

## SATUNNAISMUUTTUJAT

- Satunnaismuuttuja kuvaa kokeen tuloksen reaaliakselille
- Satunnaismuuttuja on siis funktio  $X(s)$  joka saa reaalisia arvoja
- Koe  $s$  kuuluu todennäköisyysavaruuteen  $S$  ( $s \in S$ )
- Esimerkkejä
  - Kolikon heitossa todennäköisyysavaruus  $S = \{\text{kruunu}, \text{klaava}\}$   
Satunnaismuuttuja voisi olla

$$X(s) = \begin{cases} 1 & (s = \text{kruunu}) \\ -1 & (s = \text{klaava}) \end{cases}$$

- Nopan heitossa  $S = \{1, 2, 3, 4, 5, 6\}$ .
- Satunnaismuuttuja voi olla  $X(s) = s$ , jolloin mahdolliset tulokset ovat 1,2,3,4,5,6
- Satunnaismuuttuja voi olla myös  $X(s) = s^2$ , jolloin mahdolliset tulokset ovat 1,4,9,16,25,36
- Usein merkitään yksinkertaisuuden vuoksi  $X(s) = X$ , mutta on syytä muistaa mistä on kysymys
- Kompleksinen satunnaismuuttuja  $Z$  on kahden reaalisen satunnaismuuttujan  $X$  ja  $Y$  funktio siten että  $Z = X + jY$ . Muuttujan  $Z$  ominaisuuksia tarkasteltaessa on tiedettävä ko. summan ominaisuudet

- Satunnaismuuttuja voi saada äärellisen määrän eri arvoja  $\rightarrow$  *diskreetti satunnaismuuttuja* (kuten edellisissä esimerkeissä)
- Satunnaismuuttuja voi myös saada kaikkia mahdollisia arvoja joltain tietyltä väliltä reaaliakselilla  $\rightarrow$  *jatkuva satunnaismuuttuja* (kuten elektronisten laitteiden generoiman kohinan amplitudi)

- Käytännön tutkimustyössä tehdään usein seuraavaa:
  - Näytteistetyin satunnaissignaalin (tiedonsiirtokanavasta vastaanotettu signaali) elementit ovat diskreettejä satunnaismuuttujia, mutta analyysissä niitä kohdellaan jatkuvina, koska jatkuvia muuttujia on helpompi käsitellä
  - Jos sananleveys on riittävä (useita bittejä, ei kahta), niin näin tehty analyysi vastaa kokeellisia tuloksia
  - Pienille sananleveyksille (muutama bitti) näin tehty analyysi ei ole tarkka vaan analyysi ja simulaatiotulokset (joissa käytetään ko. sananleveyttä) poikkevat jonkin verran toisistaan

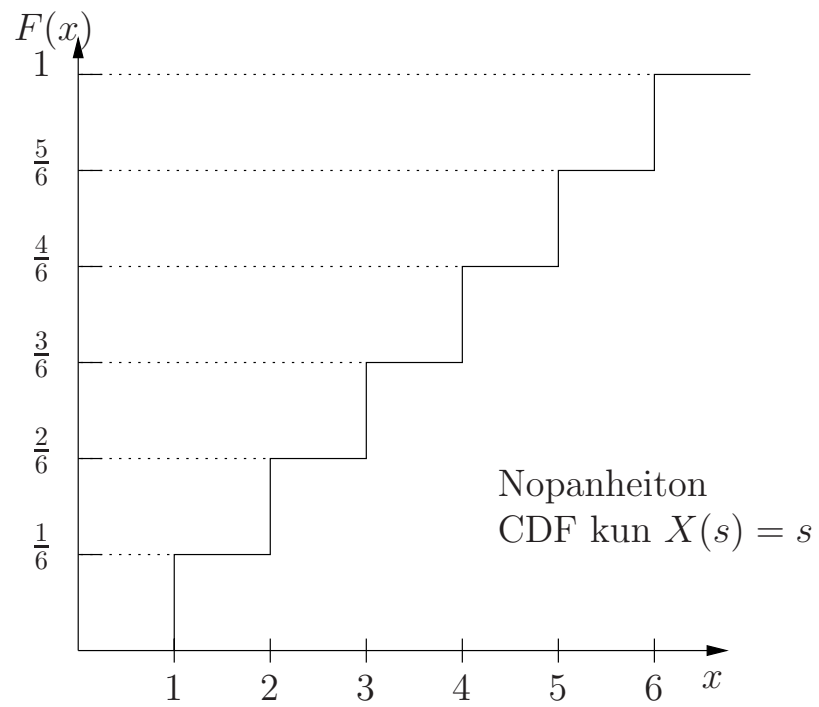
## SATUNNAISMUUTTUJAT JA TODENNÄKÖISYYS

- Tarkastellaan tapahtumaa jossa satunnaismuuttuja  $X$  on lukua  $x$  pienempi eli tarkastellaan tapahtumaa  $\{X \leq x\}$ .
- $x$  voi olla mikä tahansa reaaliluku väliltä  $(-\infty < x < \infty)$
- Tapahtuman todennäköisyys on  $P(X \leq x)$
- Yleensä se merkitään lyhyesti  $F(x)$  (tai  $F_X(x)$  jos on vaara seikoittaa johonkin muuhun vastaavaan funktioon) eli

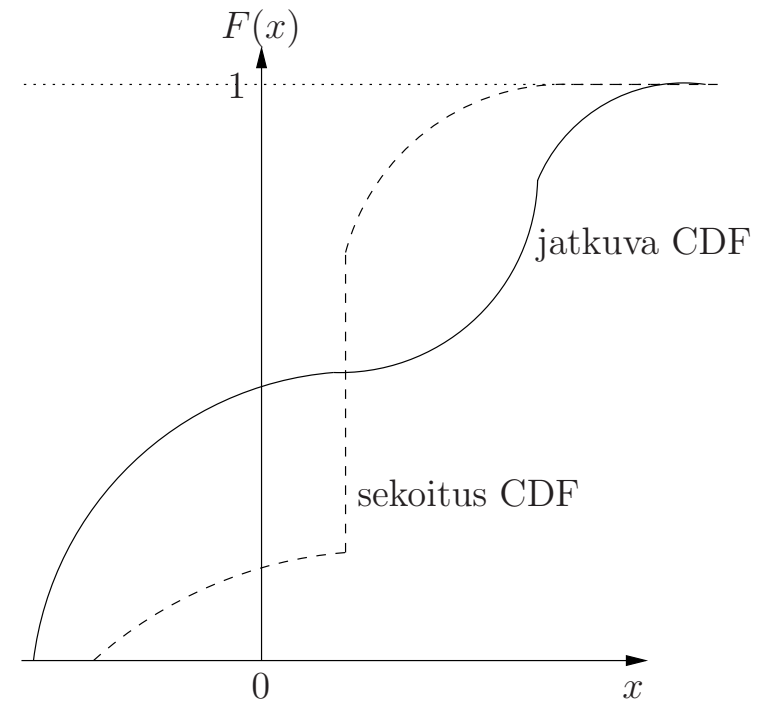
$$F(x) = P(X \leq x) \quad (-\infty < x < \infty) \quad (22)$$

- Funktiota  $F(x)$  kutsutaan *todennäköisyys kertymäfunktioksi* tai *kumulatiiviseksi kertymäfunktioksi* (CDF, cumulative distribution funktion)
- CDF siis kuvaa millä todennäköisyydellä satunnaismuuttuja  $X$  on lukua  $x$  pienempi

- CDF on todennäköisyys joten  $0 \leq F(x) \leq 1$
- On myös helppo havaita että  $F(-\infty) = 0$  ja  $F(\infty) = 1$
- CDF on kasvava funktio eli  $F(x_1) \leq F(x_2)$ ,  $x_1 < x_2$
- Seuraavassa esimerkkejä diskreetistä ja jatkuvasta kertymäfunktioista sekä näiden sekoituksesta



Diskreetti CDF



Jatkuva ja sekoitus CDF:t

- Kertymäfunktion  $F(x)$  derivaattaa  $p(x)$  (myös  $p_X(x)$ ) kutsutaan satunnaismuuttujan  $X$  *todennäköisyys tiheysfunktiksi* (PDF, probability density function)
- Nyt siis pätee

$$p(x) = \frac{dF(x)}{dx} \quad (-\infty < x < \infty) \quad (23a)$$

ja

$$F(x) = \int_{-\infty}^x p(u) du \quad (-\infty < x < \infty) \quad (23b)$$

- Koska  $F(x)$  on kasvava, niin  $p(x) \geq 0$
- Selvästi  $\int_{-\infty}^{\infty} p(x) dx = F(\infty) = 1$  (pinta-ala on 1)



- Diskreettien muuttujien tapauksessa  $p(x)$  sisältää impulssin  $F(x)$ :n epäjatkuvuuskohdassa  $x_i$  eli tällaisessa kohdassa  $p(x)$  on


$$p(x_i) = P(X = x_i)\delta(x - x_i) \quad (24)$$

jossa  $\delta(x)$  on impulssifunktio eli

$$\delta(x) = \begin{cases} 1 & x = 0 \\ 0 & x \neq 0 \end{cases} \quad (25)$$

- Satunnaismuuttujalla  $X$  sanotaan olevan *jakauma*. Jakaumat on usein nimetty henkilöiden (mahdollisesti keksijä) tai PDF funktion mukaan
- Esimerkkinä ensimmäisestä on Gaussin jakauma ja toisesta eksponentiaallinen jakauma, jossa PDF on eksponentiaallinen.
- Kullakin jakaumalla on PDF ja CDF, joista se on tunnistettavissa.

- Usein halutaan tietää todennäköisyys jolla satunnaismuuttuja on jollain välillä eli tapahtuman  $\{x_1 < X \leq x_2\}$  todennäköisyys ( $x_1 < x_2$ )
- Tapahtuma voidaan aina esittää kahden toisensa poissulkevan tapahtuman unionina (usein käytetty temppu)
- Tapahtuma  $\{X \leq x_2\}$  on selvästi tapahtumien  $\{X \leq x_1\}$  ja  $\{x_1 < X \leq x_2\}$  unioni



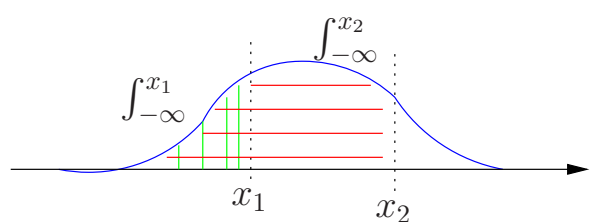
- Tällöin

$$P(X \leq x_2) = P(X \leq x_1) + P(x_1 < X \leq x_2)$$

eli

$$F(x_2) = F(x_1) + P(x_1 < X \leq x_2)$$

- Tästä seuraa

$$\begin{aligned}
 P(x_1 < X \leq x_2) &= F(x_2) - F(x_1) \\
 &= \int_{-\infty}^{x_2} p(x) dx - \int_{-\infty}^{x_1} p(x) dx \\
 &= \int_{x_1}^{x_2} p(x) dx
 \end{aligned} \tag{26}$$


- Todennäköisyys että satunaismuuttuja  $X$  saa arvoja väliltä  $x_1 < X \leq x_2$  on siis PDF:n integraali yli tuon alueen

## USEITA SATUNNAISMUUTUJIA

- Kun tarkastellaan useita yhtäaikaisia tapahtumia tai peräkkäisiä tapahtumia pitää tietää näiden yhteis kertymä- ja/tai tiheysfunktioit (*yhteisjakauma*)
- Useat satunnaismuuttujat muodostavat periaatteessa moniulotteisen funktion, joka on määritelty yhdistetyssä näyteavaruudessa
- Tarkastellaan ensin kahden muuttujan  $X_1$  ja  $X_2$  yhteisjakaumaa ja yleistetään tulokset sen jälkeen useammille muuttujille

- Yhteiskertymäfunktio (yhteis (joint) CDF) on

$$\begin{aligned} F(x_1, x_2) &= \text{P}(X_1 \leq x_1, X_2 \leq x_2) \\ &= \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} p(u_1, u_2) du_1 du_2 \end{aligned} \quad (27)$$

jossa  $p(x_1, x_2)$  on yhteis todennäköisyys tiheysfunktio (yhteis PDF), joka on

$$p(x_1, x_2) = \frac{\partial^2}{\partial x_1 \partial x_2} F(x_1, x_2) \quad (28)$$

- Kun yhteis PDF integroidaan yli toisen satunnaismuuttujan saadaan

$$\int_{-\infty}^{\infty} p(x_1, x_2) dx_2 = p(x_1) \quad (29)$$

jota kutsutaan *marginaaliseksi* PDF:ksi (erotukseksi varsinaisesta PDF:stä, jota ei ole saatu integroimalla)

- On helppo havaita että

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(x_1, x_2) dx_1 dx_2 = 1$$
$$F(-\infty, -\infty) = F(-\infty, x_2) = F(x_1, -\infty) = 0$$

- Yleistys useampiulotteisiin tapauksiin on suoraviivaista

$$\begin{aligned}
 F(x_1, \dots, x_n) &= P(X_1 \leq x_1, \dots, X_n \leq x_n) \\
 &= \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_n} p(u_1, \dots, u_n) du_1 \dots du_n \\
 p(x_1, \dots, x_n) &= \frac{\partial^n}{\partial x_1 \cdots \partial x_n} F(x_1, \dots, x_n)
 \end{aligned}$$

- Marginaaliset PDF:t voidaan generoida mille tahansa määrälle satunnaismuuttujia eli

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(x_1, x_2, x_3, x_4, x_5, \dots, x_n) dx_2 dx_4 = p(x_1, x_3, x_5, \dots, x_n)$$

- Havaitaan myös että

$$\begin{aligned}
 F(x_1, \infty, x_3, \infty, x_5, \dots, x_n) &= F(x_1, x_3, x_5, \dots, x_n) \\
 F(x_1, -\infty, x_2, \dots, x_n) &= 0
 \end{aligned}$$



## EHDOLLINEN TIHEYSFUNKTIO

- Ehdollinen todennäköisyshän oli  $P(A|B) = P(A, B)/P(B)$
- Ehdollisen todennäköisyyden, että muuttuja  $X_1$  on pienempi kuin  $x_1$  kun satunnaismuuttuja  $X_2$  on saanut arvon  $x_2$  eli todennäköisyyden  $P(X_1 \leq x_1 | X_2 = x_2)$  laskeminen ei yleisessä tapauksessa onnistu suoraan, koska tyypillisesti  $P(X_2 = x_2) = 0$  ( $\neq 0$  vain jos kyseessä distreetti muuttuja jolla jokin arvo ko. pisteessä)
- Lasketaan siis tapahtuman  $\{X_1 \leq x_1 | x_2 - \Delta < X_2 \leq x_2\}$  todennäköisyys, jossa  $\Delta$  on pieni positiivinen luku

- Tällöin

$$\begin{aligned} P(X_1 \leq x_1 \mid x_2 - \Delta < X_2 \leq x_2) &= \frac{\int_{-\infty}^{x_1} \int_{x_2 - \Delta}^{x_2} p(u_1, u_2) du_1 du_2}{\int_{x_2 - \Delta}^{x_2} p(u_2) du_2} \\ &= \frac{F(x_1, x_2) - F(x_1, x_2 - \Delta)}{F(x_2) - F(x_2 - \Delta)} \end{aligned} \tag{30}$$

- Olettaen, että vaaditut PDF:t ovat jatkuvia alueella  $(x_2 - \Delta, x_2)$  voidaan osoittaja ja nimittäjä yhtälössä (30) jakaa  $\Delta$ :lla ja ottaa raja-arvo  $\Delta \rightarrow 0$
- Derivaatan määritelmä:  $\lim_{h \rightarrow 0} (f(x) - f(x + h))/h$

- Tällöin

$$P(X_1 \leq x_1 | X_2 = x_2) \equiv F(x_1 | x_2) \quad (31)$$

$$\begin{aligned} &= \frac{\partial F(x_1, x_2) / \partial x_2}{\partial F(x_2) / \partial x_2} \\ &= \frac{\partial \left[ \int_{-\infty}^{x_1} \int_{-\infty}^{x_2} p(u_1, u_2) du_1 du_2 \right] / \partial x_2}{\partial \left[ \int_{-\infty}^{x_2} p(u_2) du_2 \right] / \partial x_2} \\ &= \frac{\int_{-\infty}^{x_1} p(u_1, x_2) du_1}{p(x_2)} \end{aligned} \quad (32)$$

- Derivoimalla tämä  $x_1$ :sen suhteen saadaan

$$p(x_1 | x_2) = \frac{p(x_1, x_2)}{p(x_2)} \quad (33)$$

joka on *ehdollinen* PDF.

- Selvästi meillä on myös

$$p(x_1, x_2) = p(x_1 | x_2)p(x_2) = p(x_2 | x_1)p(x_1) \quad (34)$$

- Yhtälön (34) yleistys on joskus hyödyllinen jakaumia määrättäessä.  
Se on

$$p(x_1, x_2, \dots, x_n) = p(x_1, \dots, x_k | x_{k+1}, \dots, x_n)p(x_{k+1}, \dots, x_n)$$

## RIIPPUMATTOMAT SATUNNAISMUUTTUJAT

- Riippumattomuushan tarkoitti että eri kokeiden ulostulot eivät millään lailla vaikuta toisiinsa.
- Havaittiin, että tällöin  $P(A_1, \dots, A_n) = P(A_1) \cdots P(A_n)$
- Koska satunnaismuuttujat liittyvät kokeisiin ja  $P(X \leq x) = F(x)$  niin

satunnaismuuttujat ovat *tilastollisesti riippumattomia* jos ja vain jos

$$F(x_1, \dots, x_n) = F(x_1) \cdots F(x_n) = \prod_{i=1}^n F(x_i) \quad (35)$$

tai

$$p(x_1, \dots, x_n) = p(x_1) \cdots p(x_n) = \prod_{i=1}^n p(x_i) \quad (36)$$

- Tämä tarkoittaa siis sitä, että riippumattomien satunnaismuuttujien CDF tai PDF on yksittäisten satunnaismuuttujien CDF:ien tai PDF:ien tulo
- Tämä on hyvin usein käytetty ja hyödyllinen tieto

## SATUNNAISMUUTTUIJEN FUNKTIOT

- Usein tarvitsee tietää mikä on satunnaismuuttujan/muuttujien funktion jakauma
- Tämä tarkoittaa, että halutaan tietää muuttujan  $Y = g(X)$  jakauma, kun tiedetään muuttujan  $X$  jakauma
- Tämä on varsin suoraviivaista jos kuvaus  $g$  on yksi-yhteen (yksikäsitteinen)
- Jos kuvaus ei ole yksikäsitteinen, esim.  $Y = X^2$ , niin jakauman määrittämisessä täytyy olla hyvin huolellinen
- Tätä tietoutta tullaan käyttämään esim. joidenkin tiedonsiirtomenetelmien suorituskyvyn määrittämisessä (DTS)

- Esimerkki 1

- Tarkastellaan muuttujaa  $Y = aX + b$ , jossa  $a > 0$  ja  $b$  ovat vakioita
- Kuvaus on lineaarinen ja monotooninen (= joko kasvava tai vähenevä funktio, nyt kasvava)
- Kuvaus on siis yksikäsitteinen
- Olkoon  $F_X(x)$  ja  $F_Y(y)$  muuttujien  $X$  ja  $Y$  CDF:t
- Selvästi

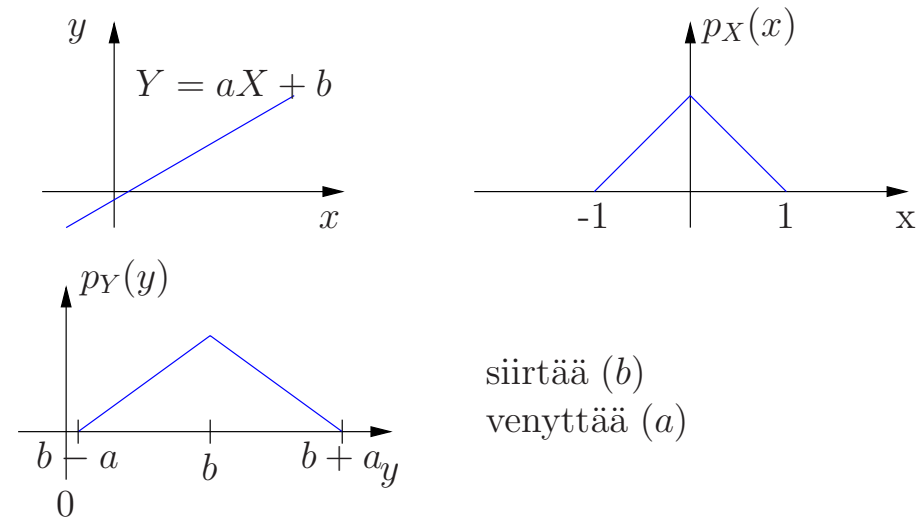
$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(aX + b \leq y) = P\left(X \leq \frac{y - b}{a}\right) \\ &= F_X\left(\frac{y - b}{a}\right) = \int_{-\infty}^{(y-b)/a} p_X(x) dx \end{aligned}$$

- Derivoimalla  $F_Y(y)$  saadaan

$$p_Y(y) = \frac{1}{a} p_X\left(\frac{y - b}{a}\right)$$



- Lineaarisisessa muunnoksessa muuttujan  $Y = aX + b$  jakauma on helposti esitettävissä muuttujan  $X$  jakauman avulla




Esimerkin 1 havainnollistaminen

- Esimerkki 2

- Tarkastellaan muuttujaa  $Y = aX^3 + b$

- Kuvaus on yksikäsitteinen



– Nyt on siis


$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(aX^3 + b \leq y) \\ &= P\left(X \leq \left(\frac{y-b}{a}\right)^{1/3}\right) = F_X\left(\left(\frac{y-b}{a}\right)^{1/3}\right) \end{aligned}$$

josta derivoimalla

$$p_Y(y) = \frac{1}{3a[(y-b)/a]^{2/3}} p_X\left(\left(\frac{y-b}{a}\right)^{1/3}\right)$$

- Esimerkki 3

- Nyt tarkastellaan muuttujaa  $Y = aX^2 + b$
- Kuvaus ei ole yksikäsitteinen sillä yhtä  $Y$ :n arvoa vastaa kaksi  $X$ :n arvoa



– Nyt

$$\begin{aligned} F_Y(y) &= P(aX^2 + b \leq y) \\ &= P\left(|X| \leq \sqrt{\frac{y-b}{a}}\right) = P\left(-\sqrt{\frac{y-b}{a}} < X \leq \sqrt{\frac{y-b}{a}}\right) \\ &= F_X\left(\sqrt{\frac{y-b}{a}}\right) - F_X\left(-\sqrt{\frac{y-b}{a}}\right) \end{aligned}$$

– Derivoimalla saadaan

$$p_Y(y) = \frac{p_X\left(\sqrt{(y-b)/a}\right)}{2a\sqrt{(y-b)/a}} + \frac{p_X\left(-\sqrt{(y-b)/a}\right)}{2a\sqrt{(y-b)/a}}$$

- Esimerkissä 3 havaittiin, että yhtälöllä  $g(x) = ax^2 + b$  on kaksi ratkaisua

$$x_1 = \sqrt{(y - b)/a} \text{ ja } x_2 = -\sqrt{(y - b)/a}$$

ja että muuttujan  $Y = aX^2 + b$  PDF on muotoa

$$p_Y(y) = \frac{p_X(x_1)}{|g'(x_1)|} + \frac{p_X(x_2)}{|g'(x_2)|}$$

jossa  $x_1$  ja  $x_2$  ovat yhtälön  $g(x) = ax^2 + b$  juuret ja  $g'(x)$  on  $g(x)$ :än derivaatta  $x$ :n suhteen

- Yleisesti muuttujalle  $Y = g(X)$  pätee

$$p_Y(y) = \frac{p_X(x_1)}{|g'(x_1)|} + \dots + \frac{p_X(x_n)}{|g'(x_n)|} = \sum_{i=1}^n \frac{p_X(x_i)}{|g'(x_i)|} \quad (37)$$

jossa  $x_i$ ,  $i = 1, \dots, n$  ovat yhtälön  $y = g(x)$  reaaliset juuret

- Sovelletaan edellistä tulosta (37) esimerkkiin 1
  - Nyt  $Y = aX + b$ , mutta ei rajoituta tilanteeseen  $a > 0$  kuten esimerkissä 1
  - Yhtälön  $y = g(x)$  juuri on  $x = (y - b)/a$  ja funktion  $g(x) = ax + b$  derivaatta on  $a$ .
  - Täten

$$p_Y(y) = \frac{p_X((y - b)/a)}{|a|}$$

## USEAN MUUTTUJAN TILANNE

- Olkoon  $\mathbf{X} = [x_1 \dots x_n]$   $n$  dimensioinen satunnaisvektori
- Sen CDF on  $F(\mathbf{X}) = F(x_1, \dots, x_n)$  ja PDF vastaavasti  $p(\mathbf{X}) = p(x_1, \dots, x_n)$ . Nämä ovat siis muuttujien  $X_1, \dots, X_n$  yhteis CDF ja PDF.

Vektorimerkintä on siis oiva tapa yksinkertaistaa merkintöjä

- Meillä on lisäksi yksiarvoiset (yksi ulostulo) funktiot  $g_i(\mathbf{X})$  ja satunnaismuuttujat  $Y_i = g_i(\mathbf{X})$ , jotka riippuvat muuttujista  $X_i$ ,  $i = 1, \dots, n$
- Myös  $Y_i$ :t ja  $g_i(\mathbf{X})$ :t voidaan vektorisoida eli  $\mathbf{Y} = [Y_1 \dots Y_n]$  ja  $\mathbf{g}(\mathbf{X}) = [g_1(\mathbf{X}) \dots g_n(\mathbf{X})]$
- Lisäksi oletetaan että käänteiskuvaukset  $x_i = g^{-1}(\mathbf{Y})$  ovat olemassa ja käänteisfunktiot ovat yksiarvoisia. Lisäksi vaaditaan, että funktioiden osittaisderivaatat ovat jatkuvia



(seuraava tulos ei siis sovi joka tilanteeseen)

- Silloin  $p(\mathbf{Y})$  on

$$p_Y(\mathbf{Y}) = p_X(\mathbf{g}^{-1}(\mathbf{Y})) \left| \frac{\partial \mathbf{g}^{-1}(\mathbf{Y})}{\partial \mathbf{Y}} \right| \quad (38)$$

$$= \frac{p_X(\mathbf{g}^{-1}(\mathbf{Y}))}{\left| \frac{\partial \mathbf{g}(\mathbf{X})}{\partial \mathbf{X}} \right|} \quad (39)$$

- Determinantit  $\left| \frac{\partial \mathbf{g}^{-1}(\mathbf{Y})}{\partial \mathbf{Y}} \right|$  ja  $\left| \frac{\partial \mathbf{g}(\mathbf{X})}{\partial \mathbf{X}} \right|$  ovat kuvausten  $\mathbf{g}^{-1}(\mathbf{Y})$  ja  $\mathbf{g}(\mathbf{X})$  Jacobiaanit
- Jacobiaanit ovat

$$\left| \frac{\partial \mathbf{g}^{-1}(\mathbf{Y})}{\partial \mathbf{Y}} \right| = \begin{vmatrix} \frac{\partial g_1^{-1}}{\partial y_1} & \cdots & \frac{\partial g_1^{-1}}{\partial y_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial g_n^{-1}}{\partial y_1} & \cdots & \frac{\partial g_n^{-1}}{\partial y_n} \end{vmatrix} \quad \text{ja} \quad \left| \frac{\partial \mathbf{g}(\mathbf{X})}{\partial \mathbf{X}} \right| = \begin{vmatrix} \frac{\partial g_1}{\partial x_1} & \cdots & \frac{\partial g_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial g_n}{\partial x_1} & \cdots & \frac{\partial g_n}{\partial x_n} \end{vmatrix} \quad (40)$$

- Jacobiaanit ovat siis muunnosten osittaisderivaatoista muodostettujen matriisien determinatteja
- Tulos (38) on esitetty oppikirjassa
- Tulosta (39) ei ole esitetty oppikirjassa mutta se voi olla hyödyllinen, sitähän käytettiin jo yhden muuttujan funktion jakauman löytämisessä eli yksikäsitteisessä tapauksessa tulos (37) on suora seuraus tuloksesta (39)

- Tulos (37) on hieman yleisempi (yhdelle muuttujalle) kuin (39), sillä siinä voi yhtälöllä  $y = g(x)$  voi olla useita ratkaisuja, mutta ratkaisussa (39) on oletettu yksi ratkaisu yhtälöryhmälle  $\mathbf{Y} = \mathbf{g}(\mathbf{X})$ . Tulos (39) on toki yleistettävissä
- Otetaan seuraava lineaarisen muunnoksen yleistys esimerkiksi kummankin tavan käytöstä. Kyseistä muunnosta käytetään hyvin usein, joten esimerkki on hyödyllinen
  - Olkoon  $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{b}$ , jossa  $\mathbf{A}$  on ei-singulaarinen  $n \times n$  muunnosmatriisi,  $\mathbf{Y}$  ja  $\mathbf{X}$  ovat  $n \times 1$  satunnaisvektoreita ja  $\mathbf{b}$  on  $n \times 1$  vakiovektori
  - Tällöin matriisin  $\mathbf{A}$  käänteismatriisi  $\mathbf{A}^{-1}$  on olemassa
  - Käytetään ensin tapaa (38)
  - Nyt  $\mathbf{X} = \mathbf{A}^{-1}(\mathbf{Y} - \mathbf{b}) = \mathbf{g}^{-1}(\mathbf{Y})$
  - Käänteiskuvauksen  $\mathbf{g}^{-1}(\mathbf{Y})$  Jacobiaani on  $|\mathbf{A}^{-1}|$

- Näin on koska  $\partial \mathbf{A}^{-1}(\mathbf{Y} - \mathbf{b}) / \partial \mathbf{Y} = \partial \{ \mathbf{A}^{-1} \mathbf{Y} - \mathbf{A}^{-1} \mathbf{b} \} / \partial \mathbf{Y} = \mathbf{A}^{-1}$
- Miksi näin? Tarkastellaan matriisi vektoritulon  $\mathbf{A}\mathbf{y}$   $i$ :nettä elementtiä  $x_i = \sum_j a_{ij}y_j$ , jossa  $a_{ij}$  ja  $y_j$  ovat  $m \times n$  matriisin  $\mathbf{A}$  ja  $n \times 1$  vektorin  $\mathbf{y}$  elementit. Silloin

$$\begin{aligned} \frac{\partial x_i}{\partial y_k} &= \frac{\partial \{ \sum_j a_{ij}y_j \}}{\partial y_k} \\ &= \frac{\partial \{ a_{i1}y_1 + \dots + a_{ik}y_k + \dots + a_{in}y_n \}}{\partial y_k} = a_{ik} \end{aligned}$$

eli matriisin  $\mathbf{A}$   $(i, k)$  :s elementti

- Osittaisderivaattoja  $\frac{\partial x_i}{\partial y_k}$  on  $m \times n$  kpl jotka järjestettynä matriisiin antavat halutun tuloksen eli

$$\frac{\partial \mathbf{x}}{\partial \mathbf{y}} = \frac{\partial \{ \mathbf{A}\mathbf{y} \}}{\partial \mathbf{y}} = \mathbf{A}$$

– Tuloksen (38) mukaan saadaan siis

$$p(\mathbf{Y}) = p_X(\mathbf{A}^{-1}(\mathbf{Y} - \mathbf{b})) |\mathbf{A}^{-1}| = \frac{p_X(\mathbf{A}^{-1}(\mathbf{Y} - \mathbf{b}))}{|\mathbf{A}|}$$

sillä determinanteille pätee  $|\mathbf{A}^{-1}| = 1/|\mathbf{A}|$

– Käytetään sitten tapaa (39)

– Tarkasteltava muunnos on  $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{b} = \mathbf{g}(\mathbf{X})$

– Muunnoksen  $\mathbf{g}(\mathbf{X})$  Jacobiaani on  $|\mathbf{A}|$

– Tuloksen (39) mukaan

$$p(\mathbf{Y}) = \frac{p_X(\mathbf{A}^{-1}(\mathbf{Y} - \mathbf{b}))}{|\mathbf{A}|}$$

joka on sama kuin tuloksen (38) avulla laskettu tulos

## TILASTOLLISET KESKIARVOT

- Satunnaismuuttujien tilastolliset keskiarvot ovat usein tarvittu ominaisuus ja ne ilmenevät useissa eri yhteyksissä, esim. demodulaattorien ja kanavakorjainten suunnittelussa
- Tärkeimpinä ovat ehkäpä ensimmäinen ja toinen momentti ja 2. keskeismomentti.
- Satunnaismuuttujan  $n$ :s momentti on

$$E\{X^n\} = \int_{-\infty}^{\infty} x^n p(x) dx \quad (41)$$

- 1. momenttia kutsutaan satunnaismuuttujan *tilastolliseksi keskiarvoksi* tai *odotusarvoksi* (mean or expected value) ja se on

$$E\{X\} \equiv m_x = \int_{-\infty}^{\infty} xp(x) dx \quad (42)$$

- Olkoon satunnaismuuttuja  $Y = g(X)$ . Sen odotusarvo on

$$E\{Y\} = \int_{-\infty}^{\infty} g(x)p(x) dx \quad (43)$$

- Miksi tämä kuvaa (yleisesti) keskiarvoa?
  - Diskreetissä tapauksessa  $E\{Y\} = \sum_i g(x_i)P(x = x_i)\delta(x - x_i)$  selvästi kuvaa muuttujien  $g(x_i)$  keskimääräistä arvoa
  - Esim. nopanheitossa, jos  $g(X) =$  nopan silmäluku, saadaan  $1 \times 1/6 + 2 \times 1/6 + \dots + 6 \times 1/6 = 3,5$   
eli 1 esiintyy frekvenssillä  $1/6$ , 2 frekvenssillä  $1/6$  jne. ja keskimääräinen arvo on 3,5
  - jatkuville muuttujille keskimääräinen arvo vastaa ylläolevaa integraalia

- Olkoon  $Y = (X - m_x)^n$  eli  $X$  josta on vähennetty keskiarvo (potenssiin  $n$ )
- Tämän keskiarvo on

$$E\{(X - m_x)^n\} = \int_{-\infty}^{\infty} (x - m_x)^n p(x) dx \quad (44)$$

jota kutsutaan *n:ksi keskeismomentiksi*

- Se on momentti keskiarvon suhteen
- 2. keskeismomenttia kutsutaan *varianssiksi* ja se on

$$E\{(X - m_x)^2\} \equiv \sigma_x^2 = \int_{-\infty}^{\infty} (x - m_x)^2 p(x) dx \quad (45)$$

ja se kuvaa muuttujan arvon heilumista keskiarvon ympärillä eli hajontaa



- Purkamalla neliöinti saadaan

$$\begin{aligned}\sigma_x^2 &= \int (x^2 - 2xm_x + m_x^2)p(x) dx \\ &= \underbrace{\int x^2 p(x) dx}_{E\{X^2\}} - 2m_x \underbrace{\int xp(x) dx}_{m_x} + m_x^2 \underbrace{\int p(x) dx}_1 \\ &= E\{X^2\} - m_x^2\end{aligned}\tag{46}$$

joka muodostaa yhteyden varianssin sekä ensimmäisen ja toisen momentin välille

- Nollakeskiarvoiselle satunnaismuuttujalle varianssi ja toinen momentti ovat samat

- Kahden muuttujan tapauksessa saadaan *yhteismomentti*

$$E\{X_1^k X_2^n\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1^k x_2^n p(x_1, x_2) dx_1 dx_2 \quad (47)$$

sekä *yhteis keskeismomentti*

$$E\{(X_1 - m_1)^k (X_2 - m_2)^n\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x_1 - m_1)^k (x_2 - m_2)^n p(x_1, x_2) dx_1 dx_2 \quad (48)$$

jossa  $m_i = E\{X_i\}$ .

- Kiinnostavin tilanne on kun  $n = k = 1$ . Silloin muuttujien  $X_i$  ja  $X_j$  yhteismomenttia kutsutaan *korrelaatioksi* ja yhteis keskeismomenttia *kovarianssiksi*

- Korrelaatio on siis

$$E\{X_i X_j\} \quad (49)$$

ja kovarianssi on

$$\mu_{ij} = E\{(X_i - m_i)(X_j - m_j)\} \quad (50)$$

eli ne ovat muuttujien tulojen odotusarvot

- Kovarianssin sekä korrelaation ja keskiarvojen välillä on yhteys

$$\begin{aligned} \mu_{ij} &= E\{X_i X_j - X_i m_j - m_i X_j + m_i m_j\} \\ &= E\{X_i X_j\} - \underbrace{E\{X_i\}}_{m_i} m_j - m_i \underbrace{E\{X_j\}}_{m_j} + m_i m_j \\ &= E\{X_i X_j\} - m_i m_j \end{aligned} \quad (51)$$

- Nollakeskiarvoisille muuttujille korrelaatio ja kovarianssi ovat samat

- Useamman muuttujan tapauksessa voidaan myös määritellä erilaisia yhteismomenteja mutta useimmiten ollaan kiinnostuttu vain korrelaatiosta ja kovarianssista eri muuttujien välillä.
- Olkoon meillä satunnaisvektori  $\mathbf{X} = [X_1 \ X_2 \ \dots \ X_n]^T$  jossa yläindeksi T tarkoittaa transpoosia.  $\mathbf{X}$  on siis  $n \times 1$  pystyvektori
- *Korrelaatiomatriisi* sisältää vektorin  $\mathbf{X}$  alkioden väliset korrelaatiot ja *kovarianssimatriisi* niiden väliset kovarianssit
- Korrelaatiomatriisi on siis

$$E\{\mathbf{X}\mathbf{X}^T\} = \begin{bmatrix} E\{X_1X_1\} & E\{X_1X_2\} & \dots & E\{X_1X_n\} \\ E\{X_2X_1\} & E\{X_2X_2\} & \dots & E\{X_2X_n\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{X_nX_1\} & E\{X_nX_2\} & \dots & E\{X_nX_n\} \end{bmatrix} \quad (52)$$

- Diagonaali sisältää kunkin alkion 2. keskeismomentin ja diagonaalin ulkopuoliset elementit alkioden välisiä yhteismomenteja

- Olkoon  $\mathbf{m} = E\{\mathbf{X}\} = [m_1 \ \dots \ m_n]^T$  muuttujien  $X_i$  keskiarvovektori
- Kovarianssimatriisi on

$$E\{(\mathbf{X} - \mathbf{m})(\mathbf{X} - \mathbf{m})^T\} = \begin{bmatrix} \mu_{11} & \mu_{12} & \dots & \mu_{1n} \\ \mu_{21} & \mu_{22} & \dots & \mu_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{n1} & \mu_{n2} & \dots & \mu_{nn} \end{bmatrix} \quad (53)$$

- Diagonaali sisältää alkioiden varianssit sillä  $\mu_{ii} = \sigma_i^2$
- Vastaavasti voidaan määrittää satunnaisvektorien  $\mathbf{X}$  ja  $\mathbf{Y}$  väliset *ristikorrelaatio-* ja *-kovarianssimatriisi* eli  $E\{\mathbf{X}\mathbf{Y}^T\}$  ja  $E\{(\mathbf{X} - \mathbf{m}_x)(\mathbf{Y} - \mathbf{m}_y)^T\}$

## KORRELOIMATTOMUUS

- Kahta satunnaismuuttujaa  $X_i$  ja  $X_j$  sanotaan *korreloimattomiksi* jos niiden välinen kovarianssi on nolla eli  $\mu_{ij} = 0$
- Tästä seuraa se, että korrelaatio on keskiarvojen tulo, sillä yhtälöstä

$$\mu_{ij} = E\{X_i X_j\} - m_i m_j = m_i m_j = 0$$

saadaan

$$E\{X_i X_j\} = m_i m_j = E\{X_i\} E\{X_j\}$$

- Tästä seuraa että tilastollisesti riippumattomat satunnaismuuttujat ovat korreloimattomia
- Tästä *ei seuraa* että korreloimattomat satunnaismuuttujat ovat välttämättä riippumattomia (näin toki voi olla)
- Satunnaismuuttujien sanotaan olevan *ortogonaalisia* jos

$$E\{X_i X_j\} = 0$$

- Näin on esim. jos muuttujat ovat korreloimattomia ja jompi kumpi tai molemmat keskiarvoista ovat nolliä

## KARAKTERISTINEN FUNKTIO

- Määritelmän mukaan satunnaismuuttujan *karakteristinen funktio* on

$$E\{e^{jvX}\} \equiv \psi(jv) = \int_{-\infty}^{\infty} e^{jvx} p(x) dx, \quad j = \sqrt{-1} \quad (54)$$

- Tämä vastaa Fourier muunnosta (lukuunottamatta eksponentin miinus merkkiä, mutta sillä ei ole väliä)
- Fourier käänteismuunnoksesta seuraa että muuttujan PDF karakteristisen funktion avulla ilmaistuna on

$$p(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \psi(jv) e^{-jvx} dv \quad (55)$$

- Karakteristisen funktion avulla voidaan siis määrittää muuttujan PDF



- Toinen hyödyllinen seikka on yhteys momentteihin
- Derivoimalla karakteristien funktio muuttujan  $v$  suhteen saadaan

$$\frac{d\psi(jv)}{dv} = j \int_{-\infty}^{\infty} x e^{jvx} p(x) dx$$

- Ratkaisemalla tämä pisteessä  $v = 0$  saadaan

$$\left. \frac{d\psi(jv)}{dv} \right|_{v=0} = j \int_{-\infty}^{\infty} xp(x) dx$$

eli 1. momentti (keskiarvo) on ilmaistavissa myös muodossa

$$E\{X\} = -j \left. \frac{d\psi(jv)}{dv} \right|_{v=0} \quad (56)$$

- Korkeamman asteen derivaatoista saadaan korkeammille momenteille yhtälö

$$E\{X^n\} = (-j)^n \frac{d^n \psi(jv)}{dv^n} \Big|_{v=0} \quad (57)$$

- Karakteristisen funktion avulla voidaan siis määrätä muuttujan momentit

- Karakteristinen funktio voidaan esittää sarjamuodossa
- Karakteristisen funktion Taylorin sarja pisteen  $v = 0$  ympäristössä on

$$\psi(jv) = \sum_{k=0}^{\infty} \frac{d^k \psi(jv)}{dv^k} \Big|_{v=0} \frac{v^k}{k!}$$

- Sijoittamalla tähän derivaatan paikalle yhtälöstä (56) saatu derivaatta saadaan

$$\psi(jv) = \sum_{k=0}^{\infty} E\{X^k\} \frac{(jv)^k}{k!} \quad (58)$$

- Karakteristinen funktio voidaan siis esittää myös momenttien avulla

- Karakteristisen funktion avulla on helppo löytää riippumattomien satunnaismuuttujien summan PDF
- Tarkastellaan usean muuttujan summaa eli muuttujaa

$$Y = \sum_{i=1}^n X_i$$

- Sen karakteristinen funktio on

$$\begin{aligned}\psi_Y(jv) &= \mathbb{E}\{e^{jvY}\} \\ &= \mathbb{E}\left\{\exp\left(jv\sum_{i=1}^n X_i\right)\right\} \\ &= \mathbb{E}\left\{\prod_{i=1}^n (e^{jvX_i})\right\} \quad (\text{sillä } e^{a+b} = e^a e^b) \\ &= \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} \left(\prod_{i=1}^n e^{jvx_i}\right) p(x_1, \dots, x_n) dx_1 \cdots dx_n\end{aligned}$$

- Koska muuttujat  $X_i$  ovat riippumattomia, niin  $p(x_1, \dots, x_n) = p(x_1) \cdots p(x_n)$  jolloin

$$\begin{aligned} \psi_Y(jv) &= \prod_{i=1}^n \left[ \int_{-\infty}^{\infty} e^{jvx_i} p(x_i) dx_i \right] \\ &= \prod_{i=1}^n \psi_{X_i}(jv) \end{aligned} \quad (59)$$

- Riippumattomien muuttujien summan karakteristinen funktio on siis yksittäisten muuttujien karakterististen funktioiden tulo
- Summan PDF on tämän käänteinen Fourier muunnos
- Jos muuttujat ovat *identtisesti jakautuneita* eli  $p(x_i) = p(x_j) \forall i, j$  niin

$$\psi_Y(jv) = \left[ \psi_X(jv) \right]^n \quad (60)$$

- Fourier muunnoksen ominaisuuksista seuraa, että PDF:iä käyttäen riippumattomien muuttujien summan PDF on yksittäisten PDF:ien konvoluutio
- Tulo on kuitenkin usein helpompi laskea kuin konvoluutio, joten karakteristisen funktion käyttö ko. summan PDF:n määrittämiseen on useimmiten järkevää

- Usean muuttujan yhteisjakauman tapauksessa tarvitaan moniulotteista Fourier muunnosta
- $n$ :lle muuttujalle karakteristinen funktio on

$$\begin{aligned}\psi(jv_1, \dots, jv_n) &= \mathbb{E} \left\{ \exp \left( j \sum_{i=1}^n v_i X_i \right) \right\} \\ &= \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} \exp \left( j \sum_{i=1}^n v_i x_i \right) p(x_1, \dots, x_n) dx_1 \cdots dx_n\end{aligned}$$

- Kahden muuttujan tapauksessa meillä on

$$\psi(jv_1, jv_2) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{j(v_1 x_1 + v_2 x_2)} p(x_1, x_2) dx_1 dx_2$$



- Momentit saadaan generoitua vastaavasti kuten yhden muuttujan tapauksessa ottamalla osittaisderivaatat muuttujien suhteen ja ratkaisemalla se pisteissä  $v_i = 0 \forall i$ .
- Esimerkiksi kahden muuttujan tapauksessa saadaan

$$\underbrace{jj}_{-1} E\{X_1 X_2\} = \frac{\partial^2 \psi(jv_1, jv_2)}{\partial v_1 \partial v_2} \Big|_{v_1=v_2=0}$$

- Korkeammat momentit voidaan käsitellä vastaavasti