

## 2.1 Satunnaismuuttuja ja sen jakauma

**Satunnaismuuttuja** (lyhenne **sm**, engl. *random variable*, *rv*; myös *variate*) on satunnaiskokeeseen liittyvä numeerinen muuttuja, jonka arvo määräytyy kokeen lopputuloksesta. Satunnaismuuttuja on siis perusjoukolla määritelty reaaliarvoinen funktio.

### Määritelmä (Satunnaismuuttuja)

Olkoon  $\Omega$  perusjoukko. Kuvaus  $X : \Omega \rightarrow \mathbb{R}$  on **satunnaismuuttuja**.

# Esimerkkejä satunnaismuuttujista

- Silmäluku nopanheitossa. Jos alkeistapaus  $\omega \in \{1, \dots, 6\}$  kertoo nopan silmäluvun, niin

$$X(\omega) = \omega$$

on nopan silmäluku.

- Silmälukujen summa kahdessa nopanheitossa. Jos  $E = \{1, \dots, 6\}$ , perusjoukko  $\Omega = E \times E$ , ja alkeistapaukselle  $(i, j) \in E \times E$  ensimmäinen koordinaatti  $i$  kertoo nopan yksi ja toinen koordinaatti  $j$  nopan kaksi silmäluvun, niin niiden summa on

$$X((i, j)) = i + j.$$

# Tapahtuman indikaattori (tärkeä esimerkki satunnaismuuttujasta)

## Määritelmä (Tapahtuman indikaattori)

Olkoon  $A \subset \Omega$  tapahtuma. Sen **indikaattori** (eli ilmaisoin eli osoitinmuuttuja)  $1_A$  on satunnaismuuttuja, jonka määrittelee lauseke

$$1_A(\omega) = \begin{cases} 1, & \text{jos } \omega \in A, \\ 0, & \text{muuten.} \end{cases}$$

*Huomautuksia:* Tapahtuman  $A$  indikaattorille käytetään yleisesti myös merkintää  $I_A$ . Jos tapahtuma  $A$  esitetään monimutkaisella lausekkeella, niin usein käytetään edellisten sijasta merkintää  $1(A)$  tai  $I(A)$ . Jos on lisäksi tarpeen merkitä argumentti  $\omega$  näkyviin, niin voidaan käyttää merkintöjä  $1(A)(\omega)$  tai  $I(A)(\omega)$ .

# Satunnaismuuttujien laskutoimitukset

- Usein samalla perusjoukolla on määritelty useampi kuin yksi satunnaismuuttuja, esim.  $X$  ja  $Y$ .
- Tällöin voidaan tarkastella myös *satunnaismuuttujien välisiä laskutoimituksia*, kuten  $aX$  (vakiolle  $a \in \mathbb{R}$ ),  $X + Y$ ,  $XY$  jne. Myös ne ovat satunnaismuuttujia.
- Esim.  $X + Y$  tarkoittaa funktioiden yhteenlaskua, ts.  $X + Y$  on se funktio  $\Omega \rightarrow \mathbb{R}$ , jolle

$$(X + Y)(\omega) = X(\omega) + Y(\omega).$$

Ts. satunnaismuuttujien laskutoimitukset tulkitaan pisteittäin.

- Jos  $Y$  ei saa arvoa nolla, niin myös  $X/Y$  on sm.

# Merkintöjä (piilota oomega)

- Jos  $X$  on sm, niin voidaan kysyä, millä todennäköisyydellä se saa arvon joukosta  $B$ , jossa  $B \subset \mathbb{R}$ .
- Kyseistä tapahtumaa voidaan merkitä  $\{\omega \in \Omega : X(\omega) \in B\}$ , mutta sitä merkitään tavallisesti lyhyemmin:  $\{X \in B\}$ .
- Sen todennäköisyyttä voidaan merkitä seuraavasti,

$$\begin{aligned} P(X \in B) &= P\{X \in B\} = P(\{X \in B\}) \\ &= P(\{\omega \in \Omega : X(\omega) \in B\}). \end{aligned} \tag{1}$$

Tavallisesti käytetään lyhyitä merkintöjä, joissa ei esiinny perusjoukkoa  $\Omega$  eikä sisäkkäisiä sulkuja.

## Lisää merkintöjä tapahtumalle $\{X \in B\}$

Huomaa, minkälaisia merkintöjä tapahtumalle  $\{X \in B\}$  käytetään seuraavissa tilanteissa.

- $B$  on yksiö  $\{x\}$ , jossa  $x \in \mathbb{R}$ . Tällöin kysytään **pistetodennäköisyyttä**

$$P(X = x) = P(\{\omega \in \Omega : X(\omega) = x\}).$$

- $B$  on väli kuten esim. suljettu väli  $[a, b]$ , jossa  $a < b$ ,

$$P(a \leq X \leq b) = P(\{\omega \in \Omega : a \leq X(\omega) \leq b\}).$$

Vastaavasti määritellään  $P(a < X \leq b)$ ,  $P(a \leq X < b)$  ja  $P(a < X < b)$ .

- Tapaus  $B = (-\infty, x]$ . Tällöin merkitään

$$P(X \leq x) = P(\{\omega \in \Omega : X(\omega) \leq x\}).$$

## Määritelmä (Satunnaismuuttujan jakauma)

Jos  $X$  on satunnaismuuttuja, niin sen **jakauma** on

$$P(X \in B)$$

ymmärrettynä argumentin  $B \subset \mathbb{R}$  funktiona.

*Huomautus:* Itse asiassa tn  $P(X \in B)$  on määritelty vain silloin, kun  $B \subset \mathbb{R}$  on ns. Borelin joukko, jollaisia ovat esim. kaikki välit ja kaikki joukot, jotka voidaan muodostaa numeroituvasta määrästä välejä soveltamalla numeroituva määrä joukko-operaatiota. Tästä lähtien jätämme tämän seikan vaille huomiota.

# Huomautuksia jakaumasta

- On mahdollista osoittaa, että sm:n  $X$  jakauma

$$P_X(B) = P(X \in B), \quad B \subset \mathbb{R}$$

toteuttaa todennäköisyyden aksioomat, joten jakauma on joukossa  $\mathbb{R}$  määritelty tn-mitta.

- Perusjoukko  $\Omega$  häviää usein kokonaan merkinnöistä. Tilanne voidaan mieltää myös siten, että perusjoukkona onkin  $\mathbb{R}$  ja että tapahtumat ovat sen osajoukkoja.
- Jakauma on hyvin abstrakti olio.
- Seuraavaksi tarkastelemme konkreettisempia välineitä, joiden avulla voimme kuvailla ja hallita jakaumia: **kertymäfunktio**, diskreetin jakauman **pistetodennäköisyysfunktio** ja jatkuvan jakauman **tiheysfunktio**.



## 2.2 Kertymäfunktio

### Määritelmä

Jos  $X$  on satunnaismuuttuja, niin funktio  $F : \mathbb{R} \rightarrow \mathbb{R}$

$$F(x) = P(X \leq x), \quad x \in \mathbb{R}$$

on  $X$ :n **kertymäfunktio** (lyhenne **kf**).

*Huomautus:* Englannin kielellä

- jakauma on *(probability) distribution* (joskus *law*),
- kertymäfunktio on *distribution function* tai *cumulative distribution function, cdf*.

# Tapahtuman indikaattorin kertymäfunktio

- Olkoon  $A$  tapahtuma, ja olkoon  $X = 1_A$ , eli  $X$  on tapahtuman  $A$  indikaattori.
- Tällöin  $X$ :n kf on

$$F(x) = \begin{cases} 0, & \text{jos } x < 0, \\ 1 - P(A), & \text{jos } 0 \leq x < 1, \\ 1, & \text{jos } x \geq 1. \end{cases}$$

- Tämä kertymäfunktio on paloittain vakio.
- Huomaa, että kf:lla voi olla hyppyjä ja että se voi olla vakio jollakin välillä.

# Monotonisen funktion raja-arvot

- Monotonisella funktiolla  $G : \mathbb{R} \rightarrow \mathbb{R}$  on jokaisessa pisteessä  $x \in \mathbb{R}$  olemassa sekä vasemmanpuoleinen että oikeanpuoleinen raja-arvo.
- Lisäksi sillä on raja-arvo pisteissä  $-\infty$  ja  $\infty$  (mutta äärettömässä raja-arvo voi olla joko jokin reaaliluku, tai jompikumpi äärettömistä  $-\infty$  tai  $\infty$ ).
- Näitä raja-arvoja merkitään seuraavasti

$$G(x-) = \lim_{y \rightarrow x-} G(y), \quad G(x+) = \lim_{y \rightarrow x+} G(y)$$

$$G(-\infty) = \lim_{y \rightarrow -\infty} G(y), \quad G(\infty) = \lim_{y \rightarrow \infty} G(y).$$

# Kertymäfunktion ominaisuudet

## Lause (Kertymäfunktion ominaisuudet)

Satunnaismuuttujan  $X$  kertymäfunktiolla  $F : \mathbb{R} \rightarrow \mathbb{R}$  on seuraavat ominaisuudet.

- (a)  $F$  on kasvava funktio.
- (b)  $F$  on oikealta jatkuva funktio, eli

$$F(x+) = F(x), \quad \text{kaikilla } x \in \mathbb{R}.$$

- (c)  $F(-\infty) = 0$  ja  $F(\infty) = 1$ .

Kääntäen, jos funktiolla  $F : \mathbb{R} \rightarrow \mathbb{R}$  on nämä ominaisuudet, niin on olemassa sm  $X$  siten, että  $F$  on  $X$ :n kf.

# Sattumistodennäköisyydet väleille

- Lasketaan tn  $P(a < X \leq b)$ , jossa  $a < b$ . Koska

$$\{X \leq b\} = \{X \leq a\} \cup \{a < X \leq b\},$$

jossa osat ovat erillisiä, on

$$P(a < X \leq b) = F(b) - F(a).$$

- Seuraavan lauseen jälkeen pystymme toistamaan vastaavan laskun myös väleille  $(a, b)$ ,  $[a, b)$  ja  $[a, b]$ .

## Lause

Jos  $F$  on sm:n  $X$  kf, niin kaikilla  $x$

$$P(X < x) = F(x-).$$

# Kertymäfunktion hyppyt

- Kertymäfunktiolla voi olla hyppyjä.
- Koska

$$\{X \leq x\} = \{X < x\} \cup \{X = x\},$$

jossa osat ovat erillisiä, niin

$$P(X = x) = P(X \leq x) - P(X < x) = F(x) - F(x-).$$

- Pistetodennäköisyys  $P(X = x)$  on yhtä kuin kertymäfunktion hyppy pisteessä  $x$ .

# Satunnaismuuttuja voidaan ilmoittaa funktion alaindeksillä

- Voidaan tarkastella useampaa kuin yhtä satunnaismuuttujaa, vaikkapa  $X$  ja  $Y$ .
- Tällöin usein käytetään sellaista merkintätapaa, jossa satunnaismuuttuja kirjoitetaan kertymäfunktion alaindeksiksi: esim.  $F_X$  on  $X$ :n kf ja  $F_Y$  on  $Y$ :n kf.
- Tällaista merkintätapaa voidaan käyttää muidenkin jakauman esitysten kuin kertymäfunktioiden kohdalla.

# Sama jakauma

## Määritelmä

Satunnaismuuttujilla  $X$  ja  $Y$  on **sama jakauma** eli ne ovat **samoin jakautuneet**, jos

$$P(X \in B) = P(Y \in B), \quad \text{kaikilla } B \subset \mathbb{R}.$$

Tämä seikka voidaan ilmaista merkinnällä

$$X \stackrel{d}{=} Y.$$



# Kertymäfunktiot ja jakaumat vastaavat toisiaan

Seuraava lause toteaa, että kertymäfunktiot ja jakaumat vastaavat toisiaan yksikäsitteisesti. Tämän takia voidaan puhua tietyn jakauman kertymäfunktioista, eikä aina tarvitse puhua  $sm:n$  kertymäfunktioista.

Lause (Kertymäfunktio määrää jakauman yksikäsitteisesti)

Seuraavat asiat ovat yhtäpitäviä.

- (a)  $X$  ja  $Y$  ovat samoin jakautuneet, eli  $X \stackrel{d}{=} Y$ .
- (b)  $F_X = F_Y$  (ts.  $X:n$  ja  $Y:n$  kertymäfunktiot ovat samat).

## 2.3 Diskreetti jakauma

### Määritelmä

Satunnaismuuttujan  $X$  jakauma on **diskreetti**, jos sen arvojoukko  $\{x_1, x_2, \dots\}$  on äärellinen tai korkeintaan numeroituvasti ääretön.

Asia voidaan ilmaista myös jollakin seuraavista tavoista

- $X$  on diskreetti sm,
- sm  $X$  on diskreetisti jakautunut
- $X$ :llä on diskreetti jakauma.

# Laajennettu määritelmä diskreetille satunnaismuuttujalle

- Joskus määritelmää laajennetaan: vaaditaan vain, että  $X$  saa todennäköisyydellä yksi arvon korkeintaan numeroituvasti äärettömästä joukosta  $S$ .
- Tällöin diskreetti sm  $X$  voi saada arvoja joukon  $S$  ulkopuolelta, mutta tämän poikkeustapahtuman todennäköisyys on nolla.
- Yksinkertaisuuden vuoksi kutsumme myös tässä tapauksessa  $X$ :n arvojoukoksi jotakin sellaista korkeintaan numeroituvaa joukkoa  $S$ , jolle  $P(X \in S) = 1$ .

## Määritelmä

Satunnaismuuttujan  $X$  **pistetodennäköisyysfunktio** (lyh. ptnf) on funktio  $f : \mathbb{R} \rightarrow \mathbb{R}$ , jolle

$$f(x) = P(X = x), \quad x \in \mathbb{R}.$$

- Pistetodennäköisyysfunktio  $x \mapsto P(X = x)$  (engl. *probability (mass) function, pmf*) on määritelty koko reaaliakselilla kaikenlaisille satunnaismuuttujille  $X$ .
- Käsite on käyttökelpoinen lähinnä vain diskreeteille satunnaismuuttujille.

- Tyypillisesti pistetodennäköisyydet ilmoitetaan vain niille  $x_i$ , jotka kuuluvat diskreetin sm:n määritelmässä esiintyvään, korkeintaan numeroituvasti äärettömään joukkoon, joka voi esimerkiksi olla jokin kokonaislukujen osajoukko. Tällöin asiayhteydestä pitää ymmärtää, että muilla  $x \in \mathbb{R}$  on  $P(X = x) = 0$ .
- Diskreetin satunnaismuuttujan ptnf:lle käytetään muuten samaa symbolia kuin sen kf:lle, mutta ptnf:n symboli kirjoitetaan pienellä kirjaimella (esim.  $f$ ,  $g$  tai  $f_X$ ) ja kf:n symboli vastaavalla isolla kirjaimella (esim.  $F$ ,  $G$  tai  $F_X$ ).

# Diskreetin jakauman ptnf:n ominaisuuksia

## Lause

Olkoon  $X$  diskreetti sm,  $f$  sen ptnf, ja olkoon  $S$  sen arvojoukko. Tällöin

- (a)  $0 \leq f(x) \leq 1$  kaikilla  $x$ , ja  $f(x) = 0$ , kun  $x \notin S$ .
- (b)  $f$  määrää  $X$ :n jakauman kaavalla

$$P(X \in B) = \sum_{x \in B} f(x)$$

*Huomautus:* Kohdassa (b) lasketaan yhteen korkeintaan numeroituva määrä ei-negatiivisia termejä  $f(x_i)$ , jossa  $x_i \in S \cap B$ , minkä takia kyseinen summamerkintä on mielekäs. (Summausjärjestyksellä ei ole väliä.)

# Ptnf:stä diskreetti jakauma

## Lause

Olkoon  $f : \mathbb{R} \rightarrow \mathbb{R}$  ei-negatiivinen funktio, joka saa positiivisia arvoja korkeintaan numeroituvassa  $\mathbb{R}$ :n osajoukossa siten, että

$$\sum_x f(x) = 1$$

Tällöin se on jonkin diskreetin satunnaismuuttujan ptnf.

## 2.4 Esimerkkejä diskreeteistä jakaumista

- diskreetti tasajakauma
- Bernoullin jakauma
- binomijakauma
- hypergeometrinen jakauma, negatiivinen binomijakauma, geometrinen jakauma, Poissonin jakauma (luvussa 5).



# Diskreetti tasajakauma

- Satunnaismuuttujalla  $X$  on **diskreetti tasajakauma** joukossa  $\{1, \dots, N\}$ , mikäli sen ptnf on

$$f(x) = \frac{1}{N}, \quad \text{kun } x = 1, 2, \dots, N.$$

- Esimerkiksi, jos  $X$  on silmäluku nopanheitossa, niin  $X$ :llä on diskreetti tasajakauma joukossa  $1, \dots, 6$ .

# Bernoullin jakauma

- Olkoon  $A$  on tapahtuma, ja merkitään  $p = P(A)$ , jolloin  $0 \leq p \leq 1$ .
- Indikaattorilla  $X = 1_A$  on **Bernoullin jakauma** parametrilla  $p$  (eli  $X$  noudattaa Bernoullin jakaumaa parametrilla  $p$ ). Tämä asia voidaan merkitä  $X \sim \text{Bernoulli}(p)$ .
- Tavallisesti sanotaan, että satunnaiskoe **onnistuu** silloin, kun  $X = 1$  ja **epäonnistuu** muuten. Tällöin  $p$ :stä käytetään nimeä **onnistumistodennäköisyys**.

# Bernoullin jakauman ptnf

- $X$ :n arvojoukko on  $\{0, 1\}$ , ja sen ptnf on

$$f(x) = f(x | p) = \begin{cases} 1 - p, & \text{kun } x = 0, \\ p, & \text{kun } x = 1, \\ 0, & \text{muuten.} \end{cases}$$

- Merkintäsopimus: ptnf:n arvot tarvitsee mainita vain ko. sm:n arvojoukossa, muualla ymmärretään sen olevan nolla.
- Jakauman Bernoulli( $p$ ) ptnf voidaan kirjoittaa lyhyesti

$$f(x | p) = p^x(1 - p)^{1-x}, \quad \text{kun } x = 0, 1,$$

Tässä tulkitaan  $0^0 = 1$ , mikäli  $p = 0$  tai  $p = 1$ .

# Jakaumien merkinnöistä


- Useimmat mielenkiintoiset jakaumat riippuvat yhden tai useamman parametrin arvosta. *Oikeastaan tarkastellaan saman tien perhettä jakaumia.*
- Pitääksemme lukua parametrin arvosta, merkitsemme sen tarvittaessa pystyviivan oikealle puolelle. Tätä merkintää voidaan käyttää kertymäfunktioille, pistetodennäköisyysfunktioille ynnä muille funktioille.
- Jos taas sekaantumisen vaaraa ei ole, parametri voidaan jättää pois merkinnöistä.

# Binomijakauma

- Olkoon  $n \geq 1$  kokonaisluku ja  $0 \leq p \leq 1$ .
- Sm  $X$  noudattaa **binomijakaumaa** parametreilla  $n$  ja  $p$ , jos sen arvojoukko on  $\{0, 1, \dots, n\}$  ja ptnf on

$$f(x) = f(x | n, p) = \binom{n}{x} p^x (1-p)^{n-x}, \quad \text{kun } x = 0, 1, \dots, n.$$

- Tämä voidaan merkitä  $X \sim \text{Bin}(n, p)$ .
- *Kuva:* Binomijakauman  $\text{Bin}(5, 0.6)$  ptnf ja kf.



# Binomijakauman toistokoetulkinta

- Binomijakaumaa  $\text{Bin}(n, p)$  noudattava sm syntyy **toistokokeessa**, jossa toistetaan riippumattomasti  $n$  kertaa sellaista (Bernoullin) koetta, jossa yhdessä kokeessa onnistumistodennäköisyys on  $p$ .
- Jos  $X$  on onnistumisten lukumäärä  $n$  toistossa, niin  $X \sim \text{Bin}(n, p)$ .
- Tulos perustellaan myöhemmin.
- Bernoullin jakauma  $\text{Bernoulli}(p)$  on tietenkin sama kuin binomijakauma  $\text{Bin}(1, p)$ .

## 2.5 Integraalilaskennan kertausta

- Matemaattisessa analyysissä on määritelty erilaisia integrointiprosesseja, joista sinulle (tässä vaiheessa opintoja) ainoastaan **Riemannin integraali** on tuttu.
- Todennäköisyytlaskennan teoriassa Riemannin integraalin käyttö johtaisi tiettyihin asian kannalta epäoleellisiin hankaluuksiin, minkä takia matemaatikot käyttävät sen sijasta ns. **Lebesguen integraalia**.
- Tämän kurssin puitteissa näiden kahden integraalikäsitteen eroilla ei ole merkitystä, vaan kurssin tehtävät saadaan ratkaistua käyttämällä tuttua Riemannin integraalia, mutta usein tarvitaan ns. **epäoleellista** Riemannin integraalia.

# Antiderivaatta eli integraalifunktio

## Määritelmä

Olkoon  $f$  välillä  $I$  määritelty reaalifunktio. Tällöin sanomme, että  $F$  on funktion  $f$  **antiderivaatta** eli **integraalifunktio**, jos

$$F'(x) = f(x), \quad \text{kaikilla } x \in I. \quad (2)$$

(Välin päätepisteissä derivaatta tässä tarvittaessa määritellään toispuoleisena derivaattana.)

- Jos  $F$  on  $f$ :n antiderivaatta ja  $C$  on vakio, niin myös  $F + C$  on  $f$ :n antiderivaatta. Antiderivaattoja on siis monta!
- Jokaisella suljetulla äärellisellä välillä  $I = [a, b]$  määritellyllä jatkuvalla funktiolla  $f$  on olemassa antiderivaatta välillä  $I$ .



# Riemannin integraalin määritelmästä

- Funktion  $f$  Riemannin integraali välin  $[a, b]$  yli määritellään eräänlaisena summien raja-arvona, mikäli ko. raja-arvo on olemassa. Tällöin sanotaan, että  $f$  on Riemann-integroituva välin  $[a, b]$  yli.
- Määritelmä toimii ainoastaan äärellisille integrointiväleille  $[a, b]$ , ja lisäksi integroitavan funktion eli integrandin  $f$  tulee on rajoitettu integrointivälillä.
- Integraalien arvoja lasketaan hyvin harvoin suoraan määritelmän perusteella, vaan tämän sijasta integraali tyypillisesti lasketaan antiderivaatan avulla.

# Integraalin laskeminen antiderivaatan avulla

- Jos  $f$  on äärellisellä välillä  $[a, b]$  määritelty jatkuva funktio, niin sen **määrätty integraali** (engl. *definite integral*) välin  $[a, b]$  yli saadaan laskettua seuraavasti, jos tunnetaan jokin  $f$ :n antiderivaatta  $F$ :

$$\int_a^b f(x) dx = \int_a^b F'(x) dx = F(b) - F(a). \quad (3)$$

- Integrandin muuttaminen äärellisessä määrässä pisteitä ei muuta integraalin arvoa. Jos  $f$  on Riemann-integroituva välin  $[a, b]$  yli ja  $g = f$  kaikkialla muualla paitsi äärellisessä määrässä pisteitä, niin  $g$  on Riemann-integroituva, ja

$$\int_a^b g(x) dx = \int_a^b f(x) dx. \quad (4)$$

# Osittaisintegrointi

- Olkoot  $u$  ja  $v$  välillä  $[a, b]$  määriteltyjä jatkuvasti derivoituvia funktioita.
- Kun otetaan huomioon tulon derivointikaava

$$\frac{d}{dx}[u(x)v(x)] = u'(x)v(x) + u(x)v'(x),$$

saadaan tulos

$$\int_a^b u(x)v(x) = \int_a^b (u'(x)v(x) + u(x)v'(x)) dx,$$

josta järjestelmällä saadaan **osittaisintegrointikaava** (engl. *integration by parts*)

$$\int_a^b u(x)v'(x) dx = \int_a^b u(x)v(x) - \int_a^b u'(x)v(x) dx. \quad (5)$$

# Sijoitus määrättyssä integraalissa

- Olkoon  $f$  jatkuva funktio välillä  $I$ , joka sisältää integrointivälin  $[a, b]$ , ja olkoon  $g : [c, d] \rightarrow I$  jatkuvasti derivoituva funktio siten, että  $g(c) = a$  ja  $g(d) = b$ . Olkoon  $F$  funktion  $f$  integraalifunktio.
- Tällöin

$$\int_a^b f(x) dx = \int_a^b F(x) = F(g(d)) - F(g(c)) = \int_c^d F(g(t)).$$

- Toisaalta

$$\frac{d}{dt} F(g(t)) = f(g(t)) g'(t), \quad \text{kaikilla } t \in [c, d]$$

jota käyttämällä saadaan sijoituskeinoon kaava

$$\int_a^b f(x) dx = \int_c^d f(g(t)) g'(t) dt. \quad (6)$$

# Sijoituskeino formaalisti

Formaalisti kaavassa

$$\int_a^b f(x) dx = \int_c^d f(g(t)) g'(t) dt.$$

sijoitetaan integraaliin

- $x = g(t)$
- $dx = g'(t) dt$ .
- Lisäksi alkuperäiset  $x$ -rajat  $(a, b)$  vaihdetaan vastaaviksi  $t$ -rajoiksi  $(c, d)$ , joille  $a = g(c)$  ja  $b = g(d)$ .

# Sijoituskeinoon käyttämisestä

## Sijoituskaava

$$\int_a^b f(x) dx = \int_c^d f(g(t)) g'(t) dt$$

on yhtälö, joten sitä voi käyttää kumpaankin suuntaan tahansa; usein käytetään oikealta vasemmalle.

- *Ideana* on tunnistaa monimutkaisesta integroitavasta lausekkeesta jokin **osalauseke**  $g(t)$ , jonka merkitseminen uudeksi muuttujaksi  $u$  yksinkertaistaa lauseketta.
- *Vaikeutena* on, että “jostain” pitää löytyä (tekijänä) kyseisen **osalausekkeen derivaatta**  $g'(t)$ .
- Aina voi kokeilla monenlaisia sijoituksia, mutta vaatii taitoa ja kokemusta löytää toimiva sijoitus joka todella yksinkertaistaa integraalin johonkin helpompaan muotoon.

# Sijoituskeino: Helppo esimerkki

Muistetaan, että  $\int \sin x \, dx = -\cos x + C$ . Yritetään laskea

$$\int_0^{\pi/2} (\sin 2x) \, dx.$$

- Toimisiko sijoitus  $u = g(x) = 2x$ ?
- Nyt  $du = g'(x)dx = 2 \, dx$ . Vakiotekijä 2 on helppo järjestää.

$$\begin{aligned} \int_0^{\pi/2} (\sin 2x) \, dx &= \frac{1}{2} \int_{x=0}^{x=\pi/2} (\sin 2x) \, 2 \, dx \\ &= \frac{1}{2} \int_{u=0}^{u=\pi} (\sin u) \, du = \frac{1}{2} (-\cos \pi + \cos 0) = 1. \end{aligned}$$

Huomaa integrointirajat! Havainnollisuuden vuoksi tässä on merkitty, minkä muuttujan rajoista on kysymys. Piirrä kuva!

## Sijoituskeino: Muita esimerkkejä

Samankaltainen vakiotekijän eliminointi tulee kohta vastaan ns. eksponenttijakauman tiheysfunktion integraalissa, joka on muotoa

$$\int \lambda e^{-\lambda x} dx.$$

Tämä sujuu helposti sijoituksella  $u = -\lambda x$ .

Entäpä jos integraali onkin tällainen?

$$\int_0^{\infty} x e^{-x^2} dx$$

Integraali sievenee huomattavasti sijoituksella  $u = x^2$ . Huomaa differentiaali  $du = 2x dx$ , johon tarvittava derivaatta  $2x$  onnekkaisesti löytyy integroitavasta (paitsi vakiotekijää 2, joka ei tuota ongelmia).



# Mitä ehtoja tarvitaan, kun integraali lasketaan antiderivaatan avulla?

- Kaavan (3) kohdalla vaadittiin, että integrandin  $f$  tulee olla **jatkuva** funktio kyseessä olevalla **äärellisellä suljetulla välillä** ennen kuin integraalin saa laskettua antiderivaatan  $F$  avulla.
- Jos  $f$  on muuten jatkuva, mutta sillä on hyppy pisteessä  $a < c < b$ , niin tällöin integrointialue voidaan pilkkoa jakopisteellä  $c$  väleihin  $[a, c]$  ja  $[c, b]$  ja yrittää laskea integraali summana

$$\int_a^b f(x) dx = \int_a^c f(x) dx + \int_c^b f(x) dx.$$

Suotuisassa tapauksessa kumpikin integraaleista saadaan laskettua antiderivaatan avulla.

# Milloin tarvitaan epäoleellista integraalia?

- Jos (a) integrointivälin päätepiste on äärettömyydessä tai jos (b) funktio  $f$  kasvaa rajatta integrointivälin päätepisteessä, niin Riemannin integraalin perusmääritelmä ei tuota mitään tulosta.
- Tällöin integraali joudutaan laskemaan ns. epäoleellisena (engl. *improper*) integraalina.
- Tämä tarkoittaa käytännössä raja-arvon laskemista sellaisesta integraalista, jossa ongelmallinen päätepiste on korvattu hyvin käyttäytyvällä pisteellä, jonka sitten annetaan lähestyä alkuperäistä ongelmallista päätepistettä.

## Esimerkki, jossa integrandi kasvaa rajatta

- Laskemme integraalin  $\int_0^1 x^{-a} dx$ , jossa  $0 < a < 1$ .
- Tämä integraali on epäoleellinen, sillä funktio  $x^{-a}$  kasvaa rajatta, kun  $x \rightarrow 0+$ .
- Jos  $\epsilon > 0$ , niin integraali välin  $[\epsilon, 1]$  yli saadaan laskettua antiderivaatan avulla, sillä

$$\int_{\epsilon}^1 x^{-a} dx = \int_{\epsilon}^1 \frac{x^{-a+1}}{-a+1} = \frac{1}{1-a} - \frac{\epsilon^{1-a}}{1-a}.$$

Tässä  $\epsilon^{1-a} \rightarrow 0$ , kun  $\epsilon \rightarrow 0+$  sen takia, että  $1 - a > 0$ .

- Koska raja-arvo on olemassa, niin alkuperäinen integraali saadaan laskettua epäoleellisena integraalina, ja

$$\int_0^1 x^{-a} dx = \lim_{\epsilon \rightarrow 0+} \int_{\epsilon}^1 x^{-a} dx = \frac{1}{1-a}.$$

# Esimerkki, jossa toinen integrointiraja on äärettömydessä

- Laskemme integraalin  $\int_1^{\infty} x^{-a} dx$ , kun  $a > 1$ .
- Integraali on epäoleellinen sen takia, että ylempi päätepiste on ääretön.

$$\begin{aligned}\int_1^{\infty} x^{-a} dx &= \lim_{M \rightarrow \infty} \int_1^M x^{-a} dx = \lim_{M \rightarrow \infty} \left[ -\frac{x^{1-a}}{a-1} \right]_1^M \\ &= \lim_{M \rightarrow \infty} \left( -\frac{M^{1-a}}{a-1} + \frac{1}{a-1} \right) = \frac{1}{a-1}.\end{aligned}$$

- Lausekkeessa  $M^{1-a}$  potenssi on negatiivinen, joten tämä lauseke lähestyy nollaa, kun  $M \rightarrow \infty$ .

## 2.6 Jatkuva jakauma

### Määritelmä (Jatkuva jakauma, tiheysfunktio)

Satunnaismuuttujalla  $X$  on **jatkuva jakauma tiheysfunktiolla  $f$**  (lyh. **tf**), jos  $f$  on ei-negatiivinen ja jos kaikilla  $a < b$

$$P(a \leq X \leq b) = \int_a^b f(x) dx$$

Tiheysfunktio on englanniksi **(probability) density function, pdf**.  
Toisinaan puhutaan tiheysfunktion sijasta lyhyesti tiheydestä.  
Sen sijaan, että sanotaan että sm:lla  $X$  on jatkuva jakauma voidaan sanoa että

- $X$ :n jakauma on jatkuva,
- $X$  on jatkuvasti jakautunut,
- $X$  on jatkuva satunnaismuuttuja.

- Jatkuvan jakauman tiheysfunktioille käytetään muuten samaa symbolia kuin sen kf:lle, mutta tiheysfunktion symboli kirjoitetaan pienellä kirjaimella (esim.  $f$ ,  $g$  tai  $f_X$ ) ja kf:n symboli vastaavalla isolla kirjaimella (esim.  $F$ ,  $G$  tai  $F_X$ ).
- Joskus tiheysfunktio häviää jonkin joukon  $B \subset \mathbb{R}$  ulkopuolella. Tällöin tiheysfunktion kaava voidaan ilmoittaa vain joukossa  $B$ , ja asiayhteydestä pitää ymmärtää, että  $f(x) = 0$ , kun  $x \notin B$ .

# Mikä integraalikäsitys?

- Jatkuvan jakauman määritelmässä esiintyvä integraali tarkoittaa itseasiassa **Lebesguen integraalia**, mutta sovelluksissa esiintyvät tiheysfunktiot ovat jatkuvia funktioita kaikkialla muualla paitsi äärellisessä määrässä pisteitä, ja niiden **integraalit voidaan käytännössä laskea Riemannin integraalien avulla**.
- Integrointialue ei välttämättä ole äärellinen väli.
- Tiheysfunktio voi olla yhdessä tai useammassa pisteessä singulaarinen siten, että ainakin toinen sen toispuoleisista raja-arvoista on ääretön.
- Integrointialue joudutaan usein ensin pilkkomaan paloihin, minkä jälkeen tiheysfunktion integraali saadaan palautettua **summaksi (mahdollisesti epäoleellisia) Riemannin integraaleja**.

# Tiheysfunktion (epä)yksikäsitteisyydestä

- Jakauman tiheysfunktio ei ole yksikäsitteinen, mutta melkein yksikäsitteinen.
- Jos  $f$  on tietyn jakauman tf ja  $g$  on yhtä kuin  $f$  muualla paitsi äärellisessä määrässä pisteitä, niin

$$\int_a^b f(x) dx = \int_a^b g(x) dx$$

kaikilla  $a < b$ . Tämän takia myös  $g$  on kyseisen jakauman tf.

- Ei-negatiiviset funktiot  $f$  ja  $g$  ovat saman jakauman tiheysfunktioita, jos ja vain jos ne yhtyvät melkein kaikkialla, eli joukko jossa  $f \neq g$  on nollamittainen (mikä käsite määritellään reaalianalyysin kursseilla).



# Välien sattumistodennäköisyydet

- Jos  $X$ :n jakauma on jatkuva ja sen tf on  $f$ , niin

$$P(X = x) = P(x \leq X \leq x) = \int_x^x f(u) du = 0$$

kaikilla  $x$ , joten **pistetodennäköisyys on aina nolla**.

- Ptnf ei ole hyödyllinen käsite jatkuville jakaumille.
- Koska kaikki pistetodennäköisyydet ovat nollia, niin

$$\begin{aligned} P(a < X < b) &= P(a \leq X < b) = P(a < X \leq b) \\ &= P(a \leq X \leq b) = \int_a^b f(x) dx, \end{aligned}$$

kun  $a < b$ .

## Toinen tapa karakterisoida jatkuva jakauma

- Rajankäynnin jälkeen huomataan, että puoliäärettömien välien todennäköisyydet saadaan myöskin tf:a integroimalla. Esim.

$$P(X \leq x) = P(X < x) = \int_{-\infty}^x f(u) du.$$

- Itse asiassa pätee

$$P(X \in B) = \int_B f(x) dx, \quad \text{kaikille } B \subset \mathbb{R}, \quad (7)$$

jossa integraalin alaindeksi  $B$  tarkoittaa joukon  $B$  yli laskettua integraalia, ts.

$$\int_B f(x) dx = \int_{-\infty}^{\infty} 1_B(x) f(x) dx.$$

# Kertymäfunktion ja tiheysfunktion yhteys

## Lause (Kertymäfunktion ja tiheysfunktion yhteys)

Olkoon  $X$ :llä jatkuva jakauma.

(a) Jos  $X$ :n tiheysfunktio on  $f$ , niin sen kertymäfunktio  $F$  on

$$F(x) = \int_{-\infty}^x f(u) \, du.$$

(b) Jos  $X$ :n kertymäfunktio on  $F$ , niin  $F$  on derivoituva melkein kaikkialla, ja  $X$ :n tiheysfunktiksi voidaan valita  $F'$ .

*Huomautus:* Kun sanotaan, että tiheysfunktiksi voidaan valita  $f = F'$ , niin tarkoitetaan sitä, että tiheysfunktiksi valitaan jokin funktio  $f$ , joka yhtyy funktion  $F$  derivaattaan niissä pisteissä, joissa derivaatta on määritelty, ja muissa pisteissä  $f$  saadaan määritellä mielivaltaisesti.

# Eräs tapa tunnistaa kertymäfunktioista, että jakauma on jatkuva

## Lause

Olkoon  $F$  sellainen kertymäfunktio, että

- (1)  $F$  on jatkuva koko reaaliakselilla,
- (2)  $F$  on derivoituva kaikkialla muualla paitsi mahdollisesti äärellisessä määrässä pisteitä,
- (3) ja lisäksi derivaatta  $f = F'$  on jatkuva kaikkialla muualla paitsi mahdollisesti äärellisessä määrässä pisteitä.

Tällöin  $F$  on jatkuvan jakauman kertymäfunktio, ja jakauman tiheysfunktioksi voidaan valita sen derivaatta  $f = F'$ .

# Todistuksen perusidea

Jos  $[a, b]$  on sellainen äärellinen väli, joka ei sisällä yhtään pistettä, jossa  $F$ :n derivaatta ei ole jatkuva, niin

$$F(b) - F(a) = \int_a^b F'(u) \, du.$$

Lisäksi otetaan raja-arvoja ja käytetään kertymäfunktion ominaisuuksia.

- Jos  $X$ :llä on jatkuva jakauma, niin sen  $k_f$  on jatkuva. Sen sijaan  $t_f$  voi olla hyvin epäsäännöllinen funktio. Tilastollisissa sovelluksissa esiintyvät tiheysfunktiot ovat varsin säännöllisiä funktioita, sillä ne ovat jatkuvia kaikkialla paitsi äärellisessä määrässä pisteitä.  $T_f$ :n ei tarvitse olla rajoitettu funktio.
- Täydellinen karakterisointi:  $k_f$   $F$  on jatkuvan jakauman  $k_f$  täsmälleen silloin, kuin  $F$  on **absoluuttisesti jatkuva**, mutta tämän asian määrittäminen jätetään reaalianalyysin kurssien huoleksi.
- Täsmällisempi nimitys jatkuvalle jakaumalle olisi *absoluuttisesti jatkuva jakauma*.

# Kuinka tunnistan, että funktio on tiheysfunktio?

Jos  $X$ :llä on tiheys  $f$ , niin

$$1 = P(\Omega) = P(X \in \mathbb{R}) = \int_{-\infty}^{\infty} f(x) dx,$$

joten tiheysfunktion integraali koko reaaliakselin yli on yksi.

## Lause

Jos  $f : \mathbb{R} \rightarrow \mathbb{R}$  on ei-negatiivinen, ja sen integraali koko reaaliakselin yli on yksi, niin se on jonkin satunnaismuuttujan tiheysfunktio.

# Normalisoimaton tiheysfunktio

## Lause

Jos  $g \geq 0$  on sellainen reaaliakselilla määritelty funktio, jonka integraali  $\int_{-\infty}^{\infty} g(x) dx$  on äärellinen ja aidosti positiivinen, niin tällöin on olemassa vakio  $k$  siten, että  $f = k g$  on tiheysfunktio.

*Todistus* Valitaan  $1/k = \int_{-\infty}^{\infty} g(x) dx$ , jonka jälkeen

$$\int f(x) dx = k \int g(x) dx = \frac{k}{k} = 1.$$

*Huomautus.* Tällä tavalla jokainen **normalisoimaton tiheysfunktio**  $g$  määrää yksikäsitteisellä tavalla jatkuvan jakauman, jonka tiheysfunktio on edellä konstruoitu  $f$ .



# Tiheysfunktion arvioiminen aineistosta

- Olkoon  $sm$ :lla  $X$  tiheysfunktio  $f$ , jota emme tunne.
- Oletetaan, että meillä on aineisto  $x_1, x_2, \dots, x_N$ , jota voidaan pitää  $N$  riippumattoman  $sm$ :n  $X$ :n jakaumaa noudattavan  $sm$ :n havaittuina arvoina.
- Toisin sanoen

$$x_1 = X_1(\omega^{\text{act}}), x_2 = X_2(\omega^{\text{act}}), \dots, x_N = X_N(\omega^{\text{act}}),$$

jossa  $\omega^{\text{act}}$  on aktualisoitunut alkeistapaus, kullakin  $X_i$  on sama jakauma kuin  $X$ :llä ja lisäksi  $X_1, \dots, X_N$  ovat riippumattomia (mikä määritellään myöhemmin).

- Kuinka tällaisessa tilanteessa voidaan arvioida tiheysfunktion arvoa pisteessä  $u$ ? Oletetaan, että  $u$  on  $f$ :n jatkuvuus piste.

# Eräs ratkaisu

- Valitaan jokin pieni luku  $h > 0$  ja lasketaan, kuinka moni otospisteistä  $x_i$  osuu  $h$ :n pituiselle välille

$$\left[u - \frac{h}{2}, u + \frac{h}{2}\right].$$

Olkoon tämä lukumäärä  $N_{u,h}$ .

- Tiheysfunktion määritelmän ja frekvenssitulkinnan nojalla

$$P\left(u - \frac{h}{2} \leq X \leq u + \frac{h}{2}\right) = \int_{u-h/2}^{u+h/2} f(x) dx \approx \frac{N_{u,h}}{N}.$$

- Toisaalta, integraalilaskennan väliarvolauseen nojalla

$$\int_{u-h/2}^{u+h/2} f(x) dx \approx hf(u).$$

- Yhdistämällä saadaan arvio  $f(u) \approx \frac{N_{u,h}}{hN}$ . Tässä voidaan käyttää myös muita  $h$ :n pituisia välejä, jotka sisältävät pisteen  $u$  kuin tämä.

## 2.7 Esimerkkejä jatkuvista jakaumista

- tasajakauma
- eksponenttijakauma
- gammajakauma, beetajakauma, normaalijakauma, khiin neliön jakauma,  $t$ -jakauma,  $F$ -jakauma (luvussa 5).

# Tasajakauma

- Olkoon  $a, b \in \mathbb{R}$  ja  $a < b$ . Satunnaismuuttujalla  $X$  on **välin  $(a, b)$  tasajakauma**,  $X \sim U(a, b)$ , jos sillä on jatkuva jakauma tiheysfunktiona  $f$ , jossa



$$f(x) = f(x \mid a, b) = \frac{1}{b-a}, \quad \text{kun } a < x < b.$$

(Tästä kaavasta pitää ymmärtää, että  $f(x) = 0$ , kun  $x \leq a$  tai  $x \geq b$ .) Tiheys on siis *vakio* koko välillä  $(a, b)$ .

- Kertymäfunktio on

$$F(x) = \int_{-\infty}^x f(u) \, du = \begin{cases} 0, & \text{kun } x \leq a, \\ \frac{x-a}{b-a}, & \text{kun } a < x < b, \\ 1, & \text{kun } x \geq b. \end{cases}$$

# Tasajakauman $U(0, 1)$ tiheys- ja kertymäfunktio



# Eksponenttijakauma (engl. *exponential distribution*)

- Satunnaismuuttujalla  $X$  on eksponenttijakauma parametrilla  $\lambda > 0$ ,  $X \sim \text{Exp}(\lambda)$ , jos  $X$ :llä on tf

$$f(x) = f(x | \lambda) = \lambda e^{-\lambda x}, \quad \text{kun } x > 0.$$

- Kun  $x > 0$ , niin eksponenttijakauman kf:lla on arvo

$$F(x) = \int_0^x (-e^{-\lambda u}) = 1 - e^{-\lambda x},$$

ja  $F(x) = 0$ , kun  $x \leq 0$ .

## 2.8 Satunnaismuuttujan muunnos

- Jos  $X$  on sm, ja  $g : \mathbb{R} \rightarrow \mathbb{R}$  on funktio, niin myös  $Y = g(X)$  on sm.
- Merkintä  $Y = g(X)$  tarkoittaa sitä, että

$$Y(\omega) = g(X(\omega)), \quad \text{kaikilla } \omega \in \Omega,$$

ts.  $Y$  on yhdistetty funktio  $g \circ X$ .

- Mitä voimme sanoa  $Y$ :n jakaumasta?

Jos  $g : \mathbb{R} \rightarrow \mathbb{R}$  on funktio ja  $A \subset \mathbb{R}$ , niin merkintä  $g^{-1}(A)$  tarkoittaa joukon  $A$  **alkukuva**a kuvauksessa  $g$ , eli

$$g^{-1}(A) = \{x \in \mathbb{R} : g(x) \in A\}.$$

Huomaa, että

$$g(x) \in A \iff x \in g^{-1}(A).$$



# Muunnoksen $g(X)$ jakauma diskreetissä tapauksessa

## Lause

Olkoon  $X$  diskreetti sm ptnf:lla  $f_X$ , ja olkoon  $g : \mathbb{R} \rightarrow \mathbb{R}$  funktio. Tällöin sm  $Y = g(X)$  diskreetti, ja sen ptnf  $f_Y$  on

$$f_Y(y) = \sum_{x \in g^{-1}(\{y\})} f_X(x).$$

*Todistus:*  $Y$  voi saada korkeintaan numeroituvasti äärettömän määrän eri arvoja, joten  $Y$  on diskreetti. Mille tahansa  $y \in \mathbb{R}$  on

$$\begin{aligned} P(Y = y) &= P(g(X) = y) = P(g(X) \in \{y\}) = P(X \in g^{-1}(\{y\})) \\ &= \sum_{x \in g^{-1}(\{y\})} f_X(x), \end{aligned}$$

- Jos yhtälöllä  $y = g(x)$  on yksikäsitteinen ratkaisu  $x = h(y)$  kaikilla  $y$ , jotka kuuluvat sm:n  $Y$  arvojoukkoon  $S_Y$ , niin

$$f_Y(y) = f_X(h(y)), \quad y \in S_Y. \quad (8)$$

- Jatkuvan jakauman tilanteessa saadaan erilainen kaava.
- Jos taas ratkaisuja on useita, niin jokainen erisuuri ratkaisu antaa ptnf:n arvoon pisteessä  $y$  yhden tällaisen termin lisää.

# Jatkuvasti jakautuneen satunnaismuuttujan muunnos

- Jos  $X$ :llä on jatkuva jakauma, niin sen muunnoksen  $Y = g(X)$  jakauma voi funktion  $g$  luonteesta riippuen joko diskreetti, jatkuva tai ei kumpaakaan näistä.
- Esim. jos  $g$  on porraskfunktio, niin  $Y = g(X)$  on diskreetti satunnaismuuttuja.
- Myöhemmin tarkastelemme tapausta, jossa satunnaismuuttujalla  $Y = g(X)$  on jatkuva jakauma.
- Luentomonisteessa on esimerkki, jossa muunnoksella  $Y = g(X)$  ei ole diskreetti eikä jatkuva jakauma, vaan ns. sekatyypin jakauma.

## 2.9 Kvantiilifunktio ja sen käyttö simuloinnissa

- Tarkastelemme sellaista jatkuvaa jakaumaa, jonka tiheysfunktio  $f$  on aidosti positiivinen välillä  $(a, b)$  ja nolla muualla.
- Päätepisteille sallitaan reaalisten arvojen lisäksi arvot  $a = -\infty$  tai  $b = \infty$ .
- Tällaisen jakauman kertymäfunktio  $F$ , on aidosti kasvava välillä  $(a, b)$ , ja lisäksi  $F(a) = 0$  ja  $F(b) = 1$ .

# Kvantiilifunktio on kertymäfunktion käänteisfunktio



- Oletusten ansiosta funktiolla  $F$  on olemassa käänteisfunktio  $F^{-1} : (0, 1) \rightarrow (a, b)$ . (Tarkemmin sanoen  $F$ :n rajoittumalla joukon  $(a, b)$  on käänteisfunktio  $F^{-1}$ .)
- Merkintä  $F^{-1}$  **ei tarkoita** funktiota  $1/F$ , vaan kertymäfunktion **käänteisfunktioita**.
- Käytännössä  $F^{-1}(u)$  määritetään ratkaisemalla  $x$  yhtälöstä

$$F(x) = u, \quad 0 < u < 1.$$

- Tällaista (avoimella välillä  $(0, 1)$  määriteltyä) kertymäfunktion käänteisfunktioita  $F^{-1}$  kutsutaan kyseisen jakauman **kvantiilifunktioksi** (engl. *quantile function*). (Myös nimitys fraktiilifunktio on käytössä.)

# Kvantiilifunktion määritelmää havainnollistava kuva

Erään jatkuvan jakauman kvantiilifunktion  $q = F^{-1}$  arvo pisteessä  $u = 0.7$ . Ylempänä on kertymäfunktio  $F$  ja alempana tiheysfunktio  $f$ .



# Kvantiilifunktion merkitys

- Osuus  $u$  jakauman todennäköisyysmassasta jää pisteen  $F^{-1}(u)$  vasemmalle puolelle eli vasemmanpuoleiseen häntään: jos sm:lla  $X$  on kf  $F$ , niin

$$P(X \leq F^{-1}(u)) = F(F^{-1}(u)) = u, \quad \text{mielivaltaiselle } 0 < u < 1.$$

- Ts. tiheysfunktion  $f$  alle jää pisteen  $F^{-1}(u)$  vasemmalle puolelle alue, jonka pinta-ala on  $u$ , sillä

$$u = P(X \leq F^{-1}(u)) = \int_{-\infty}^{F^{-1}(u)} f(x) dx.$$

- Koska jakauma on jatkuva, niin pisteen  $F^{-1}(u)$  oikealle puolelle jää jakauman todennäköisyysmassasta osuus  $1 - u$ , eli tiheysfunktion alle jäävän oikeanpuoleisen häntäalueen pinta-ala on  $1 - u$ .

# Alakvantiilit ja yläkvantiilit

- Kvantiilifunktio määriteltiin tarkastelemalla jakauman vasemmanpuoleista häntää.
- Tilastollisessa päättelyssä määritetään testien kriittisiä pisteitä usein jakauman oikeanpuoleisen hännän avulla.
- Selvyyden vuoksi voimme puhua jakauman *alakvantiileista* ja *yläkvantiileista*.
- Jos  $0 < u < 1$ , niin jakauman  **$u$ -alakvantiili** (eli  $u$ -kvantiili tai  $u$ -fraktiili) on sellainen piste, josta vasemmalle jää jakaumasta osuus  $u$ . Ts.  $u$ -alakvantiili on  $F^{-1}(u)$ .
- Jakauman  **$u$ -yläkvantiili** taas on sellainen piste, josta oikealle jää jakaumasta osuus  $u$ , joten  $u$ -yläkvantiili on  $F^{-1}(1 - u)$ , sillä

$$P(X \geq F^{-1}(1-u)) = 1 - P(X < F^{-1}(1-u)) = 1 - (1-u) = u.$$



# Erikoisnimityksiä tietyille kvantiileille

- **mediaani** on  $\frac{1}{2}$ -kvantiili,
- **alakvartiili** on  $\frac{1}{4}$ -kvantiili,
- **yläkvartiili** on  $\frac{3}{4}$ -kvantiili.
- Näiden lisäksi puhutaan myös kvintiileistä, desiileistä ja persentiileistä.

Huom! Tässä kvantiilit määriteltiin **pisteinä**, joiden alapuolelle jää tietty osuus jakaumasta. Tilastotieteessä esim. kvartiililla tai desiilillä saatetaan tarkoittaa myös **jakauman osaa**, esim.

“tulonjakotilaston alakvartiili” = tuloiltaan alin neljäsosa väestöstä;  
“III desiili” = se osa joka on kvantiilipisteiden  $\frac{2}{10}$  ja  $\frac{3}{10}$  välissä.

# Kertymäfunktion käänteisfunktion ominaisuuksia

- Funktio  $F^{-1}$  toteuttaa identiteetit

$$F^{-1}(F(x)) = x, \quad \text{kaikilla } a < x < b,$$

ja

$$F(F^{-1}(u)) = u, \quad \text{kaikilla } 0 < u < 1.$$

- Koska  $F$  on aidosti kasvava funktio, niin myös  $F^{-1}$  on aidosti kasvava funktio.
- Jos jompaa kumpaa sovelletaan epäyhtälön molemmille puolille, niin epäyhtälön ratkaisujoukko säilyy muuttumattomana.

# Kertymäfunktio muunnos

- Olkoon  $X$  sm, jolla on kertymäfunktio  $F$ . Tarkastellaan satunnaismuuttujaa  $Y = F(X)$ .
- Jos  $0 < u < 1$ , niin

$$\begin{aligned} P[Y \leq u] &= P[F^{-1}(Y) \leq F^{-1}(u)] = P[X \leq F^{-1}(u)] \\ &= F(F^{-1}(u)) = u. \end{aligned}$$

- Tämä tarkoittaa sitä, että

$$Y = F(X) \sim U(0, 1). \quad (9)$$

- Satunnaismuuttujaan  $F(X)$ , ja tulokseen  $F(X) \sim U(0, 1)$  viitataan toisinaan nimellä **kertymäfunktio muunnos** (engl. *probability integral transform, PIT*).

# Käänteisfunktio menetelmä

- Olkoon  $U \sim U(0, 1)$ , ja tarkastellaan satunnaismuuttujaa  $Z = F^{-1}(U)$ .
- Jos  $a < x < b$ , niin

$$\begin{aligned} P(Z \leq x) &= P[F^{-1}(U) \leq x] = P[F(F^{-1}(U)) \leq F(x)] \\ &= P[U \leq F(x)] = F(x) \end{aligned}$$

- Siis

$U \sim U(0, 1) \Rightarrow$  sm:n  $F^{-1}(U)$  kertymäfunktio on  $F$ .

Tällöin sanotaan, että sm  $Z = F^{-1}(U)$  on saatu **käänteisfunktio menetelmällä** (engl. *inverse transform method*).

# Käänteisfunktio menetelmä simuloinnissa

- Matemaattisissa ohjelmistoissa on yleensä **satunnaislukugeneraattori**, jonka tuottamia arvoja voidaan pitää riippumattomina jakaumaa  $U(0, 1)$  noudattavien satunnaismuuttujien arvoina.
- Jos jakauman kvantiilifunktiolla on yksinkertainen lauseke, niin käänteisfunktio menetelmä antaa kätevän keinon simuloida kyseistä jakaumaa:

generoi  $u$  jakaumasta  $U(0, 1)$ , ja laske  $x = F^{-1}(u)$ .

## Esimerkki: eksponenttijakauman $\text{Exp}(1)$ simulointi

- Kf on

$$F(x) = \begin{cases} 1 - e^{-x}, & \text{jos } x \geq 0 \\ 0, & \text{muuten,} \end{cases}$$

- Kvantiilifunktion arvo  $F^{-1}(u)$  pisteessä  $0 < u < 1$  saadaan ratkaisemalla  $x$  yhtälöstä

$$F(x) = u \quad \Leftrightarrow \quad x = -\ln(1 - u).$$

- Tämän takia jakaumaa  $\text{Exp}(1)$  voidaan simuloida asettamalla  $X = -\ln(1 - U)$ , kun  $U$  on ensin generoitu jakaumasta  $U(0, 1)$ .

# Kvantiilifunktion käyttö empiiriseen tarkasteluun

- Aiemmin todettiin: Jos  $X$  noudattaa tiettyä jakaumaa, jonka kertymäfunktio on  $F$  (voidaan merkitä:  $X \sim F$ ), niin muunnoksen  $Y = F(X)$  jakauma on tasajakauma  $U(0, 1)$ .
- Olkoon käytettävissä otos  $x_1, x_2, \dots, x_n$  ja hypoteesi (arvelu), että ne ovat peräisin jakaumasta, jonka kertymäfunktio on  $F$ .
- Lasketaan muunnokset  $y_1 = F(x_1)$  jne. Nyt saadaan  $n$  lukua, joiden pitäisi oletuksen ja kertymäfunktioimuunnoksen mukaan olla otos tasajakaumasta  $U(0, 1)$ .
- Esim. kuvallisesti voidaan tutkia, “näyttääkö” otos  $y_1, y_2, \dots, y_n$  sellaiselta otokselta. Jos ei, on ehkä oletus  $X \sim F$  väärä! Vrt. tilastotieteen *P-P plot*.

- Kvantiilifunktio voidaan yleistää mielivaltaiselle jakaumalle, ks. luentomoniste.
- Myös käänteisfunktio menetelmä yleistyy, ja tämän jälkeen reseptiä  $F^{-1}(U)$  voidaan pitää tapana konstruoida sm, jolla on haluttu kf  $F$ , mikäli ensin todistetaan että tasajakauma  $U(0, 1)$  on olemassa.



## 2.10 Muunnetun satunnaismuuttujan tiheys

- Olkoon  $X$ :llä jatkuva jakauma, ja  $g : \mathbb{R} \rightarrow \mathbb{R}$ .
- Satunnaismuuttujalla  $Y = g(X)$  ei tällöin välttämättä ole jatkuva jakauma.
- Jos kuitenkin  $g$  on riittävän sileä ja aidosti monotoninen, tai jos sen määrittelyjoukko  $\mathbb{R}$  voidaan osittaa paloihin, joissa  $g$  on riittävän sileä ja aidosti monotoninen, niin osoittautuu, että tällöin  $Y$ :llä on jatkuva jakauma.

- Jos muunnoksella  $Y = g(X)$  on jatkuva jakauma, niin tiheysfunktio on mahdollista johtaa laskemalla ensin kertymäfunktio ja sitten kertymäfunktion derivaatta.
- Tämän lisäksi pitää jollakin tavalla tarkistaa, että  $Y$ :n jakauma todellakin on jatkuva.
- Tarkistus voidaan tehdä esim. suoraan tiheysfunktion määritelmän nojalla.
- Vaihtoehtona on käyttää lausetta 2.7 (moniste s. 27)

# Kertymäfunktio tekniikka, $Y = e^X$

- Olkoon  $X$ :llä jokin jatkuva jakauma, jolla on jatkuva tiheysfunktio  $f_X$ , ja tarkastellaan muunnosta  $Y = e^X$ .
- Selvästi  $Y > 0$ , joten  $F_Y(y) = 0$ , kun  $y < 0$ . Kun  $y > 0$ , on
$$F_Y(y) = P(Y \leq y) = P(e^X \leq y) = P(X \leq \ln(y)) = F_X(\ln(y)),$$
- Lasketaan kf:n derivaatta:

$$f_Y(y) = F_Y'(y) = f_X(\ln(y))/y, \quad \text{kun } y > 0,$$

ja  $f_Y(y) = 0$ , kun  $y \leq 0$ .

- Lauseen 2.7 avulla voidaan tarkistaa, että  $Y$ :n jakauma on jatkuva. Tämän jälkeen tiedetään, että  $F$ :n derivaatta kelpaa  $Y$ :n tiheysfunktiksi.

# $Y = e^X$ : muuttujanvaihtotekniikka

- Tarkistetaan, että tn  $P(a \leq Y \leq b)$  saadaan laskettua integroimalla tiettyä funktiota välin  $(a, b)$  yli, kun  $a < b$  ovat mielivaltaisia. Koska  $Y > 0$ , voidaan olettaa, että  $a > 0$ .

$$\begin{aligned} P(a \leq Y \leq b) &= P(a \leq e^X \leq b) \\ &= P(\ln a \leq X \leq \ln b) \\ &= \int_{\ln a}^{\ln b} f_X(x) dx && (X\text{:n tf on } f_X) \\ &= \int_a^b f_X(\ln(y)) \frac{1}{y} dy && (\text{Sij. } y = e^x \Leftrightarrow x = \ln(y)) \end{aligned}$$

- Esimerkin tekniikka yleistetään kohta lauseeksi.

## Määritelmä (Diffeomorfismi)

Kuvaus  $g : A \rightarrow B$ , jossa  $A$  ja  $B$  ovat  $d$ -ulotteisen avaruuden  $\mathbb{R}^d$  avoimia osajoukkoja, on diffeomorfismi, jos

- (a)  $g$  on bijektio joukkojen  $A$  ja  $B$  välillä
- (b) sekä  $g$  että sen käänteisfunktio  $g^{-1} : B \rightarrow A$  ovat jatkuvasti derivoituvia.

# Muuttujanvaihtokaava tiheysfunktioille

## Lause (Muuttujanvaihtokaava tiheysfunktioille)

Olkoon sm:lla  $X$  jatkuva jakauma tf:lla  $f_X$ . Olkoon  $g : A \rightarrow B$  diffeomorfismi, jossa  $A, B \subset \mathbb{R}$  ovat avoimia välejä, ja olkoon

$$P(X \in A) = 1.$$

Määritellään  $h(y) = g^{-1}(y)$ , kun  $y \in B$ . Tällöin sm:lla  $Y = g(X)$  on jatkuva jakauma tiheysfunktioilla

$$f_Y(y) = \begin{cases} f_X(h(y)) |h'(y)|, & \text{kun } y \in B \\ 0, & \text{muuten.} \end{cases} \quad (10)$$

- Tulos (10) voidaan ilmaista lyhyemmin kaavalla

$$f_Y(y) = f_X(h(y)) |h'(y)|, \quad \text{kun } y \in B.$$

- Kun muunnoksen  $Y = g(X)$  tiheysfunktio ilmoitetaan, on tärkeää paitsi kertoa kaava  $f_X(h(y)) |h'(y)|$  myös ilmoittaa selkeästi kaavan pätevyysalue, eli se joukko  $B$ , jossa kyseinen kaava pätee.
- Vertaa jatkuvan jakauman tapauksen tulosta (10) vastaavan diskreetin tapauksen tulokseen (8). Vain jatkuvan jakauman tapauksessa tarvitaan käänteisfunktion derivaatan itseisarvoa.

# Kaksi erilaista tekniikkaa

Muunnetun satunnaismuuttujan tiheysfunktio voidaan johtaa kahdella erilaisella tekniikalla:

- johdetaan kertymäfunktio ja lasketaan tiheysfunktio kertymäfunktion derivaattana,
- käytetään muuttujanvaihtokaavaa.



# Huomautuksia kertymäfunktio-tekniikasta

- Kertymäfunktio-tekniikassa pitää erikseen tarkistaa, että saatu kertymäfunktio on jatkuvan jakauman kertymäfunktio.
- Ehdoton edellytys tälle asialle on se, että kertymäfunktion pitää olla jatkuva funktio koko reaaliakselilla.
- Lauseen 7 mukaan riittävää jakauman jatkuvuudelle on se, jos kertymäfunktio on lisäksi jatkuvasti derivoituva muualla paitsi äärellisessä määrässä poikkeuspisteitä. (Poikkeuspisteissä derivaatan ei välttämättä tarvitse olla olemassa.)

# Huomautuksia muuttujanvaihtokaavasta

- Muuttujanvaihtokaavaa käytettäessä pitää miettiä, mitkä ovat avoimet joukot  $A$  ja  $B$ .
- Lisäksi käänteisfunktio  $h$  pitää pystyä ratkaisemaan yhtälöstä  $g(x) = y$  (ja tämä ei onnistu ellei kyseessä ole bijektio).
- Tämän jälkeen on tyypillisesti helppo tarkistaa, onko lauseke  $g(x)$  jatkuvasti derivoituva joukossa  $A$  ja onko lauseke  $h(y)$  jatkuvasti derivoituva joukossa  $B$ .
- Jos nämä ehdot täyttyvät, niin kyseessä on diffeomorfismi.

- Jos  $g$  on diffeomorfismi, niin muuttujanvaihtokaavan muistamista helpottaa seuraava muistisääntö.
- Yhtälön

$$f_X(x) |dx| = f_Y(y) |dy| \quad (11)$$

pitää säilyä bijektiivisessä muuttujanvaihdossa


$$y = g(x) \iff x = h(y).$$

- Kun tiedosta (11) ratkaistaan  $f_Y(y)$ , saadaan

$$f_Y(y) = f_X(x) \left| \frac{dx}{dy} \right| = f_X(h(y)) |h'(y)|,$$

mutta tietenkin tämä kaava pätee vain  $g$ :n kuvajoukossa  $B$ .

# Muistisääntö $f_X(x) |dx| = f_Y(y) |dy|$ infinitesimaalisen järkeilyn avulla



# Muistisääntö on robusti

- Muistisäännöstä (11) voidaan ratkaista  $f_Y(y)$  myös toisella tavalla, nimittäin seuraavasti,

$$f_Y(y) = f_X(x) \frac{1}{\left| \frac{dy}{dx} \right|} = \frac{f_X(x)}{|g'(x)|} = \frac{f_X(h(y))}{|g'(h(y))|}.$$

- Myös tämä kaava pitää paikkansa joukossa  $B$ , sillä kaava

$$\frac{dx}{dy} = \frac{1}{\frac{dy}{dx}}$$

kertoo oikean yhteyden funktion ja sen käänteisfunktion derivaattojen välillä.

- Aidosta monotonisuudesta seuraa se, että  $|g'| > 0$  joukossa  $A$  ja  $|h'| > 0$  joukossa  $B$ .

# Esimerkki $Y = e^X$ muistisäännön avulla

- Tarkastelemme bijektiivistä vastaavuutta

$$y = e^x \Leftrightarrow x = \ln(y)$$

pisteiden  $x \in \mathbb{R}$  ja  $y > 0$  välillä. Koska molemmat lausekkeet ovat jatkuvasti derivoituvia, on kyseessä diffeomorfismi.

- Ratkaisemme muistisäännöstä kaavan

$$f_Y(y) = f_X(x) \left| \frac{dx}{dy} \right|$$

- Koska tahdomme laskea  $f_Y$ :n arvon pisteessä  $y$ , pitää kaavan oikealla puolella  $x$  esittää  $y$ :n avulla kaavalla  $x = \ln(y)$ .  
Kaavassa tarvitaan myös tämän lausekkeen derivaattaa  $1/y$ .  
Kun teemme nämä sijoitukset, saamme tuloksen

$$f_Y(y) = f_X(\ln(y)) \frac{1}{y}, \quad y > 0.$$

- Joskus tiheysfunktion muuttujanvaihtokaavaa tarvitaan myös sellaisessa tilanteessa, jossa  $g$  ei ole monotoninen, mutta jossa sen määrittelyjoukko voidaan pilkkoa väleiksi, joille rajoitettuna  $g$  on aidosti monotoninen.
- Tällaiset tilanteet saadaan hoidettua samaan tapaan kuin seuraavassa esimerkissä.

## Esimerkki $Y = X^2$

- Olkoon  $X$ :llä jatkuva jakauma, jolla on jatkuva tiheysfunktio  $f_X$ . Tarkastellaan satunnaismuuttujaa  $Y = X^2$ .
- Selvästi  $Y \geq 0$ , joten  $F_Y(y) = 0$ , kun  $y < 0$ .
- Kun  $y > 0$ , on

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(X^2 \leq y) = P(-\sqrt{y} \leq X \leq \sqrt{y}) \\ &= F_X(\sqrt{y}) - F_X(-\sqrt{y}). \end{aligned}$$

- Tarkistetaan lauseen 7 avulla, että  $Y$ :n jakauma on jatkuva.
- Funktio  $F_X$  on jatkuvan jakauman kertymäfunktiona jatkuva, joten ainoa ongelmallinen piste on  $y = 0$ . Tässä pisteessä pitää tarkistaa  $F_Y$ :n jatkuvuus, mutta tarkistus on helppoa, koska  $F_X(x)$  on jatkuva pisteessä  $x = 0$ .
- $F_Y(y)$  on derivoituva muualla paitsi mahdollisesti pisteessä  $y = 0$ .



# Tiheysfunktio kertymäfunktiota derivoimalla

- Derivaatan laskemisen jälkeen näemme, että  $Y$ :n tf on

$$f_Y(y) = f_X(\sqrt{y}) \frac{1}{2\sqrt{y}} + f_X(-\sqrt{y}) \frac{1}{2\sqrt{y}}, \quad \text{kun } y > 0,$$

ja  $f_Y(y) = 0$ , kun  $y \leq 0$ .

- Kumpaakin yhtälön  $y = x^2$  ratkaisua vastaa tässä yksi termi.

# Muuttujanvaihtotekniikka muunnokselle $Y = g(X)$ , kun $g$ ei ole monotoninen

- Luentomonisteessa on muotoiltu kohtuullisen yleinen lause 2.13.
- Tiheysfunktioon  $f_Y(y)$  saadaan summa termejä, yksi termi kutakin yhtälön  $y = g(x)$  ratkaisua kohti. Kukin termeistä on samaa muotoa kuin diffeomorfismin tapauksessa.
- Jos lauseen 2.13 oletukset ovat voimassa, niin muunnoksen  $Y = g(X)$  tiheysfunktio saadaan laskea myös kertymäfunktio tekniikalla: johdetaan ensin  $sm:n$   $Y$  kertymäfunktio  $F_Y$  ja sitten derivoidaan tämä funktio.