määritellään niin, että se on $\mathbf{m}(\mathbf{X})$, kun

$$\mathbf{m}(\mathbf{x}) = E(\mathbf{g}(\mathbf{X}, \mathbf{Y}) \mid \mathbf{X} = \mathbf{x}),$$

- Edellä funktion \mathbf{m} määritelmä jatketaan tarvittaessa nollavektoriksi niillä argumentin arvoilla, jolla se ei luonnostaan ole määritelty.

Ehdollinen kovarianssimatriisi

- Satunnaisvektorin $\mathbf{g}(\mathbf{X}, \mathbf{Y})$ ehdollinen kovarianssimatriisi ehdolla $\mathbf{X} = \mathbf{x}$ määritellään satunnaisvektorin $\mathbf{g}(\mathbf{x}, \mathbf{Y})$ kovarianssimatriisina, kun \mathbf{Y} :n jakaumana käytetään ehdollista jakaumaa $f_{\mathbf{Y}|\mathbf{X}}(\cdot | \mathbf{x})$.
- Voidaan käyttää merkintää

$$\text{Cov}(\mathbf{g}(\mathbf{X}, \mathbf{Y}) | \mathbf{X} = \mathbf{x}).$$

- Jos ehdollistetaan satunnaisvektorilla \mathbf{X} , niin ehdollinen kovarianssimatriisi on satunnaismatriisi, ja sitä merkitään

$$\text{Cov}(\mathbf{g}(\mathbf{X}, \mathbf{Y}) | \mathbf{X}).$$

9.4 Ehdollinen riippumattomuus

- Palautetaan mieleen, mitä (ei-ehdollinen) riippumattomuus tarkoittaa.
- Satunnaisvektorit \mathbf{X} ja \mathbf{Y} ovat riippumattomia, jos

$$f_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) = f_{\mathbf{X}}(\mathbf{x}) f_{\mathbf{Y}}(\mathbf{y}).$$

kaikilla argumenteilla \mathbf{x}, \mathbf{y} .

- Vastaavasti satunnaisvektorit $\mathbf{X}_1, \dots, \mathbf{X}_n$ ovat riippumattomia, jos

$$f_{\mathbf{X}_1, \dots, \mathbf{X}_n}(\mathbf{x}_1, \dots, \mathbf{x}_n) = f_{\mathbf{X}_1}(\mathbf{x}_1) \cdots f_{\mathbf{X}_n}(\mathbf{x}_n)$$

kaikilla argumenteilla.

Ehdollinen riippumattomuus

Määritelmä

Satunnaisvektorit \mathbf{X} ja \mathbf{Y} ovat riippumattomia ehdolla \mathbf{Z} (mikä voidaan merkitä $(\mathbf{X} \perp \mathbf{Y}) \mid \mathbf{Z}$), jos ne ovat riippumattomia niiden ehdollisessa yhteisjakaumassa ehdolla $\mathbf{Z} = \mathbf{z}$ kaikilla \mathbf{z} , ts. mikäli

$$f_{\mathbf{X}, \mathbf{Y} \mid \mathbf{Z}}(\mathbf{x}, \mathbf{y} \mid \mathbf{z}) = f_{\mathbf{X} \mid \mathbf{Z}}(\mathbf{x} \mid \mathbf{z}) f_{\mathbf{Y} \mid \mathbf{Z}}(\mathbf{y} \mid \mathbf{z}), \quad \text{kaikilla } \mathbf{x}, \mathbf{y} \text{ ja } \mathbf{z} \quad (13)$$

Vastaavasti, satunnaisvektorit $\mathbf{X}_1, \dots, \mathbf{X}_n$ ovat riippumattomia ehdolla \mathbf{Z} , mikäli

$$f_{\mathbf{X}_1, \dots, \mathbf{X}_n \mid \mathbf{Z}}(\mathbf{x}_1, \dots, \mathbf{x}_n \mid \mathbf{z}) = \prod_{i=1}^n f_{\mathbf{X}_i \mid \mathbf{Z}}(\mathbf{x}_i \mid \mathbf{z})$$

kaikilla $\mathbf{x}_1, \dots, \mathbf{x}_n$ ja kaikilla \mathbf{z} .

Riippumattomuus ja ehdollinen riippumattomuus ovat eri asioita

- Ehdollisesti riippumattomat satunnaisvektorit eivät tyypillisesti ole marginaalisesti riippumattomia, eli riippumattomia niiden (reuna-)yhteisreunajakaumassa.
- Esim. jos $(\mathbf{X} \perp\!\!\!\perp \mathbf{Y}) \mid \mathbf{Z}$, niin

$$\begin{aligned} f_{\mathbf{X}, \mathbf{Y}}(\mathbf{x}, \mathbf{y}) &= \int f_{\mathbf{X}, \mathbf{Y} \mid \mathbf{Z}}(\mathbf{x}, \mathbf{y} \mid \mathbf{z}) f_{\mathbf{Z}}(\mathbf{z}) d\mathbf{z} \\ &= \int f_{\mathbf{X} \mid \mathbf{Z}}(\mathbf{x} \mid \mathbf{z}) f_{\mathbf{Y} \mid \mathbf{Z}}(\mathbf{y} \mid \mathbf{z}) f_{\mathbf{Z}}(\mathbf{z}) d\mathbf{z}, \end{aligned}$$

eikä tämä tyypillisesti enää faktoroidu.

9.5 Tilastollisia malleja

- Tilastolliseen päättelyyn on kaksi pääasiallista lähestymistapaa: ns. **frekventistinen päättely** ja **Bayes-päättely**.
- Ne molemmat perustuvat **uskottavuusfunktion** käyttöön.
- Jotta uskottavuusfunktio saataisiin selville, pitää selvittää havaintosatunnaisvektorin tiheys (esim. y_{pntf} tai y_{tf}).

Tilastollisen päättelyn perusasetelma

- Meillä on numeerinen **aineisto** vektorin $\mathbf{y} = (y_1, \dots, y_n)$ muodossa.
- Ennen havaintojen tekoa aineiston arvot ovat epävarmoja (mittausvirheiden, populaation luonnollisen vaihtelun tms. syyn takia).
- Mallinamme tilanteen niin, että \mathbf{y} on jollakin perusjoukolla Ω määritellyn satunnaisvektorin \mathbf{Y} havaittu arvo, ts.

$$\mathbf{y} = \mathbf{Y}(\omega^{\text{act}}),$$

jossa ω^{act} on todennäköisyysmallissa aktualisoitunut alkeistapaus.

Tilastollinen malli

- Tyypillisesti vektorin \mathbf{Y} jakauma mallinnetaan parametrisella mallilla, jossa on yksi tai useampia parametreja $\theta_1, \dots, \theta_p$, jotka kootaan **parametrivektoriksi** θ .
- Kun parametrivektorin arvo on kiinnitetty, niin tilastollisessa mallissa sv:n \mathbf{Y} jakauman esittää tiheys

$$\mathbf{y} \mapsto f(\mathbf{y} \mid \theta).$$

- Kiinnostuksen kohteena on sv:n \mathbf{Y} jakauma.
- Sitä voidaan arvoida, jos ensin arvioidaan eli **estimoidaan** tuntematonta parametrivektoria θ .

- Kun aineisto \mathbf{y} on havaittu, ja havaittua arvoa käytetään funktion $f(\mathbf{y} \mid \theta)$ ensimmäisenä argumenttina, niin funktiota

$$\theta \mapsto f(\mathbf{y} \mid \theta)$$

kutsutaan **uskottavuusfunktiksi** (engl. *likelihood function*).

- Tässä yhteydessä tiheysfunktioista saatetaan jättää pois kertoimia, jotka eivät riipu parametrivektorista θ , ja silti kyseistä funktiota edelleen kutsutaan uskottavuusfunktiksi.

Frekventistinen päättely

- Ns. klassisessa eli frekventistisessä tilastotieteessä parametrivektoria θ pidetään tuntemattomana vakiona, josta tiedetään vain, missä joukossa (eli parametriavaruudessa) sen arvot voivat olla.
- Tällöin merkintään $f(\mathbf{y} | \theta)$ ei liitetä tulkintaa ehdollisena jakaumana, koska parametrivektorille ei ole olemassa mitään todennäköisyysjakaumaa.
- Tyypillisempi merkintä olisikin $f(\mathbf{y}; \theta)$.
- Uskottavuusfunktiota esim. maksimoidaan, jolloin saadaan määriteltyä suurimman uskottavuuden estimaatti.

- Bayes-päätelyssä parametrivektoria pidetään satunnaisvektorin Θ arvona.
- Funktio $f(\mathbf{y} \mid \theta)$ ja ehdollinen jakauma $f_{\mathbf{Y} \mid \Theta}(\mathbf{y} \mid \theta)$ samastetaan.
- Bayes-päätelyssä tilastollisessa mallissa tarvitaan uskottavuusfunktion lisäksi reunajakauma vektorille Θ . Tätä kutsutaan **priorijakaumaksi**. Sen on tarkoitus kuvata ennen havaintoja olevaa tietoa parametrien järkevästä arvoista.

Bayes-päätely: uskottavuusfunktioista ja priorista posterioriin

- Parametrivektorin ja havaintovektorin yhteisjakauman esittää tiheys

$$(\mathbf{y}, \boldsymbol{\theta}) \mapsto f_{\boldsymbol{\Theta}, \mathbf{Y}}(\boldsymbol{\theta}, \mathbf{y}) = f_{\boldsymbol{\Theta}}(\boldsymbol{\theta}) f_{\mathbf{Y}|\boldsymbol{\Theta}}(\mathbf{y} | \boldsymbol{\theta}).$$

- Kun on saatu havainto $\mathbf{Y} = \mathbf{y}$, niin tilastolliset päätelmät tehdään karakterisoimalla parametrivektorin **posteriorijakaumaa**, joka on ehdollinen jakauma

$$f_{\boldsymbol{\Theta}|\mathbf{Y}}(\boldsymbol{\theta} | \mathbf{y}) = \frac{f_{\boldsymbol{\Theta}, \mathbf{Y}}(\boldsymbol{\theta}, \mathbf{y})}{f_{\mathbf{Y}}(\mathbf{y})} = \frac{f_{\boldsymbol{\Theta}}(\boldsymbol{\theta}) f_{\mathbf{Y}|\boldsymbol{\Theta}}(\mathbf{y} | \boldsymbol{\theta})}{\int f_{\boldsymbol{\Theta}}(\mathbf{t}) f_{\mathbf{Y}|\boldsymbol{\Theta}}(\mathbf{y} | \mathbf{t}) d\mathbf{t}}$$

Mihin tilastotieteessä tarvitaan moniulotteisia jakaumia?

- Kummassakin tilastollisen päättelyn lähestymistavassa tarvitaan konkreettinen kaava uskottavuusfunktiolle.
- Uskottavuusfunktio on havaintosatunnaisvektorin yhteisjakauman tiheys (esim. y_{ptnf} tai y_{tf}) ajateltuna tuntemattoman parametrivektorin funktiona, kun havainnot on siihen sijoitettu.
- Tämän takia tilastotieteilijän pitää osata johtaa moniulotteisten satunnaisvektoreiden tiheyksiä.
- Monisteessa on tästä joitakin esimerkkejä.

9.6 Tiheysfunktion muuntokaava

- Tarkastelemme diffeomorfisimia $\mathbf{g} : A \rightarrow B$, jossa $A, B \subset \mathbb{R}^n$ ovat avoimia joukkoja.
- Tällöin \mathbf{g} :llä on käänteisfunktio $\mathbf{h} : B \rightarrow A$, ja sekä \mathbf{g} että \mathbf{h} ovat jatkuvasti derivoituvia.
- Näiden kuvausten komponenttifunktiot ovat

$$\mathbf{g} = (g_1, \dots, g_n), \quad \mathbf{h} = (h_1, \dots, h_n).$$

- Nämä funktiot määrittelevät bijektiivisen vastaavuuden koordinaattien \mathbf{x} ja \mathbf{y} välillä kaavoilla

$$\mathbf{y} = \mathbf{g}(\mathbf{x}) \quad \iff \quad \mathbf{x} = \mathbf{h}(\mathbf{y}).$$

Tätä ajatusta voidaan merkitä vaihtoehtoisesti kaavoilla

$$\mathbf{y} = \mathbf{y}(\mathbf{x}) \quad \iff \quad \mathbf{x} = \mathbf{x}(\mathbf{y}).$$

Merkintä osittaisderivaatoille

- Otamme käyttöön merkinnän $D_i h_j(\mathbf{y})$ tarkoittamaan reaaliarvoisen funktion h_j osittaisderivaattaa sen i :nnen argumentin suhteen pisteessä \mathbf{y} , ts.

$$D_i h_j(\mathbf{y}) = \frac{\partial}{\partial y_i} h_j(\mathbf{y}).$$

Derivaattamatriisi ja jacobiaani

- Kuvauksen $\mathbf{h} = (h_1, \dots, h_n)$ **derivaatta** tai **derivaattamatriisi** (tai Jacobin matriisi) pisteessä $\mathbf{y} \in B$ on

$$\begin{bmatrix} D_1 h_1(\mathbf{y}) & D_2 h_1(\mathbf{y}) & \dots & D_n h_1(\mathbf{y}) \\ D_1 h_2(\mathbf{y}) & D_2 h_2(\mathbf{y}) & \dots & D_n h_2(\mathbf{y}) \\ \vdots & \vdots & \ddots & \vdots \\ D_1 h_n(\mathbf{y}) & D_2 h_n(\mathbf{y}) & \dots & D_n h_n(\mathbf{y}) \end{bmatrix}$$

- Kuvauksen \mathbf{h} **jacobiaani**, eli Jacobin determinantti eli funktionaalideterminantti

$$J_{\mathbf{h}}(\mathbf{y}) = \frac{\partial \mathbf{x}}{\partial \mathbf{y}} = \frac{\partial(x_1, \dots, x_n)}{\partial(y_1, \dots, y_n)}$$

on derivaattamatriisin determinantti.

Tiheysfunktion muuntokaava

Lause

Jos $\mathbf{g} : A \rightarrow B$ on diffeomorfismi, $\mathbf{h} : B \rightarrow A$ on sen käänteiskuvaus, eli $\mathbf{h} = \mathbf{g}^{-1}$, ja sv:lla \mathbf{X} on jatkuva jakauma, ja $P(\mathbf{X} \in A) = 1$, niin sv:lla $\mathbf{Y} = \mathbf{g}(\mathbf{X})$ on jatkuva jakauma tf:lla

$$f_{\mathbf{Y}}(\mathbf{y}) = f_{\mathbf{X}}(\mathbf{h}(\mathbf{y})) |J_{\mathbf{h}}(\mathbf{y})|, \quad \text{kun } \mathbf{y} \in B,$$

ja nolla muualla.

Todistus on suora seuraus n -ulotteisten integraalien muuntokaavasta (jossa integraali pitää ymmärtää Lebesguen integraaliksi).

Tiheysfunktion muuntokaava (diffeomorfismille) kannattaa pitää mielessään muodossa

$$f_{\mathbf{X}}(\mathbf{x}) |\partial \mathbf{x}| = f_{\mathbf{Y}}(\mathbf{y}) |\partial \mathbf{y}|, \quad \text{kun} \quad (14)$$

$$\mathbf{y} = \mathbf{g}(\mathbf{x}) \iff \mathbf{x} = \mathbf{h}(\mathbf{y}), \quad \mathbf{x} \in A, \mathbf{y} \in B \quad (15)$$

Tiheysfunktion muuntuminen affiinissa muunnoksessa

- Jos \mathbf{A} on vakiomatriisi ja \mathbf{b} on vakiovektori siten, että seuraavassa kaavassa dimensiot ovat yhteensopivia, niin funktiota

$$\mathbf{g}(\mathbf{x}) = \mathbf{Ax} + \mathbf{b}, \quad \mathbf{x} \in \mathbb{R}^n.$$

kutsutaan **affiiniksi muunnokseksi**.

- Jos \mathbf{A} on kääntyvä matriisi (jolloin se on neliömatriisi), niin tämän kuvauksen käänteiskuvaus on myös affiini, sillä

$$\mathbf{y} = \mathbf{g}(\mathbf{x}) = \mathbf{Ax} + \mathbf{b} \quad \iff \quad \mathbf{x} = \mathbf{A}^{-1}(\mathbf{y} - \mathbf{b}) = \mathbf{h}(\mathbf{y})$$

Muuntokaava affiinille kuvaukselle — jatkoa

- Kuvauksen $\mathbf{h}(\mathbf{y}) = \mathbf{A}^{-1}(\mathbf{y} - \mathbf{b})$ derivaattamatriisi on \mathbf{A}^{-1} , joten jacobiaaniksi saadaan

$$J_{\mathbf{h}}(\mathbf{y}) = \frac{\partial \mathbf{x}}{\partial \mathbf{y}} = \det(\mathbf{A}^{-1}) = \frac{1}{\det(\mathbf{A})}.$$

- Jos \mathbf{X} on n -ulotteinen sv, jolla on jatkuva jakauma, ja sv \mathbf{Y} määritellään kaavalla $\mathbf{Y} = \mathbf{g}(\mathbf{X})$, niin muistisäännöstä

$$f_{\mathbf{X}}(\mathbf{x}) |\partial \mathbf{x}| = f_{\mathbf{Y}}(\mathbf{y}) |\partial \mathbf{y}|$$

saadaan tulos

$$f_{\mathbf{Y}}(\mathbf{y}) = f_{\mathbf{X}}(\mathbf{x}) \left| \frac{\partial \mathbf{x}}{\partial \mathbf{y}} \right| = f_{\mathbf{X}}(\mathbf{A}^{-1}(\mathbf{y} - \mathbf{b})) \frac{1}{|\det(\mathbf{A})|}.$$

9.7 Satunnaisvektorin momenttiemäfunktio

Määritelmä

Satunnaisvektorin $\mathbf{X} = (X_1, \dots, X_n)$ momenttiemäfunktio, eli satunnaismuuttujien X_1, \dots, X_n yhteismomenttiemäfunktio on

$$M(\mathbf{t}) = M_{\mathbf{X}}(\mathbf{t}) = E \exp(\mathbf{t}^T \mathbf{X}) = E \exp \left(\sum_{j=1}^n t_j X_j \right),$$

niillä $\mathbf{t} = (t_1, \dots, t_n) \in \mathbb{R}^n$, joilla odotusarvo on määritelty. Sv:n \mathbf{X} kumulanttiemäfunktio (eli sm:ien X_1, \dots, X_n yhteiskumulanttiemäfunktio) on

$$K(\mathbf{t}) = K_{\mathbf{X}}(\mathbf{t}) = \ln M_{\mathbf{X}}(\mathbf{t}),$$

niillä $\mathbf{t} \in \mathbb{R}^n$, joilla $M(\mathbf{t})$ on määritelty.

Lause

Jos $M_{\mathbf{X}}(\mathbf{t})$ on olemassa jossakin epätyhjässä origon ympäristössä, niin

- $M_{\mathbf{X}}$ määrää sv:n \mathbf{X} jakauman.
- Kertaluvun (k_1, \dots, k_n) momentti saadaan laskettuna tiettyinä momenttiemäfunktion osittaisderivaattana (ks. moniste).

Osista kootun satunnaisvektorin momenttiemäfunktio

Lause

Olkoon $\mathbf{X} = (\mathbf{Y}, \mathbf{Z})$ sellainen sv, että sen momenttiemäfunktio $M_{\mathbf{X}}(\mathbf{t})$ on olemassa jossakin origon ympäristössä. Olkoon $\mathbf{t} = (\mathbf{u}, \mathbf{v})$ ositettu samandimensioisiin osiin kuin \mathbf{Y} and \mathbf{Z} . Tällöin

(a) Sv:ien \mathbf{Y} ja \mathbf{Z} momenttiemäfunktiot ovat

$$M_{\mathbf{Y}}(\mathbf{u}) = M_{\mathbf{X}}(\mathbf{u}, \mathbf{0}), \quad M_{\mathbf{Z}}(\mathbf{v}) = M_{\mathbf{X}}(\mathbf{0}, \mathbf{v}).$$

(b) $\mathbf{Y} \perp\!\!\!\perp \mathbf{Z}$ jos ja vain jos

$$M_{\mathbf{X}}(\mathbf{u}, \mathbf{v}) = M_{\mathbf{Y}}(\mathbf{u}) M_{\mathbf{Z}}(\mathbf{v}).$$

kaikilla riittävän pienillä \mathbf{u} ja \mathbf{v} .

Todistus taululla. Hankalinta on todistaa, että riippumattomuus seuraa momenttiemäfunktion jakautumisesta tekijöihin.