



# Generointi yksinkertaisista diskreeteistä jakaumista

- Seuraavassa  $U, U_1, \dots, U_n$  tarkoittavat riippumattomia  $U(0,1)$ -jakautuneita sm:jia
- $\text{int}(X) = \lfloor X \rfloor = X$ :n kokonaisosa

Jakauma	Generointikaava
Symm. kaksiarvoinen $\{0,1\}$ jakauma $P\{X = 0\} = P\{X = 1\} = 0.5$	$\text{int}(2U)$ tai $\text{int}(U + 0.5)$
Kaksiarvoinen $\{0,1\}$ jakauma $P\{X = 0\} = 1 - p, P\{X = 1\} = p$	$\text{int}(U + p)$
Kaksiarvoinen $\{-1,1\}$ jakauma $P\{X = 0\} = 1 - p, P\{X = 1\} = p$	$2 \text{int}(U + p) - 1$
Kolmiarvoinen $\{0,1,2\}$ jakauma $\text{tn:t} = \{1 - p_1 - p_2, p_1, p_2\}$	$\text{int}(U + p_2) + \text{int}(U + p_1 + p_2)$
Tasainen diskreetti jakauma $\{0, 1, 2, \dots, n - 1\}$	$\text{int}(nU)$
Tasainen diskreetti jakauma $\{1, 2, 3, \dots, n\}$	$\text{int}(nU) + 1$
Binomijakauma $\text{Bin}(n, p)$	$\sum_{i=1}^n \text{int}(U_i + p)$



## Generointi geometrisesta jakaumasta

- Geometrista jakaumaa  $\text{Geom}(p)$  noudattavan diskreetin satunnaismuuttujan  $X$  pistetodennäköisyydet ovat

$$P\{X = i\} = p_i = p(1 - p)^i \quad i = 0, 1, 2, \dots$$

- Satunnaismuuttujan  $X$  arvojen generointiin on käytettävissä seuraava yksinkertainen menetelmä
- Algoritmi

$$X = \left\lfloor \frac{\log U}{\log(1 - p)} \right\rfloor$$

missä  $U \sim U(0, 1)$

- Kyseessä on itse asiassa  $\text{Exp}(-\log(1 - p))$ -jakaumaa noudattavan jatkuvan satunnaismuuttujan arvojen diskretointi lähinnä alempiin kokonaislukuarvoihin




## Hylkäysmenetelmä

- Tehtävänä on generoida sm:n  $X$  arvoja jakaumasta, jolla on tiheysfunktio  $f(x)$
- Olkoon  $g(x)$  toinen tiheysfunktio ja  $c$  jokin vakio siten, että
  - $c g(x)$  antaa ylärajan  $f(x)$ :lle, ts.  $c g(x) \geq f(x)$   $X$ :n koko arvoalueella
  - tiheysfunktioita  $g(x)$  noudattavan satunnaismuuttujan arvoja osataan generoida (helposti)
- Tällöin  $X$ :n generointi voidaan suorittaa seuraavasti
- Algoritmi
  - Generoi  $X$  tiheysfunktiolla  $g(x)$
  - Generoi  $Y$  tasaisesta jakaumasta  $U(0, c g(X))$
  - Jos  $Y \leq f(X)$ , niin hyväksy  $X$ 
    - \* muutoin generoi edelläolevan mukaisesti uusia arvoja  $X$  ja  $Y$ , kunnes löytyy pari, joka täyttää hyväksymisehdon; tulosta  $X$
- Todistus:

$$P\{X \in (x, x + dx) \text{ ja } Y \leq f(X)\} = g(x)dx \cdot f(x)/cg(x) = f(x)dx/c$$
$$P\{Y \leq f(X)\} = \int f(x)dx/c = 1/c$$
$$P\{X \in (x, x + dx) | Y \leq f(X)\} = (f(x)dx/c)/(1/c) = f(x)dx$$

## Hylkäysmenetelmä (esimerkki)

- Arvoalueen ollessa äärellinen väli  $(a, b)$  tiheysfunktioiksi  $g(x)$  voidaan valita kyseisellä välillä tasanjakautuneen sm:n tiheysfunktio:  $g(x) = 1/(b - a)$ , kun  $x \in (a, b)$



- Oletetaan, että  $X \in (0, 1)$  noudattaa betajakaumaa  $\beta(2, 4)$  eli tiheysfunktio on

$$f(x) = 20x(1 - x)^3, \quad 0 \leq x < 1$$

- Funktio on rajoitettu suorakulmiossa, jonka korkeus on 2.11  
– valitaan  $c = 2.11$  ja  $g(x) = 1$ , kun  $0 \leq x < 1$

- Algoritmi toimii nyt seuraavasti
  - Generoi  $X$  tasaisesta jakaumasta  $U(0, 1)$
  - Generoi  $Y$  tasaisesta jakaumasta  $U(0, 2.11)$
  - Jos  $Y \leq 20X(1 - X)^3$ , hyväksy  $X$  ja lopeta, muutoin jatka alusta, kunnes löytyy hyväksyttävä pari
- Tässä tapauksessa generoitavat  $(X, Y)$  arvot edustavat tasanjakatunutta pistettä suorakulmiossa
  - on selvää, että hyväksytyjen arvojen  $X = x$  osuus on verrannollinen  $f(x)$ :ään
  - hyväksytyjen  $X$ -arvojen tiheysfunktio on silloin  $f(x)$



## Yhdistelmämenetelmä (composition method)

- Oletetaan, että sen jakauman tiheysfunktio  $f(x)$ , josta sm  $X$  pitää arpoa, voidaan kirjoittaa (hajoittaa) muotoon

$$f(x) = \sum_{i=1}^r p_i f_i(x)$$

missä

- $p_i$ :t muodostavat diskreetin todennäköisyysjakauman,  $\sum_i p_i = 1$
- $f_i(x)$ :t ovat tiheysfunktioita,  $\int f_i(x) dx = 1$
- Tällaista jakaumaa kutsutaan sekoitusjakaumaksi (yhdistelmäjakauma, komposiittijakauma)
- Näytteenotto voidaan suorittaa seuraavasti
  - arvotaan ensin indeksi  $I$  jakaumasta  $\{p_1, p_2, \dots, p_r\}$
  - arvotaan tämän jälkeen  $X$  käyttäen tiheysfunktioita  $f_I(x)$



## Yhdistelmämenetelmä (jatkoa)

- Esimerkiksi menetelmää voidaan käyttää jakamalla  $X$ :n vaihtelualue  $(a, b)$  erillisiin intervalleihin  $(a_1, b_1)$ ,  $(a_2, b_2)$ ,  $\dots$ ,  $(a_r, b_r)$

–  $p_i$  on tällöin todennäköisyys, että  $X$  osuu intervalliin  $i$

$$p_i = \int_{a_i}^{b_i} f(x) dx$$

–  $f_i(x)$  on ehdollinen tiheysjakauma intervallissa  $i$

$$f_i(x) = \begin{cases} f(x)/p_i & x \in (a_i, b_i) \\ 0 & \text{muulloin} \end{cases}$$



## Yhdistelmämenetelmä (esimerkki 1)

- Tehtävänä on generoida pisteitä  $X$  Exp(1)-jakaumasta
- Jaetaan väli  $(0, \infty)$  intervalleihin  $(i, i + 1)$ ,  $i = 0, 1, 2, \dots$
- Välien todennäköisyydet

$$p_i = P\{i \leq X < i + 1\} = e^{-i} - e^{-(i+1)} = e^{-i}(1 - e^{-1})$$

muodostavat geometrisen jakauman (alkaa 0:sta)

- Ehdolliset tiheysfunktiot ovat

$$f_i(x) = e^{-(x-i)} / (1 - e^{-1}) \quad i \leq x < i + 1$$

eli intervallissa  $i$  ( $X - i$ ):llä on tiheysfunktio  $e^{-x} / (1 - e^{-1})$ ,  $0 \leq x < 1$

- Algoritmi

- arvotaan  $I$  geometrisesta jakaumasta  $p_i = e^{-i}(1 - e^{-1})$ ,  $i = 0, 1, 2, \dots$
- arvotaan  $Y$  tiheysfunktiolla  $e^{-x} / (1 - e^{-1})$ ,  $0 \leq x < 1$  (esim. hylkäysmenetelmällä)
- $X = I + Y$

- Etu: ei tarvita logaritmifunktiota niin kuin kertymäfunktion käänösämenetelmässä



## Yhdistelmämenetelmä (esimerkki 2)

- Tiheysfunktioiden asemesta yhdistelmämenetelmässä voidaan yhtä hyvin toimia kertymäfunktioiden avulla
- Olkoon  $X$ :n kertymäfunktio

$$\begin{aligned} F(x) &= 1 - \alpha e^{-\beta_1 x} - (1 - \alpha) e^{-\beta_2 x} \\ &= \alpha(1 - e^{-\beta_1 x}) + (1 - \alpha)(1 - e^{-\beta_2 x}) \end{aligned}$$

- Algoritmi

- valitse käytettävä jakauma  $I$ :  $P\{I = 1\} = \alpha$ ,  $P\{I = 2\} = 1 - \alpha$
- arvo  $X$  asianomaisesta jakaumasta  $F_I(x)$

$$F_1(x) = 1 - e^{-\beta_1 x} \quad F_2(x) = 1 - e^{-\beta_2 x}$$

- eli jos  $I = 1$  niin  $X = -\frac{1}{\beta_1} \log U$  ; jos  $I = 2$  niin  $X = -\frac{1}{\beta_2} \log U$

- Kertymäfunktion käänösmentelmän käyttö olisi tässä tapauksessa hankalaa
  - käänteisfunktioita ei voi kirjoittaa analyttisesti





## Jakauman karakterisointiin perustuva menetelmä

- Monet jakaumat on määritelty muodossa  $X$  on jakautunut kuten  $n$ :n riippumattoman  $sm$ :n summa, joista kukin noudattaa annettua jakaumaa “Dist”
- Tällöin  $X$  voidaan generoida kirjaimellisesti arpomalla riippumattomasti arvot  $n$ :lle muuttujalle  $Z_i$  jakaumasta “Dist”, jolloin  $X = Z_1 + Z_2 + \dots + Z_n$  noudattaa haluttua jakaumaa
- Esimerkkejä tällaisista jakaumista ovat binomijakauma, gammajakauma (Erlangin jakauma) sekä  $\chi^2$ -jakauma



## Jakauman karakterisointi (esim. binomijakauma)

- Binomijakauma  $\text{Bin}(n, p)$  on  $n$ :n riippumattoman Bernoulli( $p$ )-jakautuneen muuttujan summan jakauma

$$X = \sum_{i=1}^n B_i, \quad B_i \sim \text{Bernoulli}(p) \quad \Rightarrow \quad X \sim \text{Bin}(n, p)$$

- Bernoulli( $p$ )-jakautunut muuttuja saa arvon 1 tn:llä  $p$  ja arvon 0 tn:llä  $1 - p$
- $B_i = \text{int}(p + U_i) = \lfloor p + U_i \rfloor, \quad U_i \sim U(0, 1) \quad (\text{kokonaisosa})$

- Algoritmi

$$X = \sum_{i=1}^n \lfloor p + U_i \rfloor, \quad U_i \sim U(0, 1)$$



## Jakauman karakterisointi (esim. gammajakauma)

- Kokonaislukuarvoilla  $n$  saadaan  $\Gamma(n, \lambda)$ -jakauma  $n$ :n riippumattoman  $\text{Exp}(\lambda)$ -jakautuneen muuttujan summan jakaumana

$$X = \sum_{i=1}^n Y_i, \quad Y_i \sim \text{Exp}(\lambda) \quad \Rightarrow \quad X \sim \Gamma(n, \lambda)$$

- Ottamalla huomioon, miten eksponenttijakautunut  $\text{Exp}(\lambda)$  voidaan generoida tasanjakautuneen muuttujan  $U$  avulla, saadaan
- Algoritmi

$$X = -\frac{1}{\lambda} \log \prod_{i=1}^n U_i, \quad U_i \sim U(0, 1)$$

- Logaritmien summa kirjoitettu logaritmina tulosta
  - tämä on edullista, koska logaritmfunktio joudutaan laskemaan vain kerran



## Jakauman karakterisointi (esim. $\chi^2$ -jakauma)

- $\chi^2(\nu)$ -jakauma  $\nu$ :llä vapausasteella (kokonaisluku) on  $\nu$ :n  $N(0, 1)$ -jakautuneen muuttujan summa


$$X = \sum_{i=1}^{\nu} Y_i, \quad Y_i \sim N(0, 1) \quad \Rightarrow \quad X \sim \chi^2(\nu)$$

## Jakauman karakterisointi (esim. Poisson-jakauma)

- Toisen tyyppisen esimerkin karakterisoinnista tarjoaa Poisson-jakauma
- Poisson-prosessista (intensiteetti  $a$ ) välille  $(0, 1)$  tulevien saapumisten lukumäärä  $N$  on Poisson-jakautunut parametrilla  $a$ ,  $N \sim \text{Poisson}(a)$
- Arvotaan väliaikoja  $T_i$ ,  $i = 0, 1, 2, \dots$   $\text{Exp}(a)$ -jakaumasta,  $T_i = -(1/a) \log U_i$
- $N$  on välille  $(0,1)$  “mahtuvien” väliaikojen lukumäärä eli  $N = \min \left\{ n : \sum_{i=0}^n T_i > 1 \right\}$
- Algoritmi

$$N = \min \left\{ n : \prod_{i=0}^n U_i < e^{-a} \right\}$$

- kerrotaan lukuja  $U_i \sim U(0, 1)$ ,  $i = 0, 1, 2, \dots$  keskenään
- $N$  on ensimmäinen  $i$ :n arvo, jolla tulo on pienempi kuin  $e^{-a}$





## Poisson-jakauma: numeerinen esimerkki

- Olkoon keskiarvoparametri  $a = 0.2$
- Vertailuarvo  $u = e^{-0.2} = 0.8187$

$i$	$U_i$	$U_0 \cdots U_i$	accept/continue	Tulos
0	0.4357	0.4357	$< u$ , accept	$N = 0$
0	0.4146	0.4146	$< u$ , accept	$N = 0$
0	0.8353	0.8353	$\geq u$ , continue	
1	0.9952	0.8313	$\geq u$ , continue	
2	0.8004	0.6654	$< u$ , accept	$N = 2$

- Suurilla  $a$ :n arvoilla menetelmästä tulee hidas;  $N$ :n arvot ovat tällöin tyypillisesti suuria, ja joudutaan generoimaan monta lukua  $U_i$
- Tällöin on parempi käyttää diskretointimenetelmää (diskreetin kf:n käänös)
- Hyvin suurilla  $a$ :n arvoilla voidaan myös käyttää normaaliapproksimaatiota (merk.  $Z \sim N(0, 1)$ )

$$\text{Poisson}(a) \approx N(a, a) \Rightarrow N \approx [a + \sqrt{a}Z - 0.5]$$



## Jakauman karakterisointi (muuta esimerkkejä)

- $a$ :nneksi pienin luvuista  $U_1, U_2, \dots, U_{a+b+1}$ , missä  $U_i$ :t ovat riippumattomia tasanjakautuneita sm:ia,  $U_i \sim U(0, 1)$ , noudattaa  $\beta(a, b)$ -jakaumaa
- Kahden  $N(0, 1)$ -jakautuneen muuttujan suhde noudattaa Cauchy(0, 1)-jakaumaa
- $\chi^2(\nu)$ -jakauma parillisilla vapausasteilla  $\nu$  on sama kuin  $\Gamma(\nu/2, 1/2)$ -jakauma
- Kahden riippumattoman gamma-jakautuneen muuttujan avulla voidaan konstruoida beta-jakautunut muuttuja

$$X_1 \sim \Gamma(b, a) \quad X_2 \sim \Gamma(c, a) \quad \Rightarrow \quad \frac{X_1}{X_1 + X_2} \sim \beta(b, c)$$

- Jos  $X \sim N(0, 1)$  on normaalijakautunut sm, niin  $e^{\mu + \sigma X}$  on lognormaalinen( $\mu, \sigma$ ) sm



# Generointi monidimensioisesta jakaumasta

- Tehtävä: generoi arvoja muuttujille  $X_1, \dots, X_n$ , joilla on yhteistiheysfunktio  $f(x_1, \dots, x_n)$
- Kirjoitetaan tämä tf muotoon  $f(x_1, \dots, x_n) = f_1(x_1)f_2(x_2 | x_1) \dots f_n(x_n | x_1, \dots, x_{n-1})$  missä  $f_1(x_1)$  on  $X_1$ :n reunajakauma ja  $f_k(x_k | x_1, \dots, x_{k-1})$  on  $X_k$ :n ehdollinen jakauma ehdolla  $X_1 = x_1, \dots, X_{k-1} = x_{k-1}$
- Ideana on generoida muuttujat yksi kerrallaan: ensin generoidaan  $X_1$  oman reunajakaumansa mukaisesti, sitten generoidaan  $X_2$  ehdollisesta jakaumasta käyttäen ehtona jo arvottua  $X_1$ :n arvoa jne
- Merkitään  $F_k$ :lla ehdollista tf:ta  $f_k$  vastaavaa ehdollista kertymäfunktioita ja käytetään kertymäfunktion käännoismenetelmää
- Algoritmi
  - generoi sm:t  $U_1, \dots, U_n$  tasaisesta jakaumasta  $U(0, 1)$
  - ratkaise yhtälöt (käännä kertymäfunktioita)

$$\begin{aligned}F_1(X_1) &= U_1 \\F_2(X_2 | X_1) &= U_2 \\&\vdots \\F_n(X_n | X_1, \dots, X_{n-1}) &= U_n\end{aligned}$$



## Monidimensioinen jakauma: esimerkki

- Tehtävänä on generoida pisteitä  $(X, Y)$  yksikköneliössä, jonka vasen alakulma on origossa, käyttäen diagonaalien suunnassa kasvavaa tiheysfunktiota (integraali neliön yli on ykkönen)


$$f(x, y) = x + y$$

- $X$ :n reunajakauman tiheys ja kertymäfunktiot ovat

$$f(x) = \int_0^1 f(x, y) dy = x + \frac{1}{2}, \quad F(x) = \int_0^x f(x') dx' = \frac{1}{2}(x^2 + x)$$

- $Y$ :n ehdolliset tiheys- ja kertymäfunktiot ovat

$$f(y | x) = \frac{f(x, y)}{f(x)} = \frac{x + y}{x + \frac{1}{2}}, \quad F(y | x) = \int_0^y f(y' | x) dy' = \frac{xy + \frac{1}{2}y^2}{x + \frac{1}{2}}$$



- Kertymäfunktioiden käännökset antavat laskentakaavat

$$X = \frac{1}{2}(\sqrt{8U_1 + 1} - 1)$$

$$Y = \sqrt{X^2 + U_2(1 + 2X)} - X$$



## Generointi monidimensioisesta normaalijakaumasta

- Satunnaisvektorilla  $\mathbf{X} = (X_1, \dots, X_n)$ , joka noudattaa monidimensioista normaalijakaumaa (multinormaalijakauma) on tiheysfunktio

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{n/2} |\boldsymbol{\Sigma}|^{1/2}} e^{-\frac{1}{2}(\mathbf{x}-\mathbf{m})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x}-\mathbf{m})}$$

missä  $\mathbf{m}$  on keskiarvovektori ja  $\boldsymbol{\Sigma}$  on kovarianssimatriisi

- Koska  $\boldsymbol{\Sigma}$  on positiividefiniitti ja symmetrinen matriisi, voidaan aina löytää yksikäsitteinen alakolmiomatriisi (vaihtoehtoisesti symmetrinen matriisi)  $\mathbf{C}$  siten, että  $\boldsymbol{\Sigma} = \mathbf{C}\mathbf{C}^T$
- Arvoja  $\mathbf{X}$ :lle voidaan nyt generoida seuraavasti
- Algoritmi

$$\mathbf{X} = \mathbf{C}\mathbf{Z} + \mathbf{m}$$

missä vektorin  $\mathbf{Z} = (Z_1, \dots, Z_n)$  komponentit ovat riippumattomia normaalijakautuneita satunnaismuuttujia,  $Z_i \sim N(0, 1)$

- kaavan oikeellisuus todetaan suorittamalla muuttujien vaihto tiheysfunktiossa, jolloin  $\mathbf{Z}$ :n tiheysfunktioksi saadaan  $(2\pi)^{-n/2} e^{-\frac{1}{2}\mathbf{z}^T \mathbf{z}}$