

# Todennäköisyyslaskenta: Todennäköisyysjakaumia

- 16. Diskreettejä jakaumia
- 17. Jatkuvia jakaumia
- 18. Normaalijakaumasta johdettuja jakaumia
- 19. Moniulotteisia jakaumia



## Sisällys

<b>16. DISKREETTEJÄ JAKAUMIA</b>	<b>309</b>
<b>16.1. DISKREETTI TASAINEN JAKAUMA</b>	<b>310</b>
DISKREETIN TASAISEN JAKAUMAN TUNNUSLUVUT	310
DISKREETIN TASAISEN JAKAUMAN ODOTUSARVON JA VARIANSSIN OMINAISUUDET	311
DISKREETIN TASAISEN JAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	312
DISKREETIN TASAISEN JAKAUMAN MOMENTTIEMÄFUNKTIO	313
DISKREETIN TASAISEN JAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	313
<b>16.2. BERNOULLI-JAKAUMA</b>	<b>314</b>
BERNOULLI-KOKEET	315
BERNOULLI-JAKAUMAN TUNNUSLUVUT	315
BERNOULLI-JAKAUMAN ODOTUSARVON JA VARIANSSIN OMINAISUUDET	315
BERNOULLI-JAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	317
BERNOULLI-JAKAUMAN MOMENTTIEMÄFUNKTIO	317
BERNOULLI-JAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	317
BERNOULLI-JAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJIEN SUMMAN JAKAUMA	318
BERNOULLI-KOKEET DISKREETTIEN TODENNÄKÖISYYSJAKAUMIEN PERUSTANA	319
<b>16.3. BINOMIJAKAUMA</b>	<b>320</b>
BINOMIJAKAUMAN JOHTO	320
BINOMIJAKAUMAN TUNNUSLUVUT	321
ODOTUSARVON OMINAISUUDET	322
BINOMIJAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	323
BINOMIJAKAUMAN MOMENTTIEMÄFUNKTIO	323
BINOMIJAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	324
BINOMIJAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJIEN SUMMAN JAKAUMA	325
BINOMIJAKAUMA JA BERNOULLI-JAKAUMA	326
BERNOULLI-JAKAUMA JA BINOMIJAKAUMAN ODOTUSARVO JA VARIANSSI	327
BINOMIJAKAUMA JA OTANTA PALAUTTAEN	327
<b>16.4. GEOMETRINEN JAKAUMA</b>	<b>328</b>
GEOMETRISEN JAKAUMAN JOHTO	329
GEOMETRISEN JAKAUMAN KERTYMÄFUNKTIO	329
GEOMETRISEN JAKAUMAN TUNNUSLUVUT	330
ODOTUSARVON OMINAISUUDET	331
GEOMETRISEN JAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	331
GEOMETRISEN JAKAUMAN MOMENTTIEMÄFUNKTIO	332
GEOMETRISEN JAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	332
GEOMETRISEN JAKAUMAN UNOHTAMISOMINAISSUUS	333
<b>16.5. NEGATIIVINEN BINOMIJAKAUMA</b>	<b>334</b>
NEGATIIVISEN BINOMIJAKAUMAN JOHTO	334
NEGATIIVISEN BINOMIJAKAUMAN TUNNUSLUVUT	336
ODOTUSARVON OMINAISUUDET	337
NEGATIIVISEN BINOMIJAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	337
NEGATIIVISEN BINOMIJAKAUMAN MOMENTTIEMÄFUNKTIO	337
NEGATIIVISEN BINOMIJAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	338
NEGATIIVINEN BINOMIJAKAUMA JA GEOMETRINEN JAKAUMA	339
<b>16.6. HYPERGEOMETRINEN JAKAUMA</b>	<b>339</b>
HYPERGEOMETRISEN JAKAUMAN JOHTO	340
HYPERGEOMETRISEN JAKAUMAN TUNNUSLUVUT	341
ODOTUSARVON OMINAISUUDET	343

HYPERGEOMETRISEN JAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	343
HYPERGEOMETRINEN JAKAUMA JA BINOMIJAKAUMA	343
HYPERGEOMETRINEN JAKAUMA JA OTANTA PALAUTTAMATTA	346
OTANTA PALAUTTAEN VS OTANTA PALAUTTAMATTA	347
<b>16.7. POISSON-JAKAUMA</b>	<b>348</b>
POISSON-JAKAUMAN JOHTO	349
POISSON-JAKAUMAN TUNNUSLUVUT	350
ODOTUSARVON OMINAISUUDET	350
POISSON-JAKAUMAN PISTETODENNÄKÖISYYSFUNKTIO	351
POISSON-JAKAUMAN MOMENTTIEMÄFUNKTIO	351
POISSON-JAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	352
POISSON-JAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJIIEN SUMMAN JAKAUMA	352
POISSON-JAKAUMA JA BINOMIJAKAUMA	353
POISSON-JAKAUMA JA EKSPONENTTIJAKAUMA	355

## **17. JATKUVIA JAKAUMIA** **358**

<b>17.1. JATKUVA TASAINEN JAKAUMA</b>	<b>359</b>
JATKUVAN TASAISEN JAKAUMAN TUNNUSLUVUT	360
JATKUVAN TASAISEN JAKAUMAN TIHEYSFUNKTIO	360
JATKUVAN TASAISEN JAKAUMAN KERTYMÄFUNKTIO	361
JATKUVAN TASAISEN JAKAUMAN MOMENTTIEMÄFUNKTIO	361
JATKUVAN TASAISEN JAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	362
JATKUVAN TASAISEN JAKAUMAN TODENNÄKÖISYYDET	363
<b>17.2. EKSPONENTTIJAKAUMA</b>	<b>363</b>
EKSPONENTTIJAKAUMAN TUNNUSLUVUT	364
EKSPONENTTIJAKAUMAN TIHEYSFUNKTIO	364
EKSPONENTTIJAKAUMAN KERTYMÄFUNKTIO	365
EKSPONENTTIJAKAUMAN MOMENTTIEMÄFUNKTIO	365
EKSPONENTTIJAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	366
EKSPONENTTIJAKAUMA JA POISSON-JAKAUMA	367
EKSPONENTTIJAKAUMAN UNOHTAMISOMINAISUUS	368
EKSPONENTTIJAKAUMAN TODENNÄKÖISYYDET	369
<b>17.3. NORMAALIJAKAUMA</b>	<b>370</b>
NORMAALIJAKAUMAN TUNNUSLUVUT	372
NORMAALIJAKAUMAN TIHEYSFUNKTIO	373
NORMAALIJAKAUMAN TIHEYSFUNKTION OMINAISUUDET	373
NORMAALIJAKAUMAN KERTYMÄFUNKTIO	374
NORMAALIJAKAUMAN MOMENTTIEMÄFUNKTIO	375
NORMAALIJAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	375
STANDARDOITU NORMAALIJAKAUMA	376
NORMAALIJAKAUTUNEEN SATUNNAISMUUTTUJAN LINEAARIMUUNNOKSEN JAKAUMA	377
STANDARDOINTI	378
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN STANDARDOIDUSTA NORMAALIJAKAUMASTA	378
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN STANDARDOIDUSTA NORMAALIJAKAUMASTA JA NORMAALIJAKAUMAN TAULUKOT	379
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN MIELIVALTAISESTA NORMAALIJAKAUMASTA	381
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN NORMAALIJAKAUMASTA JA TIETOKONEOHJELMAT	382
NORMAALIJAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJIIEN SUMMAN JAKAUMA	383
NORMAALIJAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJIIEN LINEAARIKOMBINAATION JAKAUMA	384
SAMAA NORMAALIJAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJIIEN SUMMAN JAKAUMA	385

NORMAALIJAKAUMAA NOUDATTAVIEN SATUNNAISMUUTTUJUIEN ARITMEETTISEN KESKIVARVON JAKAUMA	385
<b>17.4. KESKEINEN RAJA-ARVOLAUSE</b>	<b>385</b>
BINOMIJAKAUMAN APPROKSIMOINTI NORMAALIJAKAUMALLA: DE MOIVREN JA LAPLACEN RAJA-ARVOLAUSE	388
DE MOIVREN JA LAPLACEN RAJA-ARVOLAUSEEN HAVAINNOLLISTUS	389
BINOMITODENNÄKÖISYYKSIEN APPROKSIMOINTI NORMAALIJAKAUMAN AVULLA	391
HYPERGEOMETRISEN JAKAUMAN APPROKSIMOINTI NORMAALIJAKAUMAN AVULLA	392
POISSON-JAKAUMAN APPROKSIMOINTI NORMAALIJAKAUMALLA	393
POISSON-TODENNÄKÖISYYKSIEN APPROKSIMOINTI NORMAALIJAKAUMAN AVULLA	394
<b>17.5. LOG-NORMAALIJAKAUMA</b>	<b>395</b>
LOG-NORMAALIJAKAUMAN JOHTO	395
LOG-NORMAALIJAKAUMAN TUNNUSLUVUT	396
LOG-NORMAALIJAKAUMAN TIHEYSFUNKTIO	397
LOG-NORMAALIJAKAUMAN TIHEYSFUNKTION OMINAISUUDET	398
LOG-NORMAALIJAKAUMAN KERTYMÄFUNKTIO	398
<b>17.6. CAUCHY-JAKAUMA</b>	<b>398</b>
CAUCHY-JAKAUMAN JOHTO	398
CAUCHY-JAKAUMAN TUNNUSLUVUT	399
CAUCHY-JAKAUMAN TIHEYSFUNKTIO	399
CAUCHY-JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	400
CAUCHY-JAKAUMA JA $T$ -JAKAUMA	400
<b>17.7. GAMMA-JAKAUMA</b>	<b>400</b>
GAMMA-FUNKTIO	400
GAMMA-JAKAUMAN TUNNUSLUVUT	403
GAMMA-JAKAUMAN TIHEYSFUNKTIO	404
GAMMA-JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	404
GAMMA-JAKAUMAN KERTYMÄFUNKTIO	404
GAMMA-JAKAUMAN MOMENTTIEMÄFUNKTIO	404
GAMMA-JAKAUMAN MOMENTTIEMÄFUNKTIO JA JAKAUMAN TUNNUSLUVUT	405
GAMMA-JAKAUMA JA POISSON-JAKAUMA	406
GAMMA-JAKAUMA JA EKSPONENTTIJAKAUMA	407
GAMMA-JAKAUMA JA $\chi^2$ -JAKAUMA	407
<b>17.8. BETA-JAKAUMA</b>	<b>407</b>
BETA-FUNKTIO	408
BETA-JAKAUMAN TUNNUSLUVUT	408
BETA-JAKAUMAN TIHEYSFUNKTIO	409
BETA-JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	410
BETA-JAKAUMAN KERTYMÄFUNKTIO	410
BETA-JAKAUMA JA JATKUVA TASAINEN JAKAUMA	410
<b>17.9. WEIBULL-JAKAUMA</b>	<b>410</b>
WEIBULL-JAKAUMAN TUNNUSLUVUT	411
WEIBULL-JAKAUMAN TIHEYSFUNKTIO	414
WEIBULL-JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	414
WEIBULL-JAKAUMAN KERTYMÄFUNKTIO	414
WEIBULL-JAKAUMA JA EKSPONENTTIJAKAUMA	414
<b>18. NORMAALIJAKAUMASTA JOHDETTUJA JAKAUMIA</b>	<b>416</b>
<b>18.1. <math>\chi^2</math>-JAKAUMA</b>	<b>417</b>
$\chi^2$ -JAKAUMAN TUNNUSLUVUT	417

$\chi^2$ -JAKAUMAN TIHEYSFUNKTIO	418
$\chi^2$ -JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	418
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN $\chi^2$ -JAKAUMASTA	418
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN $\chi^2$ -JAKAUMASTA JA $\chi^2$ -JAKAUMAN TAULUKOT	419
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN $\chi^2$ -JAKAUMASTA JA TIETOKONEOHJELMAT	420
<b>18.2. F-JAKAUMA</b>	<b>420</b>
F-JAKAUMAN TUNNUSLUVUT	421
F-JAKAUMAN TIHEYSFUNKTIO	421
F-JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	422
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN F-JAKAUMASTA	422
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN F-JAKAUMASTA JA F-JAKAUMAN TAULUKOT	422
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN F-JAKAUMASTA JA TIETOKONEOHJELMAT	424
<b>18.3. T-JAKAUMA</b>	<b>425</b>
T-JAKAUMAN TUNNUSLUVUT	425
T-JAKAUMAN TIHEYSFUNKTIO	426
T-JAKAUMAN TIHEYSFUNKTION OMINAISUUDET	426
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN T-JAKAUMASTA	427
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN T-JAKAUMASTA JA T-JAKAUMAN TAULUKOT	427
TODENNÄKÖISYYKSIEN MÄÄRÄÄMINEN T-JAKAUMASTA JA TIETOKONEOHJELMAT	428
T-JAKAUMA JA F-JAKAUMA	428
T-JAKAUMA JA CAUCHY-JAKAUMA	429
T-JAKAUMA JA NORMAALIJAKAUMA	429

**19. MONIULOTTEISIA JAKAUMIA** **430**

<b>19.1. MULTINOMIJAKAUMA</b>	<b>431</b>
MULTINOMIJAKAUMAN OMINAISUUDET	432
<b>19.2. KAKSIULOTTEINEN NORMAALIJAKAUMA</b>	<b>433</b>
KAKSIULOTTEISEN NORMAALIJAKAUMAN JOHTO	433
KAKSIULOTTEISEN NORMAALIJAKAUMAN TUNNUSLUVUT	438
2-ULOTTEISEN NORMAALIJAKAUMAN TIHEYSFUNKTIO JA SEN OMINAISUUDET	438
2-ULOTTEISEN NORMAALIJAKAUMAN ODOTUSARVOVEKTORI JA KOVARIANSSIMATRIISI	439
2-ULOTTEISEN NORMAALIJAKAUMAN REUNAJAKAUMAT	442
2-ULOTTEINEN NORMAALIJAKAUMA, KORRELOIMATTOMUUS JA RIIPPUMATTOMUUS	442
2-ULOTTEISEN NORMAALIJAKAUMAN EHDOLLISET JAKAUMAT	443
2-ULOTTEISEN NORMAALIJAKAUMAN EHDOLLISET ODOTUSARVOT	444
REGRESSIOSUORIEN OMINAISUUDET	445
REGRESSIOSUORIEN YHTÄLÖT JA STANDARDINTI	446
YHTEISKORRELAATIOKERROIN	447
2-ULOTTEISEN NORMAALIJAKAUMAN EHDOLLISET VARIANSSIT	447
ESIMERKKI 2-ULOTTEISESTA NORMAALIJAKAUMASTA	447

## 16. Diskreettejä jakaumia

16.1. Diskreetti tasainen jakauma

16.2. Bernoulli-jakauma

16.3. Binomijakauma

16.4. Geometrinen jakauma

16.5. Negatiivinen binomijakauma

16.6. Hypergeometrinen jakauma

16.7. Poisson-jakauma

Määrittelemme tässä luvussa seuraavat *diskreetit todennäköisyysjakaumat*:

- Diskreetti tasainen jakauma
- Bernoulli-jakauma
- Binomijakauma
- Geometrinen jakauma
- Negatiivinen binomijakauma
- Hypergeometrinen jakauma
- Poisson-jakauma

Johdamme jokaisen jakauman **pistetodennäköisyysfunktion**. Lisäksi havainnollistamme pistetodennäköisyysfunktioita **graafisesti** ja johdamme jakaumien **odotusarvot** ja **varianssit** sekä (hypergeometrista jakaumaa lukuun ottamatta) myös niiden **momenttiemäfunktiot**. Tarkastelemme myös jakaumien yhteyksiä muihin jakaumiin.

### Avainsanat:

Bernoulli-jakauma, Bernoulli-koe, Binomijakauma, Diskreetti tasainen jakauma, Eksponenttijakauma, Geometrinen jakauma, Hypergeometrinen jakauma, Kertymäfunktio, Momenttiemäfunktio, Negatiivinen binomijakauma, Odotusarvo, Otanta, Otanta palauttaen, Otanta palauttamatta, Otantasuhde, Pistetodennäköisyysfunktio, Poisson-jakauma, Standardipoikkeama, Varianssi

### 16.1. Diskreetti tasainen jakauma

Diskreettiä tasaista jakaumaa voidaan käyttää sellaisten satunnaisilmiöiden mallintamiseen, joissa on äärellinen määrä *symmetrisiä* eli *yhtä todennäköisiä* alkeistapahtumia.

Olkoon  $X$  *diskreetti satunnaismuuttuja*, jonka mahdolliset arvot ovat

$$x_1, x_2, \dots, x_n$$

Oletetaan, että satunnaismuuttujan  $X$  mahdollisiin arvoihin  $x_1, x_2, \dots, x_n$  liittyvät todennäköisyydet ovat *yhtä suuria*:

$$\Pr(X = x_i) = \frac{1}{n}, i = 1, 2, \dots, n$$

Tällöin satunnaismuuttuja  $X$  noudattaa **diskreettiä tasaista jakaumaa** ja sen *pistetodennäköisyysfunktio* on

$$f(x_i) = \Pr(X = x_i) = p_i = \frac{1}{n}, i = 1, 2, \dots, n$$

Funktio  $f(x_i)$ ,  $i = 1, 2, \dots, n$  määrittelee todennäköisyysjakauman, koska

$$f(x_i) > 0, i = 1, 2, \dots, n$$

ja

$$\sum_{i=1}^n f(x_i) = n \cdot \frac{1}{n} = 1$$

#### Diskreetin tasaisen jakauman tunnusluvut

Oletetaan, että satunnaismuuttuja  $X$  noudattaa *diskreettiä tasaista jakaumaa*, jonka *pistetodennäköisyysfunktio* on

$$f(x_i) = \Pr(X = x_i) = p_i = \frac{1}{n}, i = 1, 2, \dots, n$$

**Odotusarvo:**

$$E(X) = \mu_X = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

**Standardipoikkeama:**

$$D(X) = \sigma_X = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$



**Perustelu:**

Suoraan diskreetin jakauman odotusarvon määritelmän mukaan

$$E(X) = \mu_X = \sum_{i=1}^n x_i f(x_i) = \sum_{i=1}^n x_i \frac{1}{n} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

Suoraan diskreetin jakauman varianssin määritelmän mukaan

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = \sum_{i=1}^n (x_i - \mu_X)^2 f(x_i) = \sum_{i=1}^n (x_i - \bar{x})^2 \frac{1}{n} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

■

**Diskreetin tasaisen jakauman odotusarvon ja varianssin ominaisuudet**

Diskreetin tasaisen jakauman

$$f(x_i) = \text{Pr}(X = x_i) = p_i = \frac{1}{n}, i = 1, 2, \dots, n$$

odotusarvo

$$E(X) = \mu_X = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

on lukujen  $x_1, x_2, \dots, x_n$  *aritmeettinen keskiarvo* ja jakauman varianssi

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

on lukujen  $x_1, x_2, \dots, x_n$  *otosvarianssi*, jossa jakajana on käytetty havaintojen lukumäärää  $n$ . Lisätietoja *havaintoarvojen jakaumaa kuvaavista otostunnusluvuista*: ks. monisteen **Tilastolliset menetelmät** lukua **Tilastollisten aineistojen kuvaaminen**.

Diskreetin tasaisen jakauman varianssi voidaan kirjoittaa myös muotoon

$$\text{Var}(X) = E(X^2) - [E(X)]^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \frac{1}{n^2} \left( \sum_{i=1}^n x_i \right)^2$$

jossa

$$E(X^2) = \frac{1}{n} \sum_{i=1}^n x_i^2$$

on satunnaismuuttujan  $X$  *2. momentti* (= lukujen  $x_1, x_2, \dots, x_n$  *otosmomentti*).

**Perustelu:**

$$\begin{aligned} \text{Var}(X) &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n (x_i - 2 \cdot \bar{x} \cdot x_i + \bar{x}^2) \\ &= \frac{1}{n} \left( \sum_{i=1}^n x_i - 2 \cdot \bar{x} \cdot \sum_{i=1}^n x_i + n \bar{x}^2 \right) \end{aligned}$$

$$\begin{aligned}
 &= \frac{1}{n} \left( \sum_{i=1}^n x_i - 2 \cdot \bar{x} \cdot (n\bar{x}) + n\bar{x}^2 \right) \\
 &= \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \\
 &= E(X^2) - [E(X)]^2
 \end{aligned}$$

■

### Diskreetin tasaisen jakauman pistetodennäköisyysfunktio

Heitetään *virheetöntä* noppaa. Olkoon satunnaismuuttuja

$$X = \text{Nopanheiton tulos}$$

Satunnaismuuttujan  $X$  pistetodennäköisyysfunktio on

$$\begin{aligned}
 f(i) &= \Pr(X = i) = p_i = 1/6 \\
 & \quad i = 1, 2, 3, 4, 5, 6
 \end{aligned}$$


Kuva oikealla esittää jakauman pistetodennäköisyysfunktion *kuvaajaa*.

Kuvaan on merkitty myös jakauman *odotusarvo*

$$E(X) = 3.5$$

Jakauman *odotusarvo* saadaan seuraavalla laskutoimituksella:

$$E(X) = \sum_{i=1}^6 i f(i) = \frac{1}{6} \sum_{i=1}^6 i = \frac{1}{6} (1 + 2 + 3 + 4 + 5 + 6) = \frac{7}{2} = 3.5$$



Jakauman *varianssi* saadaan seuraavalla laskutoimituksella:

$$\begin{aligned}
 \text{Var}(X) &= D^2(X) \\
 &= \sum_{i=1}^6 (i - E(X))^2 f(i) \\
 &= \frac{1}{6} \sum_{i=1}^6 (i - E(X))^2 \\
 &= \frac{1}{6} \left[ \left(1 - \frac{7}{2}\right)^2 + \left(2 - \frac{7}{2}\right)^2 + \left(3 - \frac{7}{2}\right)^2 + \left(4 - \frac{7}{2}\right)^2 + \left(5 - \frac{7}{2}\right)^2 + \left(6 - \frac{7}{2}\right)^2 \right] \\
 &= \frac{1}{6} \left[ \left(-\frac{5}{2}\right)^2 + \left(-\frac{3}{2}\right)^2 + \left(-\frac{1}{2}\right)^2 + \left(\frac{1}{2}\right)^2 + \left(\frac{3}{2}\right)^2 + \left(\frac{5}{2}\right)^2 \right] \\
 &= \frac{35}{12} \approx 2.917
 \end{aligned}$$

Siten jakauman standardipoikkeamaksi saadaan:

$$D(X) = \frac{1}{2} \sqrt{\frac{35}{3}} \approx \sqrt{2.917} \approx 1.708$$

### Diskreetin tasaisen jakauman momenttiemäfunktio

Diskreetin tasaisen jakauman

$$f(x_i) = \Pr(X = x_i) = p_i = \frac{1}{n}, i = 1, 2, \dots, n$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_X(t) = E(e^{tX}) = \frac{1}{n} \sum_{k=1}^n e^{tx_k}$$

#### Perustelu:

Suoraan diskreetin jakauman momenttiemäfunktion määritelmän mukaan

$$m_X(t) = E(e^{tX}) = \sum_x e^{tx} f(x) = \sum_{i=1}^n e^{tx_i} f(x_i) = \sum_{i=1}^n e^{tx_i} \frac{1}{n} = \frac{1}{n} \sum_{i=1}^n e^{tx_i}$$

■

### Diskreetin tasaisen jakauman momenttiemäfunktio ja jakauman tunnusluvut

Johdetaan diskreetin tasaisen jakauman *odotusarvo* ja *varianssi* jakauman momenttiemäfunktion avulla.

#### Odotusarvo:

$$E(X) = \mu_X = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

#### Varianssi:

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

#### Perustelu:

Diskreetin tasaisen jakauman *momenttiemäfunktio* on

$$m_X(t) = \frac{1}{n} \sum_{i=1}^n e^{tx_i}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = \frac{1}{n} \sum_{i=1}^n x_i e^{tx_i} \Big|_{t=0} = \frac{1}{n} \sum_{i=1}^n x_i$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \frac{1}{n} \sum_{i=1}^n x_i^2 e^{tx_i} \Big|_{t=0} = \frac{1}{n} \sum_{i=1}^n x_i^2$$

Siten diskreetin tasaisen jakauman *odotusarvo*  $\mu_X$ , *2. momentti*  $\alpha_2$  ja *varianssi*  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\mu_X = E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$\alpha_2 = E(X^2) = \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$$\sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left( \frac{1}{n} \sum_{i=1}^n x_i \right)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

■

### 16.2. Bernoulli-jakauma

Olkoon  $A$  jokin otosvaruuden  $S$  *tapahtuma* ja olkoon

$$\Pr(A) = p$$

Olkoon tapahtuman  $A$  *komplementtitapahtuman* (tapahtuma  $A$  *ei satu*)  $A^c$  todennäköisyys

$$\Pr(A^c) = 1 - P(A) = 1 - p = q$$

Ks. Venn-diagrammia oikealla.

Määritellään *diskreetti satunnaismuuttuja*  $X$  seuraavalla tavalla:

$$X = \begin{cases} 1, & \text{jos tapahtuma } A \text{ sattuu} \\ 0, & \text{jos tapahtuma } A \text{ ei satu} \end{cases}$$

Satunnaismuuttujan  $X$  *todennäköisyysjakauma* on

$$\Pr(X = 1) = p$$

$$\Pr(X = 0) = 1 - p = q$$

ja sen *pistetodennäköisyysfunktio* voidaan esittää seuraavassa muodossa:

$$f(x) = p^x q^{1-x}, \quad 0 < p < 1, q = 1 - p, x = 0, 1$$


Sanomme, että satunnaismuuttuja  $X$  noudattaa **Bernoulli-jakaumaa parametrilla  $p$**  ja käytämme tästä merkintää:

$$X \sim \text{Bernoulli}(p)$$

Funktio  $f(x)$  määrittelee todennäköisyysjakauman, koska

$$f(0) > 0$$

$$f(1) > 0$$



ja

$$f(0) + f(1) = q + p = (1 - p) + p = 1$$

### Bernoulli-kokeet

Oletetaan, että olemme kiinnostuneita satunnaisilmiössä vain siitä sattuuko jokin ilmiöön liittyvä tapahtuma  $A$  vai ei – toisin sanoen kiinnostuksen kohteena on vain se sattuuko tapahtuma  $A$  vai tapahtuman  $A$  komplementti  $A^c$ . Kutsumme tällaista satunnaisilmiötä **Bernoulli-kokeeksi**. Yllä esitetyn mukaan Bernoulli-kokeita voidaan mallintaa *Bernoulli-jakaumalla*.

### Bernoulli-jakauman tunnusluvut

Olkoon

$$X \sim \text{Bernoulli}(p)$$

**Odotusarvo:**

$$E(X) = p$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = pq$$

**Standardipoikkeama:**

$$D(X) = \sigma_X = \sqrt{pq}$$

**Perustelu:**

Suoraan diskreetin jakauman odotusarvon määritelmän mukaan

$$E(X) = 0 \times \Pr(X = 0) + 1 \times \Pr(X = 1) = 0 \times q + 1 \times p = p$$

Määrätään satunnaismuuttujan  $X$  varianssi käyttäen kaavaa

$$\text{Var}(X) = E(X^2) - [E(X)]^2$$

jossa  $E(X^2)$  on satunnaismuuttujan  $X$  2. momentti. Suoraan diskreetin jakauman 2. momentin määritelmän mukaan

$$E(X^2) = 0^2 \times \Pr(X = 0) + 1^2 \times \Pr(X = 1) = 0 \times q + 1 \times p = p$$

Siten

$$\text{Var}(X) = E(X^2) - [E(X)]^2 = p - p^2 = p(1 - p) = pq$$

■

### Bernoulli-jakauman odotusarvon ja varianssin ominaisuudet

Olkoon

$$X \sim \text{Bernoulli}(p)$$

Bernoulli-jakauman odotusarvo

$$E(X) = p$$

yhtyy kiinnostuksen kohteena olevan tapahtuman  $A$  todennäköisyyteen  $\Pr(A) = p$ .



Bernoulli-jakauman varianssi

$$\text{Var}(X) = pq = p(1 - p) = p - p^2$$

saavuttaa *maksiminsa* 1/4, kun

$$p = q = 1/2$$

### Bernoulli-jakauman pistetodennäköisyysfunktio

Kuva oikealla esittää Bernoulli-jakauman

Bernoulli(0.8)

*pistetodennäköisyysfunktio*


$$f(x) = p^x q^{1-x}, x = 0, 1$$

jossa

$$p = 0.8, q = 1 - p$$

Kuvaan on merkitty myös jakauman *odotusarvo*

$$E(X) = p = 0.8$$



### Bernoulli-jakauman momenttiemäfunktio

Bernoulli-jakauman

$$f(x) = \Pr(X = x) = p^x q^{1-x}$$

$$0 < p < 1, q = 1 - p, x = 0, 1$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = q + pe^t$$

#### Perustelu:

Suoraan diskreetin jakauman momenttiemäfunktion määritelmän mukaan

$$m_x(t) = E(e^{tx}) = \sum_x e^{tx} f(x) = e^{t \times 0} \times \Pr(X = 0) + e^{t \times 1} \times \Pr(X = 1) = q + pe^t$$

■

### Bernoulli-jakauman momenttiemäfunktio ja jakauman tunnusluvut

Johdetaan Bernoulli-jakauman Bernoulli(*p*) *odotusarvo* ja *varianssi* jakauman momentti-emäfunktion avulla.

#### Odotusarvo:

$$E(X) = p$$

#### Varianssi:

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = pq$$

**Perustelu:**

Bernoulli-jakauman Bernoulli( $p$ ) *momenttiemäfunktio* on

$$m_X(t) = q + pe^t$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = pe^t \Big|_{t=0} = p$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = pe^t \Big|_{t=0} = p$$

Siten Bernoulli-jakauman Bernoulli( $p$ ) *odotusarvo*  $\mu_X$ , *2. momentti*  $\alpha_2$  ja *varianssi*  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\mu_X = E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = p$$

$$\alpha_2 = E(X^2) = \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = p$$

$$\sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 = p - p^2 = pq$$

■

**Bernoulli-jakaumaa noudattavien satunnaismuuttujien summan jakauma**

Olkoot

$$X_1, X_2, \dots, X_n$$

*riippumattomia* satunnaismuuttujia, jotka noudattavat *samaa Bernoulli-jakaumaa* parametrilla  $p$ :

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim \text{Bernoulli}(p), i = 1, 2, \dots, n$$

Tällöin satunnaismuuttujien  $X_1, X_2, \dots, X_n$  summa

$$Y = X_1 + X_2 + \dots + X_n$$

on diskreetti satunnaismuuttuja, joka noudattaa **binomijakaumaa** (lisätietoja: ks. kappaletta **Binomijakauma**) parametrein  $(n, p)$ :

$$Y \sim \text{Bin}(n, p)$$

**Perustelu:**

Todistus perustuu siihen, että *riippumattomien satunnaismuuttujien summan momenttiemäfunktio on ko. satunnaismuuttujien momenttiemäfunktioiden tulo*.



Oletetaan, että

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim \text{Bernoulli}(p), i = 1, 2, \dots, n$$

Satunnaismuuttujien  $X_1, X_2, \dots, X_n$  momenttiemäfunktiot ovat muotoa

$$m_i(t) = q + pe^t, i = 1, 2, \dots, n$$

Muodostetaan satunnaismuuttujien  $X_1, X_2, \dots, X_n$  summa:

$$Y = X_1 + X_2 + \dots + X_n$$

Summamuuttujan  $Y$  momenttiemäfunktio on

$$m_Y(t) = m_1(t)m_2(t)\dots m_n(t) = (q + pe^t)(q + pe^t)\dots (q + pe^t) = (q + pe^t)^n$$

Funktio  $m_Y(t)$  on *binomijakauman*

$$\text{Bin}(n, p)$$

momenttiemäfunktio (lisätietoja: ks. kappaletta **Binomijakauma**). Lisäksi funktio  $m_Y(t)$  on jatkuva pisteen

$$t = 0$$

ympäristössä. Koska momenttiemäfunktio  $m_Y(t)$  on tällöin *yksikäsitteinen*, summamuuttuja  $Y$  noudattaa *binomijakaumaa* parametrein  $n$  ja  $p$ :

$$Y = X_1 + X_2 + \dots + X_n \sim \text{Bin}(n, p)$$

■

### Huomautus:

- Kaikilla Bernoulli-jakaumilla on oltava sama tapahtuman  $A$  todennäköisyyttä kuvaava parametri  $p$ .

### Bernoulli-kokeet diskreettien todennäköisyysjakaumien perustana

Bernoulli-kokeet muodostavat perustan monille diskreeteille todennäköisyysjakaumille. Oletetaan, että toistamme *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia ja olkoon  $A$  se kiinnostuksen kohteena oleva tapahtuma, jonka sattumista toistojen aikana seurataan.

- Binomijakauma** saadaan määräämällä todennäköisyys sille, että tapahtuma  $A$  sattuu  $x$  kertaa, kun koetta toistetaan  $n$  kertaa; ks. kappaletta **Binomijakauma**.
- Geometrinen jakauma** saadaan määräämällä todennäköisyys sille, että tapahtuma  $A$  sattuu ensimmäisen kerran  $x$ . koetoistossa; ks. kappaletta **Geometrinen jakauma**.
- Negatiivinen binomijakauma** saadaan määräämällä todennäköisyys sille, että tapahtuma  $A$  sattuu  $r$ . kerran  $x$ . koetoistossa; ks. kappaletta **Negatiivinen binomijakauma**.
- Poisson-jakauma** voidaan johtaa binomijakauman raja-arvona, kun koetoistojen lukumäärän annetaan tiettyjen ehtojen vallitessa kasvaa rajatta. Poisson-jakauma kuvaa *harvinaisten* tapahtumien todennäköisyyksiä *pitkissä* toistokoesarjoissa; ks. kappaletta **Poisson-jakauma**.

### 16.3. Binomijakauma

Toistetaan *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia ja seurataan tapahtuman  $A$  sattumista toistojen aikana. Olkoon

$$\Pr(A) = p$$

jolloin tapahtuman  $A$  *komplementtitapahtuman* (= tapahtuma  $A$  ei satu)  $A^c$  todennäköisyys on

$$\Pr(A^c) = 1 - p = q$$

Oletetaan, että teemme koetoistoja  $n$  kappaletta, jossa  $n$  on kiinteä eli ei-satunnainen, etukäteen valittu luku, ja olkoon  $X$  *diskreetti satunnaismuuttuja*, joka kuvaa tapahtuman  $A$  esiintymiskertojen lukumäärää koetoistojen joukossa.

Satunnaismuuttuja  $X$  noudattaa **binomijakaumaa** parametrein  $n$  ja  $p$ :

$$X \sim \text{Bin}(n, p)$$

Binomijakauman *pistetodennäköisyysfunktio* on

$$f(x) = \Pr(X = x) = \binom{n}{x} p^x q^{n-x}, \quad 0 < p < 1, q = 1 - p, x = 0, 1, 2, \dots, n$$

#### Binomijakauman johto

Toistetaan *samaa* Bernoulli-koetta  $n$  kertaa niin, että toistot ovat toisistaan riippumattomia ja seurataan tapahtuman  $A$  sattumista toistojen aikana. Olkoon

$$\Pr(A) = p$$

ja

$$\Pr(A^c) = 1 - p = q$$

Määrätään todennäköisyys sille, että saadaan tapahtumajono, joka toteuttaa seuraavan ehdon:

$$(*) \quad \text{Jonossa on } x \text{ kappaletta tapahtumia } A \text{ ja } (n - x) \text{ kappaletta tapahtumia } A^c.$$

Olkoon

$$\begin{array}{ccccccc} A & A & A^c & A & A^c & \dots & A \\ \uparrow & \uparrow & \uparrow & \uparrow & \uparrow & \dots & \uparrow \\ n & & & & & & \end{array} \text{ kappaletta}$$

mielivaltainen tapahtumajono, joka toteuttaa ehdon (\*). Tämän jonon todennäköisyys on *riippumattomien tapahtumien tulosäännön* nojalla

$$ppqpq \dots p = p^x q^{n-x}$$

*Sama* todennäköisyys on *jokaisella* tapahtumajonolla, joka toteuttaa ehdon (\*).

*Erilaiset järjestykset*, joihin voimme asettaa  $x$  kappaletta tapahtumia  $A$  ja  $(n - x)$  kappaletta tapahtumia  $A^c$ , ovat *tapahtumajonoina toisensa poissulkevia*. Siten todennäköisyys saada jono, joka toteuttaa ehdon (\*), saadaan *toisensa poissulkevien tapahtumien yhteenlaskusäännön* mukaan laskemalla *kaikkien* ehdon (\*) toteuttavien jonojen todennäköisyydet

$$p^x q^{n-x}$$

yhteen. Siten meidän on määrättävä *kaikkien* sellaisten jonojen lukumäärä, jotka toteuttavat ehdon (\*). Tämä lukumäärä on sama kuin niiden *järjestysten* lukumäärä, joihin voimme asettaa  $x$  kappaletta tapahtumia  $A$  ja  $(n - x)$  kappaletta tapahtumia  $A^c$ .

Oletetaan, että käytössämme on kahdenlaisia *objekteja*,  $A$  ja  $A^c$ . *Lokeromallin* mukaan kysytty lukumäärä saadaan selville laskemalla kaikkien niiden tapojen lukumäärä, joilla  $x$  kappaletta objekteja  $A$  voidaan asettaa lokeriin, jossa on  $n$  lokeroa. Huomaa, että objektien  $A^c$  paikat on määrätty heti, kun objektit  $A$  on asetettu lokeriin.

Kysytyn lukumäärän antaa *binomikerroin*

$$\binom{n}{x} = \frac{n!}{x!(n-x)!}$$

Perustelu: ks. lukua **Klassinen todennäköisyys ja kombinatoriikka**.

Siten todennäköisyys saada tapahtumajono, jossa on  $x$  kappaletta tapahtumia  $A$  ja  $(n - x)$  kappaletta tapahtumia  $A^c$ , on

$$\binom{n}{x} p^x q^{n-x}$$

Olkoon  $X$  diskreetti satunnaismuuttuja, joka kuvaa tapahtuman  $A$  esiintymiskertojen lukumäärää koetoistojen joukossa. Yllä esitetyn mukaan

$$f(x) = \Pr(X = x) = \binom{n}{x} p^x q^{n-x}, \quad q = 1 - p, \quad x = 0, 1, 2, \dots, n$$

Funktio  $f(x)$  määrittelee todennäköisyysjakauman, koska

$$f(x) > 0, \quad x = 0, 1, 2, \dots, n$$

ja *binomikaavan* mukaan

$$\sum_{x=0}^n f(x) = \sum_{x=0}^n \binom{n}{x} p^x q^{n-x} = (p + q)^n = 1^n = 1$$

Binomijakauman pistetodennäköisyydet  $p_x$ ,  $x = 0, 1, 2, \dots, n$  toteuttavat siis yhtälön

$$\sum_{x=0}^n p_x = \sum_{x=0}^n f(x) = \sum_{x=0}^n \binom{n}{x} p^x q^{n-x} = 1$$

### Binomijakauman tunnusluvut

Olkoon

$$X \sim \text{Bin}(n, p)$$

**Odotusarvo:**

$$E(X) = \mu_x = np$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = npq$$

**Standardipoikkeama:**

$$D(X) = \sigma_x = \sqrt{npq}$$

**Perustelu:**

Johdamme tässä binomijakauman odotusarvon käyttäen diskreetin jakauman odotusarvon määritelmää. Johdamme jakauman odotusarvon ja varianssin jakauman *momenttiemäfunktion* avulla kohdassa **Binomijakauman momenttiemäfunktio ja jakauman tunnusluvut**. Lisäksi jakauman odotusarvo ja varianssi johdetaan käyttäen hyväksi *binomijakauman ja Bernoulli-jakauman yhteyttä* kohdassa **Binomijakauma ja Bernoulli-jakauma**.

Suoraan diskreetin jakauman odotusarvon määritelmän mukaan

$$\begin{aligned} E(X) &= \sum_{x=0}^n xf(x) \\ &= \sum_{x=0}^n x \binom{n}{x} p^x (1-p)^{n-x} \\ &= \sum_{x=0}^n x \cdot \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x} \\ &= \sum_{x=1}^n x \cdot \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x} \\ &= \sum_{x=1}^n \frac{n!}{(x-1)!(n-x)!} p^x (1-p)^{n-x} \\ &= np \sum_{x=1}^n \frac{(n-1)!}{(x-1)!(n-x)!} p^{x-1} (1-p)^{n-x} \\ &= np \end{aligned}$$

Yhtälöketjun viimeinen yhtälö perustuu siihen, että summassa

$$\begin{aligned} \sum_{x=1}^n \frac{(n-1)!}{(x-1)!(n-x)!} p^{x-1} (1-p)^{n-x} &= \sum_{x=0}^{n-1} \frac{(n-1)!}{x!(n-1-x)!} p^x (1-p)^{n-1-x} \\ &= \sum_{x=0}^{n-1} \binom{n-1}{x} p^x (1-p)^{n-1-x} \\ &= 1 \end{aligned}$$

on laskettu yhteen *kaikki* binomijakauman  $\text{Bin}(n-1, p)$  pistetodennäköisyydet.

■

**Odotusarvon ominaisuudet**

Olkkoon

$$X \sim \text{Bin}(n, p)$$

Satunnaismuuttujan  $X$  odotusarvo

$$E(X) = np$$

on *suoraan verrannollinen* tehtävien koetoistojen lukumäärään  $n$  että toistojen aikana seurattavan tapahtuman  $A$  todennäköisyyteen  $p$ .

**Binomijakauman pistetodennäköisyysfunktio**

Kuva oikealla esittää binomijakauman

$$\text{Bin}(12, 1/3)$$

pistetodennäköisyysfunktioita


$$f(x) = \binom{n}{x} p^x q^{n-x}, \quad x = 0, 1, 2, \dots, n$$

jossa




$$n = 12, \quad p = 1/3, \quad q = 1 - p$$

Kuvaan on merkitty myös jakauman *odotusarvo*

$$E(X) = np = 4$$



Alla oleva kuvasarja havainnollistaa sitä, miten parametri  $p$  vaikuttaa binomijakauman *vinouteen*:



$p < 1/2$ : Binomijakauma on *positiivisesti vino* eli *vino oikealle*.

$p = 1/2$ : Binomijakauma on *symmetrinen*.

$p > 1/2$ : Binomijakauma on *negatiivisesti vino* eli *vino vasemmalle*.

**Binomijakauman momenttiemäfunktio**

Binomijakauman

$$f(x) = \Pr(X = x) = \binom{n}{x} p^x q^{n-x}, \quad 0 < p < 1, \quad q = 1 - p, \quad x = 0, 1, 2, \dots, n$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = (q + pe^t)^n$$

**Perustelu:**

Suoraan diskreetin jakauman momenttiemäfunktion määritelmän mukaan

$$m_X(t) = E(e^{tX}) = \sum_x e^{tx} f(x) = \sum_{x=0}^n e^{tx} \binom{n}{x} p^x q^{n-x} = \sum_{x=0}^n \binom{n}{x} (pe^t)^x q^{n-x} = (q + pe^t)^n$$

■

**Binomijakauman momenttiemäfunktio ja jakauman tunnusluvut**

Johdetaan binomijakauman  $\text{Bin}(n, p)$  odotusarvo ja varianssi jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \mu_X = np$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = npq$$

**Perustelu:**

Binomijakauman  $\text{Bin}(n, p)$  momenttiemäfunktio on

$$m_X(t) = (q + pe^t)^n$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = n(q + pe^t)^{n-1} pe^t \Big|_{t=0} = np$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\begin{aligned} \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} &= \left[ n(n-1)(q + pe^t)^{n-2} pe^t pe^t + n(q + pe^t)^{n-1} pe^t \right] \Big|_{t=0} \\ &= npe^t (q + pe^t)^{n-2} \left[ (n-1)pe^t + (q + pe^t) \right] \Big|_{t=0} \\ &= np + n(n-1)p^2 \end{aligned}$$

Siten binomijakauman  $\text{Bin}(n, p)$  odotusarvo  $\mu_X$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\begin{aligned} \mu_X = E(X) = \alpha_1 &= \left. \frac{dm_X(t)}{dt} \right|_{t=0} = np \\ \alpha_2 = E(X^2) &= \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = np + n(n-1)p^2 \\ \sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 &= np + n(n-1)p^2 - n^2 p^2 = npq \end{aligned}$$

■

## Binomijakaumaa noudattavien satunnaismuuttujien summan jakauma

Olkoot

$$X_1, X_2, \dots, X_k$$

riippumattomia satunnaismuuttujia, jotka noudattavat binomijakaumaa parametrein  $(n_1, p)$ ,  $(n_2, p)$ ,  $\dots$ ,  $(n_k, p)$ :

$$\begin{aligned} X_1, X_2, \dots, X_k &\perp \\ X_i &\sim \text{Bin}(n_i, p), i = 1, 2, \dots, k \end{aligned}$$

Tällöin satunnaismuuttujien  $X_1, X_2, \dots, X_k$  summa

$$Y = X_1 + X_2 + \dots + X_k$$

on diskreetti satunnaismuuttuja, joka noudattaa binomijakaumaa parametrein  $n = n_1 + n_2 + \dots + n_k$  ja  $p$ :

$$Y \sim \text{Bin}(n, p)$$

### Perustelu:

Todistus perustuu siihen, että riippumattomien satunnaismuuttujien summan momenttiemäfunktio on ko. satunnaismuuttujien momenttiemäfunktioiden tulo.

Oletetaan, että

$$\begin{aligned} X_1, X_2, \dots, X_k &\perp \\ X_i &\sim \text{Bin}(n_i, p), i = 1, 2, \dots, k \end{aligned}$$

Satunnaismuuttujien  $X_1, X_2, \dots, X_k$  momenttiemäfunctiot ovat muotoa

$$m_i(t) = (q + pe^t)^{n_i}, i = 1, 2, \dots, k$$

Muodostetaan satunnaismuuttujien  $X_1, X_2, \dots, X_k$  summa:

$$Y = X_1 + X_2 + \dots + X_k$$

Summamuuttujan  $Y$  momenttiemäfunctio on

$$\begin{aligned} m_Y(t) &= m_1(t)m_2(t)\dots m_k(t) \\ &= (q + pe^t)^{n_1} (q + pe^t)^{n_2} \dots (q + pe^t)^{n_k} \\ &= (q + pe^t)^{n_1+n_2+\dots+n_k} \\ &= (q + pe^t)^n \end{aligned}$$

jossa

$$n = n_1 + n_2 + \dots + n_k$$

Funktio  $m_Y(t)$  on binomijakauman

$$\text{Bin}(n, p)$$

momenttiemäfunctio, jossa

$$n = n_1 + n_2 + \dots + n_k$$

Lisäksi funktio  $m_Y(t)$  on jatkuva pisteen

$$t = 0$$

ympäristössä. Koska momenttiemäfunktio  $m_Y(t)$  on tällöin *yksikäsitteinen*, summamuuttuja  $Y$  noudattaa *binomijakaumaa* parametrein  $n = n_1 + n_2 + \dots + n_k$  ja  $p$ :

$$Y = X_1 + X_2 + \dots + X_k \sim \text{Bin}(n, p)$$

### Huomautus:

- Kaikilla binomijakaumilla on oltava *sama* tapahtuman  $A$  todennäköisyyttä kuvaava parametri  $p$ , mutta sen sijaan toistokokeiden lukumäärää kuvaava parametri saa vaihdella jakaumasta toiseen.

### Binomijakauma ja Bernoulli-jakauma

Toistetaan *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia  $n$  kertaa ja seurataan tapahtuman  $A$  sattumista toistojen aikana.

Olkoon

$$\Pr(A) = p$$

ja

$$\Pr(A^c) = 1 - p = q$$

Määritellään *diskreetit satunnaismuuttujat*

$$X_i, i = 1, 2, \dots, n$$

seuraavalla tavalla:

$$X_i = \begin{cases} 1, & \text{jos tapahtuma } A \text{ sattuu kokeessa } i \\ 0, & \text{jos tapahtuma } A \text{ ei satu kokeessa } i \end{cases}$$

Tällöin

$$X_i \sim \text{Bernoulli}(p), i = 1, 2, \dots, n$$

Määritellään *diskreetti satunnaismuuttuja*  $X$  seuraavalla tavalla:

$$X = \text{Tapahtuman } A \text{ esiintymiskertojen lukumäärä}$$

Tällöin

$$X \sim \text{Bin}(n, p)$$

Selvästi

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

koska luku 1 esiintyy summassa  $\sum X_i$  *täsmälleen* yhtä monta kertaa kuin tapahtuma  $A$  sattuu  $n$ :n koetoiston aikana.

Tämä merkitsee sitä, että *jokainen binomijakautunut satunnaismuuttuja voidaan esittää riippumattomien, samaa Bernoulli-jakaumaa noudattavien satunnaismuuttujien summana.*



## Bernoulli-jakauma ja binomijakauman odotusarvo ja varianssi

Binomijakauman odotusarvoa ja varianssia johdettaessa voidaan käyttää hyväksi sitä, että jokainen binomijakautunut satunnaismuuttuja voidaan esittää riippumattomien, samaa Bernoulli-jakaumaa noudattavien satunnaismuuttujien summana.

Olkoot

$$X_i, i = 1, 2, \dots, n$$

riippumattomia satunnaismuuttujia, jotka noudattavat samaa Bernoulli-jakaumaa parametrilla  $p$ :

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim \text{Bernoulli}(p), i = 1, 2, \dots, n$$

Olkoon

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

Tällöin

$$X \sim \text{Bin}(n, p)$$

Satunnaismuuttujan  $X = \sum X_i$  odotusarvo on

$$E(X) = E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n E(X_i) = \sum_{i=1}^n p = np$$

koska satunnaismuuttujien summan odotusarvo on aina satunnaismuuttujien odotusarvojen summa.

Satunnaismuuttujan  $X = \sum X_i$  varianssi on

$$D^2(X) = D^2\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n D^2(X_i) = \sum_{i=1}^n pq = npq$$

koska riippumattomille satunnaismuuttujille pätee se, että satunnaismuuttujien summan varianssi on satunnaismuuttujien varianssien summa.

## Binomijakauma ja otanta palauttaen

Olkoon perusjoukon  $S$  alkioden lukumäärä

$$n(S) = N$$

Muodostetaan perusjoukon  $S$  alkioden osajoukko  $B$ , jossa on

$$n(B) = n$$

alkiota käyttämällä alkioden poiminnassa **otantaa takaisinpanolla** eli **palauttaen**.

### Otanta palauttaen:

- (i) Poimitaan alkiot perusjoukosta  $S$  osajoukkoon  $B$  satunnaisesti yksi kerrallaan.
- (ii) **Palautetaan** jokainen poimittu alkio ennen seuraavan alkion poimimista perusjoukkoon  $S$ .
- (iii) Oletetaan, että jokaisella perusjoukon  $S$  alkionlla on jokaisessa poiminnassa sama todennäköisyys

$$1/N$$

tulla poimituksi osajoukkoon  $B$ .

Tällöin sanomme, että osajoukko  $B$  muodostaa **yksinkertaisen satunnaisotoksen** perusjoukosta  $S$ .

Otannassa takaisinpanolla alkioden poiminta voidaan toteuttaa käyttämällä seuraavaa *arpomis-*  
*menettelyä*:

- (1) Pannaan *uurnaan* jokaista perusjoukon  $S$  alkioita vastaava arpalippu.
- (2) *Sekoitetaan* urnan sisältö huolellisesti.
- (3) *Nostetaan* urnasta arpalippu, jota vastaava alkio valitaan otokseen  $B$ .
- (4) **Palautetaan** nostettu arpalippu urnaan.
- (5) Palataan vaiheeseen (2), kunnes haluttu otoskoko  $n$  on saavutettu.

#### Huomautuksia:

- Perusjoukon  $S$  *alkioidenn todennäköisyys* tulla poimituksi otokseen *säilyy samana* poiminnan aikana.
- Jokaisella perusjoukon  $S$  samankokoisella *osajoukolla* on *sama* todennäköisyys tulla poimituksi otokseen.
- Sama perusjoukon  $S$  alkio voi tulla poimituksi otokseen *useita kertoja*.

Olkoon  $A$  perusjoukon  $S$  osajoukko, jonka alkioden lukumäärä on

$$n(A) = r$$

Tällöin todennäköisyys poimia alkio joukosta  $A$  säilyy poiminnan kaikissa vaiheissa samana:

$$\Pr(A) = p = \frac{r}{N}$$

Otannassa takaisinpanolla otokseen  $B$  poimittujen  $A$ -tyyppisten alkioden lukumäärä  $X$  on diskreetti satunnaismuuttuja, joka noudattaa *binomijakaumaa parametrein*  $n$  ja  $p$ :

$$X \sim \text{Bin}(n, p)$$

#### Huomautus:

- **Otanta ilman takaisinpanoa eli palauttamatta** tarkastellaan kappaleessa **Hyper-**  
**geometrisen jakauma**.

### 16.4. Geometrisen jakauma

Toistetaan *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia ja seurataan tapahtuman  $A$  sattumista toistojen aikana. Olkoon

$$\Pr(A) = p$$

ja

$$\Pr(A^c) = 1 - p = q$$

Oletetaan, että teemme koetoistoja *kunnes tapahtuma  $A$  sattuu 1. kerran* ja olkoon  $X$  *diskreetti satunnaismuuttuja*, joka kuvaa tehtyjen koetoistojen lukumäärää, kun tapahtuma  $A$  sattuu 1. kerran.

Satunnaismuuttuja  $X$  noudattaa **geometrista jakaumaa** parametrilla  $p$ :

$$X \sim \text{Geom}(p)$$

ja sen *pistetodennäköisyysfunktio* on

$$f(x) = \Pr(X = x) = q^{x-1} p, \quad 0 < p < 1, \quad q = 1 - p, \quad x = 1, 2, 3, \dots$$

### Geometrisen jakauman johto

Toistetaan *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia kunnes kiinnostuksen kohteena oleva tapahtuma  $A$  sattuu 1. kerran. Olkoon

$$\Pr(A) = p$$

ja

$$\Pr(A^c) = 1 - p = q$$

Oletetaan, että tapahtuma  $A$  sattuu 1. kerran  $x$ . kokeessa. Tällöin toistokokeiden tuloksena on saatu tapahtumajono

$$\underbrace{A^c A^c A^c \dots A^c}_{x \text{ kappaletta}} A$$

jossa on *ensin*  $(x - 1)$  kappaletta tapahtumia  $A^c$  ja tapahtuma  $A$  on jonossa *viimeisenä*. Tämän tapahtumajonon todennäköisyys on *riippumattomien tapahtumien tulosäännön* nojalla

$$q^{x-1} p = q^{x-1} p, \quad x = 1, 2, 3, \dots$$

Olkoon  $X$  diskreetti satunnaismuuttuja, joka kuvaa tehtyjen koetoistojen lukumäärää, kun tapahtuma  $A$  sattuu 1. kerran. Yllä esitetyn mukaan

$$f(x) = \Pr(X = x) = q^{x-1} p, \quad q = 1 - p, \quad x = 1, 2, 3, \dots$$

Funktio  $f(x)$  määrittelee todennäköisyysjakauman, koska

$$f(x) > 0, \quad x = 1, 2, 3, \dots$$

ja *geometrisen sarjan summan kaavan* mukaan

$$\sum_{x=1}^{\infty} f(x) = \sum_{x=1}^{\infty} q^{x-1} p = p \sum_{x=0}^{\infty} q^x = p \frac{1}{1-q} = p \frac{1}{p} = 1$$

### Geometrisen jakauman kertymäfunktio

Olkoon

$$X \sim \text{Geom}(p)$$

On helppo nähdä (esimerkiksi täydellisellä induktiolla), että satunnaismuuttujan  $X$  *kertymäfunktio* on

$$F(x) = \Pr(X \leq x) = 1 - (1 - p)^{[x]}$$

jossa

$$[x] = \text{suurin kokonaisluku, joka } \leq x$$

Kertymäfunktion kaavasta seuraa *komplementtitapahtuman todennäköisyyden kaavan* nojalla

$$\Pr(X > x) = 1 - \Pr(X \leq x) = 1 - F(x) = (1 - p)^{[x]}$$

### Geometrisen jakauman tunnusluvut

Olkoon

$$X \sim \text{Geom}(p)$$

**Odotusarvo:**

$$E(X) = \mu_x = \frac{1}{p}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = \frac{q}{p^2}$$

**Standardipoikkeama:**

$$D(X) = \sigma_x = \frac{\sqrt{q}}{p}$$

**Perustelu:**

Johdamme tässä geometrisen jakauman odotusarvon käyttäen diskreetin jakauman odotusarvon määritelmää. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **geometrisen jakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Suoraan diskreetin jakauman odotusarvon määritelmän mukaan

$$E(X) = \sum_{x=1}^{\infty} xf(x) = \sum_{x=1}^{\infty} x(1-p)^{x-1} p$$

Tästä seuraa, että

$$(1-p)E(X) = \sum_{x=1}^{\infty} x(1-p)^x p = \sum_{x=0}^{\infty} x(1-p)^x p = \sum_{x=1}^{\infty} (x-1)(1-p)^{x-1} p$$

Siten

$$\begin{aligned} pE(X) &= E(X) - (1-p)E(X) \\ &= \sum_{x=1}^{\infty} x(1-p)^{x-1} p - \sum_{x=1}^{\infty} (x-1)(1-p)^{x-1} p \\ &= \sum_{x=1}^{\infty} [x - (x-1)](1-p)^{x-1} p \\ &= \sum_{x=1}^{\infty} (1-p)^{x-1} p \\ &= 1 \end{aligned}$$

Yhtälöketjun viimeinen yhtälö perustuu siihen, että summassa

$$\sum_{x=1}^{\infty} (1-p)^{x-1} p$$

on laskettu yhteen *kaikki* geometrisen jakauman  $\text{Geom}(p)$  pistetodennäköisyydet.

Siten olemme saaneet yhtälön

$$p E(X) = 1$$

odotusarvon  $E(X)$  ratkaisemiseksi, joten

$$E(X) = \frac{1}{p}$$

■

### Odotusarvon ominaisuudet

Olkoon

$$X \sim \text{Geom}(p)$$

Satunnaismuuttujan  $X$  odotusarvo

$$E(X) = \frac{1}{p}$$

on *kääntäen verrannollinen* tapahtuman  $A$  todennäköisyyteen  $p$ . Siten tapahtumaa  $A$  saa odottaa keskimäärin sitä *kauemmin* mitä *pienempi* on tapahtuman  $A$  todennäköisyys.

### Geometrisen jakauman pistetodennäköisyysfunktio

Kuva oikealla esittää geometrisen jakauman

$$\text{Geom}(1/3)$$

*pistetodennäköisyysfunktio*a

$$f(x) = q^{x-1} p$$

pisteissä


$$x = 1, 2, \dots, 12$$

kun

$$p = 1/3, q = 1 - p$$

Kuvaan on merkitty myös jakauman *odotusarvo*

$$E(X) = \frac{1}{p} = 3$$



## Geometrisen jakauman momenttiemäfunktio

Geometrisen jakauman

$$\begin{aligned} f(x) &= \Pr(X = x) = q^{x-1} p \\ 0 &< p < 1, q = 1 - p \\ x &= 1, 2, 3, \dots \end{aligned}$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = \frac{pe^t}{1 - qe^t}$$

### Perustelu:

Suoraan diskreetin jakauman momenttiemäfunktion määritelmän mukaan

$$\begin{aligned} m_x(t) &= E(e^{tx}) = \sum_x e^{tx} f(x) \\ &= \sum_{x=1}^{\infty} e^{tx} pq^{x-1} \\ &= pe^t \sum_{x=1}^{\infty} e^{t(x-1)} q^{x-1} \\ &= pe^t \sum_{x=1}^{\infty} (qe^t)^{x-1} \\ &= \frac{pe^t}{1 - qe^t} \end{aligned}$$

■

## Geometrisen jakauman momenttiemäfunktio ja jakauman tunnusluvut

Johdetaan geometrisen jakauman  $\text{Geom}(p)$  odotusarvo ja varianssi jakauman momenttiemäfunktion avulla.

### Odotusarvo:

$$E(X) = \mu_x = \frac{1}{p}$$

### Varianssi:

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = \frac{q}{p^2}$$

### Perustelu:

Geometrisen jakauman  $\text{Geom}(p)$  momenttiemäfunktio on

$$m_x(t) = \frac{pe^t}{1 - qe^t}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = \left. \frac{pe^t(1-qe^t) - pe^t(-qe^t)}{(1-qe^t)^2} \right|_{t=0} = \left. \frac{pe^t}{(1-qe^t)^2} \right|_{t=0} = \frac{1}{p}$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2m_X(t)}{dt^2} \right|_{t=0} = \left. \frac{pe^t(1-qe^t)^2 - pe^t \cdot 2(1-qe^t)(-qe^t)}{(1-qe^t)^4} \right|_{t=0} = \left. \frac{pe^t(1+qe^t)}{(1-qe^t)^3} \right|_{t=0} = \frac{1+q}{p^2}$$

Siten geometrisen jakauman  $\text{Geom}(p)$  odotusarvo  $\mu_X$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\begin{aligned} \mu_X = E(X) = \alpha_1 &= \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \frac{1}{p} \\ \alpha_2 = E(X^2) &= \left. \frac{d^2m_X(t)}{dt^2} \right|_{t=0} = \frac{1+q}{p^2} \\ \sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 &= \frac{1+q}{p^2} - \frac{1}{p^2} = \frac{q}{p^2} \end{aligned}$$

■

### Geometrisen jakauman unohtamisominaisuus

Olkoon

$$X \sim \text{Geom}(p)$$

Tällöin

$$\Pr(X \geq a + b \mid X \geq a) = \Pr(X \geq b + 1)$$

jossa  $a, b \in \mathbb{N}$ .

#### Perustelu:

Todetaan ensin, että

$$\Pr(X \geq c) = 1 - \Pr(X < c) = 1 - \Pr(X \leq c - 1) = 1 - F(c - 1) = (1 - p)^{[c-1]}$$

jossa  $c \in \mathbb{N}$ ,  $F$  on geometrisen jakauman *kertymäfunktio* ja

$$[x] = \text{suurin kokonaisluku, joka } \leq x$$

Koska

$$\{X \geq a + b\} \subset \{X \geq a\}$$

niin

$$\Pr(X \geq a + b \text{ ja } X \geq a) = \Pr(X \geq a + b)$$

Siten

$$\Pr(X \geq a + b \mid X \geq a) = \frac{\Pr(X \geq a + b \text{ ja } X \geq a)}{\Pr(X \geq a)}$$

$$\begin{aligned}
 &= \frac{\Pr(X \geq a + b)}{\Pr(X \geq a)} \\
 &= \frac{(1 - p)^{[a+b-1]}}{(1 - p)^{[a-1]}} \\
 &= (1 - p)^{[b]} \\
 &= 1 - F(b) \\
 &= 1 - \Pr(X \leq b) \\
 &= \Pr(X > b) \\
 &= \Pr(X \geq b + 1)
 \end{aligned}$$

■

Siten geometrisella jakaumalla on ns. *unohtamisominaisuus*: Se, että tapahtuman  $A$  sattumista on jouduttu odottamaan  $a$  koetoistoa, *ei vaikuta* todennäköisyyteen joutua odottamaan  $b$  koetoistoa *lisää*. Tällaista unohtamisominaisuutta kutsutaan *stokastisten prosessien teoriassa* **Markv-ominaisuudeksi**.

Samanlainen unohtamisominaisuus on **eksponenttijakaumalla**, jota voidaan pitää geometrisen jakauman *jatkovana* vastineena; lisätietoja eksponenttijakaumasta: ks. lukua **Jatkuvia jakaumia**.

### 16.5. Negatiivinen binomijakauma

Toistetaan *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia ja seurataan tapahtuman  $A$  sattumista toistojen aikana. Olkoon

$$\Pr(A) = p$$

ja

$$\Pr(A^c) = 1 - p = q$$

Oletetaan, että teemme koetoistoja *kunnes tapahtuma  $A$  sattuu  $r$ . kerran* ja olkoon  $X$  *diskreetti satunnaismuuttuja*, joka kuvaa tehtyjen koetoistojen lukumäärää, kun tapahtuma  $A$  sattuu  $r$ . kerran.

Satunnaismuuttuja  $X$  noudattaa **negatiivista binomijakaumaa** parametrein  $r$  ja  $p$ :

$$X \sim \text{NegBin}(r, p)$$

ja sen *pistetodennäköisyysfunktio* on

$$\begin{aligned}
 f(x) = \Pr(X = x) &= \binom{x-1}{r-1} q^{x-r} p^r, \quad 0 < p < 1, \quad q = 1 - p \\
 & \quad r = 1, 2, 3, \dots; \quad x = r, r + 1, r + 2, \dots
 \end{aligned}$$

### Negatiivisen binomijakauman johto

Toistetaan *samaa* Bernoulli-koetta niin, että toistot ovat toisistaan riippumattomia kunnes kiinnostuksen kohteena oleva tapahtuman  $A$  sattuu  $r$ . kerran. Olkoon

$$\Pr(A) = p$$

ja

$$\Pr(A^c) = 1 - p = q$$



Määrätään todennäköisyys sille, että saadaan tapahtumajono joka toteuttaa seuraavan ehdon:

(\*) Jonossa on  $r$  kappaletta tapahtumia  $A$  ja  $(x - r)$  kappaletta tapahtumia  $A^c$  ja tapahtuma  $A$  on jonossa viimeisenä.

Olkoon

$$\underbrace{A A A^c A A^c \dots A A^c}_{n \text{ kappaletta}}$$

mielivaltainen tapahtumajono, joka toteuttaa ehdon (\*). Tämän jonon todennäköisyys on riippumattomien tapahtumien tulosäännön nojalla

$$p^r q^{x-r} \quad p = p^r q^{x-r}$$

Sama todennäköisyys on jokaisella tapahtumajonolla, joka toteuttaa ehdon (\*).

*Erilaiset järjestykset*, joihin voimme asettaa  $r$  kappaletta tapahtumia  $A$  ja  $(x - r)$  kappaletta tapahtumia  $A^c$  ja joissa tapahtuma  $A$  on viimeisenä, ovat tapahtumajoina toisensa poissulkevia. Siten todennäköisyys saada jono, joka toteuttaa ehdon (\*), saadaan toisensa poissulkevien tapahtumien yhteenlaskusäännön mukaan laskemalla kaikkien ehdon (\*) toteuttavien jonojen todennäköisyydet

$$p^r q^{x-r}$$

yhteen. Siten meidän on määrättävä kaikkien sellaisten jonojen lukumäärä, jotka toteuttavat (\*). Koska tapahtuma  $A$  pitää olla jonossa viimeisenä, tämä lukumäärä on sama kuin niiden järjestysten lukumäärä, joihin voimme asettaa  $(r - 1)$  kappaletta tapahtumia  $A$  ja  $((x - 1) - (r - 1)) = (x - r)$  kappaletta tapahtumia  $A^c$ .

Oletetaan, että meillä on käytössä kahdenlaisia objekteja,  $A$  ja  $A^c$ . Lokeromallin mukaan kysyty lukumäärä saadaan selville laskemalla kaikkien niiden tapojen lukumäärä, joilla  $(r - 1)$  kappaletta objekteja  $A$  voidaan asettaa lokerikkoon, jossa on  $(x - 1)$  lokeroa. Huomaa, että objektien  $A^c$  paikat on määrätty heti, kun objektit  $A$  on asetettu lokerikkoon.

Kysytyn lukumäärän antaa binomikerroin

$$\binom{x-1}{r-1} = \frac{(x-1)!}{(r-1)!((x-1)-(r-1))!} = \frac{(x-1)!}{(r-1)!(x-r)!}$$

Perustelu: ks. lukua **Klassinen todennäköisyys ja kombinatoriikka**.

Siten todennäköisyys saada tapahtumajono, jossa on  $r$  kappaletta tapahtumia  $A$  ja  $(x - r)$  kappaletta tapahtumia  $A^c$  ja jossa tapahtuma  $A$  on viimeisenä, on

$$\binom{x-1}{r-1} p^r q^{x-r}$$

Olkoon  $X$  diskreetti satunnaismuuttuja, joka kuvaa tehtyjen koetoistojen lukumäärää, kun tapahtuma  $A$  sattuu  $r$ . kerran. Yllä esitetyn mukaan

$$f(x) = \binom{x-1}{r-1} q^{x-r} p^r, \quad q = 1 - p$$

$$r = 1, 2, 3, \dots; \quad x = r, r + 1, r + 2, \dots$$

Voidaan osoittaa, että negatiivisen binomijakauman pistetodennäköisyyksien summa = 1. Tulos seuraa *binomikaavan yleistyksestä negatiivisille eksponenteille* (todistus sivuutetaan).

### Negatiivisen binomijakauman tunnusluvut

Olkoon

$$X \sim \text{NegBin}(r, p)$$

**Odotusarvo:**

$$E(X) = \mu_x = \frac{r}{p}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = \frac{rq}{p^2}$$

**Standardipoikkeama:**

$$D(X) = \sigma_x = \frac{\sqrt{rq}}{p}$$

**Perustelu:**

Johdamme tässä negatiivisen binomijakauman odotusarvon käyttäen diskreetin jakauman odotusarvon määritelmää. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **Negatiivisen binomijakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Suoraan diskreetin jakauman odotusarvon määritelmän mukaan

$$\begin{aligned} E(X) &= \sum_{x=r}^{\infty} xf(x) = \sum_{x=r}^{\infty} x \binom{x-1}{r-1} q^{x-r} p^r \\ &= \sum_{x=r}^{\infty} x \frac{(x-1)!}{(r-1)!(x-r)!} q^{x-r} p^r \\ &= \frac{r}{p} \sum_{x=r}^{\infty} \frac{x!}{r!(x-r)!} q^{x-r} p^{r+1} \\ &= \frac{r}{p} \sum_{x=r}^{\infty} \binom{x}{r} q^{x-r} p^{r+1} = \frac{r}{p} \end{aligned}$$

Yhtälöketjun viimeinen yhtälö perustuu siihen, että summassa

$$\sum_{x=r}^{\infty} \binom{x}{r} q^{x-r} p^{r+1} = \sum_{x=r+1}^{\infty} \binom{x-1}{r} q^{x-(r+1)} p^{r+1} = 1$$

on laskettu yhteen *kaikki* negatiivisen binomijakauman  $\text{NegBin}(r+1, p)$  pistetodennäköisyydet.

■

### Odotusarvon ominaisuudet

Olkoon

$$X \sim \text{NegBin}(r, p)$$

Satunnaismuuttujan  $X$  odotusarvo

$$E(X) = \frac{r}{p}$$

on *suoraan verrannollinen* tapahtuman  $A$  esiintymisten odotettuun lukumäärään  $r$  ja *kääntäen verrannollinen* tapahtuman  $A$  todennäköisyyteen  $p$ . Siten tapahtuman  $A$   $r$ . esiintymistä saa odottaa keskimäärin sitä *kauemmin* mitä *useampia* tapahtuman  $A$  esiintymisiä odotetaan ja mitä *pienempi* on tapahtuman  $A$  todennäköisyys.

### Negatiivisen binomijakauman pistetodennäköisyysfunktio

Kuva oikealla esittää negatiivisen binomijakauman

$$\text{NegBin}(3, 1/3)$$

pistetodennäköisyysfunktioita

$$f(x) = \binom{x-1}{r-1} q^{x-r} p^r$$

pisteissä


$$x = 3, 4, \dots, 16$$

kun

$$r = 3, p = 1/3, q = 1 - p$$

Kuvaan on merkitty myös jakauman *odotusarvo*

$$E(X) = \frac{r}{p} = 9$$



### Negatiivisen binomijakauman momenttiemäfunktio

Negatiivisen binomijakauman

$$f(x) = \Pr(X = x) = \binom{x-1}{r-1} q^{x-r} p^r, 0 < p < 1, q = 1 - p$$

$$r = 1, 2, 3, \dots; x = r, r+1, r+2, \dots$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = \frac{(pe^t)^r}{(1 - qe^t)^r}$$

**Perustelu:**

Suoraan diskreetin jakauman momenttiemäfunktion määritelmän mukaan

$$\begin{aligned}
 m_X(t) &= E(e^{tX}) = \sum_x e^{tx} f(x) \\
 &= \sum_{x=r}^{\infty} e^{tx} \binom{x-1}{r-1} q^{x-r} p^r \\
 &= (pe^t)^r \sum_{x=0}^{\infty} e^{tx} \binom{r+x-1}{r-1} q^x \\
 &= (pe^t)^r (1-qe^t)^{-r} \\
 &= \frac{(pe^t)^r}{(1-qe^t)^r}
 \end{aligned}$$

■

**Negatiivisen binomijakauman momenttiemäfunktio ja jakauman tunnusluvut**

Johdetaan negatiivisen binomijakauman  $\text{NegBin}(r, p)$  odotusarvo ja varianssi jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \mu_X = \frac{r}{p}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = \frac{rq}{p^2}$$

**Perustelu:**

Negatiivisen binomijakauman  $\text{NegBin}(r, p)$  momenttiemäfunktio on

$$m_X(t) = \frac{(pe^t)^r}{(1-qe^t)^r}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\begin{aligned}
 \left. \frac{dm_X(t)}{dt} \right|_{t=0} &= \left. \frac{r(pe^t)^{r-1} pe^t (1-qe^t)^r - (pe^t)^r r(1-qe^t)^{r-1} (-qe^t)}{(1-qe^t)^{2r}} \right|_{t=0} \\
 &= \left. \frac{r(pe^t)^r}{(1-qe^t)^{r+1}} \right|_{t=0} = \frac{r}{p}
 \end{aligned}$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\begin{aligned}
 \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} &= \left. \frac{r^2 (pe^t)^{r-1} pe^t (1-qe^t)^{r+1} - r(pe^t)^r (r+1)(1-qe^t)^r (-qe^t)}{(1-qe^t)^{2r+2}} \right|_{t=0} \\
 &= \left. \frac{r(pe^t)^r (r+qe^t)}{(1-qe^t)^{r+2}} \right|_{t=0} = \frac{r^2 + rq}{p^2}
 \end{aligned}$$

Siten negatiivisen binomijakauman  $\text{NegBin}(r, p)$  odotusarvo  $\mu_X$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\begin{aligned} \mu_X &= E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \frac{r}{p} \\ \alpha_2 &= E(X^2) = \left. \frac{d^2m_X(t)}{dt^2} \right|_{t=0} = \frac{r^2 + rq}{p^2} \\ \sigma_X^2 &= \text{Var}(X) = \alpha_2 - \alpha_1^2 = \frac{r^2 + rq}{p^2} - \frac{r^2}{p^2} = \frac{rq}{p^2} \end{aligned}$$

■

### Negatiivinen binomijakauma ja geometrinen jakauma

Olkoon

$$X \sim \text{NegBin}(r, p)$$

jossa

$$r = 1$$

Tällöin  $X$  noudattaa *geometrasta jakaumaa* parametrilla  $p$ :

$$X \sim \text{Geom}(p)$$

### 16.6. Hypergeometrinen jakauma

Oletetaan, että perusjoukossa  $S$

$$n(S) = N$$

alkioita. Olkoon  $A$  perusjoukon  $S$  jokin *osajoukko*:

$$A \subset S$$

Tällöin  $A$  ja sen *komplementti*  $A^c$  muodostavat perusjoukon  $S$  *osituksen*:

$$A \cup A^c = S$$

$$A \cap A^c = \emptyset$$

Oletetaan, että joukossa  $A$  on

$$n(A) = r$$

alkiota ja joukossa  $A^c$  on

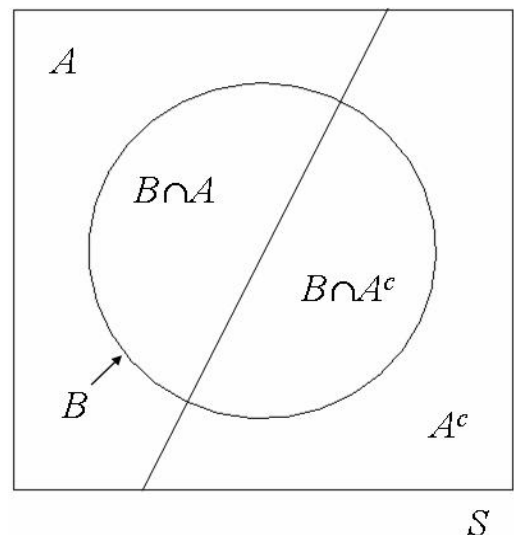
$$n(A^c) = N - r$$

alkiota.

Poimitaan perusjoukosta  $S$  *satunnaisesti* osajoukko  $B$ , jossa on

$$n(B) = n$$

alkiota. I



Perusjoukon  $S$  ositus joukoiksi  $A$  ja  $A^c$  indusoi joukon  $B$  osituksen joukoiksi  $B \cap A$  ja  $B \cap A^c$ ; ks. kuvaa edellä.

Olkoon  $X$  diskreetti satunnaismuuttuja, joka kuvaa joukkoon  $B$  poimitujen perusjoukon  $S$  osajoukon  $A$  (eli joukon  $B \cap A$ ) alkioiden lukumäärää.

Satunnaismuuttuja  $X$  noudattaa **hypergeometrista jakaumaa** parametrein  $N$ ,  $r$  ja  $n$ :

$$X \sim \text{HyperGeom}(N, r, n)$$

ja sen pistetodennäköisyysfunktio on

$$f(x) = \Pr(X = x) = \frac{\binom{r}{x} \binom{N-r}{n-x}}{\binom{N}{n}}, \max[0, n - (N - r)] \leq x \leq \min(n, r)$$

### Hypergeometrisen jakauman johto

Oletetaan, että otosavaruudessa  $S$  on

$$n(S) = N$$

alkiota.

Olkoon  $A$  jokin otosavaruuden  $S$  osajoukko:

$$A \subset S$$

ja olkoon  $A^c$  joukon  $A$  komplementti. Tällöin joukot  $A$  ja  $A^c$  muodostavat otosavaruuden  $S$  osituksen:

$$A \cup A^c = S$$

$$A \cap A^c = \emptyset$$

Oletetaan, että

$$n(A) = r$$

$$n(A^c) = N - r$$

Olkoon edelleen

$$B \subset S$$

ja

$$n(B) = n$$

Otosavaruuden  $S$  ositus joukkoihin  $A$  ja  $A^c$  indusoi joukon  $B$  osituksen joukoiksi  $B \cap A$  ja  $B \cap A^c$ :

$$(B \cap A) \cup (B \cap A^c) = B$$

$$(B \cap A) \cap (B \cap A^c) = \emptyset$$

Ks. kuvaa edellä.

Olkoon

$$n(B \cap A) = x$$

$$n(B \cap A^c) = n - x$$

Joukosta  $S$  (jossa on siis  $N$  alkioita) voidaan poimia  $n$  alkioita osajoukkoon  $B$

$$\binom{N}{n}$$

eri tavalla. Joukosta  $A$  (jossa on siis  $r$  alkioita) voidaan poimia  $x$  alkioita

$$\binom{r}{x}$$

eri tavalla. Joukosta  $A^c$  (jossa on siis  $N - r$  alkioita) voidaan poimia  $(n - x)$  alkioita

$$\binom{N - r}{n - x}$$

eri tavalla.

Joukosta  $A$  (jossa on siis  $r$  alkioita) voidaan poimia  $x$  alkioita *riippumatta* siitä, mitkä  $(n - x)$  alkioita poimitaan joukosta  $A^c$  (jossa on siis  $N - r$  alkioita). Siten *kombinatoriikan kertolaskuperiaatteesta* seuraa, että niiden tapojen lukumäärä, joilla voidaan poimia  $n$  alkioita joukosta  $S$  siten, että saadaan  $r$  alkioita joukosta  $A$  ja  $(N - r)$  alkioita joukosta  $A^c$  on

$$\binom{r}{x} \binom{N - r}{n - x}$$

Olkoon  $X$  *diskreetti satunnaismuuttuja*, joka kuvaa joukkoon  $B$  poimitujen perusjoukon  $S$  osajoukon  $A$  (eli joukon  $B \cap A$ ) alkioiden lukumäärää. Soveltamalla *klassisen todennäköisyyden* määritelmää saadaan:

$$f(x) = \Pr(X = x) = \frac{\binom{r}{x} \binom{N - r}{n - x}}{\binom{N}{n}}$$

Voidaan osoittaa, että hypergeometrisen jakauman pistetodennäköisyyksien summa = 1 (todistus sivuutetaan).

### Hypergeometrisen jakauman tunnusluvut

Olkoon

$$X \sim \text{HyperGeom}(N, r, n)$$

**Odotusarvo:**

$$E(X) = \mu_x = n \frac{r}{N}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = n \frac{r}{N} \left(1 - \frac{r}{N}\right) \left(\frac{N-n}{N-1}\right)$$

**Standardipoikkeama:**

$$D(X) = \sigma_x = \sqrt{n \frac{r}{N} \left(1 - \frac{r}{N}\right) \left(\frac{N-n}{N-1}\right)}$$

**Perustelu:**

Johdamme tässä hypergeometrisen jakauman odotusarvon käyttäen diskreetin jakauman odotusarvon määritelmää. Jakauman varianssin johtaminen sivuutetaan.

Koska

$$x \binom{r}{x} = x \frac{r!}{x!(r-x)!} = r \frac{(r-1)!}{(x-1)!(r-x)!} = r \binom{r-1}{x-1}$$

niin

$$E(X) = \sum_{x=0}^n x f(x) = \sum_{x=0}^n x \frac{\binom{r}{x} \binom{N-r}{n-x}}{\binom{N}{n}} = r \sum_{x=1}^n \frac{\binom{r-1}{x-1} \binom{N-r}{n-x}}{\binom{N}{n}}$$

Koska

$$\binom{N}{n} = \frac{N!}{n!(N-n)!} = \frac{N}{n} \cdot \frac{(N-1)!}{(n-1)!(N-n)!} = \frac{N}{n} \binom{N-1}{n-1}$$

niin

$$E(X) = r \sum_{x=1}^n \frac{\binom{r-1}{x-1} \binom{N-r}{n-x}}{\frac{N}{n} \binom{N-1}{n-1}} = \frac{nr}{N} \sum_{x=1}^n \frac{\binom{r-1}{x-1} \binom{N-r}{n-x}}{\binom{N-1}{n-1}} = \frac{nr}{N}$$

Yhtälöketjun viimeinen yhtälö perustuu siihen, että summassa

$$\sum_{x=1}^n \frac{\binom{r-1}{x-1} \binom{N-r}{n-x}}{\binom{N-1}{n-1}} = 1$$

on laskettu yhteen *kaikki* hypergeometrisen jakauman  $\text{HyperGeom}(N-1, r-1, n-1)$  pistetodennäköisyydet.

■



### Odotusarvon ominaisuudet

Olkoon

$$X \sim \text{HyperGeom}(N, r, n)$$

Satunnaismuuttujan  $X$  odotusarvo

$$E(X) = n \frac{r}{N}$$

on suoraan verrannollinen sekä perusjoukosta  $S$  poimitavan joukon  $B$  alkioden lukumäärään  $n$  että perusjoukon  $S$  osajoukon  $A$  alkioden lukumäärään  $r$  ja kääntäen verrannollinen perusjoukon  $S$  alkioden lukumäärään  $N$ .

### Hypergeometrisen jakauman pistetodennäköisyysfunktio

Kuva oikealla esittää hypergeometrisen jakauman

$$\text{HyperGeom}(100, 12, 20)$$

pistetodennäköisyysfunktioita

$$f(x) = \frac{\binom{r}{x} \binom{N-r}{n-x}}{\binom{N}{n}}$$

pisteissä


$$x = 0, 1, 2, \dots, 12$$

kun

$$N = 100, r = 12, n = 20$$

Kuvaan on merkitty myös jakauman odotusarvo

$$E(X) = n \frac{r}{N} = 2.4$$



$$E(X) = 2.4$$

### Hypergeometrisen jakauma ja binomijakauma

Hypergeometrista jakaumaa voidaan *apksimoida* binomijakaumalla, jos ns. *otantasuhde*

$$\frac{n}{N}$$

jossa

$$N = n(S) = \text{perusjoukon } S \text{ koko}$$

ja

$$n = n(B) = \text{perusjoukosta } S \text{ poimitun osajoukon } B \text{ koko}$$

on kyllin pieni. Näin on käytännössä, jos

$$\frac{n}{N} < 0.05$$

Olkoon

$$X \sim \text{HyperGeom}(N, r, n)$$

ja merkitään

$$\frac{r}{N} = p$$

Siten

$$r = Np$$

ja voimme kirjoittaa:

$$X \sim \text{HyperGeom}(N, Np, n)$$

Huomaa, että  $p$  on todennäköisyys poimia joukkoon  $B$  alkio perusjoukon  $S$  osajoukosta  $A$ , jonka koko on

$$r = n(A)$$

Annetaan nyt

$$N \rightarrow +\infty$$

ja

$$r \rightarrow +\infty$$

niin, että

$$\frac{r}{N} = p$$

Tällöin hypergeometrisen jakauman  $\text{HyperGeom}(N, Np, n)$  pistetodennäköisyydet *konvergoivat* kohden binomijakauman  $\text{Bin}(n, p)$  pistetodennäköisyyksiä:

$$\lim_{N \rightarrow +\infty} f_{\text{HyperGeom}(N, Np, n)}(x) = f_{\text{Bin}(n, p)}(x), \quad x = 0, 1, 2, \dots, n$$

**Perustelu:**

Olkoon

$$X \sim \text{HyperGeom}(N, r, n)$$

Tällöin

$$\Pr(X = x)$$

$$= \frac{\binom{r}{x} \binom{N-r}{n-x}}{\binom{N}{n}}$$

$$= \frac{r!}{x!(r-x)!} \times \frac{(N-r)!}{(n-x)!(N-r-n+x)!} \times \frac{n!(N-n)!}{N!}$$

$$= \frac{n!}{x!(n-x)!} \times \frac{r!}{(r-x)!} \times \frac{(N-r)!}{(N-r-n+x)!} \times \frac{(N-n)!}{N!}$$

$$\begin{aligned}
 &= \binom{n}{x} \times [r(r-1)\dots(r-x+1)] \times [(N-r)(N-r-1)\dots(N-r-n+x+1)] \\
 &\quad \times \frac{1}{N(N-1)\dots(N-n+1)} \\
 &= \binom{n}{x} \times \frac{r(r-1)\dots(r-x+1)}{N(N-1)\dots(N-x+1)} \times \frac{(N-r)(N-r-1)\dots(N-r-n+x+1)}{(N-x)(N-x-1)\dots(N-x-(n-x)+1)} \\
 &= \binom{n}{x} \times \frac{r}{N} \times \frac{\frac{r-1}{N} \dots \frac{r-(x-1)}{N}}{\frac{N-1}{N} \dots \frac{N-(x-1)}{N}} \times \frac{\frac{N-r}{N} \dots \frac{N-r-1}{N} \dots \frac{N-r-(n-x-1)}{N}}{\frac{N-x}{N} \dots \frac{N-x-1}{N} \dots \frac{N-x-(n-x-1)}{N}}
 \end{aligned}$$

Oletetaan, että

$$N \rightarrow +\infty$$

ja

$$r \rightarrow +\infty$$

niin, että

$$\frac{r}{N} = p$$

Tällöin

$$\frac{r-i}{N} \rightarrow p, i=1,2,\dots,x-1$$

$$\frac{N-i}{N} \rightarrow 1, i=1,2,\dots,x-1$$

$$\frac{N-r-i}{N} \rightarrow 1-p, i=0,1,2,\dots,n-x-1$$

$$\frac{N-x-i}{N} \rightarrow 1, i=0,1,2,\dots,n-x-1$$

Siten

$$\Pr(X = x) = \frac{\binom{r}{x} \binom{N-r}{n-x}}{\binom{N}{n}} \rightarrow \binom{n}{x} p^x (1-p)^{n-x}$$

mikä on binomijakauman  $\text{Bin}(n, p)$  pistetodennäköisyys pisteessä  $x$ .

■

Hypergeometrisen jakauman  $\text{HyperGeom}(N, Np, n)$  ja binomijakauman  $\text{Bin}(n, p)$  yhteys näkyy myös siinä, että jakaumilla on *sama* odotusarvo:

$$E(X_{\text{HyperGeom}(N, Np, n)}) = E(X_{\text{Bin}(n, p)}) = np$$

ja niiden varianssit

$$\text{Var}(X_{\text{HyperGeom}(N, Np, n)}) = np(1-p) \frac{N-n}{N-1}$$

$$\text{Var}(X_{\text{Bin}(n, p)}) = np(1-p)$$

*eroavat vain multiplikaatiivisella tekijällä*

$$\frac{N-n}{N-1}$$

jota sanotaan *äärellisen perusjoukon korjaustekijäksi*. Korjaustekijä vaikuttaa hypergeometrisen jakauman varianssiin sitä *vähemmän* mitä *pienempi* on otantasuhde  $n/N$ , sillä

$$\frac{N-n}{N-1} \approx 1$$

jos

$$\frac{n}{N} \approx 0$$

### Hypergeometrisen jakauma ja otanta palauttamatta

Olkoon perusjoukon  $S$  alkioden lukumäärä

$$n(S) = N$$

Muodostetaan perusjoukon  $S$  alkioista osajoukko  $B$ , jonka alkioden lukumäärä on

$$n(B) = n$$

käyttämällä alkioden poiminnassa **otantaa ilman takaisinpanoa** eli **palauttamatta**.

#### Otanta palauttamatta:

- (i) Poimitaan alkiot perusjoukosta  $S$  osajoukkoon  $B$  *satunnaisesti* yksi kerrallaan.
- (ii) **Ei palauteta** poimittua alkioita ennen seuraavan alkion poimimista perusjoukkoon  $S$ .
- (iii) Oletetaan, että *jokaisella perusjoukon  $S$  jäljellä olevalla alkioilla* on  $k$  alkioita poimittaessa *sama todennäköisyys*

$$1/(N - k + 1)$$

*tulla poimituksi osajoukkoon  $B$ .*

Tällöin sanomme, että osajoukko  $B$  muodostaa **yksinkertaisen satunnaisotoksen** perusjoukosta  $S$ .

Otannassa ilman takaisinpanoa alkioden poiminta voidaan toteuttaa käyttämällä seuraavaa *arpomis-*  
*menettelyä:*

- (1) Pannaan *uurnaan* jokaista perusjoukon  $S$  alkioita vastaava arpalippu.
- (2) *Sekoitetaan* urnan sisältö huolellisesti.

- (3) *Nostetaan* urnasta arpalippu, jota vastaava alkio valitaan otokseen  $B$ .
- (4) **Ei palauteta** nostettua arpalippu urnaan.
- (5) Palataan vaiheeseen (3), kunnes haluttu otoskoko  $n$  on saavutettu.

**Huomautuksia:**

- Perusjoukon  $S$  alkioden todennäköisyys tulla poimituksi otokseen *muuttuu* poiminnan aikana.
- Jokaisella perusjoukon  $S$  samankokoisella *osajoukolla* on *sama* todennäköisyys tulla poimituksi otokseen.
- Sama perusjoukon  $S$  alkio voi tulla poimituksi otokseen *vain kerran*.

Olkoon  $A$  perusjoukon  $S$  osajoukko, jonka alkioden lukumäärä on

$$n(A) = r$$

Tällöin todennäköisyys poimia *yksi* alkio joukosta  $A$  on

$$\Pr(A) = p = \frac{r}{N}$$

Otannassa ilman takaisinpanoa otokseen  $B$  poimitujen  $A$ -tyyppisten alkioden lukumäärä  $X$  on diskreetti satunnaismuuttuja, joka noudattaa *hypergeometrista jakaumaa parametrein*  $N$ ,  $n$  ja  $r$ :

$$X \sim \text{HyperGeom}(N, r, n)$$

**Huomautus:**

- **Otanta takaisinpanolla** eli **palauttaen** tarkastellaan kappaleessa **Binomijakauma**.

**Otanta palauttaen vs otanta palauttamatta**

Poimitaan perusjoukosta *satunnaisesti otos* (osajoukko) arpomalla alkio perusjoukosta otokseen yksi kerrallaan.

Otoksen poiminta voidaan toteuttaa joko **palauttaen** (*takaisinpanolla*) tai **palauttamatta** (*ilman takaisinpanoa*):

- Otannassa palauttaen* perusjoukon alkio *arvotaan* otokseen yksi kerrallaan niin, että jokainen alkio *palautetaan* välittömästi arpomisen jälkeen takaisin perusjoukkoon, jolloin sama alkio voi tulla poimituksi otokseen *useita kertoja*.
- Otannassa palauttamatta* alkio *arvotaan* otokseen yksi kerrallaan niin, että alkioita *ei palauteta* arpomisen jälkeen takaisin perusjoukkoon, jolloin sama alkio voi tulla poimituksi otokseen *vain kerran*.

Olkoon perusjoukon  $S$  koko

$$n(S) = N$$

Tarkastellaan perusjoukon  $S$  osajoukkoa  $A$ , jonka koko on

$$n(A) = r$$

Poimitaan perusjoukosta  $S$  satunnaisesti osajoukko  $B$ , jonka koko on

$$n(B) = n$$

Määritellään *diskreetti satunnaismuuttuja*

$$X = \text{"A-tyyppisten alkoiden lukumäärä otoksessa B"}$$

Jos otos poimitaan perusjoukosta *palauttaen*, satunnaismuuttuja  $X$  noudattaa *binomijakaumaa* parametrein  $n$  ja  $p = r/N$ :

$$X \sim \text{Bin}(n, p)$$

Jos otos poimitaan perusjoukosta *palauttamatta* eli *ilman takaisinpanoa*, satunnaismuuttuja  $X$  noudattaa *hypergeometrinen jakaumaa* parametrein  $N$ ,  $r$  ja  $n$ :

$$X \sim \text{HyperGeom}(N, r, n)$$

**Huomautus:**

- Koska hypergeometrinen jakauma konvergoi kohden binomijakaumaa, kun perusjoukon koon  $N$  annetaan kasvaa rajatta, ero otannon palauttaen ja otannon palauttamatta välillä on merkityksetön, jos otoskoko  $n$  on *pieni* perusjoukon kokoon  $N$  verrattuna ja ero häviää kokonaan, jos perusjoukko on *ääretön*.

### 16.7. Poisson-jakauma

Toistetaan *samaa satunnaiskoetta* ja oletetaan, että toistot ovat toisistaan *riippumattomia*. Tarkastellaan jonkin *tapahtuman A* sattumista toistojen aikana. Oletetaan, että tapahtuman  $A$  *tapahtumaintensiteetti* eli tapahtuman  $A$  esiintymisten *keskimääräinen lukumäärä aikayksikköä kohden* on  $\lambda$ .

Määritellään *diskreetti satunnaismuuttuja X*:

$$X = \text{Tapahtuman A esiintymisten lukumäärä ajanjaksona, jonka kesto on s aikayksikköä}$$

Tietyin oletuksin satunnaismuuttuja  $X$  noudattaa **Poisson-jakaumaa** parametrilla  $\lambda s$ :

$$X \sim \text{Poisson}(\lambda s)$$

jossa

$$s = \text{ajanjakson pituus aikayksiköissä}$$

$$\lambda = \text{tapahtuman A esiintymisten keskimääräinen lukumäärä aikayksikköä kohden}$$

ja sen *pistetodennäköisyysfunktio* on

$$f(x) = \Pr(X = x) = \frac{e^{-\lambda s} (\lambda s)^x}{x!}, \lambda > 0, x = 0, 1, 2, \dots$$

**Huomautus:**

- Poisson-jakauma syntyy myös sellaisessa tilanteessa, jossa tarkastellaan tapahtuman  $A$  esiintymistä *avaruudessa*. Tällöin parametri  $\lambda$  kuvaa tapahtumien  $A$  esiintymisten *keskimääräistä lukumäärää tilavuusyksikköä kohden* ja satunnaismuuttuja  $X$  kuvaa tapahtuman  $A$  esiintymisten *lukumäärää avaruuden osa-alueessa, jonka koko on s tilavuusyksikköä*.

### Poisson-jakauman johto

Luonnostelemme seuraavassa vain pääkohdat Poisson-jakauman johdosta.

Tarkastellaan jonkin tapahtuman  $A$  sattumista *saman* satunnaiskokeen toistojen aikana.

Oletukset:

- (1) Toistot ovat toisistaan *riippumattomia*.
- (2)  $\Pr(\text{Yksi tapahtuma } A \text{ lyhyellä aikavälillä } ds) = \lambda ds$
- (3) Aikaväli on  $ds$  on *niin lyhyt*, että todennäköisyys  
 $\Pr(k \text{ kappaletta tapahtumia } A \text{ aikavälillä } ds, k > 1)$   
 on häviävän pieni eli kertaluokkaa  $o(s)$ .

Olkoon

$$f(x; s) = \Pr(x \text{ kappaletta tapahtumia } A \text{ aikavälillä } [0, s])$$

Oletusten (1)-(3) pätiessä aikavälillä

$$[0, s + ds]$$

voi sattua  $x$  kappaletta tapahtumia  $A$  kahdella *toisensa poissulkevalla tavalla* ( $tn = \text{todennäköisyys}$ ):

Tapaus 1:  $x$  kappaletta tapahtumia  $A$  ajanhetkeen  $s$  mennessä:  $tn = f(x; s)$

Ei tapahtumia  $A$  aikavälillä  $ds$ :  $tn = 1 - \lambda ds$

Lisäksi nämä ovat tapahtumina toisistaan *riippumattomia*.

Tapaus 2:  $(x - 1)$  kappaletta tapahtumia  $A$  ajanhetkeen  $s$  mennessä:  $tn = f(x - 1; s)$

Yksi tapahtuma  $A$  aikavälillä  $ds$ :  $tn = \lambda ds$

Lisäksi nämä ovat tapahtumina toisistaan *riippumattomia*.

*Riippumattomien tapahtumien tulosäännön ja toisensa poissulkevien tapahtumien yhteenlaskusäännön* mukaan

$$f(x; s + ds) = f(x; s)(1 - \lambda ds) + f(x - 1; s)\lambda ds$$

josta saamme *erotusosamäärän*

$$\frac{f(x; s + ds) - f(x; s)}{ds} = \lambda[f(x - 1; s) - f(x; s)]$$

Antamalla

$$ds \rightarrow 0$$

saamme  $(x:n$  suhteen) *differenssiyhtälön*

$$\frac{df(x; s)}{ds} = \lambda[f(x - 1; s) - f(x; s)]$$

On helppo nähdä, että

$$f(x) = \frac{e^{-\lambda s} (\lambda s)^x}{x!}, x = 0, 1, 2, \dots$$

on tämän differenssiyhtälön *ratkaisu*.

Funktio  $f(x)$  määrittelee todennäköisyysjakauman, koska

$$f(x) > 0, x = 0, 1, 2, \dots$$

ja eksponenttifunktion määritelmän mukaan

$$\sum_{x=0}^{\infty} f(x) = \sum_{x=0}^{\infty} \frac{e^{-\lambda s} (\lambda s)^x}{x!} = e^{-\lambda s} \sum_{x=0}^{\infty} \frac{(\lambda s)^x}{x!} = e^{-\lambda s} e^{\lambda s} = 1$$

### Poisson-jakauman tunnusluvut

Olkoon

$$X \sim \text{Poisson}(\lambda s)$$

**Odotusarvo:**

$$E(X) = \mu_x = \lambda s$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_x^2 = \lambda s$$

**Standardipoikkeama:**

$$D(X) = \sigma_x = \sqrt{\lambda s}$$

**Perustelu:**

Johdamme tässä Poisson-jakauman odotusarvon käyttäen diskreetin jakauman odotusarvon määritelmää. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **Poisson-jakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Suoraan diskreetin jakauman odotusarvon määritelmän mukaan ja eksponenttifunktion ominaisuuksien mukaan

$$\begin{aligned} E(X) &= \sum_{x=0}^{\infty} x f(x) = \sum_{x=0}^{\infty} x \frac{e^{-\lambda s} (\lambda s)^x}{x!} \\ &= e^{-\lambda s} \sum_{x=1}^{\infty} x \frac{(\lambda s)^x}{x!} \\ &= \lambda s e^{-\lambda s} \sum_{x=1}^{\infty} \frac{(\lambda s)^{x-1}}{(x-1)!} \\ &= \lambda s e^{-\lambda s} e^{\lambda s} = \lambda s \end{aligned}$$

■

### Odotusarvon ominaisuudet

Poisson-jakauman odotusarvo  $\lambda$  kuvaa *tapahtumaintensiteettiä*: Mitä suurempi on  $\lambda$ , sitä enemmän tapahtumia on odotettavissa aikayksikköä kohden.



### Poisson-jakauman pistetodennäköisyysfunktio

Kuva oikealla esittää Poisson-jakauman

Poisson(5)

pistetodennäköisyysfunktioita

$$f(x) = \frac{e^{-\lambda_s} (\lambda_s)^x}{x!}$$

pisteissä


$$x = 0, 1, 2, \dots, 12$$

kun

$$\lambda_s = 5$$

Kuvaan on merkitty myös jakauman odotusarvo

$$E(x) = \lambda_s = 5$$



$E(X) = 5$

### Esimerkki 1. Radioaktiivinen hajoaminen.

Tarkastellaan radioaktiivista hajoamista ja olkoon

$X =$  aikavälillä  $[0, s]$  hajoavien atomien lukumäärä

Tällöin

$$X \sim \text{Poisson}(\lambda_s)$$

jossa  $\lambda$  on alkuainekohtainen parametri, joka kuvaa keskimäärin aikayksikköä kohden hajoavien atomien lukumäärää.

### Poisson-jakauman momenttiemäfunktio

Poisson-jakauman

$$f(x) = \Pr(X = x) = \frac{e^{-\lambda_s} (\lambda_s)^x}{x!}, \lambda > 0, x = 0, 1, 2, \dots$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_X(t) = E(e^{tX}) = e^{\lambda_s(e^t - 1)}$$

### Perustelu:

Suoraan diskreetin jakauman momenttiemäfunktion määritelmän mukaan

$$m_X(t) = E(e^{tX}) = \sum_x e^{tx} f(x) = \sum_{x=0}^{\infty} e^{tx} \frac{e^{-\lambda_s} (\lambda_s)^x}{x!} = e^{-\lambda_s} \sum_{x=0}^{\infty} \frac{(\lambda_s e^t)^x}{x!} = e^{-\lambda_s} e^{\lambda_s e^t} = e^{\lambda_s(e^t - 1)}$$

■

### Poisson-jakauman momenttiemäfunktio ja jakauman tunnusluvut

Johdetaan Poisson-jakauman Poisson( $\lambda s$ ) *odotusarvo* ja *varianssi* jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \mu_X = \lambda s$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = \lambda s$$

**Perustelu:**

Poisson-jakauman Poisson( $\lambda$ ) *momenttiemäfunktio* on

$$m_X(t) = e^{\lambda s(e^t - 1)}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = e^{\lambda s(e^t - 1)} \lambda s e^t \Big|_{t=0} = \lambda s e^{t + \lambda s(e^t - 1)} \Big|_{t=0} = \lambda s$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \lambda s e^{t + \lambda s(e^t - 1)} (1 + \lambda s e^t) \Big|_{t=0} = \lambda s + (\lambda s)^2$$

Siten Poisson-jakauman Poisson( $\lambda$ ) *odotusarvo*  $\mu_X$ , *2. momentti*  $\alpha_2$  ja *varianssi*  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\mu_X = E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \lambda s$$

$$\alpha_2 = E(X^2) = \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \lambda s + (\lambda s)^2$$

$$\sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 = \lambda s + (\lambda s)^2 - (\lambda s)^2 = \lambda s$$

■

### Poisson-jakaumaa noudattavien satunnaismuuttujien summan jakauma

Olkoot

$$X_1, X_2, \dots, X_k$$

*riippumattomia* satunnaismuuttujia, jotka noudattavat *Poisson-jakaumia* parametrein  $\lambda_1 s, \lambda_2 s, \dots$  ja  $\lambda_k s$ :

$$X_1, X_2, \dots, X_k \perp$$

$$X_i \sim \text{Poisson}(\lambda_i s), i = 1, 2, \dots, k$$

Tällöin satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *summa*

$$Y = X_1 + X_2 + \dots + X_k$$

on diskreetti satunnaismuuttuja, joka noudattaa *Poisson-jakaumaa* parametrilla  $\lambda s = \lambda_1 s + \lambda_2 s + \dots + \lambda_k s$  :

$$X \sim \text{Poisson}(\lambda s)$$

**Perustelu:**

Todistus perustuu siihen, että *riippumattomien satunnaismuuttujien summan momenttiemäfunktio ko. satunnaismuuttujien momenttiemäfunktioiden tulo.*

Oletetaan, että

$$X_1, X_2, \dots, X_k \perp \\ X_i \sim \text{Poisson}(\lambda_i), i = 1, 2, \dots, k$$

Satunnaismuuttujien  $X_1, X_2, \dots, X_k$  momenttiemäfunktiot ovat muotoa

$$m_i(t) = e^{\lambda_i s (e^t - 1)}, i = 1, 2, \dots, k$$

Muodostetaan satunnaismuuttujien  $X_1, X_2, \dots, X_k$  summa:

$$Y = X_1 + X_2 + \dots + X_k$$

Summamuuttujan  $Y$  momenttiemäfunktio on

$$m_Y(t) = m_1(t) m_2(t) \dots m_k(t) = e^{\lambda_1 s (e^t - 1)} e^{\lambda_2 s (e^t - 1)} \dots e^{\lambda_k s (e^t - 1)} = e^{(\lambda_1 + \lambda_2 + \dots + \lambda_k) s (e^t - 1)} = e^{\lambda s (e^t - 1)}$$

jossa

$$\lambda = \lambda_1 + \lambda_2 + \dots + \lambda_k$$

Funktio  $m_Y(t)$  on *Poisson-jakauman*

$$\text{Poisson}(\lambda s)$$

momenttiemäfunktio, jossa

$$\lambda s = \lambda_1 s + \lambda_2 s + \dots + \lambda_k s$$

Lisäksi funktio  $m_Y(t)$  on selvästi jatkuva pisteen

$$t = 0$$

ympäristössä. Koska momenttiemäfunktio  $m_Y(t)$  on tällöin yksikäsitteinen, summamuuttuja  $Y$  noudattaa *Poisson-jakaumaa* parametrilla  $\lambda s = \lambda_1 s + \lambda_2 s + \dots + \lambda_k s$  :

$$Y = X_1 + X_2 + \dots + X_k \sim \text{Poisson}(\lambda s)$$

■

**Huomautus:**

- Jokaisella Poisson-jakaumalla saa olla eri parametri.

**Poisson-jakauma ja binomijakauma**

Olkoon

$$X_n \sim \text{Bin}(n, p)$$

Annetaan

$$n \rightarrow \infty$$

ja

$$p \rightarrow 0$$

siten, että

$$np = \lambda s$$

Tällöin satunnaismuuttujan  $X_n$  jakauma lähestyy Poisson-jakaumaa parametrilla  $\lambda$ :

$$\lim_{\substack{n \rightarrow \infty \\ p \rightarrow 0 \\ np = \lambda s}} f_{\text{Bin}(n,p)}(x) = f_{\text{Poisson}(\lambda s)}(x), \quad x = 0, 1, 2, \dots$$

**Perustelu:**

Olkoon

$$X \sim \text{Bin}(n, p)$$

Tällöin

$$f_X(x) = \binom{n}{x} p^x q^{n-x}, \quad q = 1 - p, \quad x = 0, 1, 2, \dots, n$$

Oletetaan, että

$$n \rightarrow +\infty$$

ja samaan aikaan

$$p \rightarrow 0$$

niin, että

$$np = \lambda s$$

jossa  $\lambda > 0$  on ei-satunnainen vakio. Ottamalla huomioon, että  $np = \lambda s$  ja  $q = 1 - p$ , voimme kirjoittaa, että

$$\begin{aligned} f_X(x) &= \binom{n}{x} p^x q^{n-x} \\ &= \frac{n(n-1)(n-2)\dots(n-x+1)}{n^x x!} (np)^x (1-p)^{n-x} \\ &= \frac{n(n-1)(n-2)\dots(n-x+1)}{n^x} \cdot \frac{(\lambda s)^x}{x!} \cdot \frac{(1-p)^n}{(1-p)^x} \\ &= 1 \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \dots \left(1 - \frac{x-1}{n}\right) \cdot \frac{(\lambda s)^x}{x!} \cdot \frac{(1-p)^n}{(1-p)^x} \end{aligned}$$

Edelleen voimme kirjoittaa, että

$$(1-p)^n = [(1-p)^{-1/p}]^{-np} = [(1-p)^{-1/p}]^{-\lambda}$$

Eksponttifunktio ominaisuuksien perusteella

$$(1) \quad \lim_{p \rightarrow 0} [(1-p)^{-1/p}]^{-\lambda} = e^{-\lambda}$$

Lisäksi pätee:

$$(2) \quad \lim_{n \rightarrow \infty} \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \dots \left(1 - \frac{x-1}{n}\right) = 1$$

$$(3) \quad \lim_{p \rightarrow 0} (1-p)^x = 1$$

Yhdistämällä kaavat (1), (2) ja (3) saadaan haluttu lopputulos:

$$\lim_{\substack{n \rightarrow \infty \\ p \rightarrow 0 \\ np = \lambda s}} f_X(x) = \frac{e^{-\lambda s} (\lambda s)^x}{x!}$$

■

Poisson-jakauman ja binomijakauman välinen yhteys tulee esille myös siinä, että

$$E(X) = \lambda s \approx np$$

jos  $n$  on *suuri* ja  $p$  on *pieni*. Lisäksi myös jakaumien varianssit ovat tällöin lähellä toisiaan:

$$\text{Var}(X) = D^2(X) = \lambda s \approx np \approx np(1-p)$$

koska

$$p \approx 0 \Rightarrow 1 - p \approx 1$$

### Poisson-jakauma ja eksponenttijakauma

Tarkastellaan jonkin tapahtuman  $A$  sattumista *saman* satunnaiskokeen toistojen aikana ja olkoon

$$X = \text{tapahtumien lukumäärä aikayksikköä kohden}$$

Oletetaan, että

$$X \sim \text{Poisson}(\lambda)$$

jolloin

$$E(X) = \lambda$$

Parametri  $\lambda$  kuvaa tarkastelun kohteena olevan tapahtuman *tapahtumaintensiteettiä* eli tarkastelun kohteena olevan tapahtuman esiintymisten keskimääräistä lukumäärää aikayksikköä kohden.

Olkoon

$$Y = \text{odotusaika 1. tapahtumalle (tai tapahtumien väliaika)}$$

Tällöin  $Y$  on *jatkuva satunnaismuuttuja*, joka noudattaa **eksponenttijakaumaa** parametrilla  $\lambda$ :

$$Y \sim \text{Exp}(\lambda)$$

jolloin

$$E(Y) = 1/\lambda$$

Lisätietoja eksponenttijakaumasta: ks. lukua **Jatkuvia jakaumia**.

Voidaan osoittaa, että jakaumien välinen yhteys toimii myös toiseen suuntaan: Olkoon siis

$$Y = \text{odotusaika 1. tapahtumalle (tai tapahtumien väliaika)}$$

ja oletetaan, että

$$Y \sim \text{Exp}(\lambda)$$

Olkoon

$X =$  tapahtumien lukumäärä aikayksikköä kohden

Tällöin  $X$  on *diskreetti satunnaismuuttuja*, joka noudattaa **Poisson-jakaumaa** parametrilla  $\lambda$ :

$X \sim \text{Poisson}(\lambda)$

## 17. Jatkuvia jakaumia

### 17.1. Jatkuva tasainen jakauma

### 17.2. Eksponenttijakauma

### 17.3. Normaalijakauma.

### 17.4. Keskeinen raja-arvolause

### 17.5. Log-normaalijakauma

### 17.6. Cauchy-jakauma

### 17.7. Gamma-jakauma

### 17.8. Beta-jakauma

### 17.9. Weibull-jakauma

Määrittelemme tässä luvussa seuraavat *jatkuvat todennäköisyysjakaumat*:

- **Jatkuva tasainen jakauma**
- **Eksponenttijakauma**
- **Normaalijakauma**
- **Log-normaalijakauma**
- **Cauchy-jakauma**
- **Gamma-jakauma**
- **Beta-jakauma**
- **Weibull-jakauma**

Tarkastelemme jakaumien ominaisuuksia havainnollistamalla jakaumien **tiheysfunktioita graafisesti** ja johtamalla jakaumien **odotusarvot** ja **variانسit** sekä (useimmissa tapauksissa) jakaumien **momenttiemäfunktiot**. Tarkastelemme myös jakaumien yhteyksiä muihin jakaumiin.

Kohdassa **Keskeinen raja-arvolause** esitämme perustelun sille, miksi normaalijakauma on ”normaali”.

### Avainsanat:

Binomijakauma, Beta-jakauma, Cauchy-jakauma, Eksponenttijakauma, Gamma-jakauma, Jatkuva tasainen jakauma, Kertymäfunktio, Keskeinen raja-arvolause, Log-normaalijakauma, Momenttiemäfunktio, Normaaliproksimaatio, Normaalijakauma, Odotusarvo, Poisson-jakauma, Standardipoikkeama, Standardointi, Taulukot, Tiheysfunktio, Varianssi, Weibull-jakauma



### 17.1. Jatkuva tasainen jakauma

Jatkuva tasainen jakauma on *diskreetin tasaisen jakauman* (ks. lukua **Diskreettejä jakaumia**) *jatkuva vastine*.

Olkoon *jatkuvan satunnaismuuttujan X tiheysfunktio*

$$f(x) = \begin{cases} 0 & , x < a \\ \frac{1}{b-a} & , a \leq x \leq b \\ 0 & , x > b \end{cases}$$

Tällöin satunnaismuuttuja X noudattaa **jatkovaa tasaista jakaumaa** parametrein  $a$  ja  $b$  ja merkitsemme:

$$X \sim \text{Uniform}(a, b)$$

Funktio  $f(x)$  kelpaa tiheysfunktiksi, koska

$$f(x) > 0, x \in [a, b]$$

ja

$$\int_{-\infty}^{+\infty} f(x) dx = \int_a^b \frac{1}{b-a} dx = \left[ \frac{x}{b-a} \right]_a^b = \frac{b-a}{b-a} = 1$$

Jakauman *nimi* johtuu siitä, että jatkuvalla tasaisella jakaumalla on seuraava ominaisuus:

Olkoot  $[c_1, d_1]$  ja  $[c_2, d_2]$  jatkuvan tasaisen jakauman  $\text{Uniform}(a, b)$  määrittelyvälin  $[a, b]$  kaksi *mielivaltaista, samanpituista osaväliä*:

$$[c_1, d_1] \subset [a, b]$$

$$[c_2, d_2] \subset [a, b]$$

$$d_1 - c_1 = d_2 - c_2$$

Tällöin väleihin  $[c_1, d_1]$  ja  $[c_2, d_2]$  liittyvät todennäköisyydet ovat *yhtä suuria*.

#### Perustelu:

Todetaan ensin, että

$$\Pr(X \in [c_1, d_1]) = \int_{c_1}^{d_1} f(x) dx = \int_{c_1}^{d_1} \frac{1}{b-a} dx = \left[ \frac{x}{b-a} \right]_{c_1}^{d_1} = \frac{d_1 - c_1}{b-a}$$

ja vastaavasti

$$\Pr(X \in [c_2, d_2]) = \int_{c_2}^{d_2} f(x) dx = \int_{c_2}^{d_2} \frac{1}{b-a} dx = \left[ \frac{x}{b-a} \right]_{c_2}^{d_2} = \frac{d_2 - c_2}{b-a}$$

Koska oletuksen mukaan

$$d_1 - c_1 = d_2 - c_2$$

niin

$$\Pr(X \in [c_1, d_1]) = \Pr(X \in [c_2, d_2])$$

■

**Jatkuvan tasaisen jakauman tunnusluvut**

Olkoon

$$X \sim \text{Uniform}(a, b)$$

**Odotusarvo:**

$$E(X) = \frac{a+b}{2}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \frac{(b-a)^2}{12}$$

**Standardipoikkeama:**

$$D(X) = \frac{b-a}{2\sqrt{3}}$$

**Perustelu:**

Johdamme tässä jatkuvan tasaisen jakauman odotusarvon käyttäen jatkuvan jakauman odotusarvon määritelmää. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **Jatkuvan tasaisen jakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Suoraan jatkuvan jakauman odotusarvon määritelmästä saadaan, että

$$E(X) = \int_{-\infty}^{+\infty} xf(x)dx = \int_a^b x \frac{1}{b-a} dx = \frac{1}{b-a} \left[ \frac{1}{2} x^2 \right]_a^b = \frac{b^2 - a^2}{2(b-a)} = \frac{a+b}{2}$$

■

**Jatkuvan tasaisen jakauman tiheysfunktio**

Kuva oikealla esittää jatkuvan tasaisen jakauman


$$\text{Uniform}(a, b)$$

*tiheysfunktioita*

$$f(x) = \begin{cases} 0 & , x < a \\ \frac{1}{b-a} & , a \leq x \leq b \\ 0 & , x > b \end{cases}$$

Kuvaan on merkitty myös jakauman *odotusarvo*:

$$E(X) = \frac{a+b}{2}$$



Jatkuvan tasaisen jakauman tiheysfunktioilla  $f(x)$  on seuraavat ominaisuudet:

- (i) Tiheysfunktio  $f(x)$  saa positiivisen vakioarvon

$$1/(b - a)$$

välillä  $[a, b]$  ja arvon 0 välin  $[a, b]$  ulkopuolella.

- (ii) Tiheysfunktio on symmetrinen pisteen

$$E(X) = (a + b)/2$$

suhteen.

**Jatkuvan tasaisen jakauman kertymäfunktio**

Jatkuvan tasaisen jakauman kertymäfunktio on


$$F(x) = \Pr(X \leq x) = \begin{cases} 0 & , x \leq a \\ \frac{x-a}{b-a} & , a \leq x \leq b \\ 1 & , x \geq b \end{cases}$$

Ks. kuvaa oikealla

**Perustelu:**

Olkoon

$$X \sim \text{Uniform}(a, b)$$



Satunnaismuuttujan  $X$  tiheysfunktion lauseke on välillä  $[a, b]$  :

$$f(x) = \frac{1}{b-a}$$

Siten satunnaismuuttujan  $X$  kertymäfunktion lausekkeeksi saadaan, kun  $x \in [a, b]$  :

$$F(x) = \Pr(X \leq x) = \int_{-\infty}^x f(t)dt = \int_a^x \frac{1}{b-a} dt = \left[ \frac{t}{b-a} \right]_a^x = \frac{x-a}{b-a}$$

■

**Jatkuvan tasaisen jakauman momenttiemäfunktio**

Jatkuvan tasaisen jakauman

$$f(x) = \frac{1}{b-a}, a \leq x \leq b$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = \frac{e^{bt} - e^{at}}{t(b-a)}$$

**Perustelu:**

Suoraan jatkuvan jakauman momenttiemäfunktion määritelmän mukaan

$$m_X(t) = E(e^{tX}) = \int_{-\infty}^{+\infty} e^{tx} f(x) dx = \int_a^b e^{tx} \frac{1}{b-a} dx = \frac{1}{b-a} \left[ \frac{e^{tx}}{t} \right]_a^b = \frac{e^{bt} - e^{at}}{t(b-a)}$$

■

**Jatkuvan tasaisen jakauman momenttiemäfunktio ja jakauman tunnusluvut**

Johdetaan jatkuvan tasaisen jakauman Uniform( $a, b$ ) odotusarvo ja varianssi jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \frac{a+b}{2}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \frac{(b-a)^2}{12}$$

**Perustelu:**

Jatkuvan tasaisen jakauman Uniform( $a, b$ ) momenttiemäfunktio on

$$m_X(t) = \frac{e^{bt} - e^{at}}{t(b-a)}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\begin{aligned} \left. \frac{dm_X(t)}{dt} \right|_{t=0} &= \left. \frac{(be^{bt} - ae^{at})t(b-a) - (e^{bt} - e^{at})(b-a)}{t^2(b-a)^2} \right|_{t=0} \\ &= \left. \frac{(be^{bt} - ae^{at})t - (e^{bt} - e^{at})}{t^2(b-a)} \right|_{t=0} \\ &= \frac{a+b}{2} \end{aligned}$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\begin{aligned} \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} &= \left\{ \frac{[(b^2 e^{bt} - a^2 e^{at})t + (be^{bt} - ae^{at}) - (be^{bt} - ae^{at})]t^2(b-a)}{t^4(b-a)^2} \right. \\ &\quad \left. - \frac{[(be^{bt} - ae^{at})t - (e^{bt} - e^{at})]2t(b-a)}{t^4(b-a)^2} \right\} \Bigg|_{t=0} \\ &= \left. \frac{(b^2 e^{bt} - a^2 e^{at})t^2 - 2(be^{bt} - ae^{at})t + 2(e^{bt} - e^{at})}{t^3(b-a)} \right|_{t=0} \\ &= \frac{a^2 + ab + b^2}{3} \end{aligned}$$

Siten jatkuvan tasaisen jakauman  $\text{Uniform}(a, b)$  odotusarvo  $\mu_X$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\begin{aligned}\mu_X &= E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \frac{a+b}{2} \\ \alpha_2 &= E(X^2) = \left. \frac{d^2m_X(t)}{dt^2} \right|_{t=0} = \frac{a^2 + ab + b^2}{3} \\ \sigma_X^2 &= \text{Var}(X) = \alpha_2 - \alpha_1^2 = \frac{a^2 + ab + b^2}{3} - \frac{(a+b)^2}{4} = \frac{(b-a)^2}{12}\end{aligned}$$

■

### Jatkuvan tasaisen jakauman todennäköisyydet

Olkoon

$$X \sim \text{Uniform}(a, b)$$

ja olkoon

$$[c, d] \subset [a, b]$$

jokin jakauman määrittelyvälin  $[a, b]$  osaväli. Välin  $[c, d]$  todennäköisyys saadaan integroimalla tiheysfunktio

$$f(x) = \begin{cases} 0 & , x < a \\ \frac{1}{b-a} & , a \leq x \leq b \\ 0 & , x > b \end{cases}$$

välillä  $[c, d]$ :

$$\Pr(c \leq X \leq d) = \int_c^d f(x) dx = \int_c^d \frac{1}{b-a} dx = \left[ \frac{x}{b-a} \right]_c^d = \frac{d-c}{b-a}$$

*Kaikkien muiden jatkuvaan tasaiseen jakaumaan  $\text{Uniform}(a, b)$  liittyvien tapahtumien todennäköisyydet saadaan välin  $[a, b]$  osavälien todennäköisyyksistä todennäköisyysslaskennan laskusääntöjen avulla.*

### 17.2. Eksponenttijakauma

Eksponenttijakauma on *geometrisen jakauman* (ks. lukua **Diskreettejä jakaumia**) jatkuva vastine ja sitä käytetään usein *elinajan* mallintamiseen. Tietyt ehdot täyttävissä *jonotapahtumissa* 1. *tapahtuman odotusaika* ja *tapahtumien väliaika* noudattaa eksponenttijakaumaa.

Olkoon *jatkuvan satunnaismuuttujan*  $X$  tiheysfunktio

$$f(x) = \lambda \exp(-\lambda x), \lambda > 0, x \geq 0$$

Tällöin satunnaismuuttuja  $X$  noudattaa **eksponenttijakaumaa** parametrilla  $\lambda$  ja merkitsemme:

$$X \sim \text{Exp}(\lambda)$$

Johdamme eksponenttijakauman tiheysfunktion kohdassa **Eksponenttijakauma ja Poisson-jakauma**.

Funktio  $f(x)$  kelpaa tiheysfunktiksi, koska

$$f(x) > 0, x \geq 0$$

ja

$$\int_{-\infty}^{+\infty} f(x) dx = \int_0^{+\infty} \lambda e^{-\lambda x} dx = \left[ -e^{-\lambda x} \right]_0^{+\infty} = 1$$

### Eksponenttijakauman tunnusluvut

Olkoon

$$X \sim \text{Exp}(\lambda)$$

**Odotusarvo:**

$$E(X) = \frac{1}{\lambda}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \frac{1}{\lambda^2}$$

**Standardipoikkeama:**

$$D(X) = \frac{1}{\lambda}$$

**Perustelu:**

Johdamme tässä eksponenttijakauman odotusarvon käyttäen jatkuvan jakauman odotusarvon määritelmää. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **Eksponenttijakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Jatkuvan jakauman odotusarvon määritelmästä saadaan soveltamalla *osittaisintegrointia*, että

$$E(X) = \int_0^{+\infty} x f(x) dx = \int_0^{+\infty} x \lambda e^{-\lambda x} dx = \left[ -x e^{-\lambda x} \right]_0^{+\infty} + \int_0^{+\infty} e^{-\lambda x} dx = \left[ -\frac{1}{\lambda} e^{-\lambda x} \right]_0^{+\infty} = \frac{1}{\lambda}$$

■

### Eksponenttijakauman tiheysfunktio

Kuva alla esittää eksponenttijakauman

$$\text{Exp}(\lambda)$$

*tiheysfunktioita*

$$f(x) = \lambda \exp(-\lambda x)$$

$$\lambda > 0, x \geq 0$$

välillä  $[0, 6]$  seuraavissa tapauksissa:

(i)  $\lambda = 1/2$

(ii)  $\lambda = 1/4$

Eksponenttijakauman *odotusarvo*:

$$E(X) = \frac{1}{\lambda}$$


Eksponenttijakauman tiheysfunktiolla on seuraavat ominaisuudet:

- (i) Eksponenttijakauman tiheysfunktio  $f(x)$  saa *positiivisia* arvoja kaikille ei-negatiivisille argumentin  $x$  arvoille:

$$f(x) > 0, x \geq 0$$

- (ii) Tiheysfunktio *monotonisesti laskeva* ja sillä on *maksimi* pisteessä  $x = 0$ .

- (iii) Tiheysfunktio on *vino oikealle*.



**Eksponenttijakauman kertymäfunktio**

Eksponenttijakauman *kertymäfunktio*ksi saadaan

$$F(x) = \int_0^x f(t)dt = \int_0^x \lambda \exp(-\lambda t)dt = [-\exp(-\lambda t)]_0^x = 1 - \exp(-\lambda x)$$

$$\lambda > 0, x \geq 0$$

*Komplementtitapahtuman todennäköisyyden kaavan* mukaan

$$\begin{aligned} \Pr(X > x) &= 1 - P(X \leq x) \\ &= 1 - F(x) \\ &= \exp(-\lambda x) \end{aligned}$$

Kuva oikealla esittää eksponenttijakauman

$$\text{Exp}(\lambda)$$


*kertymäfunktio*ta

$$F(x) = 1 - \exp(-\lambda x)$$

$$\lambda > 0, x \geq 0$$

välillä  $[0, 6]$ , kun

$$\lambda = 1/2$$



**Eksponenttijakauman momenttiemäfunktio**

Eksponenttijakauman

$$f(x) = \lambda e^{-\lambda x}, \lambda > 0, x \geq 0$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_X(t) = E(e^{tX}) = \frac{\lambda}{\lambda - t}$$

**Perustelu:**

Suoraan jatkuvan jakauman momenttiemäfunktion määritelmän mukaan

$$\begin{aligned} m_X(t) = E(e^{tX}) &= \int_{-\infty}^{+\infty} e^{tx} f(x) dx \\ &= \int_0^{\infty} e^{tx} \lambda e^{-\lambda x} dx \\ &= \lambda \int_0^{\infty} e^{(t-\lambda)x} dx \\ &= \lambda \left[ \frac{e^{(t-\lambda)x}}{t-\lambda} \right]_0^{\infty} \\ &= \frac{\lambda}{\lambda - t} \end{aligned}$$

■

**Eksponttijakauman momenttiemäfunktio ja jakauman tunnusluvut**

Johdetaan eksponenttijakauman  $\text{Exp}(\lambda)$  odotusarvo ja varianssi jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \frac{1}{\lambda}$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \frac{1}{\lambda^2}$$

**Perustelu:**

Eksponttijakauman  $\text{Exp}(\lambda)$  momenttiemäfunktio on

$$m_X(t) = \frac{\lambda}{\lambda - t}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = \left. \frac{\lambda}{(\lambda - t)^2} \right|_{t=0} = \frac{1}{\lambda}$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \left. \frac{2\lambda}{(\lambda - t)^3} \right|_{t=0} = \frac{2}{\lambda^2}$$



Siten eksponenttijakauman  $\text{Exp}(\lambda)$  odotusarvo  $\mu_x$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_x^2$  saadaan seuraavilla kaavoilla:

$$\mu_x = E(X) = \alpha_1 = \left. \frac{dm_x(t)}{dt} \right|_{t=0} = \frac{1}{\lambda}$$

$$\alpha_2 = E(X^2) = \left. \frac{d^2 m_x(t)}{dt^2} \right|_{t=0} = \frac{2}{\lambda^2}$$

$$\sigma_x^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}$$

■

### Eksponenttijakauma ja Poisson-jakauma

Tarkastellaan jonkin tapahtuman sattumista *saman* satunnaiskokeen toistojen aikana ja olkoon

$X$  = odotusaika 1. tapahtumalle (tai tapahtumien väliaika)

Oletetaan, että

$$X \sim \text{Exp}(\lambda)$$

jolloin

$$E(X) = 1/\lambda$$

Olkoon

$Z$  = tapahtumien lukumäärä aikayksikköä kohden

Tällöin  $Z$  on *diskreetti satunnaismuuttuja*, joka noudattaa **Poisson-jakaumaa** parametrilla  $\lambda$ :

$$Z \sim \text{Poisson}(\lambda)$$

jolloin siis

$$E(Z) = \lambda$$

Parametri  $\lambda$  kuvaa tarkastelun kohteena olevan tapahtuman *tapahtumaintensiteettiä* eli tarkastelun kohteena olevan tapahtuman esiintymisten keskimääräistä lukumäärää aikayksikköä kohden. Lisätietoja Poisson-jakaumasta; ks. lukua **Diskreettejä jakaumia**.

Voidaan osoittaa, että jakaumien välinen yhteys toimii myös toiseen suuntaan: Olkoon siis

$Z$  = tapahtumien lukumäärä aikayksikköä kohden

ja oletetaan, että

$$Z \sim \text{Poisson}(\lambda)$$

Olkoon

$X$  = odotusaika 1. tapahtumalle (tai tapahtumien väliaika)

Tällöin  $X$  on *jatkuva satunnaismuuttuja*, joka noudattaa **eksponenttijakaumaa** parametrilla  $\lambda$ :

$$X \sim \text{Exp}(\lambda)$$

**Perustelu:**

Olkoon

$X =$  odotusaika 1. tapahtumalle

Johdetaan satunnaismuuttujan  $X$  kertymäfunktio  $F_X$ .

Kertymäfunktion määritelmän ja komplementtitapahtuman todennäköisyyden kaavan mukaan

$$(*) \quad F_X(x) = \Pr(X \leq x) = 1 - \Pr(X > x)$$

Ensimmäinen tapahtuma sattuu ajanhetken  $x$  jälkeen, jos ja vain jos aikavälillä  $[0, x]$  ei ole sattunut yhtään tapahtumaa. Siten

$$\Pr(X > x) = \Pr(Z = 0)$$

jossa

$$Z \sim \text{Poisson}(\lambda x)$$

Poisson-jakauman pistetodennäköisyysfunktion kaavasta

$$f(z) = \Pr(Z = z) = \frac{e^{-\lambda x} (\lambda x)^z}{z!}, \quad z = 0, 1, 2, \dots$$

saadaan:

$$\Pr(X > x) = \Pr(Z = 0) = \exp(-\lambda x)$$

Sijoittamalla tämä kaavaan (\*) saamme satunnaismuuttujan  $X$  kertymäfunktiksi

$$F_X(x) = \Pr(X \leq x) = 1 - \Pr(X > x) = 1 - \exp(-\lambda x)$$

Satunnaismuuttujan  $X$  tiheysfunktio saadaan derivoimalla kertymäfunktio  $F_X(x)$  argumenttinsa  $x$  suhteen:

$$f_X(x) = \frac{d}{dx} F_X(x) = \lambda \exp(-\lambda x)$$

Siten

$$X \sim \text{Exp}(\lambda)$$

■

**Eksponenttijakauman unohtamisominaisuus**

Olkoon

$$X \sim \text{Exp}(\lambda)$$

Tällöin

$$\Pr(X \geq a + b \mid X \geq a) = \Pr(X \geq b)$$

jossa  $a \geq 0, b \geq 0$ .

**Perustelu:**

Todetaan ensin, että

$$\Pr(X \geq c) = 1 - \Pr(X \leq c) = 1 - F(c) = \exp(-\lambda c)$$

jossa  $c \geq 0$  ja  $F$  on eksponenttijakauman *kertymäfunktio*.

Koska

$$\{X \geq a+b\} \subset \{X \geq a\}$$

niin

$$\Pr(X \geq a+b \text{ ja } X \geq a) = \Pr(X \geq a+b)$$

Siten

$$\begin{aligned} \Pr(X \geq a+b | X \geq a) &= \frac{\Pr(X \geq a+b \text{ ja } X \geq a)}{\Pr(X \geq a)} \\ &= \frac{\Pr(X \geq a+b)}{\Pr(X \geq a)} \\ &= \frac{\exp(-\lambda(a+b))}{\exp(-\lambda a)} \\ &= \exp(-\lambda b) \\ &= 1 - F(b) \\ &= 1 - \Pr(X \leq b) \\ &= \Pr(X \geq b) \end{aligned}$$

■

Siten eksponenttijakaumalla ns. on *unohtamisominaisuus*: Se, että tapahtuman sattumista on jouduttu odottamaan ajan  $a$ , ei vaikuta todennäköisyyteen joutua odottamaan ajan  $b$  lisää. Tällaista unohtamisominaisuutta kutsutaan *stokastisten prosessien teoriassa Markov-ominaisuudeksi*.

Samanlainen unohtamisominaisuus on **geometrisella jakaumalla**, jota voidaan pitää eksponenttijakauman *diskreettinä* vastineena; lisätietoja geometrisesta jakaumasta: ks. lukua **Diskreettejä jakaumia**.

## Eksponenttijakauman todennäköisyydet

Olkoon

$$X \sim \text{Exp}(\lambda)$$

ja olkoon

$$[c, d] \subset [0, +\infty)$$

jokin jakauman määrittelyvälin  $[0, +\infty)$  osaväli. Välin  $[c, d]$  todennäköisyys saadaan integroimalla eksponenttijakauman  $\text{Exp}(\lambda)$  tiheysfunktio

$$f(x) = \lambda \exp(-\lambda x), \lambda > 0, x \geq 0$$

välillä  $[c, d]$ :

$$\Pr(c \leq X \leq d) = \int_c^d f(x) dx = \int_c^d \lambda e^{-\lambda x} dx = \left[ -e^{-\lambda x} \right]_c^d = e^{-\lambda c} - e^{-\lambda d}$$

*Kaikkien* muiden eksponenttijakaumaan  $\text{Exp}(\lambda)$  liittyvien tapahtumien todennäköisyydet saadaan välin  $[0, +\infty)$  osavälien todennäköisyyksistä *todennäköisyysslaskennan laskusääntöjen* avulla.

### 17.3. Normaalijakauma

Normaalijakauma on sekä *teoreettisen* että *soveltavan tilastotieteen tärkein jakauma*. Tämä johtuu seuraavista seikoista:

- (i) **Empiirisen kokemuksen mukaan monia satunnaisilmiöitä koskevat havainnot noudattavat ainakin approksimatiivisesti normaalijakaumaa.**
- (ii) **Monet satunnaismuuttujat noudattavat approksimatiivisesti normaalijakaumaa.**
- (iii) **Monet tärkeät todennäköisyysjakaumat saadaan sopivilla muunnoksilla normaalijakaumasta.**
- (iv) **Keskeisen raja-arvolauseen mukaan usean satunnaismuuttujan summat noudattavat ainakin approksimatiivisesti normaalijakaumaa, jos summassa on riittävästi tekijöitä.**

Olkoon *jatkuvan satunnaismuuttujan X tiheysfunktio*

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}, -\infty < \mu < +\infty, \sigma > 0, -\infty < x < +\infty$$

Tällöin satunnaismuuttuja X noudattaa **normaalijakaumaa** parametrein  $\mu$  ja  $\sigma^2$  ja merkitsemme:

$$X \sim N(\mu, \sigma^2)$$

Funktio  $f(x)$  kelpaa tiheysfunktioiksi, koska

$$f(x) > 0, -\infty < x < +\infty$$

ja

$$\int_{-\infty}^{+\infty} f(x)dx = 1$$

**Perustelu:**

Sen perusteleminen, että

$$\int_{-\infty}^{+\infty} f(x)dx = 1$$

on siinä mielessä hankalaa, että *normaalijakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktiota ei voida esittää suljetussa muodossa* (so. alkeisfunktioiden avulla). Perusteleminen onnistuu kuitenkin alla käytettävän ”tempun” avulla.

Tarkastellaan yksinkertaisuuden vuoksi ns. *standardoitua normaalijakaumaa*, jossa

$$\mu = 0, \sigma^2 = 1$$

Tämä ei ole rajoittava oletus, koska *jokainen* yleistä normaalijakaumaa  $N(\mu, \sigma^2)$  noudattava satunnaismuuttuja saadaan lineaarimuunnoksella standardoitua normaalijakaumaa  $N(0,1)$  noudattavasta satunnaismuuttujasta; ks. kohta **Normaalijakautuneen satunnaismuuttujan lineaarimuunnoksen jakauma**.

Jos

$$\mu = 0, \sigma^2 = 1$$

niin normaalijakauman tiheysfunktio on muotoa

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

Koska  $f(x)$  on *symmetrinen*, väite

$$\int_{-\infty}^{+\infty} f(x) dx = 1$$

tulee todistetuksi, jos näytämme, että

$$\int_0^{\infty} e^{-x^2/2} dx = \frac{\sqrt{2\pi}}{2} = \sqrt{\frac{\pi}{2}}$$

Tarkastellaan integraalia

$$\left( \int_0^{\infty} e^{-x^2/2} dx \right)^2 = \left( \int_0^{\infty} e^{-u^2/2} du \right) \left( \int_0^{\infty} e^{-v^2/2} dv \right) = \int_0^{\infty} \int_0^{\infty} e^{-(u^2+v^2)/2} du dv$$

Siirrytään tässä integraalissa *napakoordinaatteihin* muunnoksella

$$u = r \cos(\theta)$$

$$v = r \sin(\theta)$$

Tällöin

$$u^2 + v^2 = r^2 \cos^2(\theta) + r^2 \sin^2(\theta) = r^2 [\cos^2(\theta) + \sin^2(\theta)] = r^2$$

$$du dv = r d\theta dr$$

ja integroimisalueeksi tulee

$$0 < r < \infty$$

$$0 < \theta < \pi/2$$

Siten

$$\int_0^{\infty} \int_0^{\infty} e^{-(u^2+v^2)/2} du dv = \int_0^{\infty} \int_0^{\pi/2} r e^{-r^2/2} d\theta dr = \frac{\pi}{2} \int_0^{\infty} r e^{-r^2/2} dr = \frac{\pi}{2} \left[ -e^{-r^2/2} \right]_0^{\infty} = \frac{\pi}{2}$$

joten olemme todistaneet, että

$$\left( \int_0^{\infty} e^{-x^2/2} dx \right)^2 = \frac{\pi}{2}$$

josta väite seuraa. ■

Normaalijakaumaa kutsutaan kehittäjänsä mukaan usein **Gaussin jakaumaksi** ja sen tiheysfunktion kuvaajaa kutsutaan tavallisesti joko **Gaussin käyräksi** tai **kellokäyräksi** (engl. *bell curve*).

### Normaalijakauman tunnusluvut

Olkoon

$$X \sim N(\mu, \sigma^2)$$

**Odotusarvo:**

$$E(X) = \mu$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma^2$$

**Standardipoikkeama:**

$$D(X) = \sigma$$

**Perustelu:**

Johdamme tässä normaalijakauman odotusarvon käyttäen jatkuvan jakauman odotusarvon määritelmää. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **Normaalijakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Suoraan jatkuvan jakauman odotusarvon määritelmästä saadaan, että

$$E(X) = \int_{-\infty}^{+\infty} xf(x)dx = \int_{-\infty}^{+\infty} \frac{1}{\sigma\sqrt{2\pi}} xe^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} dx$$

*Sijoituksella*

$$z = \frac{x - \mu}{\sigma}$$

saadaan:

$$E(X) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} (\mu + \sigma z) e^{-\frac{1}{2}z^2} dz = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} \mu e^{-\frac{1}{2}z^2} dz + \int_{-\infty}^{+\infty} \frac{\sigma}{\sqrt{2\pi}} z e^{-\frac{1}{2}z^2} dz$$

Nyt

$$E(X) = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} \mu e^{-\frac{1}{2}z^2} dz + \int_{-\infty}^{+\infty} \frac{\sigma}{\sqrt{2\pi}} z e^{-\frac{1}{2}z^2} dz = \mu$$

Tämä seuraa siitä, että

$$\int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} \mu e^{-\frac{1}{2}z^2} dz = \mu \int_{-\infty}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2} dz = \mu \cdot 1 = \mu$$

koska integroitava on ns. *standardoidun normaalijakauman*  $N(0,1)$  tiheysfunktio ja

$$\int_{-\infty}^{+\infty} \frac{\sigma}{\sqrt{2\pi}} z e^{-\frac{1}{2}z^2} dz = 0$$

koska integroitava on muuttujan  $z$  *pariton funktio*.

■

### Normaalijakauman tiheysfunktio

Kuva oikealla esittää normaalijakauman


$$N(\mu, \sigma^2)$$

tiheysfunktioita

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2}(x-\mu)^2\right\}$$

välillä  $[-6,+6]$  seuraavissa tapauksissa:

- (i)  $\mu = -2, \sigma^2 = 4$
- (ii)  $\mu = 0, \sigma^2 = 1$
- (iii)  $\mu = +3, \sigma^2 = 0.09$



Normaalijakauman odotusarvo:

$$E(X) = \mu$$

Normaalijakauman varianssi:

$$\text{Var}(X) = \sigma^2$$

### Normaalijakauman tiheysfunktion ominaisuudet

Kaikille normaalijakaumille pätee:

- (i) Normaalijakauman tiheysfunktio  $f(x)$  on kaikkialla positiivinen:

$$f(x) > 0, -\infty < x < +\infty$$

- (ii) Tiheysfunktio on yksihuippuinen.
- (iii) Tiheysfunktiolla on maksimi pisteessä

$$E(X) = \mu$$

- (iv) Tiheysfunktio on symmetrinen pisteen  $x = \mu$  suhteen:

$$f(\mu - x) = f(\mu + x), -\infty < x < +\infty$$

- (v) Tiheysfunktiolla on käännepisteet pisteissä

$$\mu - \sigma \text{ ja } \mu + \sigma$$


- (vi) Tiheysfunktio on kupera ylöspäin välin

$$[\mu - \sigma, \mu + \sigma]$$

sisäpuolella ja kupera alaspäin välin

$$[\mu - \sigma, \mu + \sigma]$$

ulkopuolella.



(vii) Kaikkien normaalijakaumien tiheysfunktiot ovat *samanmuotoisia*, jos ne piirretään *standardoiduissa yksiköissä*

$$z = \frac{x - \mu}{\sigma}$$

**68-95-99.7-sääntö**

*Kaikille* normaalijakaumille pätee:

(i) Noin 68% jakauman todennäköisyysmassasta on välillä

$$[\mu - \sigma, \mu + \sigma]$$

(ii) Noin 95% jakauman todennäköisyysmassasta on välillä


$$[\mu - 2\sigma, \mu + 2\sigma]$$

(iii) Noin 99.7% jakauman todennäköisyysmassasta on välillä

$$[\mu - 3\sigma, \mu + 3\sigma]$$

68-95-99.7-sääntö nähdään helposti oikeaksi vetoamalla normaalijakauman tiheysfunktion ominaisuuteen (vii) ja *standardoidun normaalijakauman taulukoihin*; lisätietoja normaalijakauman taulukoiden käytöstä: ks. kohtia **Todennäköisyyksien määrääminen standardoidusta normaalijakaumasta** ja **Todennäköisyyksien määrääminen mielivaltaisesta normaalijakaumasta**.

Kuva alla havainnollistaa 68-95-99.7-sääntöä.



**Normaalijakauman kertymäfunktio**

Olkoon

$$X \sim N(\mu, \sigma^2)$$



Satunnaismuuttujan  $X$  **kertymäfunktio** on

$$F(x) = \Pr(X \leq x) = \int_{-\infty}^x \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{t-\mu}{\sigma}\right)^2} dt$$

**Huomautuksia:**

- **Normaalijakauman kertymäfunktiole ei voida antaa eksplisiittistä lauseketta**, koska normaalijakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktiota ei voida esittää suljetussa muodossa (so. alkeisfunktioiden avulla).
- Normaalijakauman kertymäfunktion arvojen määrittämiseen on käytettävä **numeerista integrointia** ja siksi tilastotieteen oppikirjoihin on tavallisesti liitetty ns. standardoidun normaalijakauman kertymäfunktion arvoja sisältävä **taulukko**.
- Standardoidun normaalijakauman kertymäfunktion arvoja sisältävän taulukon avulla voidaan määrätä todennäköisyydet reaaliakselin väleille mielivaltaisesta normaalijakaumasta.

Lisätietoja: ks. kohtia **Todennäköisyyksien määrittäminen standardoidusta normaalijakaumasta** ja **Todennäköisyyksien määrittäminen mielivaltaisesta normaalijakaumasta**.

### Normaalijakauman momenttiemäfunktio

Normaalijakauman

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}, -\infty < \mu < +\infty, \sigma > 0, -\infty < x < +\infty$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = \exp(\mu t + \frac{1}{2}\sigma^2 t^2)$$

**Perustelu:**

Jatkuvan jakauman momenttiemäfunktion määrittelyn mukaan

$$\begin{aligned} m_x(t) = E(e^{tx}) &= \int_{-\infty}^{+\infty} e^{tx} f(x) dx \\ &= \int_{-\infty}^{+\infty} \exp(tx) \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2}(x-\mu)^2\right\} dx \\ &= \exp(\mu t + \frac{1}{2}\sigma^2 t^2) \int_{-\infty}^{+\infty} \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2}[x-2(\mu+\sigma^2 t)]^2\right\} dx \\ &= \exp(\mu t + \frac{1}{2}\sigma^2 t^2) \end{aligned}$$

■

### Normaalijakauman momenttiemäfunktio ja jakauman tunnusluvut

Johdetaan normaalijakauman  $N(\mu, \sigma^2)$  *odotusarvo* ja *varianssi* jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \mu$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = \sigma^2$$

**Perustelu:**

Normaalijakauman  $N(\mu, \sigma^2)$  momenttiemäfunktio on

$$m_X(t) = \exp(\mu t + \frac{1}{2} \sigma^2 t^2)$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = e^{\mu + \frac{1}{2} \sigma^2 t^2} (\mu + \sigma^2 t) \Big|_{t=0} = \mu$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \left[ e^{\mu + \frac{1}{2} \sigma^2 t^2} (\mu + \sigma^2 t)^2 + e^{\mu + \frac{1}{2} \sigma^2 t^2} \sigma^2 \right] \Big|_{t=0} = \mu^2 + \sigma^2$$

Siten normaalijakauman  $N(\mu, \sigma^2)$  odotusarvo  $\mu_X$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\mu_X = E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \mu$$

$$\alpha_2 = E(X^2) = \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \mu^2 + \sigma^2$$

$$\sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 = \mu^2 + \sigma^2 - \mu^2 = \sigma^2$$

■

**Standardoitu normaalijakauma**

Jos

$$Z \sim N(0,1)$$

jolloin siis

$$E(Z) = \mu = 0$$

$$\text{Var}(Z) = D^2(Z) = \sigma^2 = 1$$



niin sanomme, että satunnaismuuttuja  $X$  noudattaa **standardoitua normaalijakaumaa**.

Alla olevista kuvista vasemmanpuoleinen esittää standardoidun normaalijakauman  $N(0,1)$  tiheysfunktiota

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}$$

ja kuvista oikeanpuoleinen esittää standardoidun normaalijakauman  $N(0,1)$  kertymäfunktiota

$$\Phi(z) = \Pr(Z \leq z) = \int_{-\infty}^z f(t)dt = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{1}{2}t^2} dt$$



Kuten edellä on todettu, **normaalijakauman kertymäfunktiolle ei voida antaa eksplisiittistä lauseketta**, koska normaalijakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktiota ei voida esittää suljetussa muodossa (so. alkeisfunktioiden avulla).

**Normaalijakautuneen satunnaismuuttujan lineaarimuunnoksen jakauma**

Olkoon

$$X \sim N(\mu, \sigma^2)$$

Määritellään satunnaismuuttuja

$$Y = a + bX$$

jossa  $a$  ja  $b$  ovat ei-satunnaisia vakioita. Tällöin satunnaismuuttuja  $Y$  on **normaalinen**:

$$Y \sim N(a + b\mu, b^2\sigma^2)$$

**Perustelu:**

Ks. lukua **Satunnaismuuttujien muunnokset ja niiden jakaumat**.

Tästä tuloksesta seuraa erikoistapauksena seuraava tulos: Jos

$$X \sim N(0,1)$$

ja

$$Y = \mu + \sigma X$$

jossa  $\mu$  ja  $\sigma$  ovat ei-satunnaisia vakioita, niin

$$Y \sim N(\mu, \sigma^2)$$

Siten **kaikki normaalijakautuneet satunnaismuuttujat saadaan lineaarimuunnoksella standardoitua normaalijakaumaa  $N(0,1)$  noudattavista satunnaismuuttujista**.

**Huomautus:**

- Kaikille satunnaismuuttujille (joilla on odotusarvo ja varianssi) pätee seuraava:

Oletetaan, että

$$E(X) = \mu$$

$$\text{Var}(X) = \sigma^2$$

ja olkoon

$$Y = a + bX$$

Tällöin

$$E(Y) = a + b\mu$$

$$\text{Var}(Y) = b^2\sigma^2$$

Ks. lukua **Jakaumien tunnusluvut**.

Edellä esitetyn tuloksen merkitys on siinä, että sen mukaan *satunnaismuuttujan X normaalisuudesta seuraa sen lineaarimuunnoksen  $Y = a + bX$  normaalisuus*.

**Standardointi**

Olkoon

$$X \sim N(\mu, \sigma^2)$$

jolloin siis

$$E(X) = \mu$$

$$\text{Var}(X) = D^2(X) = \sigma^2$$

Tällöin **standardoitu satunnaismuuttuja**

$$Z = \frac{X - E(X)}{D(X)} = \frac{X - \mu}{\sigma}$$

noudattaa *standardoitua normaalijakaumaa*:

$$Z \sim N(0,1)$$

**Perustelu:**

Tulos seuraa edellä esitetystä normaalijakautuneen satunnaismuuttujan lineaarimuunnoksen jakaumaa koskevasta tuloksesta, koska

$$Z = \frac{X - \mu}{\sigma} = -\frac{\mu}{\sigma} + \frac{1}{\sigma} X$$

■

**Todennäköisyyksien määrääminen standardoidusta normaalijakaumasta**

Todennäköisyydet *standardoidusta normaalijakaumasta*  $N(0,1)$  voidaan määrätä jakauman *kertymäfunktion* avulla.

Oletetaan, että

$$Z \sim N(0,1)$$

ja olkoon

$$\Phi(z) = \Pr(Z \leq z)$$

satunnaismuuttujan  $Z$  kertymäfunktio.

*Kaikkien* standardoituun normaalijakaumaan liittyvien tapahtumien todennäköisyydet saadaan todennäköisyyksistä

$$\Phi(z) = \Pr(Z \leq z)$$

*todennäköisyslaskennan laskusääntöjen avulla.* Perusoperaationa on tällöin muotoa

$$[a, b]$$

olevien reaaliakselin *välien* todennäköisyyksien määrääminen. Jatkuvan jakauman kertymäfunktioiden yleisten ominaisuuksien perusteella

$$\Pr(a \leq Z \leq b) = \Phi(b) - \Phi(a)$$

Kuten edellä on todettu, **normaalijakauman kertymäfunktiole ei voida antaa eksplisiittistä lauseketta**, koska normaalijakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktiota ei voida esittää suljetussa muodossa (so. alkeisfunktioiden avulla). Siksi todennäköisyyksien määräämisessä standardoidusta normaalijakaumasta on turvaututtava joko **taulukoihin** tai **tietokoneohjelmiin**; ks. seuraavia kappaleita.

### Todennäköisyyksien määrääminen standardoidusta normaalijakaumasta ja normaalijakauman taulukot

Standardoidun normaalijakauman *taulukot* sisältävät standardoidun normaalijakauman  $N(0,1)$  kertymäfunktion  $\Phi(z)$  arvoja taulukoituna usealle eri argumentin  $z$  arvolle.

Tähän monisteeseen liittyvässä taulukkokokoelmassa on taulukoituna standardoidun normaalijakauman  $N(0,1)$  kertymäfunktion  $\Phi(z)$  arvoja, kun  $z$  vaihtelee välillä  $[-3.59, +3.59]$  askelin, joiden pituus on 0.01:

$$z = -3.59 (0.01) + 3.59$$

Taulukot mahdollistavat seuraavien tehtävien ratkaisemisen:

- (i) Määrää todennäköisyys

$$\Pr(Z \leq z) = \Phi(z)$$

kun  $z$  on annettu.

- (ii) Määrää  $z$ , kun todennäköisyys

$$\Pr(Z \leq z) = \Phi(z)$$

on annettu.

Monissa standardoidun normaalijakauman taulukoissa on taulukoituna todennäköisyyksiä

$$\Pr(Z \leq z) = \Phi(z)$$

vain, kun  $z \geq 0$ . Tällöin todennäköisyydet

$$\Pr(Z \leq -z) = \Phi(-z)$$

saadaan nojaamalla standardoidun normaalijakauman tiheysfunktion *symmetrisyyteen* pisteen

$$z = 0$$

suhteen:

$$\Phi(-z) = \Pr(Z \leq -z) = 1 - \Pr(Z \geq -z) = 1 - \Pr(Z \leq z) = 1 - \Phi(z)$$

**Esimerkki 1. Todennäköisyyksien määrittäminen standardoidun normaalijakauman taulukoista.**

Olkoon

$$Z \sim N(0,1)$$

Tällöin

$$f(z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2}$$

on satunnaismuuttujan  $Z$  tiheysfunktio ja



$$\Phi(z) = \Pr(Z \leq z) = \int_{-\infty}^z f(t) dt$$

on satunnaismuuttujan  $Z$  kertymäfunktio.

Standardoidun normaalijakauman  $N(0,1)$  taulukoista saadaan:

$$\Phi(1) = \Pr(Z \leq 1) = 0.8413$$

Ks. vasemmanpuoleista kuvaa alla.



Oikeanpuoleinen kuva yllä havainnollistaa sitä, että

$$\text{Alueen } A \text{ pinta-ala} = \int_{-\infty}^1 f_Z(z) dz = \Pr(Z \leq 1) = \Phi(1) = 0.8413$$

## Todennäköisyyksien määrittäminen mielivaltaisesta normaalijakaumasta

Kuten edellä on todettu, *kaikki* normaalijakaumat  $N(\mu, \sigma^2)$  ovat *samanmuotoisia standardoiduissa yksiköissä*

$$Z = \frac{X - \mu}{\sigma}$$

Tämä merkitsee sitä, että todennäköisyydet *mielivaltaisesta normaalijakaumasta*  $N(\mu, \sigma^2)$  voidaan määrätä *standardoidun normaalijakauman*  $N(0,1)$  todennäköisyyksien avulla.

Oletetaan, että

$$X \sim N(\mu, \sigma^2)$$

jolloin

$$Z = \frac{X - \mu}{\sigma} \sim N(0,1)$$

Tällöin siis

$$\Pr(a \leq X \leq b) = \Pr\left(\frac{a - \mu}{\sigma} \leq \frac{X - \mu}{\sigma} \leq \frac{b - \mu}{\sigma}\right) = \Pr\left(\frac{a - \mu}{\sigma} \leq Z \leq \frac{b - \mu}{\sigma}\right)$$

### Esimerkki 1: Todennäköisyyksien määrittäminen mielivaltaisesta normaalijakaumasta.

Olkoon

$$X \sim N(2, 1/4)$$

jolloin

$$E(X) = \mu = 2$$

$$\text{Var}(X) = D^2(X) = \sigma^2 = \frac{1}{4}$$

ja

$$D(X) = \sigma = \frac{1}{2}$$

Haluamme määrätä todennäköisyyden

$$\Pr(1.5 \leq X \leq 3)$$

Käytämme tehtävän ratkaisemisessa *standardoidun normaalijakauman*  $N(0,1)$  taulukoita.

Olkoon

$$X \sim N(\mu, \sigma^2)$$

jossa

$$\mu = 2$$

$$\sigma^2 = 1/4$$

Tällöin *standardoitu satunnaismuuttuja*



$$Z = \frac{X - \mu}{\sigma} = \frac{X - 2}{1/2} \quad N(0,1)$$

Standardoidun normaalijakauman  $N(0,1)$  taulukoista saadaan:

$$\begin{aligned} \Pr(1.5 \leq X \leq 3) &= \Pr\left(\frac{1.5-2}{1/2} \leq \frac{X-2}{1/2} \leq \frac{3-2}{1/2}\right) \\ &= \Pr(-1 \leq Z \leq 2) \quad | \quad Z \sim N(0,1) \\ &= \Pr(Z \leq 2) - \Pr(Z \leq -1) \\ &= 0.9772 - 0.1587 \\ &= 0.8185 \end{aligned}$$

Ks. alla olevia kuvia, joissa siis

$$\begin{aligned} \text{Alueen } A_1 \text{ pinta-ala} &= \Pr(1.5 \leq X \leq 3) = \Pr(-1 \leq Z \leq 2) = \text{Alueen } A_2 \text{ pinta-ala} \\ &= 0.8185 \end{aligned}$$



### Todennäköisyyksien määrittäminen normaalijakaumasta ja tietokoneohjelmat

Olkoon

$$X \sim N(\mu, \sigma^2)$$

Monet *tietokoneohjelmat* mahdollistavat seuraavien tehtävien ratkaisemisen mielivaltaisille parametrien  $\mu$  ja  $\sigma^2$  arvoille:

- (i) Määrittää todennäköisyys

$$\Pr(X \leq x)$$

kun  $x$  on annettu.



(ii) Määrittää  $x$ , kun todennäköisyys

$$\Pr(X \leq x)$$

on annettu.

### Normaalijakaumaa noudattavien satunnaismuuttujien summan jakauma

Olkoot

$$X_1, X_2, \dots, X_n$$

riippumattomia satunnaismuuttujia, jotka noudattavat *normaalijakaumaa* parametrein  $(\mu_1, \sigma_1^2)$ ,  $(\mu_2, \sigma_2^2)$ , ...,  $(\mu_n, \sigma_n^2)$ :

$$\begin{aligned} X_1, X_2, \dots, X_n &\perp \\ X_i &\sim N(\mu_i, \sigma_i^2), i = 1, 2, \dots, n \end{aligned}$$

Tällöin satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *summa*

$$Y = X_1 + X_2 + \dots + X_n$$

noudattaa *normaalijakaumaa* parametrein  $\mu = \mu_1 + \mu_2 + \dots + \mu_n$  ja  $\sigma^2 = \sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2$ :

$$Y \sim N(\mu, \sigma^2)$$

#### Perustelu:

Todistus perustuu siihen, että *riippumattomien satunnaismuuttujien summan momenttiemäfunctio ko. satunnaismuuttujien momenttiemäfunctioiden tulo.*

Oletetaan, että

$$\begin{aligned} X_1, X_2, \dots, X_n &\perp \\ X_i &\sim N(\mu_i, \sigma_i^2), i = 1, 2, \dots, n \end{aligned}$$

Satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *momenttiemäfunctiot* ovat muotoa

$$m_i(t) = \exp(\mu_i t + \frac{1}{2} \sigma_i^2 t^2), i = 1, 2, \dots, n$$

Muodostetaan satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *summa*:

$$Y = X_1 + X_2 + \dots + X_n$$

Summamuuttujan  $Y$  *momenttiemäfunctio* on

$$\begin{aligned} m_Y(t) &= m_1(t) m_2(t) \dots m_n(t) \\ &= \exp(\mu_1 t + \frac{1}{2} \sigma_1^2 t^2) \exp(\mu_2 t + \frac{1}{2} \sigma_2^2 t^2) \dots \exp(\mu_n t + \frac{1}{2} \sigma_n^2 t^2) \\ &= \exp((\mu_1 + \mu_2 + \dots + \mu_n) t + \frac{1}{2} (\sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2) t^2) \\ &= \exp(\mu t + \frac{1}{2} \sigma^2 t^2) \end{aligned}$$

jossa

$$\begin{aligned} \mu &= \mu_1 + \mu_2 + \dots + \mu_n \\ \sigma^2 &= \sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2 \end{aligned}$$

Funktio  $m_Y(t)$  on *normaalijakauman*

$$N(\mu, \sigma^2)$$

*momenttiemäfunktio*. Lisäksi funktio  $m_Y(t)$  on selvästi jatkuva pisteen

$$t = 0$$

ympäristössä. Koska momenttiemäfunktio  $m_Y(t)$  on tällöin *yksikäsitteinen*, summamuuttuja  $Y$  noudattaa *normaalijakaumaa* parametrein

$$\mu = \mu_1 + \mu_2 + \dots + \mu_n$$

ja

$$\sigma^2 = \sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2$$

eli

$$Y = X_1 + X_2 + \dots + X_n \sim N(\mu, \sigma^2)$$

■

### Normaalijakaumaa noudattavien satunnaismuuttujien lineaarikombinaation jakauma

Yhdistämällä riippumattomien normaalijakaumaa noudattavien satunnaismuuttujien summan jakaumaa koskeva tulos ja normaalijakauman lineaarimuunnoksen jakaumaa koskeva tulos saadaan seuraava, *riippumattomien normaalijakautuneiden satunnaismuuttujien lineaarikombinaation jakaumaa* koskeva tulos:

Olkoot

$$X_1, X_2, \dots, X_n$$

*riippumattomia* satunnaismuuttujia, jotka noudattavat *normaalijakaumaa* parametrein  $(\mu_1, \sigma_1^2), (\mu_2, \sigma_2^2), \dots, (\mu_n, \sigma_n^2)$ :

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim N(\mu_i, \sigma_i^2), i = 1, 2, \dots, n$$

Olkoot lisäksi

$$a_1, a_2, \dots, a_n$$

ei satunnaisia *vakioita*. Tällöin satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *lineaarikombinaatio*

$$Y = a_1 X_1 + a_2 X_2 + \dots + a_n X_n$$

noudattaa *normaalijakaumaa* parametrein

$$\mu = a_1 \mu_1 + a_2 \mu_2 + \dots + a_n \mu_n$$

ja

$$\sigma^2 = a_1^2 \sigma_1^2 + a_2^2 \sigma_2^2 + \dots + a_n^2 \sigma_n^2$$

eli

$$Y \sim N(\mu, \sigma^2)$$

### Samaa normaalijakaumaa noudattavien satunnaismuuttujien summan jakauma

Riippumattomien normaalijakaumaa noudattavien satunnaismuuttujien summan jakaumaa koskevan tuloksen seurauksena saadaan *riippumattomien, samaa normaalijakaumaa noudattavien satunnaismuuttujien summan jakaumaa* koskeva tulos:

Olkoot

$$X_1, X_2, \dots, X_n$$

*riippumattomia* satunnaismuuttujia, jotka noudattavat *samaa normaalijakaumaa* parametrein  $\mu$  ja  $\sigma^2$ :

$$\begin{aligned} X_1, X_2, \dots, X_n &\perp \\ X_i &\sim N(\mu, \sigma^2), i = 1, 2, \dots, n \end{aligned}$$

Tällöin satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *summa*

$$Y = X_1 + X_2 + \dots + X_n$$

noudattaa *normaalijakaumaa* parametrein  $n\mu$  ja  $n\sigma^2$ :

$$Y \sim N(n\mu, n\sigma^2)$$

### Normaalijakaumaa noudattavien satunnaismuuttujien aritmeettisen keskiarvon jakauma

Olkoot

$$X_1, X_2, \dots, X_n$$

*riippumattomia* satunnaismuuttujia, jotka noudattavat *samaa normaalijakaumaa* parametrein  $\mu$  ja  $\sigma^2$ :

$$\begin{aligned} X_1, X_2, \dots, X_n &\perp \\ X_i &\sim N(\mu, \sigma^2), i = 1, 2, \dots, n \end{aligned}$$

Olkoon

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

satunnaismuuttujien  $X_1, X_2, \dots, X_n$  *aritmeettinen keskiarvo*. Tällöin *riippumattomien, samaa normaalijakaumaa noudattavien satunnaismuuttujien summan jakaumaa ja normaalijakautuneen satunnaismuuttujan lineaarimuunnoksen jakaumaa* koskevista tuloksista seuraa, että

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

#### 17.4. Keskeinen raja-arvolause

Se, että **normaalijakauma** (ks. kappaletta **Normaalijakauma**) on sekä *teoreettisen että soveltavan tilastotieteen tärkein jakauma* perustuu hyvin pitkälti siihen *teoreettiseen ja empiiriseen* havaintoon, että moniin satunnaisilmiöihin liittyvät satunnaismuuttujat noudattavat ainakin *approksimatiivisesti* normaalijakaumaa.

Mikä on selitys tälle havainnolle? Selityksenä on **keskeinen raja-arvolause**.

Tarkastellaan jonoa

$$X_i, i = 1, 2, \dots, n$$

riippumattomia ja samaa normaalijakaumaa noudattavia satunnaismuuttujia:

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim N(\mu, \sigma^2), i = 1, 2, \dots, n$$

Edellä esitettyjen tulosten mukaan satunnaismuuttujien  $X_i, i = 1, 2, \dots, n$  summa

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

noudattaa normaalijakaumaa:

$$Y_n \sim N(n\mu, n\sigma^2)$$

**Kysymys:** Mitä voidaan sanoa riippumattomien, samaa jakaumaa noudattavien satunnaismuuttujien summan jakaumasta, jos ko. satunnaismuuttujat eivät noudata normaalijakaumaa?

**Vastaus:** Ei-normaalisten satunnaismuuttujien summa ei yleensä ole normaalin.

**Mutta:** Jos yhteenlaskettavia on ”tarpeeksi paljon”, satunnaismuuttujien summa on (hyvin yleisin ehdoin) **aproksimatiivisesti normaalin**. Tämä on **keskeisen raja-arvolauseen** olennainen sisältö.

Koska monia satunnaismuuttujia voidaan pitää usean riippumattoman tekijän summana, antaa keskeinen raja-arvolause selityksen *empiiriselle havainnolle* niiden normaalisuudesta.

Olkoon siis

$$X_i, i = 1, 2, \dots, n$$

jono riippumattomia ja samoin jakautuneita satunnaismuuttujia, joiden odotusarvo ja varianssi ovat

$$E(X_i) = \mu, i = 1, 2, \dots, n$$

$$\text{Var}(X_i) = D^2(X_i) = \sigma^2, i = 1, 2, \dots, n$$

Olkoon

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

satunnaismuuttujien  $X_i, i = 1, 2, \dots, n$  summa. Tällöin

$$E(Y_n) = n\mu$$

$$\text{Var}(Y_n) = D^2(Y_n) = n\sigma^2$$

Standardoidaan satunnaismuuttuja  $Y_n$ :

$$Z_n = \frac{Y_n - E(Y_n)}{D(Y_n)} = \frac{Y_n - n\mu}{\sigma\sqrt{n}}$$

Annetaan

$$n \rightarrow +\infty$$

**Keskeisen raja-arvolauseen** mukaan *satunnaismuuttujan*  $Z_n$  *jakauma lähestyy tällöin rajatta standardoitua normaalijakaumaa*  $N(0,1)$ :

$$\lim_{n \rightarrow +\infty} \Pr \left( \frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \leq z \right) = \Phi(z)$$

jossa  $\Phi(z)$  on *standardoidun normaalijakauman*  $N(0,1)$  *kertymäfunktio*.

Merkintä:

$$Z_n \underset{a}{\sim} N(0,1)$$

jossa

$$a = \text{asymptoottisesti (tai approksimatiivisesti suurille } n)$$

**Perustelu:**

Ks. luvun **Stokastiikan konvergenssikäsitteet ja raja-arvolauseet** kappaletta **Keskeinen raja-arvolause**.

Keskeisen raja-arvolauseen mukaan *usean satunnaismuuttujan summa on* (tietyin ehdoin) *approksimatiivisesti normaalin* (lähes) *riippumatta yhteenlaskettavien jakaumasta*.

**Huomautus:**

- Yhteenlaskettavien ei tarvitse olla edes *jatkuvia*, vaan ne voivat olla jopa *diskreettejä*.

Approksimaation *hyvyys* riippuu yhteenlaskettavien satunnaismuuttujien lukumäärästä ja niiden jakaumasta. Approksimaation *hyvyys paranee, kun yhteenlaskettavien satunnaismuuttujien lukumäärän annetaan kasvaa*.

Jos yhteenlaskettavien satunnaismuuttujien jakauma on *symmetrinen*, approksimaatio on hyvä jo suhteellisen pienillä yhteenlaskettavien lukumäärillä. Sen sijaan, jos yhteenlaskettavien satunnaismuuttujien jakauma on *epäsymmetrinen*, hyvä approksimaatio vaatii enemmän yhteenlaskettavia.

Keskeisen raja-arvolauseen tulos esitetään usein seuraavassa muodossa: Riippumattomien samaa jakaumaa noudattavien satunnaismuuttujien  $X_i, i = 1, 2, \dots, n$  **aritmeettinen keskiarvo**

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

on suurille  $n$  *approksimatiivisesti normaalin parametrein*  $\mu$  ja  $\sigma^2/n$ :

$$\bar{X}_n \underset{a}{\sim} N\left(\mu, \frac{\sigma^2}{n}\right)$$

Keskeinen raja-arvolause koskee satunnaismuuttujien **asymptoottista käyttäytymistä** samaan tapaan kuin luvussa **Jakaumien tunnusluvut** esitetty **suurten lukujen laki**. Keskeisessä raja-arvolauseessa esiintyvä *rajakäyttäytymisen muoto* on esimerkki ns. **jakaumakonvergenssista** eli **heikosta konvergenssista**; lisätietoja: ks. lukua **Stokastiikan konvergenssikäsitteet ja raja-arvolauseet**.

Keskeisestä raja-arvolauseesta on olemassa *yleisempiä muotoja*, joissa voidaan lieventää *samoinjakautuneisuus-* ja *riippumattomuusoletuksia*. Tällä on suuri merkitys esimerkiksi **stokastisten prosessien ja aikasarja-analyysin** teoriassa.

### Binomijakauman approksimointi normaalijakaumalla: De Moivre'n ja Laplace'n raja-arvolause

Oletetaan, että satunnaismuuttuja  $X$  noudattaa **binomijakaumaa** parametrein  $n$  ja  $p$ :

$$X \sim \text{Bin}(n, p)$$

Tällöin

$$E(X) = np$$

$$\text{Var}(X) = npq$$

jossa

$$q = 1 - p$$

Lisätietoja binomijakaumasta: ks. lukua **Diskreettejä jakaumia**.

Koska jokainen binomijakautunut satunnaismuuttuja voidaan esittää *riippumattomien ja samaa Bernoulli-jakaumaa* Bernoulli( $p$ ) noudattavien satunnaismuuttujien summana (lisätietoja: ks. lukua **Diskreettejä jakaumia**), niin *keskeisestä raja-arvolauseesta* seuraa, että

$$\lim_{n \rightarrow +\infty} \Pr\left(\frac{X - np}{\sqrt{npq}} \leq z\right) = \Phi(z)$$

jossa  $\Phi$  on *standardoidun normaalijakauman*  $N(0, 1)$  kertymäfunktio.

#### Perustelu:

Olkoon

$$X \sim \text{Bin}(n, p)$$

Tällöin satunnaismuuttuja  $X$  voidaan esittää *riippumattomien ja samaa Bernoulli-jakaumaa* Bernoulli( $p$ ) noudattavien satunnaismuuttujien summana:

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

jossa

$$X_i \sim \text{Bernoulli}(p), i = 1, 2, \dots, n$$

Koska

$$E(X_i) = p, i = 1, 2, \dots, n$$

$$\text{Var}(X_i) = pq, q = 1 - p, i = 1, 2, \dots, n$$

niin

$$E(X) = \sum_{i=1}^n E(X_i) = np$$

$$\text{Var}(X) = \sum_{i=1}^n \text{Var}(X_i) = npq$$

Siten keskeisestä raja-arvolauseesta seuraa, että

$$\lim_{n \rightarrow +\infty} \Pr \left( \frac{X - np}{\sqrt{npq}} \leq z \right) = \Phi(z)$$

■

Tätä keskeisen raja-arvolauseen erikoistapausta kutsutaan tavallisesti **De Moivren ja Laplacen raja-arvolauseeksi**.

Binomijakauman approksimointi normaalijakaumalla onnistuu kohtuullisen hyvin jo melko pienille toistokokeiden lukumäärille  $n$ , jos  $p \approx 1/2$ . Sen sijaan, jos  $p \approx 0$  tai  $p \approx 1$ , vaatii hyvä approksimaatio selvästi suuremman toistokokeiden lukumäärän  $n$ .

### De Moivren ja Laplacen raja-arvolauseen havainnollistus

Alla esitetty neljän kuvan sarja näyttää miten satunnaismuuttujien

$$\begin{aligned} X & \text{ Bin}(n, p) \\ Z & \text{ N}(np, npq), q = 1 - p \end{aligned}$$

jakaumat alkavat muistuttaa yhä enemmän toisiaan, kun toistokokeiden lukumäärän  $n$  annetaan kasvaa.

Kuvasarjan kaikissa kuvissa

$$p = 0.1$$

mutta  $n$  vaihtelee saaden arvot

$$n = 1, 10, 30, 100$$

Kuviin piirretyn normaalijakauman  $N(\mu, \sigma^2)$  odotusarvo ja varianssi on asetettu samoiksi kuin binomijakauman  $\text{Bin}(n, p)$  odotusarvo ja varianssi, ts.

$$\begin{aligned} \mu & = np \\ \sigma^2 & = npq, q = 1 - p \end{aligned}$$

#### Kuva 1:


Olkoon  $X \text{ Bin}(n, p)$ , jossa

$$\begin{aligned} n & = 1 \\ p & = 0.1 \end{aligned}$$

ja olkoon  $Z \text{ N}(\mu, \sigma^2)$ , jossa

$$\begin{aligned} \mu & = np = 0.1 \\ \sigma^2 & = np(1 - p) = 0.09 \end{aligned}$$

Kuva 1 esittää satunnaismuuttujan  $X$  pistetodennäköisyysfunktiota ja satunnaismuuttujan  $Z$  tiheysfunktiota välillä  $[-3, 12]$ .



**Kuva 2:**

Olkoon  $X \sim \text{Bin}(n, p)$ , jossa

$$n = 10$$


$$p = 0.1$$

ja olkoon  $Z \sim N(\mu, \sigma^2)$ , jossa

$$\mu = np = 1$$

$$\sigma^2 = np(1-p) = 0.9$$

Kuva 2 esittää satunnaismuuttujan  $X$  pistetodennäköisyysfunktiota ja satunnaismuuttujan  $Z$  tiheysfunktiota välillä  $[-3, 12]$ .



**Kuva 3:**

Olkoon  $X \sim \text{Bin}(n, p)$ , jossa

$$n = 30$$


$$p = 0.1$$

ja olkoon  $Z \sim N(\mu, \sigma^2)$ , jossa

$$\mu = np = 3$$

$$\sigma^2 = np(1-p) = 2.7$$

Kuva 3 esittää satunnaismuuttujan  $X$  pistetodennäköisyysfunktiota ja satunnaismuuttujan  $Z$  tiheysfunktiota välillä  $[-3, 12]$ .



**Kuva 4:**

Olkoon  $X \sim \text{Bin}(n, p)$ , jossa

$$n = 100$$


$$p = 0.1$$

ja olkoon  $Z \sim N(\mu, \sigma^2)$ , jossa

$$\mu = np = 10$$

$$\sigma^2 = np(1-p) = 9$$

Kuva 4 esittää satunnaismuuttujan  $X$  pistetodennäköisyysfunktiota ja satunnaismuuttujan  $Z$  tiheysfunktiota välillä  $[0, 20]$ .



Huomaa, että kuvan 4 koordinaattiakseleilla on eri skaala kuin kuvien 1, 2 ja 3 koordinaattiakseleilla.



## Binomitodennäköisyyksien approksimointi normaalijakauman avulla

De Moivre'n ja Laplace'n raja-arvolauseen mukaan *binomijakaumaa*

$$\text{Bin}(n, p)$$

voidaan suurille  $n$  approksimoida normaalijakaumalla

$$N(\mu, \sigma^2)$$

jossa

$$\mu = np$$

$$\sigma^2 = npq, q = 1 - p$$

Jos siis

$$X \sim \text{Bin}(n, p)$$

niin De Moivre'n ja Laplace'n raja-arvolauseen mukaan suurille  $n$

$$\Pr(a < X \leq b) \approx \Phi\left(\frac{b - np}{\sqrt{npq}}\right) - \Phi\left(\frac{a - np}{\sqrt{npq}}\right)$$

jossa  $\Phi$  on standardoidun normaalijakauman  $N(0,1)$  kertymäfunktio.

Jos  $a$  ja  $b$  ovat kokonaislukuja, approksimaatio on hieman parempi, jos käytetään kaavaa

$$\Pr(a < X \leq b) \approx \Phi\left(\frac{b + 1/2 - np}{\sqrt{npq}}\right) - \Phi\left(\frac{a - 1/2 - np}{\sqrt{npq}}\right)$$

Korjaustekijä  $1/2$  perustuu siihen, että diskreettiä binomijakaumaa approksimoidaan jatkuvalla normaalijakaumalla; ks. seuraavaa esimerkkiä.

Jos annetaan  $a \rightarrow -\infty$ , saadaan approksimaatiotulos

$$\Pr(X \leq b) = F_X(b) \approx \Phi\left(\frac{b + 1/2 - np}{\sqrt{npq}}\right)$$

jossa  $F_X(\cdot)$  on binomijakauman kertymäfunktio.

Jos  $a = b$ , saadaan approksimaatiotulos

$$\Pr(X = a) = f_X(a) \approx \Phi\left(\frac{a + 1/2 - np}{\sqrt{npq}}\right) - \Phi\left(\frac{a - 1/2 - np}{\sqrt{npq}}\right)$$

jossa  $f_X(\cdot)$  on binomijakauman pistetodennäköisyysfunktio.

### Esimerkki 2. Binomitodennäköisyyksien approksimointi normaalijakauman avulla.

Kuva alla esittää jakauman

$$\text{Bin}(100, 0.1)$$

pistetodennäköisyysfunktioita ja jakauman

$$N(10, 9)$$

tiheysfunktioita välillä [6, 12].

De Moivre'n ja Laplace'n raja-arvolauseen mukaan binomitodennäköisyyttä pisteessä

$$x = 8$$

voidaan *aprosimoida* varjostetun alueen pinta-alalla.

Olkoon siis  $X \sim \text{Bin}(n, p)$ , jossa

$$n = 100$$

$$p = 0.1$$

Tällöin

$$f_X(8) = 0.1148$$

jossa

$$f_X(x) = \binom{n}{p} p^x (1-p)^{n-x}$$

on binomijakauman  $\text{Bin}(100, 0.1)$  *piste-*  
*todennäköisyysfunktio*.

Asetetaan

$$\mu = np = 10$$


$$\sigma^2 = np(1-p) = 9$$

Tällöin

$$\begin{aligned} & \Phi\left(\frac{8+1/2-\mu}{\sigma}\right) - \Phi\left(\frac{8-1/2-\mu}{\sigma}\right) \\ &= \Phi(-0.5) - \Phi(-0.8333) \\ &= 0.3085 - 0.2033 \\ &= 0.1052 \end{aligned}$$

jossa  $\Phi$  on standardoidun normaalijakauman  $N(0,1)$  *kertymäfunktio*.

Todennäköisyydet ovat kahden desimaalin tarkkuudella samat!



## Hypergeometrisen jakauman aproksimointi normaalijakauman avulla

### Hypergeometrisen jakauma

$$\text{HyperGeom}(N, r, n)$$

lähestyy perusjoukon koon  $N$  kasvaessa rajatta *binomijakaumaa*

$$\text{Bin}(n, p)$$

jos samanaikaisesti myös  $r$  kasvaa rajatta ja

$$r/N = p$$

Lisätietoja binomijakaumasta ja hypergeometrisestä jakaumasta: ks. lukua **Diskreettejä jakaumia**.

Siten *De Moivre'n ja Laplacen raja-arvolauseesta* seuraa, että *hypergeometrinen jakauma*

$$\text{HyperGeom}(N, r, n)$$

voidaan suurille  $N$  approksimoida normaalijakaumalla

$$N(\mu, \sigma^2)$$

jossa

$$\mu = n \frac{r}{N}$$

$$\sigma^2 = n \frac{r}{N} \left( 1 - \frac{r}{N} \right)$$

### Poisson-jakauman approksimointi normaalijakaumalla

Oletetaan, että satunnaismuuttuja  $X$  noudattaa **Poisson-jakaumaa** parametrilla  $\lambda$ :

$$X \sim \text{Poisson}(\lambda)$$

Tällöin

$$E(X) = \lambda$$

$$\text{Var}(X) = \lambda$$

Parametri  $\lambda$  kuvaa tarkastelun kohteena olevan tapahtuman *tapahtumaintensiteettiä* eli tarkastelun kohteena olevan tapahtuman esiintymisten keskimääräistä lukumäärää aikayksikköä kohden; lisätietoja Poisson-jakaumasta: ks. lukua **Diskreettejä jakaumia**.

Poisson-jakaumaa koskevassa kappaleessa (ks. lukua **Diskreettejä jakaumia**) todetaan, että Poisson-jakauma saadaan raja-prosessin kautta binomijakaumasta. Koska *De Moivre'n ja Laplacen raja-arvolauseen* mukaan binomijakaumaa voidaan approksimoida normaalijakaumalla, on perusteltua olettaa, että myös Poisson-jakaumaa voidaan approksimoida normaalijakaumalla.

On helppoa todistaa momenttiemäfunktioita hyväksi käyttäen (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**), että

$$\lim_{\lambda \rightarrow +\infty} \Pr \left( \frac{X - \lambda}{\sqrt{\lambda}} \leq z \right) = \Phi(z)$$

jossa  $\Phi$  on *standardoidun normaalijakauman*  $N(0,1)$  *kertymäfunktio*.

#### Perustelu:

Olkoon

$$X \sim \text{Poisson}(\lambda)$$

Satunnaismuuttujan  $X$  *momenttiemäfunktio* on

$$m_X(t) = E(e^{tX}) = \exp[\lambda(e^t - 1)]$$

Tarkastellaan *standardoitua muuttujaa*

$$Z = \frac{X - \lambda}{\sqrt{\lambda}}$$

Satunnaismuuttujan *lineaarimuunnoksen* momenttiemäfunktiota koskevan tuloksen perusteella satunnaismuuttujan  $Z$  momenttiemäfunktio on

$$m_Z(t) = E(e^{tZ}) = \exp[-\sqrt{\lambda}t] \exp[\lambda(e^{t/\sqrt{\lambda}} - 1)] = \exp[\lambda e^{t/\sqrt{\lambda}} - \lambda - \sqrt{\lambda}t]$$

Kehittämällä funktio

$$e^{t/\sqrt{\lambda}}$$

Taylorin sarjaksi saadaan lauseke

$$\begin{aligned} m_Z(t) &= \exp[\lambda e^{t/\sqrt{\lambda}} - \lambda - \sqrt{\lambda}t] \\ &= \exp\left[\lambda\left(1 + \frac{t}{\lambda^{1/2}} + \frac{t^2}{2\lambda} + \frac{t^3}{3!\lambda^{3/2}} + L\right) - \lambda - \sqrt{\lambda}t\right] \\ &= \exp\left[\lambda + \lambda^{1/2}t + \frac{t^2}{2} + \frac{t^3}{3!\lambda^{1/2}} + L - \lambda - \sqrt{\lambda}t\right] \\ &= \exp\left[\frac{t^2}{2} + \frac{t^3}{3!\lambda^{1/2}} + L\right] \end{aligned}$$

Jos

$$\lambda \rightarrow \infty$$

niin

$$\exp\left[\frac{t^2}{2} + \frac{t^3}{3!\lambda^{1/2}} + L\right] \rightarrow \exp\left[\frac{t^2}{2}\right]$$

joka on *standardoidun normaalijakauman*  $N(0,1)$  momenttiemäfunktio.

Siten satunnaismuuttujan

$$Z = \frac{X - \lambda}{\sqrt{\lambda}}$$

jakauma konvergoi standardoitua normaalijakauma kohti, kun  $\lambda \rightarrow \infty$ .

■

### Poisson-todennäköisyyksien approksimointi normaalijakauman avulla

Edellä esitetyn mukaan *Poisson-jakaumaa*

$$\text{Poisson}(\lambda)$$

voidaan approksimoida normaalijakaumalla

$$N(\mu, \sigma^2)$$

jossa

$$\mu = \lambda$$

$$\sigma^2 = \lambda$$

Jos siis

$$X \sim \text{Poisson}(\lambda)$$

niin

$$\Pr(a < X \leq b) \approx \Phi\left(\frac{b-\lambda}{\sqrt{\lambda}}\right) - \Phi\left(\frac{a-\lambda}{\sqrt{\lambda}}\right)$$

jossa  $\Phi$  on standardoidun normaalijakauman  $N(0,1)$  kertymäfunktio.

Jos  $a$  ja  $b$  ovat kokonaislukuja, approksimaatio on hieman parempi, jos käytetään kaavaa

$$\Pr(a < X \leq b) \approx \Phi\left(\frac{b+1/2-\lambda}{\sqrt{\lambda}}\right) - \Phi\left(\frac{a-1/2-\lambda}{\sqrt{\lambda}}\right)$$

Korjaustekijä  $1/2$  perustuu siihen, että diskreettiä Poisson-jakaumaa approksimoidaan jatkuvalla normaalijakaumalla.

Jos annetaan  $a \rightarrow -\infty$ , saadaan approksimaatitulos

$$\Pr(X \leq b) = F_X(b) \approx \Phi\left(\frac{b+1/2-\lambda}{\sqrt{\lambda}}\right)$$

jossa  $F_X(\cdot)$  on Poisson-jakauman kertymäfunktio.

Jos  $a = b$ , saadaan approksimaatitulos

$$\Pr(X = a) = f_X(a) \approx \Phi\left(\frac{a+1/2-\lambda}{\sqrt{\lambda}}\right) - \Phi\left(\frac{a-1/2-\lambda}{\sqrt{\lambda}}\right)$$

jossa  $f_X(\cdot)$  on Poisson-jakauman pistetodennäköisyysfunktio.

### 17.5. Log-normaalijakauma

Log-normaalijakaumaa voidaan käyttää mallintamaan sellaisten satunnaismuuttujien jakaumia, jotka eivät voi saada negatiivisia arvoja, mutta voivat saada miten suuria arvoja tahansa. Tyypillinen esimerkki tällaisesta jakaumasta on tulojakauma.

Olkoon jatkuvan satunnaismuuttujan  $X$  tiheysfunktio

$$f(x) = \frac{1}{\sqrt{2\pi\sigma}} \cdot \frac{1}{x} \exp\left\{-\frac{1}{2}\left(\frac{\log x - \mu}{\sigma}\right)^2\right\}, -\infty < \mu < +\infty, \sigma > 0, 0 < x < +\infty$$

Tällöin satunnaismuuttuja  $X$  noudattaa **log-normaalijakaumaa** parametrein  $\mu$  ja  $\sigma^2$  ja merkitsemme:

$$X \sim \text{LogN}(\mu, \sigma^2)$$

#### Log-normaalijakauman johto

Olkoon

$$Y = \log X \sim N(\mu, \sigma^2)$$

Tällöin

$$X = \exp(Y) \quad \text{LogN}(\mu, \sigma^2)$$

**Perustelu:**

Olkoon

$$Y \sim \text{N}(\mu, \sigma^2)$$

Tällöin satunnaismuuttujan  $Y$  tiheysfunktio on

$$f_Y(y) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2}\left(\frac{y-\mu}{\sigma}\right)^2\right\}, \quad -\infty < \mu < +\infty, \sigma > 0, -\infty < y < +\infty$$

Tehdään muuttujan vaihto

$$X = \exp(Y)$$

Funktio

$$x = h(y) = \exp(y)$$

on *aidosti kasvava ja derivoituva* ja sen käänteismuunnoksen

$$y = h^{-1}(x) = \log(x)$$

derivaatta on

$$\frac{dh^{-1}(x)}{dx} = \frac{d \log(x)}{dx} = \frac{1}{x}$$

Siten (ks. luvun **Satunnaismuuttujien muunnosten jakaumat** kappaletta **Satunnaismuuttujan monotonisen muunnoksen jakauma**)

$$f_X(x) = f_Y(h^{-1}(x)) \left| \frac{dh^{-1}(x)}{dx} \right| = \frac{1}{\sqrt{2\pi}\sigma} \cdot \frac{1}{x} \exp\left\{-\frac{1}{2}\left(\frac{\log(x)-\mu}{\sigma}\right)^2\right\}$$

■

Log-normaalijakauman johdossa käytetystä menetelmästä seuraa automaattisesti, että funktio  $f_X(x)$  on tiheysfunktio.

### Log-normaalijakauman tunnusluvut

Olkoon

$$X \sim \text{LogN}(\mu, \sigma^2)$$

**Odotusarvo:**

$$E(X) = e^{\mu + \sigma^2/2}$$

**Varianssi:**

$$D^2(X) = \text{Var}(X) = e^{2(\mu + \sigma^2)} - e^{2(\mu + \sigma^2/2)}$$

**Standardipoikkeama:**

$$D(X) = \sqrt{e^{\mu+\sigma^2} - e^{\mu+\sigma^2/2}}$$

**Perustelu:**

Johdamme tässä log-normaalijakauman odotusarvon.

Käytetään hyväksi sitä, että jos

$$Y = \log X \quad N(\mu, \sigma^2)$$

niin

$$X = e^Y \quad \text{LogN}(\mu, \sigma^2)$$

Koska

$$Y \sim N(\mu, \sigma^2)$$

niin satunnaismuuttujan  $Y$  momenttiemäfunktio on

$$m_Y(t) = E(e^{tY}) = \exp(\mu t + \frac{1}{2} \sigma^2 t^2)$$

Tällöin

$$E(X) = E(e^{\log(X)}) = E(e^Y) = m_Y(1) = \exp(\mu + \sigma^2 / 2)$$

■

**Log-normaalijakauman tiheysfunktio**

Kuva oikealla esittää log-normaalijakauman

$$\text{LogN}(\mu, \sigma^2)$$

tiheysfunktioita

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \cdot \frac{1}{x} \cdot \exp\left\{-\frac{1}{2}Q(x)\right\}$$

$$-\infty < \mu < +\infty, \sigma > 0$$


$$0 < x < +\infty$$

jossa

$$Q(x) = \left(\frac{\log x - \mu}{\sigma}\right)^2$$

välillä  $[0, 4]$  seuraavissa tapauksissa:

- (i)  $\mu = -0.25, \sigma^2 = 1.5^2$
- (ii)  $\mu = 0, \sigma^2 = 1^2$
- (iii)  $\mu = +1, \sigma^2 = 0.5^2$



Log-normaalijakauman *odotusarvo*:

$$E(X) = e^{\mu + \sigma^2/2}$$

**Log-normaalijakauman tiheysfunktion ominaisuudet**

(i) Log-normaalijakauman tiheysfunktio  $f(x)$  on *positiivinen* kaikille positiivisille argumentin  $x$  arvoille:

$$f(x) > 0, x > 0$$

(ii) Tiheysfunktio on *yksihuippuinen* ja sillä on *maksimi* pisteessä  $x = e^{\mu - \sigma^2}$ .

(iii) Tiheysfunktio on *vino oikealle*.

**Log-normaalijakauman kertymäfunktio**

Log-normaalijakauma kuuluu niiden jakaumien joukkoon, joiden kertymäfunktioille ei voida antaa eksplisiittistä lauseketta, koska *log-normaalijakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktiota ei voida esittää suljetussa muodossa* (so. alkeisfunktioiden avulla).

**17.6. Cauchy-jakauma**

Cauchy-jakauma on esimerkki jakaumasta, *jolla ei ole momentteja*.

Olkoon *jatkuvan satunnaismuuttujan X tiheysfunktio*

$$f(x) = \frac{1}{\pi} \cdot \frac{1}{1 + (x - \theta)^2}, -\infty < \theta < +\infty, -\infty < x < +\infty$$

Tällöin satunnaismuuttuja  $X$  noudattaa **Cauchy-jakaumaa** parametrilla  $\theta$  ja merkitsemme:

$$X \sim \text{Cauchy}(\theta)$$

Funktio  $f(x)$  kelpaa tiheysfunktiksi, koska

$$f(x) > 0, -\infty < x < +\infty$$

ja

$$\int_{-\infty}^{+\infty} f(x) dx = \int_{-\infty}^{+\infty} \frac{1}{\pi} \cdot \frac{1}{1 + (x - \theta)^2} dx = \frac{1}{\pi} [\arctan(x - \theta)]_{-\infty}^{+\infty} = \frac{1}{\pi} \cdot \pi = 1$$

**Cauchy-jakauman johto**

Olkoon

$$Y \sim \text{Uniform}(-\pi/2, \pi/2)$$

Tällöin

$$X = \tan(Y) \sim \text{Cauchy}(0)$$

Perustelu: ks. luvun **Satunnaismuuttujien muunnosten jakaumat** kappaletta **Satunnaismuuttujan monotonisen muunnoksen jakauma**.



Yleinen Cauchy-jakauma parametrilla  $\theta$  saadaan *siirrolla* Cauchy-jakaumasta, jonka parametrina on 0.

### Cauchy-jakauman tunnusluvut

Olkoon

$$X \sim \text{Cauchy}(\theta)$$

**Cauchy-jakaumalla ei ole momenteja.**

**Perustelu:**

Olkoon

$$X \sim \text{Cauchy}(\theta)$$

Näytetään, että

$$E(|X|) = \infty$$

jolloin *satunnaismuuttujalla X ei ole odotusarvoa*, mistä seuraa, että *satunnaismuuttujalla X ei ole myöskään korkeampia momenteja*.

Voimme yleisyyden kärsimättä olettaa, että  $\theta = 0$ . Kirjoitetaan

$$E(|X|) = \int_{-\infty}^{+\infty} |x| f(x) dx = \int_{-\infty}^{+\infty} \frac{|x|}{\pi} \cdot \frac{1}{1+x^2} dx = \frac{2}{\pi} \int_0^{+\infty} \frac{x}{1+x^2} dx$$

Olkoon  $M$  mielivaltainen *positiivinen* luku. Tällöin voimme kirjoittaa

$$\int_0^M \frac{x}{1+x^2} dx = \left[ \frac{1}{2} \log(1+x^2) \right]_0^M = \frac{1}{2} \log(1+M^2)$$

js siten

$$E(|X|) = \lim_{M \rightarrow \infty} \frac{2}{\pi} \int_0^M \frac{x}{1+x^2} dx = \frac{1}{\pi} \lim_{M \rightarrow \infty} \log(1+M^2) = \infty$$

■

On helppo nähdä, että parametri  $\theta$  on Cauchy-jakauman **mediaani** ja **moodi**.

### Cauchy-jakauman tiheysfunktio

Kuva oikealla esittää Cauchy-jakauman

$$\text{Cauchy}(\theta)$$


*tiheysfunktioita*

$$f(x) = \frac{1}{\pi} \cdot \frac{1}{1+(x-\theta)^2}$$

$$-\infty < \theta < +\infty, -\infty < x < +\infty$$

välillä  $[-4,+4]$ , kun

$$\theta = 0$$



Kuten edellä todettiin, Cauchy-jakaumalla *ei ole momentteja*, mutta parametri  $\theta$  on siis jakauman *mediaani* ja *moodi*.

### Cauchy-jakauman tiheysfunktion ominaisuudet

(i) Cauchy-jakauman tiheysfunktio  $f(x)$  on kaikkialla *positiivinen*:

$$f(x) > 0, -\infty < x < +\infty$$

(ii) Tiheysfunktio on *yksihuippuinen* ja sillä on *maksimi* pisteessä  $x = \theta$ .

(iii) Tiheysfunktio on *symmetrinen* pisteen  $x = \theta$  suhteen.

### Cauchy-jakauma ja t-jakauma

Voidaan osoittaa, että ns. **t-jakauma yhdellä vapausasteella** on sama kuin Cauchy-jakauma; lisätietoja t-jakaumasta: ks. lukua **Normaalijakaumasta johdettuja jakaumia**.

### 17.7. Gamma-jakauma

Gamma-jakauma on joustava jakauma, jolla voidaan mallintaa monia erilaisia satunnaisilmiöitä. Sitä käytetään mm. *elinajan* mallintamiseen kuten erikoistapaustaan *eksponenttijakaumaa*.

Olkoon *jatkuvan satunnaismuuttujan X tiheysfunktio*

$$f(x) = \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-x/\beta}, \alpha > 0, \beta > 0, x \geq 0$$

jossa

$$\Gamma(\alpha) = \int_0^\infty t^{\alpha-1} e^{-t} dt$$

on ns. *gamma-funktio*. Tällöin satunnaismuuttuja  $X$  noudattaa **gamma-jakaumaa** parametrein  $\alpha$  ja  $\beta$  ja merkitsemme:

$$X \sim \text{Gamma}(\alpha, \beta)$$

Funktio  $f(x)$  kelpaa tiheysfunktiksi, koska

$$f(x) > 0, x \geq 0$$

ja gamma-funktion määritelmän perusteella

$$\int_{-\infty}^{+\infty} f(x) dx = \int_0^{+\infty} \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-x/\beta} dx = \frac{1}{\Gamma(\alpha)} \int_0^{+\infty} t^{\alpha-1} e^{-t} dt = \frac{1}{\Gamma(\alpha)} \cdot \Gamma(\alpha) = 1$$

### Gamma-funktio

**Gamma-funktio** määritellään kaavalla

$$\Gamma(\alpha) = \int_0^\infty t^{\alpha-1} e^{-t} dt$$

Voidaan osoittaa, että gamma-funktiolla on seuraavat ominaisuudet:

(i)  $\Gamma(\alpha + 1) = \alpha\Gamma(\alpha)$

(ii)  $\Gamma(n) = (n-1)!, n \in \mathbb{N}$

(iii)  $\Gamma(\frac{1}{2}) = \sqrt{\pi}$

**Perustelu:**

(i) Saamme osittaisintegroinnilla rekursiokaavan

$$\Gamma(\alpha + 1) = \int_0^{\infty} t^{\alpha} e^{-t} dt = \left[ -t^{\alpha} e^{-t} \right]_0^{\infty} + \alpha \int_0^{\infty} t^{\alpha-1} e^{-t} dt = \alpha \int_0^{\infty} t^{\alpha-1} e^{-t} dt = \alpha \Gamma(\alpha)$$

(ii) Todetaan ensin, että

$$\Gamma(1) = \int_0^{\infty} e^{-t} dt = \left[ -e^{-t} \right]_0^{\infty} = 1$$

Soveltamalla kaavan (i) rekursiota ja sitä, että  $\Gamma(1) = 1$ , saamme

$$\begin{aligned} \Gamma(n) &= (n-1)\Gamma(n-1) \\ &= (n-1)(n-2)\Gamma(n-2) \\ &= (n-1)(n-2)(n-3)\Gamma(n-3) \\ &\quad \vdots \\ &= (n-1)(n-2)(n-3)\dots(n-(n-2))(n-(n-1))\Gamma(n-(n-1)) \\ &= (n-1)(n-2)(n-3)\dots 2 \cdot 1 \cdot \Gamma(1) \\ &= (n-1)! \end{aligned}$$

(iii) Kaava

$$\Gamma(\frac{1}{2}) = \sqrt{\pi}$$

voidaan todistaa vetoamalla kappaleessa **Normaalijakauma** esitettyyn todistukseen sille, että normaalijakauman tiheysfunktio  $f(x)$  toteuttaa ehdon

$$\int_{-\infty}^{+\infty} f(x) dx = 1$$

Tällöin todettiin, että

$$\int_0^{\infty} e^{-z^2/2} dz = \sqrt{\frac{1}{2}\pi}$$

Tehdään tässä integraalissa muuttujan vaihto

$$z = \sqrt{2t}$$

jolloin

$$dz = (2t)^{-1/2} dt$$

Saamme siten yhtälön

$$\int_0^{\infty} 2^{-1/2} t^{-1/2} e^{-t} dt = \sqrt{\frac{1}{2}\pi}$$



Tästä yhtälöstä seuraa välittömästi, että

$$\int_0^{\infty} t^{-1/2} e^{-t} dt = \sqrt{\pi}$$

Koska toisaalta

$$\Gamma\left(\frac{1}{2}\right) = \int_0^{\infty} t^{-1/2} e^{-t} dt$$

saamme lopulta haluamamme yhtälön

$$\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

■

### Gamma-jakauman tunnusluvut

Olkoon

$$X \sim \text{Gamma}(\alpha, \beta)$$

**Odotusarvo:**

$$E(X) = \alpha\beta$$

**Varianssi:**

$$D^2(X) = \text{Var}(X) = \alpha\beta^2$$

**Standardipoikkeama:**

$$D(X) = \beta\sqrt{\alpha}$$

**Perustelu:**

Johdamme tässä gamma-jakauman odotusarvon. Jakauman odotusarvo ja varianssi johdetaan jakauman *momenttiemäfunktion* avulla kohdassa **Gamma-jakauman momenttiemäfunktio ja jakauman tunnusluvut**.

Suoraan jatkuva jakauman odotusarvon määritelmän mukaan

$$E(X) = \int_0^{+\infty} xf(x)dx = \int_0^{+\infty} \frac{1}{\Gamma(\alpha)\beta^\alpha} xx^{\alpha-1} e^{-x/\beta} dx = \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_0^{+\infty} x^\alpha e^{-x/\beta} dx$$

Koska integroitava

$$x^\alpha e^{-x/\beta}$$

on gamma-jakauman  $\text{Gamma}(\alpha + 1, \beta)$  tiheysfunktion *ydin* (funktion ydin on funktion *pääosa* eli se osa funktiosta, joka jää jäljelle, kun integroimiseen vaikuttamattomat vakiot jätetään funktiosta pois), niin

$$\int_0^{+\infty} x^\alpha e^{-x/\beta} dx = \Gamma(\alpha + 1)\beta^{\alpha+1}$$

Siten

$$E(X) = \frac{\Gamma(\alpha + 1)\beta^{\alpha+1}}{\Gamma(\alpha)\beta^\alpha} = \frac{\alpha\Gamma(\alpha)\beta^{\alpha+1}}{\Gamma(\alpha)\beta^\alpha} = \alpha\beta$$

jossa olemme käyttäneet hyväksi sitä gamma-funktion ominaisuutta, että

$$\Gamma(\alpha + 1) = \alpha\Gamma(\alpha)$$

■

### Gamma-jakauman tiheysfunktio

Kuva oikealla esittää gamma-jakauman

$$\text{Gamma}(\alpha, \beta)$$

tiheysfunktioita

$$f(x) = \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-x/\beta}$$


$$\alpha > 0, \beta > 0, x \geq 0$$

välillä [0, 8] seuraavissa tapauksissa:

- (i)  $\alpha = 1, \beta = 1$
- (ii)  $\alpha = 2, \beta = 1$
- (iii)  $\alpha = 2, \beta = 2$

Gamma-jakauman odotusarvo:

$$E(X) = \alpha\beta$$



### Gamma-jakauman tiheysfunktion ominaisuudet

- (i) Gamma-jakauman tiheysfunktio on *positiivinen* kaikille positiivisille argumentin  $x$  arvoille:  
 $f(x) > 0, x > 0$
- (ii) Jos  $\alpha \leq 1$ , niin tiheysfunktio on *monotonisesti laskeva* ja sillä on *maksimi* pisteessä  $x = 0$ .
- (iii) Jos  $\alpha > 1$ , niin tiheysfunktio on *yksihuippuinen* ja sillä on *maksimi* pisteessä  $x = (\alpha - 1)\beta$ .
- (iv) Tiheysfunktio on *vino oikealle*.

### Gamma-jakauman kertymäfunktio

Gamma-jakauma kuuluu niiden jakaumien joukkoon, joiden kertymäfunktiolle ei voida antaa eksplisiittistä lauseketta, koska *gamma-jakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktioita ei voida esittää suljetussa muodossa* (so. alkeisfunktioiden avulla).

### Gamma-jakauman momenttiemäfunktio

Gamma-jakauman

$$f(x) = \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-x/\beta}, \alpha > 0, \beta > 0, x \geq 0$$

**momenttiemäfunktio** (ks. lukua **Momenttiemäfunktio ja karakteristinen funktio**) on

$$m_x(t) = E(e^{tx}) = \left( \frac{1}{1-\beta t} \right)^\alpha, t < \frac{1}{\beta}$$

**Perustelu:**

Jatkuvan jakauman momenttiemäfunktion määritelmän mukaan

$$\begin{aligned} m_x(t) = E(e^{tx}) &= \int_{-\infty}^{+\infty} e^{tx} f(x) dx \\ &= \int_{-\infty}^{+\infty} e^{tx} \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-x/\beta} dx \\ &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_{-\infty}^{+\infty} x^{\alpha-1} e^{-\left(\frac{1}{\beta}-t\right)x} dx \\ &= \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_{-\infty}^{+\infty} x^{\alpha-1} e^{-x\left(\frac{\beta}{1-\beta t}\right)} dx \end{aligned}$$

Koska integroitava

$$x^{\alpha-1} e^{-x\left(\frac{\beta}{1-\beta t}\right)}$$

on gamma-jakauman  $\text{Gamma}(\alpha, \beta/(1-\beta t))$  tiheysfunktion *ydin* (funktion ydin on funktion *pääosa* eli se osa funktiosta, joka jää jäljelle, kun integroimisen kannalta vakiot jätetään funktiosta pois), niin

$$\int_0^{+\infty} x^{\alpha-1} e^{-x\left(\frac{\beta}{1-\beta t}\right)} dx = \Gamma(\alpha) \left( \frac{\beta}{1-\beta t} \right)^\alpha$$

Siten

$$m_x(t) = E(e^{tx}) = \frac{1}{\Gamma(\alpha)\beta^\alpha} \Gamma(\alpha) \left( \frac{\beta}{1-\beta t} \right)^\alpha = \left( \frac{1}{1-\beta t} \right)^\alpha$$

joka pätee, kun

$$t < \frac{1}{\beta}$$

koska lausekkeen  $\beta/(1-\beta t)$  on oltava gamma-jakauman parametrina *positiivinen*. ■

### Gamma-jakauman momenttiemäfunktio ja jakauman tunnusluvut

Johdetaan gamma-jakauman  $\text{Gamma}(\alpha, \beta)$  odostusarvo ja varianssi jakauman momenttiemäfunktion avulla.

**Odotusarvo:**

$$E(X) = \alpha\beta$$

**Varianssi:**

$$D^2(X) = \text{Var}(X) = \alpha\beta^2$$

**Perustelu:**

Gamma-jakauman  $\text{Gamma}(\alpha, \beta)$  momenttiemäfunktio on

$$m_X(t) = E(e^{tX}) = \left( \frac{1}{1 - \beta t} \right)^\alpha, \quad t < \frac{1}{\beta}$$

Momenttiemäfunktion 1. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{dm_X(t)}{dt} \right|_{t=0} = \left. \frac{\alpha\beta}{(1 - \beta t)^{\alpha+1}} \right|_{t=0} = \alpha\beta$$

Momenttiemäfunktion 2. derivaatta pisteessä  $t = 0$ :

$$\left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \left. \frac{\alpha(\alpha + 1)\beta^2}{(1 - \beta t)^{\alpha+2}} \right|_{t=0} = \alpha(\alpha + 1)\beta^2$$

Siten eksponenttijakauman  $\text{Exp}(\lambda)$  odotusarvo  $\mu_X$ , 2. momentti  $\alpha_2$  ja varianssi  $\sigma_X^2$  saadaan seuraavilla kaavoilla:

$$\mu_X = E(X) = \alpha_1 = \left. \frac{dm_X(t)}{dt} \right|_{t=0} = \alpha\beta$$

$$\alpha_2 = E(X^2) = \left. \frac{d^2 m_X(t)}{dt^2} \right|_{t=0} = \alpha(\alpha + 1)\beta^2$$

$$\sigma_X^2 = \text{Var}(X) = \alpha_2 - \alpha_1^2 = \alpha(\alpha + 1)\beta^2 - \alpha^2\beta^2 = \alpha\beta^2$$

■

**Gamma-jakauma ja Poisson-jakauma**

Olkoon

$$X \sim \text{Gamma}(\alpha, \beta)$$

jossa  $\alpha$  on kokonaisluku eli

$$\alpha \in \mathbb{N}$$

Voidaan osoittaa, että tällöin

$$\Pr(X \leq x) = \Pr(Y \geq \alpha)$$

jossa satunnaismuuttuja  $Y$  noudattaa **Poisson-jakaumaa** parametrilla  $x/\beta$ :

$$Y \sim \text{Poisson}(x/\beta)$$

Lisätietoja Poisson-jakaumasta: ks. lukua **Diskreettejä jakaumia**.



## Gamma-jakauma ja eksponenttijakauma

Olkoon

$$X \sim \text{Gamma}(\alpha, \beta)$$

jossa

$$\alpha = 1$$

Tällöin  $X$  noudattaa **eksponenttijakaumaa** parametrilla  $1/\beta$ :

$$X \sim \text{Exp}(1/\beta)$$

Lisätietoja eksponenttijakaumasta: ks. kappaletta **Eksponenttijakauma**.

## Gamma-jakauma ja $\chi^2$ -jakauma

Olkoon

$$X \sim \text{Gamma}(\alpha, \beta)$$

jossa

$$\alpha = \frac{p}{2}$$

$$\beta = 2$$

Voidaan osoittaa, että tällöin  $X$  noudattaa  **$\chi^2$ -jakaumaa  $p$ :llä vapausasteella**:

$$X \sim \chi^2(p)$$

Lisätietoja  $\chi^2$ -jakaumasta: ks. lukua **Normaalijakaumasta johdettuja jakaumia**.

### 17.8. Beta-jakauma

Beta-jakaumaa käytetään (*bayeslaisessa tilastotieteessä*) *suhteellisen osuuden* (piori-) jakaumana.

Olkoon *jatkuvan satunnaismuuttujan  $X$  tiheysfunktio*

$$f(x) = \frac{1}{\text{B}(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, \quad \alpha > 0, \beta > 0, 0 \leq x \leq 1$$

jossa

$$\text{B}(\alpha, \beta) = \int_0^1 t^{\alpha-1} (1-t)^{\beta-1} dt$$

on ns. *beta-funktio*. Tällöin satunnaismuuttuja  $X$  noudattaa **beta-jakaumaa** parametrein  $\alpha$  ja  $\beta$  ja merkitsemme:

$$X \sim \text{Beta}(\alpha, \beta)$$

Funktio  $f(x)$  kelpaa tiheysfunktiksi, koska

$$f(x) > 0, \quad x \in (0, 1)$$

ja beta-funktion määritelmän perusteella

$$\begin{aligned}\int_{-\infty}^{+\infty} f(x) dx &= \int_0^1 \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} dx \\ &= \frac{1}{B(\alpha, \beta)} \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dt = \frac{1}{B(\alpha, \beta)} \cdot B(\alpha, \beta) = 1\end{aligned}$$

## Beta-funktio

**Beta-funktio** määritellään kaavalla

$$B(\alpha, \beta) = \int_0^1 t^{\alpha-1} (1-t)^{\beta-1} dt$$

*Beta-funktiolla* ja *gamma-funktiolla* on seuraava yhteys:

$$B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha + \beta)}$$

jossa  $\Gamma(\cdot)$  ns. *gamma-funktio*; lisätietoja gamma-funktiosta: ks. kappaletta **Gamma-jakauma**.

## Beta-jakauman tunnusluvut

Olkoon

$$X \sim \text{Beta}(\alpha, \beta)$$

**Odotusarvo:**

$$E(X) = \frac{\alpha}{\alpha + \beta}$$

**Varianssi:**

$$D^2(X) = \text{Var}(X) = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$

**Standardipoikkeama:**

$$D(X) = \frac{1}{\alpha + \beta} \sqrt{\frac{\alpha\beta}{(\alpha + \beta + 1)}}$$

**Perustelu:**

Johdamme tässä beta-jakauman odotusarvon.

Suoraan jatkuva jakauman odotusarvon määritelmän mukaan

$$E(X) = \int_0^1 xf(x) dx = \int_0^1 \frac{1}{B(\alpha, \beta)} xx^{\alpha-1} (1-x)^{\beta-1} dx = \frac{1}{B(\alpha, \beta)} \int_0^1 x^\alpha (1-x)^{\beta-1} dx$$

Koska integroitava

$$x^\alpha (1-x)^{\beta-1}$$

on beta-jakauman  $Beta(\alpha + 1, \beta)$  tiheysfunktion *ydin* (funktion ydin on funktion *pääosa* eli se osa funktiosta, joka jää jäljelle, kun integroimiseen vaikuttamattomat vakiot jätetään funktiosta pois), niin

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

Siten

$$E(X) = \frac{B(\alpha + 1, \beta)}{B(\alpha, \beta)} = \frac{\Gamma(\alpha + 1)\Gamma(\beta)}{\Gamma(\alpha + 1 + \beta)} \cdot \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} = \frac{\alpha}{\alpha + \beta}$$

jossa olemme käyttäneet hyväksi sekä beta-funktion ja gamma-funktion yhteyttä, että sitä gamma-funktion ominaisuutta, että

$$\Gamma(\alpha + 1) = \alpha\Gamma(\alpha)$$

■

### Beta-jakauman tiheysfunktio

Ylempi kuva oikealla esittää beta-jakauman

$$Beta(\alpha, \beta)$$


tiheysfunktioita

$$f(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}$$

$$\alpha > 0, \beta > 0, 0 \leq x \leq 1$$

välillä [0, 1] seuraavissa tapauksissa:

- (i)  $\alpha = 1, \beta = 4$
- (ii)  $\alpha = 2, \beta = 3$
- (iii)  $\alpha = 2, \beta = 1.5$
- (iv)  $\alpha = 2.5, \beta = 1$




Alempi kuva oikealla esittää beta-jakauman

$$Beta(\alpha, \beta)$$

tiheysfunktioita välillä [0, 1] seuraavissa tapauksissa:

- (i)  $\alpha = 0.3, \beta = 0.3$
- (ii)  $\alpha = 0.7, \beta = 0.7$
- (iii)  $\alpha = 1, \beta = 1$
- (iv)  $\alpha = 2, \beta = 1$

Beta-jakauma *odotusarvo*:



$$E(X) = \frac{\alpha}{\alpha + \beta}$$

**Beta-jakauman tiheysfunktion ominaisuudet**

(i) Beta-jakauman tiheysfunktio  $f(x)$  on *positiivinen* välillä  $(0,1)$ :

$$f(x) > 0, x \in (0,1)$$

(ii) Jos  $\alpha > 1$  ja  $\beta = 1$ , niin tiheysfunktio on *aidosti kasvava* ja sillä on *maksimi* pisteessä  $x = 1$ .

(iii) Jos  $\alpha = 1$  ja  $\beta > 1$ , niin tiheysfunktio on *aidosti vähenevä* ja sillä on *maksimi* pisteessä  $x = 0$ .

(iv) Jos  $\alpha > 1$  ja  $\beta > 1$ , niin tiheysfunktio on *yksihuippuinen* ja sillä on *maksimi* pisteessä  $x = (\alpha - 1)/(\alpha + \beta - 2)$ .

(v) Jos  $\alpha < 1$  ja  $\beta < 1$ , niin tiheysfunktio on *U:n muotoinen* ja sillä on *lokaalit maksimit* pisteissä  $x = 0$  ja  $x = 1$ .

(vi) Tiheysfunktio on *symmetrinen*, jos  $\alpha = \beta$ .

**Beta-jakauman kertymäfunktio**

Beta-jakauma kuuluu niiden jakaumien joukkoon, joiden kertymäfunktiolle ei voida antaa eksplisiittistä lauseketta, koska *beta-jakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktiota ei voida esittää suljetussa muodossa* (so. alkeisfunktioiden avulla).

**Beta-jakauma ja jatkuva tasainen jakauma**

Olkoon

$$X \sim \text{Beta}(\alpha, \beta)$$

jossa

$$\alpha = \beta = 1$$

Helposti nähdään, että tällöin  $X$  noudattaa **jatkovaa tasaista jakaumaa** välillä  $(0,1)$ :

$$X \sim \text{Uniform}(0,1)$$

Lisätietoja jatkuvasta tasaisesta jakaumasta: ks. kappaletta **Jatkuva tasainen jakauma**.

**17.9. Weibull-jakauma**

Weibull-jakaumaa käytetään *luotettavuustekniikassa* komponentin *elinän* jakaumana tilanteessa, jossa komponenttia ei huolleta ja todennäköisyys sille, että komponentti vikaantuu saattaa muuttua käytön aikana.

Olkoon *jatkuvan satunnaismuuttujan*  $X$  *tiheysfunktio*

$$f(x) = \frac{\gamma}{\beta} x^{\gamma-1} e^{-x^\gamma/\beta}, \gamma > 0, \beta > 0, 0 \leq x < \infty$$

Tällöin satunnaismuuttuja  $X$  noudattaa **Weibull-jakaumaa** parametrein  $\gamma$  ja  $\beta$  ja merkitsemme:

$$X \sim \text{Weibull}(\gamma, \beta)$$

Funktio  $f(x)$  kelpaa tiheysfunktioksi, koska

$$f(x) > 0, x > 0$$

ja

$$\int_{-\infty}^{+\infty} f(x) dx = 1$$

**Perustelu:**

Todistetaan, että

$$\int_{-\infty}^{+\infty} f(x) dx = \int_0^{+\infty} \frac{\gamma}{\beta} x^{\gamma-1} e^{-x^\gamma/\beta} dx = \frac{\gamma}{\beta} \int_0^{+\infty} x^{\gamma-1} e^{-x^\gamma/\beta} dx = 1$$

Tarkastellaan siksi integraalia

$$\int_0^{+\infty} x^{\gamma-1} e^{-x^\gamma/\beta} dx$$

Tehdään tässä integraalissa muuttujan vaihto

$$x^\gamma / \beta = t$$

jolloin

$$x = \beta^{1/\gamma} t^{1/\gamma}$$

ja

$$dx = \frac{\beta^{1/\gamma}}{\gamma} \cdot \frac{t^{1/\gamma}}{t} dt$$

Siten

$$\int_0^{+\infty} x^{\gamma-1} e^{-x^\gamma/\beta} dx = \int_0^{+\infty} \beta^{(\gamma-1)/\gamma} t^{(\gamma-1)/\gamma} e^{-t} \frac{\beta^{1/\gamma}}{\gamma} \cdot \frac{t^{1/\gamma}}{t} dt = \frac{\beta}{\gamma} \int_0^{+\infty} e^{-t} dt = \frac{\beta}{\gamma}$$

joten

$$\int_{-\infty}^{+\infty} f(x) dx = \frac{\gamma}{\beta} \int_0^{+\infty} x^{\gamma-1} e^{-x^\gamma/\beta} dx = \frac{\gamma}{\beta} \cdot \frac{\beta}{\gamma} = 1$$

■

## Weibull-jakauman tunnusluvut

Olkoon

$$X \sim \text{Weibull}(\gamma, \beta)$$

**Odotusarvo:**

$$E(X) = \beta^{1/\gamma} \Gamma(1 + 1/\gamma)$$

jossa  $\Gamma(\cdot)$  ns. *gamma-funktio*; lisätietoja gamma-funktiosta: ks. tämän luvun kappaletta **Gamma-jakauma**.

**Varianssi:**

$$D^2(X) = \text{Var}(X) = \beta^{2/\gamma} \Gamma(1 + 2/\gamma) - [E(X)]^2$$

**Standardipoikkeama:**

$$D(X) = \sqrt{\text{Var}(X)}$$

**Perustelu:**

Johdamme tässä Weibull-jakauman odotusarvon.

Suoraan jatkuva jakauman odotusarvon määritelmän mukaan

$$E(X) = \int_0^{+\infty} xf(x)dx = \int_0^{+\infty} \frac{\gamma}{\beta} x x^{\gamma-1} e^{-x^\gamma/\beta} dx = \frac{\gamma}{\beta} \int_0^{+\infty} x^\gamma e^{-x^\gamma/\beta} dx$$

Tarkastellaan integraalia

$$\int_0^{+\infty} x^\gamma e^{-x^\gamma/\beta} dx$$

Tehdään tässä integraalissa muuttujan vaihto

$$x^\gamma / \beta = t$$

jolloin

$$x = \beta^{1/\gamma} t^{1/\gamma}$$

ja

$$dx = \frac{\beta^{1/\gamma}}{\gamma} \cdot \frac{t^{1/\gamma}}{t} dt$$

Siten

$$\int_0^{+\infty} x^\gamma e^{-x^\gamma/\beta} dx = \int_0^{+\infty} \beta t e^{-t} \frac{\beta^{1/\gamma}}{\gamma} \cdot \frac{t^{1/\gamma}}{t} dt = \frac{\beta^{1/\gamma+1}}{\gamma} \int_0^{+\infty} t^{1/\gamma} e^{-t} dt$$

Koska integroitava

$$t^{1/\gamma} e^{-t}$$

on gamma-jakauman  $\text{Gamma}(1+1/\gamma, 1)$  tiheysfunktion ydin (funktion ydin on funktion pääosa eli se osa funktiosta, joka jää jäljelle, kun integroimisen kannalta vakiot jätetään funktiosta pois), niin

$$\int_0^{+\infty} t^{1/\gamma} e^{-t} dt = \Gamma(1+1/\gamma)$$

Siten

$$E(X) = \frac{\gamma}{\beta} \cdot \frac{\beta^{1/\gamma+1}}{\gamma} \Gamma(1+1/\gamma) = \beta^{1/\gamma} \Gamma(1+1/\gamma)$$

■



### Weibull-jakauman tiheysfunktio

Kuva oikealla esittää Weibull-jakauman

$$\text{Weibull}(\gamma, \beta)$$


tiheysfunktioita

$$f(x) = \frac{\gamma}{\beta} x^{\gamma-1} e^{-x^\gamma/\beta}$$

$$\gamma > 0, \beta > 0, 0 \leq x < \infty$$

välillä [0, 4] seuraavissa tapauksissa:

- (i)  $\gamma = 0.8, \beta = 1$
- (ii)  $\gamma = 2, \beta = 1$
- (iii)  $\gamma = 2, \beta = 4$



Weibull-jakauman odotusarvo:

$$E(X) = \beta^{1/\gamma} \Gamma(1 + 1/\gamma)$$

### Weibull-jakauman tiheysfunktion ominaisuudet

- (i) Weibull-jakauman tiheysfunktio on *positiivinen* kaikille positiivisille argumentin  $x$  arvoille:

$$f(x) > 0, x > 0$$

- (ii) Jos  $\gamma \leq 1$ , niin tiheysfunktio on *monotonisesti laskeva* ja sillä on *maksimi* pisteessä  $x = 0$ .

- (iii) Jos  $\gamma > 1$ , niin tiheysfunktio on *yksihuippuinen* ja sillä on *maksimi* pisteessä  $x = [\beta(1 - 1/\gamma)]^{1/\gamma}$ .

- (iv) Tiheysfunktio on *vino oikealle*.

### Weibull-jakauman kertymäfunktio

Weibull-jakauma kuuluu niiden jakaumien joukkoon, joiden kertymäfunktioille ei voida antaa eksplisiittistä lauseketta, koska *Weibull-jakauman tiheysfunktio kuuluu sellaisten funktioiden joukkoon, joiden integraalifunktioita ei voida esittää suljetussa muodossa* (so. alkeisfunktioiden avulla).

### Weibull-jakauma ja eksponenttijakauma

Olkoon

$$X \sim \text{Exp}(\beta)$$

Voidaan osoittaa, että tällöin satunnaismuuttuja

$$Y = X^{1/\gamma}$$

noudattaa *Weibullin jakaumaa* parametrein  $\gamma$  ja  $\beta$ :

$$Y \sim \text{Weibull}(\gamma, \beta)$$

Lisätietoja eksponenttijakaumasta: ks. kappaletta **Eksponenttijakauma**.



Kääntäen: Jos

$$Y \sim \text{Weibull}(1, \beta)$$

niin

$$Y \sim \text{Exp}(\beta)$$

## 18. Normaalijakaumasta johdettuja jakaumia

Tässä luvussa määritellään seuraavat *normaalijakaumasta johdetut todennäköisyysjakaumat*:

- (i)  $\chi^2$ -jakauma.
- (ii)  $F$ -jakauma.
- (iii)  $t$ -jakauma.

Näillä jakaumilla on jakaumilla on normaalijakauman itsensä rinnalla keskeinen rooli **tilastotieteessä**; ks. tästä esimerkkejä seuraavissa monisteen **Tilastolliset menetelmät** luvuissa:

**Otos ja otosjakaumat**

**Väliestimointi**

**Testit suhdeasteikollisille muuttujille**

**Yhteensopivuuden, homogeenisuuden ja riippumattomuuden testaaminen**

**Yhden selittäjän lineaarinen regressiomalli**

**Yleinen lineaarinen malli**

### Avainsanat:

$\chi^2$ -jakauma,  $F$ -jakauma, Kertymäfunktio. Normaalijakauma, Normaalijakaumasta johdetut jakaumat, Odotusarvo, Standardipoikkeama,  $t$ -jakauma, Taulukot, Tiheysfunktio, Vapausasteet, Varianssi

### 18.1. $\chi^2$ -jakauma

Olkoot

$$X_i, i = 1, 2, \dots, n$$

riippumattomia ja standardoitua normaalijakaumaa  $N(0,1)$  noudattavia satunnaismuuttujia:

$$\begin{aligned} X_1, X_2, \dots, X_n &\perp \\ X_i &\sim N(0,1), i = 1, 2, \dots, n \end{aligned}$$

Tällöin satunnaismuuttuja

$$X = \sum_{i=1}^n X_i^2$$

noudattaa  $\chi^2$ -jakaumaa vapausasteella (eli parametrilla)  $n$ :

$$X \sim \chi^2(n)$$

$\chi^2$ -jakauman tiheysfunktio on muotoa

$$f(x) = \frac{1}{2^{\frac{n}{2}} \Gamma\left(\frac{n}{2}\right)} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, 0 \leq x < \infty$$

jossa  $\Gamma(\cdot)$  ns. *gamma-funktio*; lisätietoja gamma-funktiosta: ks. luvun **Jatkuvia jakaumia** kappaletta **Gamma-jakauma**.  $\chi^2$ -jakauman tiheysfunktio on johdettu luvussa **Satunnais-muuttujien muunnosten jakaumat**.

#### $\chi^2$ -jakauman tunnusluvut

Olkoon

$$X \sim \chi^2(n)$$

**Odotusarvo:**

$$E(X) = n$$

**Varianssi:**

$$\text{Var}(X) = D^2(X) = 2n$$

**Standardipoikkeama:**

$$D(X) = \sqrt{2n}$$

**Perustelu:**

Johdamme tässä  $\chi^2$ -jakauman odotusarvon. Nojaamme johdossa jakauman määritelmään.

Olkoon

$$\begin{aligned} X_1, X_2, \dots, X_n &\perp \\ X_i &\sim N(0,1), i = 1, 2, \dots, n \end{aligned}$$

Tällöin

$$X = \sum_{i=1}^n X_i^2 \quad \chi^2(n)$$

Oletuksista seuraa, että

$$E(X_i) = 0, i = 1, 2, \dots, n$$

$$\text{Var}(X_i) = E(X_i^2) - [E(X_i)]^2 = E(X_i^2) = 1, i = 1, 2, \dots, n$$

Siten

$$E(X) = E\left(\sum_{i=1}^n X_i^2\right) = \sum_{i=1}^n E(X_i^2) = \sum_{i=1}^n \text{Var}(X_i) = \underbrace{1+1+\dots+1}_{n \text{ kpl}} = n$$

koska odotusarvo on operaattorina *lineaarinen*.

■

### $\chi^2$ -jakauman tiheysfunktio

Kuva oikealla esittää  $\chi^2$ -jakauman

$$\chi^2(n)$$

tiheysfunktioita välillä  $[0, 10]$ , kun vapausasteiden lukumäärällä  $n$  on seuraavat arvot:


$$n = 1$$

$$n = 2$$

$$n = 5$$

Jakauman *odotusarvo*:

$$E(X) = n$$



### $\chi^2$ -jakauman tiheysfunktion ominaisuudet

(i)  $\chi^2$ -jakauman tiheysfunktio  $f(x)$  on *positiivinen* kaikille *positiivisille* argumentin  $x$  arvoille:

$$f(x) > 0, x > 0$$

(ii) Jos vapausasteiden lukumäärä

$$n = 1, 2$$

niin tiheysfunktio on *monotonisesti laskeva* kaikille  $x \geq 0$ .

(iii) Jos vapausasteiden lukumäärä

$$n \geq 3$$

niin tiheysfunktiolla on *maksimi* jossakin pisteessä  $x > 0$ .

### Todennäköisyyksien määrittäminen $\chi^2$ -jakaumasta

Todennäköisyydet  $\chi^2$ -jakaumasta voidaan määrätä jakauman *kertymäfunktion* avulla. Olkoon

$$X \sim \chi^2(n)$$

ja olkoon satunnaismuuttujan  $X$  kertymäfunktio

$$F_{\text{Chi}}(x; n) = \Pr(X \leq x)$$

Kaikkien  $\chi^2$ -jakaumaan liittyvien tapahtumien todennäköisyydet saadaan todennäköisyyksistä

$$\Pr(X \leq x) = F_{\text{Chi}}(x; n)$$

todennäköisyyslaskennan laskusääntöjen avulla. Siten esimerkiksi

$$\Pr(a \leq X \leq b) = F_{\text{Chi}}(b) - F_{\text{Chi}}(a)$$

Koska  $\chi^2$ -jakauman tiheysfunktion integraalifunktiota ei pystytä esittämään suljetussa muodossa (so. alkeisfunktioiden avulla), todennäköisyyksien määrittämisessä  $\chi^2$ -jakaumasta on käytettävä jotakin numeerista menetelmää. Tämä voi tapahtua tietokoneohjelmien tai taulukoiden avulla.

### Todennäköisyyksien määrittäminen $\chi^2$ -jakaumasta ja $\chi^2$ -jakauman taulukot

Olkoon

$$X \sim \chi^2(n)$$

Tähän kirjaan liittyvässä taulukkokokoelmassa on taulukoituna usealle eri vapausasteiden  $df = n$  arvolle pisteet  $x$ , jotka toteuttavat ehdon

$$p_x = \Pr(X \geq x)$$

kun

$$p_x = 0.999, 0.99, 0.95, 0.9, 0.1, 0.05, 0.01, 0.001$$

Siten piste  $x$  erottaa  $\chi^2$ -jakauman oikealle hänälle todennäköisyssmassan, jonka koko on

$$p_x = \Pr(X \geq x)$$

Huomaa, että piste  $x$  erottaa  $\chi^2$ -jakauman vasemmalle hänälle todennäköisyssmassan, jonka koko on

$$1 - p_x = \Pr(X \leq x)$$


Koska eräs taulukoiden tärkeimmistä käyttö-alueista on **tilastollinen testaus** (ks. monistetta **Tilastolliset menetelmät**), todennäköisyyttä  $p_x$  kutsutaan *merkitsevyystasoksi* ja pistettä  $x$  merkitsevyystasoa  $p_x$  vastaavaksi *kriittiseksi arvoksi* tai *rajaksi*.

#### Esimerkki 1. Todennäköisyyksien määrittäminen $\chi^2$ -jakauman taulukoista.

Kuva oikealla esittää  $\chi^2$ -jakauman

$$\chi^2(10)$$

tiheysfunktiota välillä  $[0, 35]$ .



$\chi^2$ -jakauman taulukoiden mukaan:

$$\begin{aligned} & \text{Alueen } A \text{ pinta-ala} \\ &= \Pr(3.940 \leq X \leq 18.307) \\ &= F_{Chi}(18.307; 10) - F_{Chi}(3.940; 10) \\ &= 0.95 - 0.05 = 0.9 \end{aligned}$$

### Todennäköisyyksien määrittäminen $\chi^2$ -jakaumasta ja tietokoneohjelmat

Olkoon

$$X \sim \chi^2(n)$$

Monet tietokoneohjelmat mahdollistavat seuraavien tehtävien ratkaisemisen ilman  $\chi^2$ -jakauman taulukoiden asettamia rajoituksia:

(i) Määrää todennäköisyys

$$\Pr(X \leq x) = F_{Chi}(x; n)$$

kun  $x$  on annettu.

(ii) Määrää  $x$ , kun todennäköisyys

$$\Pr(X \leq x) = F_{Chi}(x; n)$$

on annettu.

### 18.2. F-jakauma

Olkoot  $Y_i, i = 1, 2, \dots, m$  ja  $X_i, i = 1, 2, \dots, n$  riippumattomia, standardoitua normaalijakaumaa  $N(0,1)$  noudattavia satunnaismuuttujia:

$$\begin{aligned} & Y_i \sim N(0,1), i = 1, 2, \dots, m; X_i \sim N(0,1), i = 1, 2, \dots, n \\ & Y_1, Y_2, \dots, Y_m, X_1, X_2, \dots, X_n \perp \end{aligned}$$

Tällöin satunnaismuuttujat

$$Y = \sum_{i=1}^m Y_i^2; X = \sum_{i=1}^n X_i^2$$

ovat riippumattomia ja noudattavat  $\chi^2$ -jakaumia vapausastein  $m$  ja  $n$ :

$$\begin{aligned} & Y \sim \chi^2(m); X \sim \chi^2(n) \\ & Y \perp X \end{aligned}$$

Määritellään satunnaismuuttuja

$$F = \frac{\frac{1}{m} Y}{\frac{1}{n} X} = \frac{n}{m} \cdot \frac{Y}{X}$$

Satunnaismuuttujat  $F$  noudattaa **F-jakaumaa** vapausastein (eli *parametrein*)  $m$  ja  $n$ :

$$F \sim F(m, n)$$

$F$ -jakauman tiheysfunktio on muotoa

$$f(x) = \frac{\Gamma\left(\frac{m+n}{2}\right)}{\Gamma\left(\frac{m}{2}\right)\Gamma\left(\frac{n}{2}\right)} \left(\frac{m}{n}\right)^{\frac{m}{2}} x^{\frac{m}{2}-1} \left(1 + \frac{m}{n}x\right)^{-\frac{m+n}{2}}, 0 \leq x < \infty$$

jossa  $\Gamma(\cdot)$  ns. *gamma-funktio*; lisätietoja gamma-funktiosta: ks. luvun **Jatkuvia jakaumia** kappaletta **Gamma-jakauma**.  $F$ -jakauman tiheysfunktio on johdettu luvussa **Satunnaismuuttujien muunnosten jakaumat**.

Suoraan  $F$ -jakauman määritelmästä nähdään, että  $F$ -jakaumalla on seuraava ominaisuus: Jos satunnaismuuttuja  $F$  noudattaa  $F$ -jakaumaa vapausastein  $m$  ja  $n$ :

$$F \sim F(m, n)$$

niin satunnaismuuttuja  $1/F$  noudattaa  $F$ -jakaumaa vapausastein  $n$  ja  $m$ :

$$\frac{1}{F} \sim F(n, m)$$

### **$F$ -jakauman tunnusluvut**

Olkoon

$$F \sim F(m, n)$$

**Odotusarvo:**

$$E(X) = \frac{n}{n-2}, n > 2$$

$F$ -jakaumalla *ei ole* odotusarvoa, kun  $n = 1, 2$ . Huomaa myös, että  $F$ -jakauman odotusarvo *ei riipu* parametrilla  $m$  (= yhteenlaskettavien lukumäärä  $F$ -jakauman määritelmän *osoittajassa* olevassa  $\chi^2$ -satunnaismuuttujassa  $Y = \sum Y_i^2$ ).

**Varianssi:**

$$D^2(F) = \text{Var}(F) = \frac{2n^2(m+n-2)}{m(n-2)^2(n-4)}, n > 4$$

$F$ -jakaumalla *ei ole* varianssia, kun  $n = 1, 2, 3, 4$ .

**Standardipoikkeama:**

$$D(F) = \sqrt{\frac{2n^2(m+n-2)}{m(n-2)^2(n-4)}}, n > 4$$

$F$ -jakaumalla *ei ole* standardipoikkeamaa, kun  $n = 1, 2, 3, 4$ .

### **$F$ -jakauman tiheysfunktio**

Kuva alla esittää  $F$ -jakauman

$$F(m, n)$$

*tiheysfunktio* välillä  $[0, 5]$ , kun vapausasteiden lukumäärillä  $m$  ja  $n$  on seuraavat arvot:

$$m = 10, n = 40$$

$$m = 40, n = 10$$

$$m = 40, n = 40$$

Jakauman *odotusarvo*:

$$E(X) = \frac{n}{n-2}, n > 2$$

**F-jakauman tiheysfunktion ominaisuudet**

(i) F-jakauman tiheysfunktio  $f(x)$  on *positiivinen* kaikille *positiivisille* argumentin  $x$  arvoille:

$$f(x) > 0, x > 0$$

(ii) Jos *osoittajan* vapausasteiden lukumäärä


$$m = 1, 2$$

niin tiheysfunktio on *monotonisesti laskeva* kaikille  $x \geq 0$ .

(iii) Jos *osoittajan* vapausasteiden lukumäärä

$$m \geq 3$$

niin tiheysfunktiolla on *maksimi* jossakin pisteessä  $x > 0$ .



**Todennäköisyyksien määrääminen F-jakaumasta**

Todennäköisyydet F-jakaumasta voidaan määrätä jakauman *kertymäfunktion* avulla. Olkoon

$$F \sim F(m, n)$$

ja olkoon satunnaismuuttujan  $F$  *kertymäfunktion*

$$F_F(x; m, n) = \Pr(F \leq x)$$

*Kaikkien* F-jakaumaan liittyvien tapahtumien todennäköisyydet saadaan todennäköisyyksistä

$$\Pr(F \leq x) = F_F(x; m, n)$$

*todennäköisyyyslaskennan laskusääntöjen* avulla. Siten esimerkiksi

$$\Pr(a \leq F \leq b) = F_F(b) - F_F(a)$$

Koska **F-jakauman tiheysfunktion integraalifunktiota ei pystytä esittämään suljetussa muodossa** (so. alkeisfunktioiden avulla), todennäköisyyksien määräämisessä F-jakaumasta on käytettävä jotakin *numeerista menetelmää*. Tämä voi tapahtua tietokoneohjelmien tai *taulukoiden* avulla.

**Todennäköisyyksien määrääminen F-jakaumasta ja F-jakauman taulukot**

Olkoon

$$F \sim F(m, n)$$

Tähän kirjaan liittyvässä taulukkokokoelmassa on taulukoituna usealle eri vapausasteiden  $df_1 = m$  ja  $df_2 = n$  arvoille pisteet  $x$ , jotka toteuttavat ehdon



$$p_x = \Pr(F \geq x)$$

kun

$$p_x = 0.05, 0.025, 0.01, 0.005$$

Siten piste  $x$  erottaa  $F$ -jakauman *oikealle* hänälle todennäköisyysmassan, jonka koko on

$$p_x = \Pr(F \geq x)$$

Koska eräs taulukoiden tärkeimmistä käyttöalueista on **tilastollinen testaus** (ks. monistetta **Tilastolliset menetelmät**), kutsutaan todennäköisyyttä  $p_x$  taulukoissa *merkitsevyystasoksi* ja pistettä  $x$  merkitsevyystasoa  $p_x$  vastaavaksi *kriittiseksi arvoksi* tai *rajaksi*.

$F$ -jakauman *vasenman* hännän todennäköisyydet saadaan käyttämällä hyväksi sitä, että satunnaismuuttuja  $1/F$  noudattaa  $F$ -jakaumaa vapausastein  $n$  ja  $m$ , jos satunnaismuuttuja  $F$  noudattaa  $F$ -jakaumaa vapausastein  $m$  ja  $n$ . Jos siis

$$F \sim F(m, n)$$

niin

$$G = \frac{1}{F} \sim F(n, m)$$

Oletetaan nyt, että haluamme määrätä pisteen  $x$  siten, että

$$\Pr(F \leq x) = p$$

jossa

$$F \sim F(m, n)$$

Tällöin voimme toimia seuraavasti: Määrätään  $F$ -jakauman taulukoista piste  $y$  siten, että

$$\Pr(G \geq y) = p$$

jossa

$$G \sim F(n, m)$$

Yllä esitetyn mukaan

$$\Pr(G \geq y) = \Pr\left(\frac{1}{G} \leq \frac{1}{y}\right) = \Pr\left(F \leq \frac{1}{y}\right)$$

jossa

$$F \sim F(m, n)$$

Siten piste

$$x = 1/y$$

toteuttaa ehdon

$$\Pr(F \leq x) = p$$

**Esimerkki 1. Todennäköisyyksien määrittäminen  $F$ -jakauman taulukoista.**

Kuva oikealla esittää  $F$ -jakauman

$$F(10, 60)$$

tiheysfunktiota välillä  $[0, 4]$ .

$F$ -jakauman taulukoiden mukaan:

$$\begin{aligned} \text{Alueen } A \text{ pinta-ala} &= \Pr(0.3815 \leq F \leq 1.993) \\ &= F_F(1.993; 10, 60) \\ &\quad - F_F(0.3815; 10, 60) \\ &= 0.95 - 0.05 = 0.9 \end{aligned}$$

Piste

$$b = 1.993$$

joka erottaa  $F$ -jakauman  $F(10,60)$  oikealle hänälle todennäköisyysmassan 0.05, saadaan suoraan  $F$ -jakauman taulukoista. Piste

$$a = 0.3815$$

joka erottaa  $F$ -jakauman  $F(10,60)$  vasemmalle hänälle todennäköisyysmassan 0.05, saadaan taulukoista seuraavalla tavalla: Olkoon

$$G \sim F(60, 10)$$

$F$ -jakauman taulukoiden mukaan

$$\Pr(G \geq 2.621) = 0.05$$

Siten piste


$$a = \frac{1}{2.621} \approx 0.3815$$

toteuttaa ehdon

$$\Pr(F \leq 0.3815) = 0.05$$

jossa

$$F \sim F(10, 60)$$



**Todennäköisyyksien määrittäminen  $F$ -jakaumasta ja tietokoneohjelmat**

Olkoon

$$F \sim F(m, n)$$

Monet tietokoneohjelmat mahdollistavat seuraavien tehtävien ratkaisemisen ilman  $F$ -jakauman taulukoiden asettamia rajoituksia:

(i) Määrää todennäköisyys

$$\Pr(F \leq x) = F_F(x; m, n)$$

kun  $x$  on annettu.

(ii) Määää  $x$ , kun todennäköisyys

$$\Pr(F \leq x) = F_F(x; m, n)$$

on annettu.

### 18.3. $t$ -jakauma

Olkoot  $Y$  ja  $X_i, i = 1, 2, \dots, n$  riippumattomia, standardoitua normaalijakaumaa  $N(0,1)$  noudattavia satunnaismuuttujia:

$$Y \sim N(0,1); X_i \sim N(0,1), i = 1, 2, \dots, n$$

$$Y, X_1, X_2, \dots, X_n \perp$$

Tällöin satunnaismuuttuja

$$X = \sum_{i=1}^n X_i^2$$

noudattaa  $\chi^2$ -jakaumaa vapausastein  $n$ :

$$X \sim \chi^2(n)$$

Lisäksi satunnaismuuttujat  $Y$  ja  $X$  ovat riippumattomia:

$$Y \perp X$$

Määritellään satunnaismuuttuja

$$t = \frac{Y}{\sqrt{\frac{1}{n} X}}$$

Satunnaismuuttuja  $t$  noudattaa (**Studentin**)  $t$ -jakaumaa vapausastein (eli parametrilla)  $n$ :

$$t \sim t(n)$$

$t$ -jakauman tiheysfunktio on muotoa

$$f(x) = \frac{1}{\sqrt{n\pi}} \cdot \frac{\Gamma\left(\frac{n+1}{2}\right)}{\Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{1}{n}x^2\right)^{-\frac{n+1}{2}}, -\infty < x < +\infty$$

jossa  $\Gamma(\cdot)$  ns. *gamma-funktio*; lisätietoja gamma-funktiosta: ks. luvun **Jatkuvia jakaumia** kappaletta **Gamma-jakauma**.  $t$ -jakauman tiheysfunktio on johdettu luvussa **Satunnaismuuttujien muunnosten jakaumat**.

#### $t$ -jakauman tunnusluvut

Olkoon

$$t \sim t(n)$$

**Odotusarvo:**

$$E(X) = 0, n > 1$$

$t$ -jakaumalla *ei ole* odotusarvoa, kun  $n = 1$ .

**Varianssi:**

$$\text{Var}(t) = D^2(t) = \frac{n}{n-2}, n > 2$$

$t$ -jakaumalla *ei ole* varianssia, kun  $n = 1$  tai  $2$ .

**Standardipoikkeama:**

$$D(t) = \sqrt{\frac{n}{n-2}}, n > 2$$

$t$ -jakaumalla *ei ole* standardipoikkeamaa, kun  $n = 1$  tai  $2$ .

**$t$ -jakauman tiheysfunktio**

Kuva oikealla esittää  $t$ -jakauman

$$t(n)$$

tiheysfunktioita välillä  $[-4, +4]$ , kun vapausasteiden lukumäärällä  $n$  on seuraavat arvot:

$$n = 1$$


$$n = 3$$

$$n = 100$$

Jakauman *odotusarvo*:

$$E(X) = 0, n > 1$$

Kuvaan on piirretty myös standardoidun normaalijakauman  $N(0,1)$  tiheysfunktion kuvaaja. Huomaa, että standardoidun normaalijakauman  $N(0,1)$  tiheysfunktion kuvaaja ei erotu  $t$ -jakauman kuvaajasta, kun vapauseiden lukumäärä  $n = 100$ ; ks. kohta  **$t$ -jakauma ja normaalijakauma**.



**$t$ -jakauman tiheysfunktion ominaisuudet**

(i)  $t$ -jakauman tiheysfunktio  $f(x)$  on *positiivinen* kaikille argumentin  $x$  arvoille:

$$f(x) > 0, -\infty < x < +\infty$$

(ii) Tiheysfunktio on *yksihuippuinen* ja sillä on *maksimi* pisteessä  $x = 0$ .

(iii) Tiheysfunktio on *symmetrinen* pisteen  $0$  suhteen:

$$f(-x) = f(+x), -\infty < x < +\infty$$

## Todennäköisyyksien määrittäminen $t$ -jakaumasta

Todennäköisyydet  $t$ -jakaumasta voidaan määrätä jakauman *kertymäfunktion* avulla. Olkoon

$$t \sim t(n)$$

ja olkoon satunnaismuuttujan  $t$  *kertymäfunktio*

$$F_t(x; n) = \Pr(t \leq x)$$

Kaikkien  $t$ -jakaumaan liittyvien tapahtumien todennäköisyydet saadaan todennäköisyyksistä

$$\Pr(t \leq x) = F_t(x; n)$$

*todennäköisyyslaskennan laskusääntöjen* avulla. Siten esimerkiksi

$$\Pr(a \leq t \leq b) = F_t(b) - F_t(a)$$

Koska  $t$ -jakauman tiheysfunktion integraalifunktiota ei pystytä esittämään suljetussa muodossa (so. alkeisfunktioiden avulla), todennäköisyyksien määrittämisessä  $t$ -jakaumasta on käytettävä jotakin *numeerista menetelmää*. Tämä voi tapahtua tietokoneohjelmien tai *taulukoiden* avulla.

## Todennäköisyyksien määrittäminen $t$ -jakaumasta ja $t$ -jakauman taulukot

Olkoon

$$t \sim t(n)$$

Tähän kirjaan liittyvässä taulukkokokoelmassa on taulukoituna usealle eri vapausasteiden  $df = n$  arvoille pisteet  $x$ , jotka toteuttavat ehdon

$$p_x = \Pr(t \geq x)$$

kun

$$p_x = 0.4, 0.3, 0.2, 0.1, 0.05, 0.025, 0.01, 0.005, 0.001, 0.0005$$

Siten piste  $x$  erottaa  $t$ -jakauman *oikealle* hänälle todennäköisyysmassan, jonka koko on

$$p_x = \Pr(t \geq x)$$

Koska eräs taulukoiden tärkeimmistä käyttöalueista on **tilastollinen testaus** (ks. monistetta **Tilastolliset menetelmät**), kutsutaan todennäköisyyttä  $p_x$  taulukoissa *merkitsevyystasoksi* ja pistettä  $x$  merkitsevyystasoa  $p_x$  vastaavaksi *kriittiseksi arvoksi* tai *rajaksi*.

Pisteet  $x$ , jotka erottavat todennäköisyysmassat

$$0.4, 0.3, 0.2, 0.1, 0.05, 0.025, 0.01, 0.005, 0.001, 0.0005$$

$t$ -jakauman *vasemmalle* hänälle saadaan käyttämällä hyväksi sitä, että  $t$ -jakauma on *symmetrinen* origon suhteen.

Siten

$$p_x = \Pr(t \geq x) = \Pr(t \leq -x)$$

**Esimerkki 1. Todennäköisyyksien määrittäminen  $t$ -jakauman taulukoista.**


Kuva oikealla esittää  $t$ -jakauman

$$t(10)$$

tiheysfunktiota välillä  $[0, 4]$ .

$t$ -jakauman taulukoista saadaan:

$$\begin{aligned} \text{Alueen } A \text{ pinta-ala} &= \Pr(-1.812 \leq t \leq +1.812) \\ &= F_t(+1.812; 10) - F_t(-1.812; 10) \\ &= 0.95 - 0.05 \\ &= 0.9 \end{aligned}$$



**Todennäköisyyksien määrittäminen  $t$ -jakaumasta ja tietokoneohjelmat**

Olkoon

$$t \sim t(n)$$

Monet tietokoneohjelmat mahdollistavat seuraavien tehtävien ratkaisemisen ilman  $t$ -jakauman taulukoiden asettamia rajoituksia:

(i) Määrää todennäköisyys

$$\Pr(t \leq x) = F_t(x; n)$$

kun  $x$  on annettu.

(ii) Määrää  $x$ , kun todennäköisyys

$$\Pr(t \leq x) = F_t(x; n)$$

on annettu.

**$t$ -jakauma ja  $F$ -jakauma**

Suoraan  $t$ -jakauman ja  $F$ -jakauman määritelmistä nähdään seuraavaa:

Jos

$$t \sim t(n)$$

niin

$$t^2 \sim F(1, n)$$

Kääntäen, jos

$$F \sim F(1, n)$$

niin

$$\sqrt{F} \sim t(n)$$

### **$t$ -jakauma ja Cauchy-jakauma**

Olkoon

$$t \sim t(n)$$

jossa

$$n = 1$$

Tällöin  $t$  noudattaa **Cauchy-jakaumaa** parametrilla 0:

$$t \sim \text{Cauchy}(0)$$

Lisätietoja Cauchy-jakaumasta: ks. luvun **Jatkuvia jakaumia** kappaletta **Cauchy-jakauma**.

### **$t$ -jakauma ja normaalijakauma**

$t$ -jakauma lähestyy standardoitua normaalijakaumaa, kun *vapausasteiden* lukumäärä  $n$  kasvaa.

Olkoon

$$t \sim t(n)$$

Tällöin

$$\lim_{n \rightarrow +\infty} \Pr(t \leq z) = \Phi(z)$$

missä  $\Phi$  on *standardoidun normaalijakauman*  $N(0,1)$  *kertymäfunktio*.

Koska  $t$ -jakauma lähestyy vapausasteiden lukumäärän  $n$  kasvaessa standardoitua normaalijakaumaa  $N(0,1)$ , voidaan  $t$ -jakaumaan liittyvät todennäköisyydet määrätä suurilla vapausasteiden luvuilla  $n$  standardoidun normaalijakauman avulla. *Normaalijakauma-approksimaatio  $t$ -jakaumalle* on kohtuullisen hyvä jo, kun  $n = 30$ , ja riittää useimpiin tarkoituksiin, kun  $n > 100$ .

### **Esimerkki 2. Normaalijakauma-approksimaation hyvyys.**

Kohdan  **$t$ -jakauman tiheysfunktio** kuvassa jakaumien  $t(100)$  ja  $N(0,1)$  tiheysfunktioiden kuvaajia ei pysty erottamaan toisistaan.

## 19. Moniulotteisia jakaumia

Tässä luvussa määritellään seuraavat *moniulotteiset todennäköisyysjakaumat*:

- (i) **Multinomijakauma.**
- (ii) **Kaksiulotteinen normaalijakauma.**

**Multinomijakauma** on **binomijakauman** *yleistys useamman kuin kahden toisensa poissulkevan tapahtuman tilanteeseen*.

**Normaalijakauman** *yleistystä* useampiulotteiseen avaruuteen kutsutaan **multinormaali-jakaumaksi** tai **moniulotteiseksi normaalijakaumaksi**. Multinormaali-jakaumalla on keskeinen rooli *useamman muuttujan tilastollisten aineistojen* analyysissä käytettävien tilastollisten menetelmien kuten **regressioanalyysin** tai **monimuuttujamenetelmien teoriassa**.

Rajoitumme tässä esityksessä tarkastelemaan multinormaali-jakauman kaksiulotteista erikoistapausta **kaksiulotteista normaalijakaumaa**, mutta esitetty teoria on (suhteellisen) helppo yleistää useampiulotteisen normaalijakauman tapaukseen.

### Avainsanat:

Binomijakauma, Diskreetti jakauma, Ehdollinen jakauma, Ehdollinen odotusarvo, Ehdollinen varianssi, Jatkuva jakauma, Kaksiulotteinen normaalijakauma, Korrelaatio, Korreloimattomuus, Korreloituneisuus, Kovarianssi, Kulmakerroin, Multinomijakauma, Odotusarvo, Painopiste, Pistetodennäköisyysfunktio, Regressiofunktio, Regressiosuora, Reunajakauma, Riippumattomuus, Riippuvuus, Suora, Tiheysfunktio, Todennäköisyysmassa, Varianssi, Yhteisjakauma, Yhteiskorrelaatiokerroin



### 19.1. Multinomijakauma

*Multinomijakauma* on **binomijakauman** *yleistys* useamman kuin kahden toisensa poissulkevan tapahtuman tilanteeseen; lisätietoja binomijakaumasta: ks. lukua **Diskreettejä jakaumia**.

Olkoon

$$A_1, A_2, \dots, A_k$$

otosavaruuden  $S$  ositus. Tällöin

$$S = A_1 \cup A_2 \cup \dots \cup A_k$$

$$A_i \cap A_j = \emptyset, i \neq j$$

Oletetaan, että tapahtumien  $A_1, A_2, \dots, A_k$  *todennäköisyydet*

$$\Pr(A_i) = p_i, i = 1, 2, \dots, k$$

toteuttavat ehdon

$$p_1 + p_2 + \dots + p_k = 1$$

Olkoon satunnaismuuttuja

$X_i =$  Tapahtuman  $A_i$  esiintymisten lukumäärä  $n$ -kertaisessa toistokokeessa

$$i = 1, 2, \dots, k$$

Tällöin *binomijakauman* määritelmästä seuraa, että

$$X_i \sim \text{Bin}(n, p_i), i = 1, 2, \dots, k$$

jossa

$$p_i = \Pr(A_i), i = 1, 2, \dots, k$$

Lisäksi satunnaismuuttujat  $X_1, X_2, \dots, X_k$  toteuttavat ehdon

$$X_1 + X_2 + \dots + X_k = n$$

Satunnaismuuttujien

$$X_1, X_2, \dots, X_k$$

*yhteisjakaumaa* kutsutaan **multinomijakaumaksi**.

**Huomautus:**

Satunnaismuuttuja  $X_i$  *eivät ole riippumattomia*, koska niitä sitoo toisiinsa ehto

$$X_1 + X_2 + \dots + X_k = n$$

jossa toistokokeiden lukumäärä  $n$  on *kiinteä, ei-satunnainen* luku.

Voidaan osoittaa, että satunnaismuuttujat  $X_1, X_2, \dots, X_k$  noudattavat  $(k - 1)$ -ulotteista **multinomi-jakaumaa**, jos niiden *yhteisjakauman pistetodennäköisyysfunktio* on muotoa

$$\Pr(X_1 = n_1 \text{ ja } X_2 = n_2 \text{ ja } \dots \text{ ja } X_k = n_k) = \frac{n!}{n_1! n_2! \dots n_k!} p_1^{n_1} p_2^{n_2} \dots p_k^{n_k}$$

jossa

$$p_1 + p_2 + \dots + p_k = 1$$

$$n_1 + n_2 + \dots + n_k = n$$

Merkintä:

$$(X_1, X_2, \dots, X_k) \sim \text{Multinom}(p_1, p_2, \dots, p_k; n)$$

### Multinomijakauman ominaisuudet

(i) Jos  $k = 2$ , niin multinomijakauma yhtyy *binomijakaumaan*:

$$\Pr_{\text{Multinom}}(X_1 = n_1 \text{ ja } X_2 = n - n_1) = \Pr_{\text{Bin}}(X_1 = n_1)$$

(ii) Kaikki multinomijakauman *yksiulotteiset reunajakaumat* ovat *binomijakaumia*.

(iii) *Multinomitodennäköisyydet* saadaan korottamalla *multinomi*

$$(p_1 + p_2 + \dots + p_k)$$

potenssiin  $n$ :

$$(p_1 + p_2 + \dots + p_k)^n = \sum \frac{n!}{n_1! n_2! \dots n_k!} p_1^{n_1} p_2^{n_2} \dots p_k^{n_k}$$

jossa summa lasketaan yli kaikkien lukujen  $n_1, n_2, \dots, n_k$ , jotka toteuttavat ehdon

$$n_1 + n_2 + \dots + n_k = n$$

## 19.2. Kaksiulotteinen normaalijakauma

*Kaksiulotteinen normaalijakauma on normaalijakauman (ks. lukua **Jatkuvia jakaumia**) kaksiulotteinen yleistys. Normaalijakauman yleistystä  $p$ -ulotteiseen avaruuteen ( $p > 1$ ) kutsutaan joko  **$p$ -ulotteiseksi normaalijakaumaksi** tai **multinormaalijakaumaksi**. Rajoitumme tässä esityksessä pelkäästään kaksiulotteisen normaalijakauman käsittelyyn.*

On syytä huomata, että multinormaalijakaumalla on keskeinen asema **lineaaristen mallien ja monimuuttujamenetelmien** teoriassa.

Satunnaismuuttujien  $X$  ja  $Y$  muodostama pari  $(X, Y)$  noudattaa **2-ulotteista normaalijakaumaa** parametrein  $\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2$  ja  $\rho_{XY}$ , jos sen *tiheysfunktio* on

$$(1) \quad f_{XY}(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho_{XY}^2}} \exp\left\{-\frac{1}{2(1-\rho_{XY}^2)} Q(x, y)\right\}$$

jossa

$$Q(x, y) = \left(\frac{x - \mu_X}{\sigma_X}\right)^2 - 2\rho_{XY} \left(\frac{x - \mu_X}{\sigma_X}\right) \left(\frac{y - \mu_Y}{\sigma_Y}\right) + \left(\frac{y - \mu_Y}{\sigma_Y}\right)^2$$

ja

$$\begin{aligned} -\infty < \mu_X < +\infty & \quad \sigma_X > 0 \\ -\infty < \mu_Y < +\infty & \quad \sigma_Y > 0 \\ -1 \leq \rho_{XY} \leq +1 & \end{aligned}$$

Muuttujat  $x$  ja  $y$  voivat saada kaavassa (1) kaikki reaalityyppiset arvot:

$$\begin{aligned} -\infty < x < +\infty \\ -\infty < y < +\infty \end{aligned}$$

Merkitään:

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

### Kaksiulotteisen normaalijakauman johto

Näytämme, että **kaksiulotteinen normaalijakauma saadaan lineaarimuunnoksella kahdesta riippumattomasta standardoitua normaalijakaumaa noudattavasta satunnaismuuttujasta.**

Olkoot  $Z_1$  ja  $Z_2$  kaksi *riippumatonta* satunnaismuuttujaa, jotka noudattavat *standardoitua normaalijakaumaa*  $N(0,1)$ :

$$\begin{aligned} Z_1 & \perp Z_2 \\ Z_1 & \sim N(0,1) \quad Z_2 \sim N(0,1) \end{aligned}$$

Muodostetaan uudet satunnaismuuttujat  $X$  ja  $Y$  seuraavilla kaavoilla:

$$\begin{aligned} X & = \mu_X + \sigma_X Z_1 \\ Y & = \mu_Y + \sigma_Y \left[ \rho_{XY} Z_1 + (1 - \rho_{XY}^2)^{1/2} Z_2 \right] \end{aligned}$$

Oletetaan, että ei-satunnaiset vakiot  $\mu_X, \mu_Y, \sigma_X, \sigma_Y$  ja  $\rho_{XY}$  toteuttavat seuraavat ehdot:

$$\begin{aligned} -\infty < \mu_X < +\infty & \quad \sigma_X > 0 \\ -\infty < \mu_Y < +\infty & \quad \sigma_Y > 0 \\ -1 \leq \rho_{XY} \leq +1 & \end{aligned}$$

Satunnaismuuttujilla  $X$  ja  $Y$  on seuraavat **odotusarvot, varianssit, kovarianssi ja korrelaatio**:

$$\begin{aligned} E(X) = \mu_X & \quad E(Y) = \mu_Y \\ \text{Var}(X) = \sigma_X^2 & \quad \text{Var}(Y) = \sigma_Y^2 \\ \text{Cov}(X, Y) = \rho_{XY} \sigma_X \sigma_Y \\ \text{Cor}(X, Y) = \rho_{XY} \end{aligned}$$

Lisäksi satunnaismuuttujat  $X$  ja  $Y$  ovat **normaalijakautuneita** ja satunnaismuuttujien  $X$  ja  $Y$  yhteisjakauma on **kaksiulotteinen normaalijakauma** parametrein  $\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2$  ja  $\rho_{XY}$ :

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

**Perustelu:**

Olkoot

$$\begin{aligned} Z_1 \perp Z_2 \\ Z_1 \sim N(0, 1) \quad Z_2 \sim N(0, 1) \end{aligned}$$

Tällöin

$$\begin{aligned} E(Z_1) = E(Z_2) = 0 \\ \text{Var}(Z_1) = E(Z_1^2) = E(Z_2^2) = \text{Var}(Z_2) = 1 \end{aligned}$$

Määritellään satunnaismuuttujat  $X$  ja  $Y$  kaavoilla

$$\begin{aligned} X &= \mu_X + \sigma_X Z_1 \\ Y &= \mu_X + \sigma_Y [\rho_{XY} Z_1 + (1 - \rho_{XY}^2)^{1/2} Z_2] \end{aligned}$$

jossa

$$\begin{aligned} -\infty < \mu_X < +\infty & \quad \sigma_X > 0 \\ -\infty < \mu_Y < +\infty & \quad \sigma_Y > 0 \\ -1 \leq \rho_{XY} \leq +1 & \end{aligned}$$

(i) Johdetaan ensin satunnaismuuttujien  $X$  ja  $Y$  tunnusluvut.

Satunnaismuuttujien  $X$  ja  $Y$  odotusarvot ovat

$$E(X) = E\{\mu_X + \sigma_X Z_1\} = \mu_X + \sigma_X E(Z_1) = \mu_X + \sigma_X \times 0 = \mu_X$$

ja

$$\begin{aligned} E(Y) &= E\{\mu_Y + \sigma_Y[\rho Z_1 + (1 - \rho^2)^{1/2} Z_2]\} \\ &= \mu_Y + \sigma_Y[\rho E(Z_1) + (1 - \rho^2)^{1/2} E(Z_2)] \\ &= \mu_Y + \sigma_Y[\rho \times 0 + (1 - \rho^2)^{1/2} \times 0] = \mu_Y \end{aligned}$$

Satunnaismuuttujien  $X$  ja  $Y$  varianssit ovat

$$\text{Var}(X) = E\{(X - E(X))^2\} = E\{\sigma_X^2 Z_1^2\} = \sigma_X^2 E(Z_1^2) = \sigma_X^2 \cdot 1 = \sigma_X^2$$

ja

$$\begin{aligned} \text{Var}(Y) &= E\{(Y - E(Y))^2\} \\ &= E\{\sigma_Y^2[\rho Z_1 + (1 - \rho^2)^{1/2} Z_2]^2\} \\ &= \sigma_Y^2 E\{\rho^2 Z_1^2 + (1 - \rho^2) Z_2^2 + 2\rho(1 - \rho^2)^{1/2} Z_1 Z_2\} \\ &= \sigma_Y^2 \{\rho^2 E(Z_1^2) + (1 - \rho^2) E(Z_2^2) + 2\rho(1 - \rho^2)^{1/2} E(Z_1 Z_2)\} \\ &= \sigma_Y^2 \{\rho^2 \times 1 + (1 - \rho^2) \times 1 + 2\rho(1 - \rho^2)^{1/2} \times 0\} \\ &= \sigma_Y^2 \end{aligned}$$

Satunnaismuuttujien  $X$  ja  $Y$  kovarianssi on

$$\begin{aligned} \text{Cov}(X, Y) &= E\{(X - E(X))(Y - E(Y))\} \\ &= E\{\sigma_X Z_1 \times \sigma_Y[\rho Z_1 + (1 - \rho^2)^{1/2} Z_2]\} \\ &= \sigma_X \sigma_Y E\{\rho Z_1^2 + (1 - \rho^2)^{1/2} Z_1 Z_2\} \\ &= \sigma_X \sigma_Y \{\rho E(Z_1^2) + (1 - \rho^2)^{1/2} E(Z_1 Z_2)\} \\ &= \sigma_X \sigma_Y \{\rho \times 1 + (1 - \rho^2)^{1/2} \times 0\} \\ &= \sigma_X \sigma_Y \rho \end{aligned}$$

Satunnaismuuttujien  $X$  ja  $Y$  korrelaatio on

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_X} = \frac{\sigma_X \sigma_Y \rho}{\sigma_X \sigma_X} = \rho$$

- (ii) Määritään seuraavaksi satunnaismuuttujien  $X$  ja  $Y$  jakaumat.

Satunnaismuuttuja  $X$  noudattaa *normaalijakaumaa*, koska se on standardoitua normaali-jakaumaa noudattavan satunnaismuuttujan  $Z_1$  *lineaarimuunnos*. Satunnaismuuttuja  $Y$  noudattaa *normaalijakaumaa*, koska se on riippumattomien standardoitua normaali-jakaumaa noudattavien satunnaismuuttujien  $Z_1$  ja  $Z_2$  *linearikombinaatio*.

Siten kohdassa (i) saatujen tulosten perusteella:

$$\begin{aligned} X & \sim N(\mu_X, \sigma_X^2) \\ Y & \sim N(\mu_Y, \sigma_Y^2) \end{aligned}$$

- (iii) Johdetaan lopuksi satunnaismuuttujien  $X$  ja  $Y$  yhteisjakauman tiheysfunktio.

Koska satunnaismuuttujat  $Z_1$  ja  $Z_2$  ovat *riippumattomia*, satunnaismuuttujien  $Z_1$  ja  $Z_2$  yhteisjakauman tiheysfunktio on satunnaismuuttujien  $Z_1$  ja  $Z_2$  tiheysfunktioiden tulo:

$$\begin{aligned}
 f_{z_1 z_2}(z_1, z_2) &= f_{z_1}(z_1) f_{z_2}(z_2) \\
 &= \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{1}{2} z_1^2\right\} \times \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{1}{2} z_2^2\right\} = \frac{1}{2\pi} \exp\left\{-\frac{1}{2}(z_1^2 + z_2^2)\right\}
 \end{aligned}$$

Olkoon

$$\begin{cases} x = \mu_x + \sigma_x z_1 \\ y = \mu_x + \sigma_y [\rho_{xy} z_1 + (1 - \rho_{xy}^2)^{1/2} z_2] \end{cases}$$

Transformaatio

$$(z_1, z_2) \rightarrow (x, y)$$

on bijektio:

$$\begin{cases} z_1 = \frac{x - \mu_x}{\sigma_x} \\ z_2 = \frac{1}{(1 - \rho_{xy}^2)^{1/2}} \left[ \frac{y - \mu_y}{\sigma_y} - \rho_{xy} \frac{x - \mu_x}{\sigma_x} \right] \end{cases}$$

Muunnoksen

$$(z_1, z_2) \rightarrow (x, y)$$

Jacobin determinantti on

$$\begin{aligned}
 \frac{\partial(x, y)}{\partial(z_1, z_2)} &= \frac{\partial x}{\partial z_1} \cdot \frac{\partial y}{\partial z_2} - \frac{\partial x}{\partial z_2} \cdot \frac{\partial y}{\partial z_1} \\
 &= \sigma_x \times \sigma_y (1 - \rho_{xy}^2)^{1/2} - 0 \times \sigma_y \rho_{xy} \\
 &= \sigma_x \sigma_y (1 - \rho_{xy}^2)^{1/2}
 \end{aligned}$$

Jos

$$\rho_{xy} = \pm 1$$

niin Jacobin determinantti

$$\frac{\partial(x, y)}{\partial(z_1, z_2)} = 0$$

Tällöin muunnoksen  $(Z_1, Z_2) \rightarrow (X, Y)$  tuloksena saadaan ns. *singulaarinen kaksikulotteinen normaalijakauma*, jonka jätämme tässä vain maininnan varaan.

Sen sijaan jos

$$-1 < \rho_{xy} < +1$$

niin

$$\frac{\partial(x, y)}{\partial(z_1, z_2)} = \sigma_x \sigma_y (1 - \rho_{xy}^2)^{1/2} \neq 0$$

ja satunnaisuuttujen  $X$  ja  $Y$  tiheysfunktio saadaan kaavasta

$$f_{XY}(x, y) = f_{z_1 z_2}(z_1, z_2) \left| \frac{\partial(x, y)}{\partial(z_1, z_2)} \right|^{-1}$$

Edellä on todettu, että

$$f_{z_1 z_2}(z_1, z_2) = \frac{1}{2\pi} \exp \left\{ -\frac{1}{2}(z_1^2 + z_2^2) \right\}$$

Tarkastellaan lauseketta

$$z_1^2 + z_2^2$$

Sijoitetaan tähän lausekkeeseen  $z_1$  ja  $z_2$  lausuttuina muuttujien  $x$  ja  $y$  funktioina eli

$$\begin{cases} z_1 = \frac{x - \mu_X}{\sigma_X} \\ z_2 = \frac{1}{(1 - \rho_{XY}^2)^{1/2}} \left[ \frac{y - \mu_Y}{\sigma_Y} - \rho_{XY} \frac{x - \mu_X}{\sigma_X} \right] \end{cases}$$

Siten

$$\begin{aligned} z_1^2 + z_2^2 &= \left( \frac{x - \mu_X}{\sigma_X} \right)^2 \\ &\quad + \frac{1}{1 - \rho_{XY}^2} \left[ \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2 - 2\rho_{XY} \left( \frac{y - \mu_Y}{\sigma_Y} \right) \left( \frac{x - \mu_X}{\sigma_X} \right) + \rho_{XY}^2 \left( \frac{x - \mu_X}{\sigma_X} \right)^2 \right] \\ &= \frac{1}{1 - \rho_{XY}^2} \left[ \left( \frac{x - \mu_X}{\sigma_X} \right)^2 - 2\rho_{XY} \left( \frac{y - \mu_Y}{\sigma_Y} \right) \left( \frac{x - \mu_X}{\sigma_X} \right) + \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2 \right] \end{aligned}$$

Lisäksi

$$\left| \frac{\partial(x, y)}{\partial(z_1, z_2)} \right|^{-1} = \left| \sigma_X \sigma_Y (1 - \rho_{XY}^2)^{1/2} \right|^{-1} = \frac{1}{\sigma_X \sigma_Y \sqrt{1 - \rho_{XY}^2}}$$

Yhdistämällä saadut tulokset saamme *satunnaismuuttujien X ja Y yhteisjakauman tiheysfunktion* lausekkeeksi *kaksiulotteisen normaalijakauman*  $N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$  *tiheysfunktion* lausekkeen:

$$f_{XY}(x, y) = f_{z_1 z_2}(z_1, z_2) \left| \frac{\partial(x, y)}{\partial(z_1, z_2)} \right|^{-1} = \frac{1}{2\pi \sigma_X \sigma_Y \sqrt{1 - \rho_{XY}^2}} \exp \left\{ -\frac{1}{2(1 - \rho_{XY}^2)} Q(x, y) \right\}$$

jossa

$$Q(x, y) = \left( \frac{x - \mu_X}{\sigma_X} \right)^2 - 2\rho_{XY} \left( \frac{y - \mu_Y}{\sigma_Y} \right) \left( \frac{x - \mu_X}{\sigma_X} \right) + \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2$$

■

## Kaksiulotteisen normaalijakauman tunnusluvut

Olkoon

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

**Odotusarvot:**

$$E(X) = \mu_X$$

$$E(Y) = \mu_Y$$

**Varianssit:**

$$\text{Var}(X) = D^2(X) = \sigma_X^2 = E[(X - \mu_X)^2]$$

$$\text{Var}(Y) = D^2(Y) = \sigma_Y^2 = E[(Y - \mu_Y)^2]$$

**Korrelaatio:**

$$\text{Cor}(X, Y) = \rho_{XY}$$

**Kovarianssi:**

$$\text{Cov}(X, Y) = \sigma_{XY} = E[(X - \mu_X)(Y - \mu_Y)] = \rho_{XY}\sigma_X\sigma_Y$$

## 2-ulotteisen normaalijakauman tiheysfunktio ja sen ominaisuudet

Kaksiulotteisen normaalijakauman tiheysfunktio  $f_{XY}(x, y)$  muodostaa *pinnan*

$$z = f_{XY}(x, y)$$

kolmiulotteisessa avaruudessa <sup>3</sup>. Pinnalla  $z = f_{XY}(x, y)$  on *maksimi* satunnaismuuttujien  $X$  ja  $Y$  odotusarvojen  $\mu_X$  ja  $\mu_Y$  määräämässä pisteessä

$$(\mu_X, \mu_Y)$$

Piste  $(\mu_X, \mu_Y)$  määrää kaksiulotteisen normaalijakauman *todennäköisyysmassan painopisteen*.

2-ulotteisen normaalijakauman tiheysfunktion määrittelevässä yhtälössä (1) lauseke

$$Q(x, y) = \left( \frac{x - \mu_X}{\sigma_X} \right)^2 - 2\rho_{XY} \left( \frac{x - \mu_X}{\sigma_X} \right) \left( \frac{y - \mu_Y}{\sigma_Y} \right) + \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2$$

määrää pinnan  $z = f_{XY}(x, y)$  muodon määräämällä sen *tasa-arvokäyrät*. Tasa-arvokäyrät ovat **ellipsejä**, joiden yhtälöt voidaan esittää muodossa

$$Q(x, y) = c^2$$

missä  $c$  on vakio. Kaksiulotteisen normaalijakauman tiheysfunktion muodostaman pinnan muodon määräävillä *tasa-arvoellipseilla* on seuraavat *ominaisuudet*:

(i) Ellipsien *keskipisteenä* on jakauman todennäköisyysmassan *painopiste*

$$(\mu_X, \mu_Y)$$

(ii) Ellipsien *eksentrisyys* on sekä korrelaatiokertoimen  $\rho_{XY}$  että standardipoikkeamien  $\sigma_X$  ja  $\sigma_Y$  funktio.



- (iii) Ellipsi on sitä *eksentrisempi* mitä *voimakkaammin* satunnaismuuttujat  $X$  ja  $Y$  ovat *korreloituneita* eli mitä suurempi on

$$|\rho_{XY}|$$

- (iv) Jos

$$\rho_{XY} = 0$$

ellipsien *pääakselit* ovat koordinaattiakselien suuntaiset.

- (v) Jos

$$\rho_{XY} = 0$$

ja lisäksi

$$\sigma_X = \sigma_Y$$

niin ellipsit ovat *ympyröitä*.

- (vi) Jos

$$\rho_{XY} = \pm 1$$

niin ellipsit surkastuvat *janoiksi*.

## 2-ulotteisen normaalijakauman odotusarvovektori ja kovarianssimatriisi

Olkoon

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

Määritellään 2-ulotteista normaalijakaumaa noudattavan satunnaismuuttujien  $X$  ja  $Y$  muodostaman parin  $(X, Y)$  **odotusarvovektori**  $\mu$  ja **kovarianssimatriisi**  $\Sigma$  kaavoilla

$$\mu = \begin{bmatrix} \mu_X \\ \mu_Y \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} \sigma_X^2 & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 \end{bmatrix} = \begin{bmatrix} \sigma_X^2 & \rho_{XY}\sigma_X\sigma_Y \\ \rho_{XY}\sigma_X\sigma_Y & \sigma_Y^2 \end{bmatrix}$$

Huomaa, että kovarianssimatriisi  $\Sigma$  on *symmetrinen*:

$$\Sigma' = \Sigma$$

Odotusarvovektori  $\mu = (\mu_X, \mu_Y)$  määrää 2-ulotteisen normaalijakauman tiheysfunktion muodostaman pinnan muodon määrävien *tasa-arvoellipsien*

$$Q(x, y) = \left( \frac{x - \mu_X}{\sigma_X} \right)^2 - 2\rho \left( \frac{x - \mu_X}{\sigma_X} \right) \left( \frac{y - \mu_Y}{\sigma_Y} \right) + \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2 = c^2$$

*keskipisteen*.

2-ulotteisen normaalijakauman tiheysfunktion muodostaman pinnan muodon määrävien *tasa-arvoellipsien pääakselien pituudet* (oikeammin: pituuksien suhteet) ja *suunnat* saadaan määräämällä *kovarianssimatriisin*

$$\Sigma = \begin{bmatrix} \sigma_X^2 & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 \end{bmatrix} = \begin{bmatrix} \sigma_X^2 & \rho_{XY}\sigma_X\sigma_Y \\ \rho_{XY}\sigma_X\sigma_Y & \sigma_Y^2 \end{bmatrix}$$

ominaisarvot ja ominaisvektorit.

Olkoon

$$\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

2×2-yksikkömatriisi.

Kovarianssimatriisin  $\Sigma$  ominaisarvot saadaan määräämällä *determinanttiyhtälön*

$$(1) \quad |\Sigma - \lambda \mathbf{I}| = \begin{vmatrix} \sigma_X^2 - \lambda & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 - \lambda \end{vmatrix} = \lambda^2 - (\sigma_X^2 + \sigma_Y^2)\lambda + \sigma_X^2\sigma_Y^2 - \sigma_{XY}^2 = 0$$

ratkaisut muuttujan  $\lambda$  suhteen. Ominaisarvot ovat *reaalisia*, koska kovarianssimatriisi  $\Sigma$  on *symmetrinen*. 2. asteen yhtälön (1) juuret saadaan kaavasta

$$\lambda = \frac{\sigma_X^2 + \sigma_Y^2 \pm \sqrt{(\sigma_X^2 + \sigma_Y^2)^2 - 4(\sigma_X^2\sigma_Y^2 - \sigma_{XY}^2)}}{2}$$

Olkoot juuret

$$(2) \quad \begin{aligned} \lambda_1 &= \frac{1}{2} \left[ \sigma_X^2 + \sigma_Y^2 + \sqrt{(\sigma_X^2 + \sigma_Y^2)^2 - 4(\sigma_X^2\sigma_Y^2 - \sigma_{XY}^2)} \right] \\ \lambda_2 &= \frac{1}{2} \left[ \sigma_X^2 + \sigma_Y^2 - \sqrt{(\sigma_X^2 + \sigma_Y^2)^2 - 4(\sigma_X^2\sigma_Y^2 - \sigma_{XY}^2)} \right] \end{aligned}$$

Näemme myös kaavoista (2), että ominaisarvot  $\lambda_1$  ja  $\lambda_2$  ovat reaalisia. Tämä johtuu siitä, että yhtälön (1) *diskriminantti*

$$D = (\sigma_X^2 + \sigma_Y^2)^2 - 4(\sigma_X^2\sigma_Y^2 - \sigma_{XY}^2)$$

on aina *ei-negatiivinen*:

$$D = (\sigma_X^2 + \sigma_Y^2)^2 - 4(\sigma_X^2\sigma_Y^2 - \sigma_{XY}^2) = (\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_{XY}^2 \geq 0$$

Lisäksi yhtälön (1) juurien kaavoista (2) nähdään, että

$$\lambda_1 \geq \lambda_2$$

Ominaisarvot  $\lambda_1$  ja  $\lambda_2$  ovat aina *ei-negatiivisia*. On helppo nähdä, että ominaisarvo  $\lambda_1$  on itse asiassa aina *positiivinen*. Ominaisarvon  $\lambda_2$  *ei-negatiivisuus* nähdään seuraavalla tavalla:

Koska

$$\rho_{XY}^2 = \frac{\sigma_{XY}^2}{\sigma_X^2\sigma_Y^2} \leq 1$$

niin

$$D = (\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_{XY}^2 \leq (\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_X^2\sigma_Y^2 = (\sigma_X^2 + \sigma_Y^2)^2$$

jolloin

$$\lambda_2 = \frac{1}{2} \left[ \sigma_X^2 + \sigma_Y^2 - \sqrt{(\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_{XY}^2} \right] \geq \frac{1}{2} \left[ \sigma_X^2 + \sigma_Y^2 - \sqrt{(\sigma_X^2 + \sigma_Y^2)^2} \right] = 0$$

Lisäksi

$$\lambda_2 = 0$$

täsmälleen silloin, kun

$$\rho_{XY}^2 = \frac{\sigma_{XY}^2}{\sigma_X^2 \sigma_Y^2} = 1$$

Matriisin  $\Sigma$  ominaisarvoja  $\lambda_1$  ja  $\lambda_2$  vastaavat **ominaisvektorit**

$$\mathbf{q}_1 = (q_{11}, q_{21})$$

$$\mathbf{q}_2 = (q_{12}, q_{22})$$

saadaan yhtälöistä

$$\Sigma \mathbf{q}_i = \lambda_i \mathbf{q}_i, \quad i = 1, 2$$

ottamalla huomioon ehdot

$$\mathbf{q}_i' \mathbf{q}_i = q_{1i}^2 + q_{2i}^2 = 1, \quad i = 1, 2$$

Siten ominaisvektori  $\mathbf{q}_i, i = 1, 2$  saadaan ratkaistuksi yhtälöryhmästä

$$\begin{cases} (\sigma_X^2 - \lambda_i) q_{1i} + \sigma_{XY} q_{2i} = 0 \\ \sigma_{XY} q_{1i} + (\sigma_Y^2 - \lambda_i) q_{2i} = 0 \\ q_{1i}^2 + q_{2i}^2 = 1 \end{cases}$$

Muodostetaan matriisin  $\Sigma$  ominaisarvoista  $\lambda_1$  ja  $\lambda_2$  *diagonaalimatriisi*

$$\mathbf{L} = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix}$$

ja matriisin  $\Sigma$  ominaisvektoreiden  $\mathbf{q}_1 = (q_{11}, q_{21})$  ja  $\mathbf{q}_2 = (q_{12}, q_{22})$  komponenteista matriisi

$$\mathbf{Q} = \begin{bmatrix} q_{11} & q_{12} \\ q_{21} & q_{22} \end{bmatrix}$$

Symmetristen matriisien ominaisarvojen ja -vektoreiden yleisten ominaisuuksien perusteella tiedetään, että matriisi  $\mathbf{Q}$  on *ortogonaalinen*, joten

$$\mathbf{Q}'\mathbf{Q} = \mathbf{Q}\mathbf{Q}' = \mathbf{I}$$

Matriisit  $\Sigma, \mathbf{L}$  ja  $\mathbf{Q}$  toteuttavat matriisiyhtälöt

$$\Sigma = \mathbf{Q}\mathbf{L}\mathbf{Q}'$$

ja

$$\mathbf{L} = \mathbf{Q}'\Sigma\mathbf{Q}$$

Yhtälöä  $\Sigma = \mathbf{Q}\mathbf{L}\mathbf{Q}'$  kutsutaan tavallisesti matriisin  $\Sigma$  **pääakselihajotelmaksi**.

Tasa-arvoellipsien

$$Q(x, y) = c^2$$

pääakseleiden *pituudet* suhtautuvat toisiinsa kuten *ominaisarvojen*  $\lambda_1$  ja  $\lambda_2$  *neliöjuuret* ja pääakseleiden *suunnat* yhtyvät vastaavien *ominaisvektoreiden* suuntiin.

## 2-ulotteisen normaalijakauman reunajakaumat

Olkoon

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

Satunnaismuuttujien  $X$  ja  $Y$  **reunajakaumat** ovat 1-ulotteisia normaalijakaumia:

$$\begin{aligned} X &\sim N(\mu_X, \sigma_X^2) \\ Y &\sim N(\mu_Y, \sigma_Y^2) \end{aligned}$$

## 2-ulotteinen normaalijakauma, korreloimattomuus ja riippumattomuus

Olkoon

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

Jos

$$\rho_{XY} = 0$$

niin satunnaismuuttujat  $X$  ja  $Y$  ovat *riippumattomia*.

### Perustelu:

Kaksiulotteisen normaalijakauman *tiheysfunktio* on

$$f_{XY}(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho_{XY}^2}} \exp\left\{-\frac{1}{2(1-\rho_{XY}^2)}Q(x, y)\right\}$$

jossa

$$Q(x, y) = \left(\frac{x-\mu_X}{\sigma_X}\right)^2 - 2\rho_{XY}\left(\frac{x-\mu_X}{\sigma_X}\right)\left(\frac{y-\mu_Y}{\sigma_Y}\right) + \left(\frac{y-\mu_Y}{\sigma_Y}\right)^2$$

Oletetaan, että

$$\rho_{XY} = 0$$

Tällöin satunnaismuuttujien  $X$  ja  $Y$  yhteisjakauman tiheysfunktio hajoaa satunnaismuuttujien reunajakaumien tiheysfunktioiden tuloksi:

$$\begin{aligned} f_{XY}(x, y) &= \frac{1}{2\pi\sigma_X\sigma_Y} \exp\left\{-\frac{1}{2}\left[\left(\frac{x-\mu_X}{\sigma_X}\right)^2 + \left(\frac{y-\mu_Y}{\sigma_Y}\right)^2\right]\right\} \\ &= \frac{1}{\sqrt{2\pi}\sigma_X} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu_X}{\sigma_X}\right)^2\right\} \cdot \frac{1}{\sqrt{2\pi}\sigma_Y} \exp\left\{-\frac{1}{2}\left(\frac{y-\mu_Y}{\sigma_Y}\right)^2\right\} \end{aligned}$$

$$= f_X(x)f_Y(y)$$

jossa  $f_X(x)$  on satunnaismuuttujan  $X$  reunajakauman tiheysfunktio ja  $f_Y(y)$  on satunnaismuuttujan  $Y$  reunajakauman tiheysfunktio.

Koska satunnaismuuttujien  $X$  ja  $Y$  yhteisjakauman tiheysfunktio  $f_{XY}(x, y)$  on voitu esittää satunnaismuuttujien  $X$  ja  $Y$  reunajakaumien tiheysfunktioiden tulona, satunnaismuuttujat  $X$  ja  $Y$  ovat *riippumattomia*. ■

On syytä huomata, että **vaikka 2-ulotteisen normaalijakauman tapauksessa satunnaismuuttujien  $X$  ja  $Y$  korreloimattomuudesta seuraa niiden riippumattomuus, tämä ei ole yleisesti totta**. Sen sijaan aina pätee, että **satunnaismuuttujien riippumattomuudesta seuraa niiden korreloimattomuus**.

### 2-ulotteisen normaalijakauman ehdolliset jakaumat

Olkoon

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

2-ulotteisen normaalijakauman **ehdolliset jakaumat** ovat 1-ulotteisia normaalijakaumia:

$$(X | Y) \sim N(\mu_X + \beta_{XY}(y - \mu_Y), \sigma_X^2(1 - \rho_{XY}^2)), \beta_{XY} = \rho_{XY} \frac{\sigma_X}{\sigma_Y}$$

$$(Y | X) \sim N(\mu_Y + \beta_{YX}(x - \mu_X), \sigma_Y^2(1 - \rho_{XY}^2)), \beta_{YX} = \rho_{XY} \frac{\sigma_Y}{\sigma_X}$$

### Perustelu:

Esitetään perustelu *kaksiulotteisen normaalijakauman ehdollisten jakaumien normaalisuudelle* tarkastelemalla satunnaismuuttujan  $X$  ehdollista jakaumaa satunnaismuuttujan  $Y$  suhteen (ehdolla  $Y = y$ ).

Olkoon

$f_{XY}(x, y)$  = Satunnaismuuttujien  $X$  ja  $Y$  yhteisjakauman tiheysfunktio

$f_{X|Y}(x | y)$  = Satunnaismuuttujan  $X$  ehdollisen jakauman tiheysfunktio satunnaismuuttujan  $Y$  suhteen

$f_Y(y)$  = Satunnaismuuttujan  $Y$  reunajakauman tiheysfunktio

Ehdollisen jakauman tiheysfunktion määritelmän mukaan

$$f_{X|Y}(x | y) = \frac{f_{XY}(x, y)}{f_Y(y)}$$

Kaksiulotteisen normaalijakauman *tiheysfunktio* on muotoa

$$f_{XY}(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho_{XY}^2}} \exp\left\{-\frac{1}{2(1-\rho_{XY}^2)}Q(x, y)\right\}$$

jossa

$$Q(x, y) = \left( \frac{x - \mu_X}{\sigma_X} \right)^2 - 2\rho_{XY} \left( \frac{x - \mu_X}{\sigma_X} \right) \left( \frac{y - \mu_Y}{\sigma_Y} \right) + \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2$$

Satunnaismuuttujan  $Y$  reunajakauman *tiheysfunktio* on muotoa

$$f_Y(y) = \frac{1}{\sqrt{2\pi}\sigma_Y} \exp \left\{ -\frac{1}{2} \left( \frac{y - \mu_Y}{\sigma_Y} \right)^2 \right\}$$

Melko helposti nähdään, että

$$f_{X|Y}(x | y) = \frac{f_{XY}(x, y)}{f_Y(y)} = \frac{1}{\sqrt{2\pi\sigma_X^2(1-\rho_{XY}^2)}} \exp \left\{ -\frac{1}{2\sigma_X^2(1-\rho_{XY}^2)} Q(x | y) \right\}$$

jossa

$$Q(x | y) = \left[ x - \mu_X - \rho_{XY} \frac{\sigma_X}{\sigma_Y} (y - \mu_Y) \right]^2$$

Siten satunnaismuuttujan  $X$  *ehdollinen jakauma* satunnaismuuttujan  $Y$  suhteen (ehdolla  $Y = y$ ) on *normaalinen*:

$$(X | Y = y) \sim N(\mu_{X|Y}, \sigma_{X|Y}^2)$$

jossa

$$\mu_{X|Y} = E(X | Y = y) = \mu_X + \rho_{XY} \frac{\sigma_X}{\sigma_Y} (y - \mu_Y)$$

$$\sigma_{X|Y}^2 = \text{Var}(X | Y = y) = (1 - \rho_{XY}^2) \sigma_X^2$$

■

## 2-ulotteisen normaalijakauman ehdolliset odotusarvot

Olkoon

$$(X, Y) \sim N_2(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho_{XY})$$

Satunnaismuuttujan  $X$  **ehdollinen odotusarvo** satunnaismuuttujan  $Y$  suhteen on muotoa

$$E(X | Y) = \mu_X + \beta_{XY}(y - \mu_Y)$$

Satunnaismuuttujan  $X$  ehdollinen odotusarvo satunnaismuuttujan  $Y$  suhteen muodostaa satunnaismuuttujan  $Y$  arvojen  $y$  funktiona satunnaismuuttujan  $X$  **regressiofunktion** satunnaismuuttujan  $Y$  arvojen suhteen. 2-ulotteisen normaalijakauman tapauksessa satunnaismuuttujan  $X$  regressiofunktio satunnaismuuttujan  $Y$  suhteen määrää *suoran*

$$x = \mu_X + \beta_{XY}(y - \mu_Y)$$

Kutsumme tätä suoraa muuttujan  $x$  **regressiosuoraksi** muuttujan  $y$  suhteen. Suoran *kulmakerroin* on

$$\beta_{XY} = \rho_{XY} \frac{\sigma_X}{\sigma_Y}$$

ja se kulkee satunnaismuuttujien  $X$  ja  $Y$  odotusarvojen määräämän pisteen  $(\mu_X, \mu_Y)$  kautta.

Satunnaismuuttujan  $X$  **ehdollinen odotusarvo** satunnaismuuttujan  $Y$  suhteen on

$$E(X | Y) = \mu_X + \beta_{XY}(y - \mu_Y)$$

Satunnaismuuttujan  $Y$  ehdollinen odotusarvo satunnaismuuttujan  $X$  suhteen muodostaa satunnaismuuttujan  $X$  arvojen  $x$  funktiona satunnaismuuttujan  $Y$  **regressiofunktion** satunnaismuuttujan  $X$  arvojen suhteen. 2-ulotteisen normaalijakauman tapauksessa satunnaismuuttujan  $Y$  regressiofunktio satunnaismuuttujan  $X$  suhteen määrää *suoran*

$$y = \mu_Y + \beta_{YX}(x - \mu_X)$$

Kutsumme tätä suoraa muuttujan  $y$  **regressiosuoraksi** muuttujan  $x$  suhteen. Suoran *kulmakerroin* on

$$\beta_{YX} = \rho_{XY} \frac{\sigma_Y}{\sigma_X}$$

ja se kulkee satunnaismuuttujien  $X$  ja  $Y$  odotusarvojen määräämän pisteen  $(\mu_X, \mu_Y)$  kautta.

Huomaa, että regressiosuorien kulmakertoimet  $\beta_{YX}$  ja  $\beta_{XY}$  toteuttavat yhtälön

$$\beta_{YX} \beta_{XY} = \rho_{XY}^2$$

Lisäksi *molemmat* regressiosuorat kulkevat 2-ulotteisen normaalijakauman todennäköisyysmassan painopisteen  $(\mu_X, \mu_Y)$  kautta.

### Regressiosuorien ominaisuudet

Kirjoitetaan molempien regressiosuorien yhtälöt muuttujan  $x$  funktiona.

Muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen:

$$y = \mu_Y + \frac{1}{\beta_{XY}}(x - \mu_X) = \mu_Y + \frac{1}{\rho_{XY}} \cdot \frac{\sigma_Y}{\sigma_X}(x - \mu_X)$$

Muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen:

$$y = \mu_Y + \beta_{YX}(x - \mu_X) = \mu_Y + \rho_{XY} \frac{\sigma_Y}{\sigma_X}(x - \mu_X)$$

Regressiosuorilla on seuraavat ominaisuudet:

- (i) Molemmat regressiosuorat kulkevat 2-ulotteisen normaalijakauman todennäköisyysmassan painopisteen  $(\mu_X, \mu_Y)$  kautta.
- (ii) Molempien regressiosuorien kulmakertoimilla  $\beta_{YX}$  ja  $\beta_{XY}$  sekä satunnaismuuttujien  $X$  ja  $Y$  korrelaatiokertoimella  $\rho_{XY}$  on *aina sama merkki*:

Suorat ovat *nousevia*, jos

$$\rho_{XY} > 0$$

Suorat ovat *laskevia*, jos

$$\rho_{XY} < 0$$

- (iii) Muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen on *aina loivempi* kuin muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen, koska

$$\rho_{XY}^2 \leq 1$$

- (iv) Muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen on *sitä loivempi mitä voimakkaammin satunnaismuuttujat  $X$  ja  $Y$  ovat korreloituneita* eli mitä suurempi on

$$|\rho_{XY}|$$

- (v) Muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen on *sitä jyrkempi mitä voimakkaammin satunnaismuuttujat  $X$  ja  $Y$  ovat korreloituneita* eli mitä suurempi on

$$|\rho_{XY}|$$

- (vi) Molemmat regressiosuorat ovat *sitä jyrkempiä mitä pienempi on satunnaismuuttujan  $X$  varianssi*

$$\sigma_x^2$$

- (vii) Molemmat regressiosuorat ovat *sitä jyrkempiä mitä suurempi on satunnaismuuttujan  $Y$  varianssi*

$$\sigma_y^2$$

- (viii) Regressiosuorat *yhtyvät* täsmälleen silloin, kun

$$\rho_{XY} = \pm 1$$

- (ix) Jos

$$\rho_{XY} = 0$$

niin regressiosuorat ovat *kohtisuorassa toisiaan vastaan* ja muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen on

$$x = \mu_x$$

ja muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen on

$$y = \mu_y$$

Tällöin satunnaismuuttujan  $X$  saamat arvot *eivät riipu* satunnaismuuttujan  $Y$  saamista arvoista ja satunnaismuuttujan  $Y$  saamat arvot *eivät riipu* satunnaismuuttujan  $X$  saamista arvoista.

### Regressiosuorien yhtälöt ja standardointi

Regressiosuorien yhtälöt voidaan kirjoittaa **standardoitujen muuttujien**

$$x' = \frac{x - \mu_x}{\sigma_x}$$

$$y' = \frac{y - \mu_y}{\sigma_y}$$

*funktioina* seuraaviin muotoihin: Muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen on standardoiduissa muuttujissa  $x'$  ja  $y'$  muotoa



$$y' = \frac{1}{\rho_{XY}} x'$$

ja muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen on standardoiduissa muuttujissa  $x'$  ja  $y'$  muotoa

$$y' = \rho_{XY} x'$$

Huomaa, että *standardoitujen muuttujien* välisten regressiosuorien kulmakertoimet ovat toistensa käänteislukuja.

### Yhteiskorrelaatiokerroin

2-ulotteisen normaalijakauman tapauksessa satunnaismuuttujien  $X$  ja  $Y$  yhteiskorrelaatiokerroin on

$$R_{X|Y} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = \rho_{XY} = \frac{\sigma_{YX}}{\sigma_Y \sigma_X} = R_{Y|X}$$

### 2-ulotteisen normaalijakauman ehdolliset varianssit

Satunnaismuuttujan  $X$  ehdollinen varianssi satunnaismuuttujan  $Y$  suhteen on

$$\sigma_{X|Y}^2 = \sigma_X^2 (1 - \rho_{XY}^2)$$

Satunnaismuuttujan  $X$  ehdollinen varianssi satunnaismuuttujan  $Y$  suhteen on

$$\sigma_{Y|X}^2 = \sigma_Y^2 (1 - \rho_{XY}^2)$$

Huomaa, että kumpikaan ehdollinen varianssi *ei riipu* ehtomuuttujansa arvosta.

Koska

$$|\rho_{XY}| \leq 1$$

niin ehdollisten varianssien kaavoista nähdään, että

$$\sigma_{X|Y}^2 \leq \sigma_X^2$$

ja

$$\sigma_{Y|X}^2 \leq \sigma_Y^2$$

### Esimerkki 2-ulotteisesta normaalijakaumasta

Olkoon

$$(X, Y) \sim N_2(4, 3, 2, 1, 0.7)$$

Siten jakauman parametrit ovat

$$\begin{aligned} E(X) &= \mu_X = 4 & \text{Var}(X) &= \sigma_X^2 = 2 \\ E(Y) &= \mu_Y = 3 & \text{Var}(Y) &= \sigma_Y^2 = 1 \\ \text{Cor}(X, Y) &= \rho_{XY} = 0.7 \end{aligned}$$

joten

$$\text{Cov}(X, Y) = \rho_{XY} \sigma_X \sigma_Y = 0.7 \times \sqrt{2} \times \sqrt{1} \approx 0.9899$$

Kuva oikealla esittää esimerkin 2-ulotteisen normaalijakauman tiheysfunktiota

$$f_{XY}(x, y)$$

Jakauman todennäköisyysmassan painopisteenä on piste

$$(\mu_x, \mu_y) = (4, 3)$$


**Odotusarvovektori ja kovarianssimatriisi**

Jakauman odotusarvovektori on

$$\boldsymbol{\mu} = \begin{bmatrix} \mu_x \\ \mu_y \end{bmatrix} = \begin{bmatrix} 4 \\ 3 \end{bmatrix}$$

Jakauman kovarianssimatriisi on

$$\begin{aligned} \boldsymbol{\Sigma} &= \begin{bmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{bmatrix} \\ &= \begin{bmatrix} \sigma_x^2 & \rho_{xy}\sigma_x\sigma_y \\ \rho_{xy}\sigma_x\sigma_y & \sigma_y^2 \end{bmatrix} \\ &= \begin{bmatrix} 2 & 0.7 \times \sqrt{2} \times \sqrt{1} \\ 0.7 \times \sqrt{2} \times \sqrt{1} & 1 \end{bmatrix} \\ &= \begin{bmatrix} 2 & 0.9899 \\ 0.9899 & 1 \end{bmatrix} \end{aligned}$$



**Tasa-arvoellipsit**

Tiheysfunktion  $f_{XY}(x, y)$  määrävän pinnan muodon määrävät *tasa-arvoellipsit*

$$Q(x, y) = \left(\frac{x-4}{\sqrt{2}}\right)^2 - 2 \times 0.7 \left(\frac{x-4}{\sqrt{2}}\right) \left(\frac{y-3}{\sqrt{1}}\right) + \left(\frac{y-3}{\sqrt{1}}\right)^2 = c^2$$

Ellipsien *keskipisteenä* on jakauman todennäköisyysmassan *painopiste*

$$(\mu_x, \mu_y) = (4, 3)$$

Olkoon

$$\boldsymbol{\Sigma} = \mathbf{QLQ}'$$

kovarianssimatriisin  $\boldsymbol{\Sigma}$  *pääakselihajotelma*, jossa  $\mathbf{L}$  on matriisin  $\boldsymbol{\Sigma}$  *ominaisarvojen* muodostama *diagonaalimatriisi* ja  $\mathbf{Q}$  on vastaavien *ominaisvektoreiden* muodostama *ortogonaalinen matriisi*, jossa ominaisvektorit ovat sarakkeina.

Olkoot

$$\lambda_1 \geq \lambda_2$$

matriisin  $\boldsymbol{\Sigma}$  *ominaisarvot* ja

$$\mathbf{q}_1 = (q_{11}, q_{21})$$

$$\mathbf{q}_2 = (q_{12}, q_{22})$$

vastaavat *ominaisvektorit*. Tällöin

$$\mathbf{L} = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix}$$

$$\mathbf{Q} = \begin{bmatrix} q_{11} & q_{12} \\ q_{21} & q_{22} \end{bmatrix}$$

Matriisit  $\Sigma$ ,  $\mathbf{L}$  ja  $\mathbf{Q}$  toteuttavat matriisiyhtälöt

$$\Sigma = \mathbf{Q}\mathbf{L}\mathbf{Q}'$$

ja

$$\mathbf{L} = \mathbf{Q}'\Sigma\mathbf{Q}$$

Olkoon  $\lambda$  kovarianssimatriisin  $\Sigma$  *ominaisarvo*. Tällöin  $\lambda$  toteuttaa 2. asteen yhtälön

$$\det(\Sigma - \lambda\mathbf{I}_2) = \det \begin{bmatrix} \sigma_X^2 - \lambda & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 - \lambda \end{bmatrix} = \lambda^2 - (\sigma_X^2 + \sigma_Y^2)\lambda + \sigma_X^2\sigma_Y^2 - \sigma_{XY}^2 = 0$$

Tämän 2. asteen yhtälön ratkaisut saadaan kaavasta

$$\lambda = \frac{\sigma_X^2 + \sigma_Y^2 \pm \sqrt{(\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_{XY}^2}}{2}$$

Ratkaisuiksi saadaan

$$\begin{aligned} \lambda_1 &= \left[ \sigma_X^2 + \sigma_Y^2 + \sqrt{(\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_{XY}^2} \right] \\ &= \frac{1}{2} \left[ 2 + 1 + \sqrt{(2-1)^2 + 4 \times (0.7 \times \sqrt{2})^2} \right] \\ &= \frac{1}{2} \left[ 3 + \sqrt{4.92} \right] \approx 2.6091 \end{aligned}$$

$$\begin{aligned} \lambda_2 &= \left[ \sigma_X^2 + \sigma_Y^2 - \sqrt{(\sigma_X^2 - \sigma_Y^2)^2 + 4\sigma_{XY}^2} \right] \\ &= \frac{1}{2} \left[ 2 + 1 - \sqrt{(2-1)^2 + 4 \times (0.7 \times \sqrt{2})^2} \right] \\ &= \frac{1}{2} \left[ 3 - \sqrt{4.92} \right] \approx 0.3909 \end{aligned}$$

Olkoon  $\mathbf{q} = (q_1, q_2)$  kovarianssimatriisin  $\Sigma$  ominaisarvoa  $\lambda$  vastaava *ominaisvektori*. Tällöin  $\mathbf{q}$  toteuttaa *matriisiyhtälön*

$$\Sigma\mathbf{q} = \lambda\mathbf{q}$$

Koska vaadimme, että

$$\mathbf{q}'\mathbf{q} = q_1^2 + q_2^2 = 1$$

niin vektori  $\mathbf{q} = (q_1, q_2)$  saadaan ratkaistuksi yhtälöryhmästä

$$\begin{cases} (\sigma_X^2 - \lambda)q_1 + \sigma_{XY}q_2 = 0 \\ \sigma_{XY}q_1 + (\sigma_Y^2 - \lambda)q_2 = 0 \\ q_1^2 + q_2^2 = 1 \end{cases}$$

Ominaisarvoa

$$\lambda_1 = 2.6091$$

vastaavaksi ominaisvektoriksi saadaan

$$\mathbf{q}_1 = (q_{11}, q_{21}) = (0.8517, 0.5240)$$

Ominaisarvoa

$$\lambda_2 = 0.3909$$

vastaavaksi ominaisvektoriksi saadaan

$$\mathbf{q}_2 = (q_{12}, q_{22}) = (-0.5240, 0.8517)$$

Siten kovarianssimatriisin

$$\Sigma = \begin{bmatrix} \sigma_X^2 & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 \end{bmatrix} = \begin{bmatrix} 2 & 0.7\sqrt{2} \\ 0.7\sqrt{2} & 1 \end{bmatrix} = \begin{bmatrix} 2 & 0.9899 \\ 0.9899 & 1 \end{bmatrix}$$

*pääakselihajotelman*

$$\Sigma = \mathbf{Q}\mathbf{L}\mathbf{Q}'$$

matriiseiksi  $\mathbf{L}$  ja  $\mathbf{Q}$  saadaan

$$\mathbf{L} = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} = \begin{bmatrix} 2.6091 & 0 \\ 0 & 0.3909 \end{bmatrix}$$

$$\mathbf{Q} = \begin{bmatrix} q_{11} & q_{12} \\ q_{21} & q_{22} \end{bmatrix} = \begin{bmatrix} 0.8517 & -0.5240 \\ 0.5240 & 0.8517 \end{bmatrix}$$

jossa  $\mathbf{L}$  on matriisin  $\Sigma$  ominaisarvojen muodostama *diagonaalimatriisi* ja  $\mathbf{Q}$  on vastaavien *ominaisvektoreiden* muodostama *ortogonaalinen matriisi*, jossa matriisin  $\Sigma$  vastaavat ominaisvektorit ovat sarakkeina.

Yllä esitetyn mukaan jakauman tiheysfunktion määräämän pinnan muodon määräävien tasa-arvoellipsien *pääakselit leikkaavat* jakauman todennäköisyysmassan *painopisteessä*

$$(\mu_X, \mu_Y) = (4, 3)$$

Tasa-arvoellipsien *pääakseleiden pituudet* suhtautuvat toisiinsa kuten kovarianssimatriisin  $\Sigma$  ominaisarvojen

$$\lambda_1 = 2.6091$$

$$\lambda_2 = 0.3909$$

neliöjuuret ja vastaavat ominaisvektorit  $\mathbf{q}_1$  ja  $\mathbf{q}_2$  määräävät *pääakseleiden suunnat*.

Tasa-arvoellipsien *pääakseleiden suuntaisten suorien yhtälöt* ovat

$$y = a_1 + b_1x$$

$$y = a_2 + b_2x$$

jossa

$$b_1 = \frac{q_{21}}{q_{11}} = \frac{0.5240}{0.8517} = 0.6152$$

$$a_1 = \mu_y - b_1\mu_x = 3 - b_1 \times 4 = 0.5390$$

ovat suurempaa ominaisarvoa  $\lambda_1 = 2.6091$  vastaavan, pitempään pääakseliin liittyvän suoran kertoimet ja

$$b_2 = \frac{q_{22}}{q_{12}} = -\frac{0.8517}{0.5240} = -1.6254$$

$$a_2 = \mu_y - b_2\mu_x = 3 - b_2 \times 4 = 9.5015$$

ovat pienempää ominaisarvoa  $\lambda_2 = 0.3909$  vastaavan, lyhyempään pääakseliin liittyvän suoran kertoimet.


Kuva oikealla esittää esimerkin 2-ulotteisen normaali-jakauman tiheysfunktion *tasa-arvoellipsejä*, jotka vastaavat (likimäärin) *todennäköisyyksiä* 68 %, 95 % ja 99.7 %.

Esimerkiksi *uloimman* ellipsin sisään jää n. 99.7 % jakauman todennäköisyssmassasta.

Kuvaan on lisäksi piirretty tasa-arvoellipsien *pääakseliensa suuntaiset suorat*

$$y = 0.5390 + 0.6152 \times x$$

$$y = 9.5015 - 1.6254 \times x$$





### Reunajakaumat

Esimerkin 2-ulotteisen normaalijakauman *reunajakaumat* ovat seuraavat:

$$X \sim N(4, 2) \quad Y \sim N(3, 1)$$

Kuvat alla esittävät reunajakaumien *tiheysfunktioita*.



**Regressiosuorat**

Esimerkin tapauksessa muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen on

$$\begin{aligned} y &= \mu_y + \frac{1}{\rho_{xy}} \times \frac{\sigma_y}{\sigma_x} (x - \mu_x) \\ &= 3 + \frac{1}{0.7} \times \frac{1}{\sqrt{2}} (x - 4) \\ &= -1.0406 + 1.0101x \end{aligned}$$

ja muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen on

$$\begin{aligned} y &= \mu_y + \rho_{xy} \frac{\sigma_y}{\sigma_x} (x - \mu_x) \\ &= 3 + 0.7 \frac{1}{\sqrt{2}} (x - 4) \\ &= 1.0201 + 0.4950x \end{aligned}$$

Kuva oikealla esittää esimerkin 2-ulotteisen normaali-jakauman tiheysfunktion *tasa-arvoellipsejä*, jotka vastaavat (likimäärin) *todennäköisyyksiä* 68 %, 95 % ja 99.7 %.

Esimerkiksi *uloimman* ellipsin sisään jää n. 99.7 % jakauman todennäköisyysmassasta.

Kuvaan on lisäksi piirretty sekä muuttujan  $x$  regressiosuora muuttujan  $y$  suhteen että muuttujan  $y$  regressiosuora muuttujan  $x$  suhteen.

Suorista *jyrkempi* eli

$$y = -1.0406 + 1.0101 \times x$$

on  $x$ :n regressiosuora  $y$ :n suhteen ja suorista *loivempi* eli

$$y = 1.0201 + 0.4950 \times x$$

on  $y$ :n regressiosuora  $x$ :n suhteen.

**Ehdolliset varianssit**

Esimerkin tapauksessa satunnaismuuttujan  $X$  ehdollinen varianssi satunnaismuuttujan  $Y$  suhteen on

$$0 \leq \sigma_{x|y}^2 = (1 - \rho_{xy}^2) \sigma_x^2 = (1 - 0.7^2) \times 2 = 1.02 \leq 2 = \sigma_x^2$$

ja satunnaismuuttujan  $Y$  ehdollinen varianssi satunnaismuuttujan  $X$  suhteen on

$$0 \leq \sigma_{y|x}^2 = (1 - \rho_{xy}^2) \sigma_y^2 = (1 - 0.7^2) \times 1 = 0.51 \leq 1 = \sigma_y^2$$

