

A *variable* is a “quantity that may assume any one of a set of values” (Webster’s dictionary).

*Random variables* are variables whose observed value is determined by chance.

#### Definition 3.1.1: Discrete random variable

A random variable is discrete if it can assume at most a finite or a countably infinite number of possible values.

#### Definition 4.1.1: Continuous random variable

A random variable is continuous if it can assume any value in some interval or intervals of real numbers and the probability that it assumes any specific value is 0.

#### Definition 3.2.1: Discrete density

Let  $X$  be a discrete random variable. The function  $f$  given by

$$f(x) = P[X = x]$$

for  $x$  real is called the density function for  $X$ .

Notera att

$$P[X \in A] = \sum_{x \in A} f(x)$$

(summationen är över alla  $x \in A$ , sådana att  $f(x) > 0$ )

#### Exempel: Bernoullitänheten

Låt  $A$  vara en händelse i ett försök och låt  $p = P[A]$ . Om man bara är intresserad av huruvida  $A$  inträffar eller ej, kan man införa

$$X = \begin{cases} 1 & \text{då } A \text{ inträffar} \\ 0 & \text{då } A^c \text{ inträffar} \end{cases}$$

En stokastisk variabel som endast kan antaga värdet 0 eller 1 kallas för Bernoullivariabel. Obs. att  $p = P[X = 1]$  och att  $X$ :s täthet är

$$f(x) = \begin{cases} 1-p & \text{då } x = 0 \\ p & \text{då } x = 1 \\ 0 & \text{då } x \notin \{0, 1\} \end{cases}$$

Vi skriver  $X \sim \text{Ber}(p)$  när vi vill tala om att  $X$  tar sina värden ur  $\{0, 1\}$  och att  $P[X = 1] = p$ , där  $0 < p < 1$ .

#### Exempel: Ett tärningskastexperiment

Nedan visas resultatet av totalt  $100 = 5 \cdot 20$  tärningskast, där vi endast noterat ifall tärningen visar sexa (kodat 1) eller ej (kodat 0).

data	f	f/n
0 1 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 1 0 0 0	3	0.15
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 0	2	0.1
0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 1 0 0 1 0 0 0	3	0.15
0 0 0 1 0 0 1 1 1 0 0 1 0 0 0 0 1 0 0 0	6	0.3
1 0 0 1 0 1 1 0 0 1 0 0 1 0 0 1 0 0 0 0	7	0.35

Sammanlagt erhölls  $f = 21$  sexor. Proportionen sexor i försöket blev alltså  $f/n = 0.21$ .

Ytterligare 900 kast gjordes. Totalt erhölls  $f = 169$  sexor. Proportionen sexor efter 1000 kast blev alltså  $f/n = 0.169$ .

#### Definition 3.2.2: Discrete distribution function

Let  $X$  be a discrete random variable with density  $f$ . The (cumulative) distribution function for  $X$ , denoted by  $F$ , is defined by

$$F(x) = \sum_{y \leq x} f(y)$$

for  $x$  real.

Notera att

$$F(x) = P[X \leq x]$$

samt att

$$f(x) = F(x) - F(x-)$$

där

$$F(x-) = \sum_{y < x} f(y) = P[X < x]$$

## Definition 5.1.1: Discrete joint density

Let  $X$  and  $Y$  be discrete random variables. The function  $f_{XY}$  given by

$$f_{XY}(x, y) = P[X = x, Y = y]$$

for  $x$  and  $y$  real is called the joint density for  $X, Y$ .

Notera att

$$P[X \in A, Y \in B] = \sum_{x \in A} \sum_{y \in B} f_{XY}(x, y)$$

## Definition 5.1.2: Discrete marginal densities

Let  $X$  and  $Y$  be discrete random variables with joint density  $f_{XY}$ . The marginal density for  $X$ , denoted by  $f_X$ , is given by

$$f_X(x) = \sum_y f_{XY}(x, y)$$

The marginal density for  $Y$ , denoted by  $f_Y$ , is given by

$$f_Y(y) = \sum_x f_{XY}(x, y)$$

Ibland är det praktiskt att slarva lite med beteckningarna och om  $f(x, y)$  betecknar den två-dimensionella tätheten, beteckna de endimensionella marginalerna med  $f(x)$  resp.  $f(y)$ . Då

$$f(x) = \sum_y f(x, y) \text{ och } f(y) = \sum_x f(x, y)$$

## Några diskreta tälteter

Vi säger att  $X$  är Bernoullifördelad om  $X$  är diskret och har tätheten

$$f(x) = \begin{cases} 1-p & \text{då } x=0 \\ p & \text{då } x=1 \end{cases} = p^x (1-p)^{1-x} \text{ för } x=0, 1$$

Vi skriver detta  $X \sim \text{Ber}(p)$ . Obs att  $0 < p < 1$ .

Vi säger att  $X$  är geometriskt fördelad om  $X$  har tätheten

$$f(x) = (1-p)^{x-1} p \text{ för } x=1, 2, \dots$$

för något  $p$  uppfyllande  $0 < p < 1$ . Vi skriver  $X \sim \text{Geo}(p)$ .

Vi säger att  $X$  är binomialfördelad med parametrar  $n$  och  $p$ , om  $X$  har tätheten

$$f(x) = \binom{n}{x} p^x (1-p)^{n-x} \text{ för } x=0, 1, \dots, n$$

Här är  $n$  ett positivt heltal och  $0 < p < 1$ . Vi skriver  $X \sim \text{Bin}(n, p)$ .

Vi säger att  $X$  är Poissonfördelad med parameter  $\lambda > 0$  om  $X$  har tätheten

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

Vi skriver  $X \sim \text{Poi}(\lambda)$ .

## Exempel: Poisson-observationer

Låt  $X \sim \text{Poi}(2.5)$ .

Nedan visas resultatet av  $n = 100$  oberoende observationer av  $X$

$x$	$f_x$	$f_x/n$	$p(x)$
0	9	0.090	0.082
1	16	0.160	0.205
2	28	0.280	0.257
3	22	0.220	0.214
4	15	0.150	0.134
5	5	0.050	0.067
6	2	0.020	0.028
7	2	0.020	0.010
8	1	0.010	0.003

Nedan visas resultatet av  $n = 1000$  oberoende observationer av  $X$

$x$	$f_x$	$f_x/n$	$p(x)$
0	80	0.080	0.0821
1	212	0.212	0.2052
2	226	0.226	0.2565
3	229	0.229	0.2138
4	137	0.137	0.1336
5	73	0.073	0.0668
6	27	0.027	0.0278
7	9	0.009	0.0099
8	5	0.005	0.0031
9	2	0.002	0.0009

## Definition 4.1.2: Continuous density

Let  $X$  be a continuous random variable. A function  $f$  such that

1.  $f(x) \geq 0$  for  $x$  real
2.  $\int_{-\infty}^{\infty} f(x) dx = 1$
3.  $P[a \leq X \leq b] = \int_a^b f(x) dx$

is called a density for  $X$ .

## Definition 4.1.3: Continuous distribution function

Let  $X$  be a continuous random variable with density  $f$ . The distribution function for  $X$ , denoted by  $F$ , is defined by

$$F(x) = \int_{-\infty}^x f(y) dy$$

Notera att

$$F(x) = P[X \leq x] = P[X < x]$$

samt att

$$f(x) = F'(x)$$

## Definition 5.1.3: Continuous joint density

Let  $X$  and  $Y$  be continuous random variables. A function  $f(x, y)$  such that

1.  $f(x, y) \geq 0$  for  $x, y$  real
2.  $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dy dx = 1$
3.  $P[a \leq X \leq b, c \leq Y \leq d] = \int_a^b \int_c^d f(x, y) dy dx$

is called a joint density for  $X, Y$ .

## Definition 5.1.4: Continuous marginal densities

Let  $X$  and  $Y$  be continuous random variables with joint density  $f(x, y)$  such that. The marginal densities for  $X$  and  $Y$ , denoted  $f(x)$  and  $f(y)$ , respectively, are given by

1.  $f(x) = \int_{-\infty}^{\infty} f(x, y) dy$
2.  $f(y) = \int_{-\infty}^{\infty} f(x, y) dx$

I bland måste man vara väldigt tydlig och använda beteckningar, som

$$f_{XY}, f_X, f_Y$$

för den gemensamma tätheten resp de två marginalerna.

## Några kontinuerliga täteter

Vi säger att  $X$  är likformigt fördelad på  $(a, b)$  om  $X$  är kontinuerlig och har täteten

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

Detta skrives  $X \sim U(a, b)$ .

Vi säger att  $X$  är exponentialfördelad med parameter  $\lambda$  om täteten är

$$f(x) = \lambda e^{-\lambda x} \text{ för } x > 0$$

Vi skriver detta  $X \sim \text{Exp}(\lambda)$ .

(Observera att Milton & Arnold definierar exponentialfördelningen med hjälp av parametern  $\beta = 1/\lambda$ )

Vi säger att  $X$  är normalfördelad med parametrar  $\mu$  och  $\sigma$  om täteten är

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}(\frac{x-\mu}{\sigma})^2} \text{ för } -\infty < x < \infty$$

Vi skriver detta  $X \sim N(\mu, \sigma)$ . För parametrarna gäller  $-\infty < \mu < \infty$  och  $\sigma > 0$ .

Analogt skriver vi  $X, Y \sim N(\mu_x, \mu_y; \sigma_x, \sigma_y, \rho)$  om täteten är

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}[(\frac{x-\mu_x}{\sigma_x})^2 - 2\rho(\frac{x-\mu_x}{\sigma_x})(\frac{y-\mu_y}{\sigma_y}) + (\frac{y-\mu_y}{\sigma_y})^2]}$$

För parametern  $\rho$  gäller att  $-1 < \rho < 1$ .

## Definition 5.1.5: Independent random variables

Let  $X$  and  $Y$  be random variables with joint density  $f_{XY}$  and marginal densities  $f_X$  and  $f_Y$ , respectively. We say that  $X, Y$  are independent if and only if

$$f_{XY}(x, y) = f_X(x)f_Y(y)$$

for all  $x, y$ .

Analogt,  $X_1, \dots, X_n$  sags vara oberoende då

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

## Exempel: Bivariat normalfördelning

Låt  $X, Y \sim N(\mu_x, \mu_y; \sigma_x, \sigma_y, \rho)$ . Då är  $X, Y$  oberoende om och endast om  $\rho = 0$ .

## Definition 5.4.1: Conditional density

Let  $X$  and  $Y$  be random variables with joint density  $f_{XY}$  and marginal densities  $f_X$  and  $f_Y$ , respectively. The conditional density for  $X$  given  $Y = y$ , denoted  $f_{X|Y}$  or  $f_{XY|Y=y}$ , is given by

$$f_{X|Y}(x|y) = \frac{f_{XY}(x, y)}{f_Y(y)}$$

The conditional density for  $Y$  given  $X = x$ , denoted  $f_{Y|X}$  or  $f_{XY|X=x}$ , is given by

$$f_{Y|X}(y|x) = \frac{f_{XY}(x, y)}{f_X(x)}$$

Starviga men praktiska beteckningar:

$$f(x, y), f(x), f(y)$$

(som tidigare) samt de betingade täteterna

$$f(x|y) = \frac{f(x, y)}{f(y)} \text{ och } f(y|x) = \frac{f(x, y)}{f(x)}$$

Observera att

$$\begin{aligned} X, Y \text{ är oberoende} &\Leftrightarrow f(x, y) = f(x)f(y) \\ &\Leftrightarrow f(y|x) = f(y) \\ &\Leftrightarrow f(x|y) = f(x) \end{aligned}$$

Bra att veta om bivariata normalfördelningen

Låt  $X, Y \sim N(\mu_x, \mu_y; \sigma_x, \sigma_y, \rho)$ . Då

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}[(\frac{x-\mu_x}{\sigma_x})^2 - 2\rho(\frac{x-\mu_x}{\sigma_x})(\frac{y-\mu_y}{\sigma_y}) + (\frac{y-\mu_y}{\sigma_y})^2]}$$

Medelst integration får

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

D.v.s.  $X \sim N(\mu_x, \sigma_x)$ .

Detta ger

$$f(y|x) = \frac{1}{\sqrt{2\pi}\sigma_y\sqrt{1-\rho^2}} e^{-\frac{1}{2\sigma_y^2(1-\rho^2)}[y - (\mu_y + \rho\sigma_y \frac{x-\mu_x}{\sigma_x})]^2}$$

Vi ser att

$$Y|x \sim N\left(\mu_y + \rho\sigma_y \frac{x-\mu_x}{\sigma_x}, \sigma_y\sqrt{1-\rho^2}\right)$$

Definition 3.3.1, 4.2.1, 5.2.1: Expected value

Let  $X$  be a discrete random variable with density  $f$ . Then  $H(X)$  is a random variable. The expected value of  $H(X)$  exists and is given by

$$E[H(X)] = \sum_x H(x)f(x)$$

provided  $\sum_x |H(x)|f(x) < \infty$ .

Let  $X$  be a continuous random variable with density  $f$ . The expected value of  $H(X)$  exists and is given by

$$E[H(X)] = \int_{-\infty}^{\infty} H(x)f(x) dx$$

provided  $\int_{-\infty}^{\infty} |H(x)|f(x) dx < \infty$ .

Let  $X, Y$  be random variables with joint density  $f_{XY}$ . The expected value of  $H(X, Y)$  exists and is given by

$$E[H(X, Y)] = \sum_x \sum_y H(x, y)f_{XY}(x, y)$$

for  $X, Y$  discrete, or

$$E[H(X, Y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H(x, y)f_{XY}(x, y) dy dx$$

for  $X, Y$  continuous, provided the sum (integral) is absolutely convergent.

Var och en bör nu förstå t.ex hur man beräknar  $E[W]$  om  $W = H(X, Y, Z)$  med hjälp av trippeln  $X, Y, Z$ :s täthet  $f(x, y, z)$ .

Notera att

$$E[X] = \sum_x xf(x) \text{ eller } E[X] = \int_{-\infty}^{\infty} xf(x) dx$$

om väntevärdet existerar och tätheten är  $f(x)$ . Men vi kan också beräkna väntevärdet så här

$$E[X] = \sum_x \sum_y xf(x, y) \text{ eller } E[X] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xf(x, y) dy dx$$

om man har givet en två-dimensionell gemensam täthet  $f(x, y)$ .

Ofta använder man beteckningen  $\mu$  (eller  $\mu_X$ ) istället för  $E[X]$

#### Theorem 3.3.1: Rules for expectation

Let  $X$  and  $Y$  be random variables and let  $c$  be any real number.

Then

1.  $E[c] = c$
2.  $E[cX] = cE[X]$
3.  $E[X + Y] = E[X] + E[Y]$

#### Theorem 5.2.2

Let  $X$  and  $Y$  be independent random variables. Then

$$E[XY] = E[X]E[Y]$$

Definition 3.3.2: Variance

Let  $X$  be a random variable with mean  $\mu = E[X]$ . The variance of  $X$ , denoted by  $\text{Var}[X]$  or  $\sigma^2$ , is given by

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

Notera att  $\text{Var}[X] = E[X^2] - E[X]^2$  (sats 3.3.2)

Definition 3.3.2: Standard deviation

Let  $X$  be a random variable with variance  $\sigma^2$ . The standard deviation of  $X$ , denoted by  $\sigma$ , is given by

$$\sigma = \sqrt{\sigma^2}$$

#### Theorem 3.3.3: Rules for variance

Let  $X$  and  $Y$  be random variables and let  $c$  be any real number.

Then

1.  $\text{Var}[c] = 0$
2.  $\text{Var}[cX] = c^2\text{Var}[X]$
3.  $\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y]$  if  $X$  and  $Y$  are independent

**Definition 3.4.2: Ordinary moments**

Let  $X$  be a random variable. The  $k$ th (ordinary) moment for  $X$  is defined as  $E[X^k]$ .

**Definition 3.4.3: Moment generating function**

Let  $X$  be a random variable. The moment generating function for  $X$  (m.g.f.) is denoted by  $m_X(t)$  and is given by

$$m_X(t) = E[e^{tX}]$$

provided this expectation exists for all real numbers  $t$  in some open interval  $(-h, h)$ .

**Theorem 3.4.2**

Let  $m_X(t)$  be a moment generating function for a random variable  $X$ . Then

$$\frac{d^k m_X(t)}{dt^k} \Big|_{t=0} = m_X^{(k)}(0) = E[X^k]$$

Låt  $Y = X_1 + \dots + X_n$ , där  $X_1, \dots, X_n$  är oberoende, likafördelade och har m.g.f  $m_X(t)$ . Då är funktionen

$$m_Y(t) = (m_X(t))^n$$

$Y$ :s m.g.f (j.f.r den något generellare sats 7.3.2).

Låt  $X$  ha m.g.f  $m_X(t)$  och sätt  $Y = \alpha + \beta X$ . Då är funktionen

$$m_Y(t) = e^{\alpha t} m_X(\beta t)$$

$Y$ :s m.g.f (j.f.r sats 7.3.3).

Låt  $X \sim \text{Ber}(p)$ . Då

$$E[X] = p$$

och

$$\text{Var}[X] = p(1-p)$$

Notera också att

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

där  $q = 1 - p$ .

**Theorem 3.4.1**

M.g.f för  $\text{Geo}(p)$  är

$$m(t) = \frac{pe^t}{1 - qe^t} \quad \text{för } t < -\ln q$$

där  $q = 1 - p$ .

**Theorem 3.4.3**

För  $\text{Geo}(p)$  gäller

1.  $\mu = 1/p$
2.  $\sigma^2 = q/p^2$  där  $q = 1 - p$

## Theorem 3.5.1

M.g.f för  $\text{Bin}(n, p)$  är

$$m(t) = (q + pe^t)^n \quad \text{för } -\infty < t < \infty$$

där  $q = 1 - p$ . Vidare

1.  $\mu = np$
2.  $\sigma^2 = np(1 - p)$

## Theorem 3.8.1

M.g.f för  $\text{Poi}(\lambda)$  är

$$m(t) = e^{\lambda(e^t - 1)} \quad \text{för } -\infty < t < \infty$$

där  $q = 1 - p$ . Vidare

1.  $\mu = \lambda$
2.  $\sigma^2 = \lambda$

Notera att

$$\binom{n}{x} p^x (1-p)^{n-x} \approx e^{-np} \frac{(np)^x}{x!}$$

om  $n$  är stort och  $p$  är litet.

Vi har alltså att

$$\text{Bin}(n, p) \approx \text{Poi}(\lambda)$$

där  $\lambda = np$  är litet

Läs själv om Poissonprocessen på sida 76–77.

Steps in solving a Poisson problem:

1. Determine the basic unit of measurements used.
2. Determine the average number of occurrences of the event per unit. This number is denoted by  $\lambda$ .
3. Determine the length or size of the observation period. This number is denoted by  $s$ .
4. The random variable  $X$ , the number of occurrences of the event in a unit of size  $s$ , follows a Poisson distribution with parameter  $k = \lambda s$ .

Vi säger att  $X$  är likformigt fördelad på  $(a, b)$  om  $X$  är kontinuerlig och har tätheten

$$f(x) = \frac{1}{b-a} \quad \text{för } a < x < b$$

Detta skrivs  $X \sim \text{U}(a, b)$ .

Observera att

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

samt

$$E[X] = \frac{a+b}{2}$$

och

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

Standardisering:

$$U = \frac{X-a}{b-a} \sim \text{U}(0, 1)$$

## Del A

Milton &amp; Arnold, Chapter 3-5, OH no 25

Vi säger att  $X$  är exponentalfördelad med parameter  $\lambda$  om tätheten är

$$f(x) = \lambda e^{-\lambda x} \text{ för } x > 0$$

Vi skriver detta  $X \sim \text{Exp}(\lambda)$ . Observera att boken definierar exponentialfördelningen med hjälp av parametern  $\beta = 1/\lambda$ .

## Theorem 4.3.3: Connection to the Poisson process

Consider a Poisson process with parameter  $\lambda$ . Let  $W$  denote the time of occurrence of the first event. Then  $W \sim \text{Exp}(\lambda)$ .

$X$ :s fördelningsfunktion är

$$F(x) = 1 - e^{-\lambda x} \text{ för } x > 0$$

Notera dessutom

$$E[X] = \frac{1}{\lambda} \text{ och } \text{Var}[X] = \frac{1}{\lambda^2}$$

Standardisering:

$$Y = \lambda X \sim \text{Exp}(1)$$

## Del A

Milton &amp; Arnold, Chapter 3-5, OH no 26

Vi säger att  $X$  är normalfördelad med parametrar  $\mu$  och  $\sigma$  om tätheten är

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2} \text{ för } -\infty < x < \infty$$

Vi skriver detta  $X \sim N(\mu, \sigma)$ . För parametrarna gäller

$$-\infty < \mu < \infty \text{ och } \sigma > 0$$

## Theorem 4.4.1, 4.4.2

M.g.f för  $N(\mu, \sigma)$  är

$$m(t) = e^{\mu t + \sigma^2 t^2/2} \text{ för } -\infty < t < \infty$$

Härur följer att om  $X \sim N(\mu, \sigma)$  så gäller

$$\mu = E[X] \text{ och } \sigma^2 = \text{Var}[X]$$

## Theorem 4.4.3: Standardization theorem

$$X \sim N(\mu, \sigma) \Leftrightarrow Z = \frac{X - \mu}{\sigma} \sim N(0, 1)$$

## Del A

Milton &amp; Arnold, Chapter 3-5, OH no 27

Notera att  $N(0, 1)$ -tätheten är

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

Motsvarande fördelningsfunktion betecknas  $\Phi$ :

$$\Phi(z) = \int_{-\infty}^z \varphi(z) dz$$

Notera nu att

$$\begin{aligned} P[a \leq X \leq b] &= P\left[\frac{a-\mu}{\sigma} \leq Z \leq \frac{b-\mu}{\sigma}\right] \\ &= P\left[Z \leq \frac{b-\mu}{\sigma}\right] - P\left[Z \leq \frac{a-\mu}{\sigma}\right] \\ &= \Phi\left(\frac{b-\mu}{\sigma}\right) - \Phi\left(\frac{a-\mu}{\sigma}\right) \end{aligned}$$

I tabell V (sida 697–698) hittar man  $\Phi(z)$  för  $z$ -värden från  $-3.40$  till och med  $3.49$  i steg om  $0.01$ . Tabell över normalfördelningen hittar du även i Beta och i kursens formelsamling. I vissa tabeller är  $\Phi(z)$  endast tabellerad för icke-negativa  $z$ -värden. Utnyttja då att

$$\Phi(-z) = 1 - \Phi(z)$$

## Del A

Milton &amp; Arnold, Chapter 3-5, OH no 28

## Theorem 4.5.1: Normal probability rule

Låt  $X \sim N(\mu, \sigma)$ . Då

$$P[|X - \mu| \leq \sigma] = 0.68 \leftarrow$$

$$P[|X - \mu| \leq 1.96\sigma] = 0.95 \leftarrow$$

$$P[|X - \mu| \leq 2\sigma] \approx 0.95 \leftarrow$$

$$P[|X - \mu| \leq 2.576\sigma] = 0.99 \leftarrow$$

$$P[|X - \mu| \leq 3\sigma] = 0.997 \leftarrow$$

## Theorem 4.5.2: Chebyshev's inequality

Let  $X$  be a random variable with mean  $\mu$  and standard deviation  $\sigma$ . Then

$$P[|X - \mu| \leq k\sigma] \geq 1 - \frac{1}{k^2}$$

T.ex

$$P[|X - \mu| \leq \sigma] \geq 0$$

$$P[|X - \mu| \leq 2\sigma] \geq 0.75$$

$$P[|X - \mu| \leq 3\sigma] \geq 0.88$$

J.f.r med "Normal probability rule"

Fler nyttigheter om bivariata normalfördelningen

Låt  $X, Y \sim N(\mu_x, \mu_y; \sigma_x, \sigma_y, \rho)$ . Då

$$Y = \mu_y + \rho\sigma_y \frac{X - \mu_x}{\sigma_x} + \sigma_y \sqrt{1 - \rho^2} Z$$

där  $Z \sim N(0, 1)$  och oberoende av  $X$ .

Låt  $Z_1, Z_2 \sim N(0, 1)$  och oberoende. Om

$$\begin{aligned} X &= \mu_x + \sigma_x Z_1 \\ Y &= \mu_y + \rho\sigma_y Z_1 + \sigma_y \sqrt{1 - \rho^2} Z_2 \end{aligned}$$

så är  $X, Y \sim N(\mu_x, \mu_y; \sigma_x, \sigma_y, \rho)$ .

Vi säger att en stokastisk variabel  $T$  är Weibullfördelad med parametrar  $\alpha > 0$  och  $\beta > 0$  om tätheten är

$$f(t) = \alpha\beta t^{\beta-1} e^{-\alpha t^\beta} \text{ för } t > 0$$

och vi skriver  $T \sim \text{Weibull}(\alpha, \beta)$ .

Observera att

$$\text{Weibull}(\alpha, 1) = \text{Exp}(\alpha)$$

Weibull-fördelningens väntevärde och varians är

$$\mu = \alpha^{-1/\beta} \Gamma(1 + 1/\beta)$$

$$\sigma^2 = \alpha^{-2/\beta} \Gamma(1 + 2/\beta) - \mu^2$$

där  $\Gamma$  är Eulers gammafunktion (sats 4.7.1). Fördelningsfunktion är

$$F(t) = 1 - e^{-\alpha t^\beta} \text{ för } t \geq 0$$

Standardisering:

$$S = \alpha T^\beta \sim \text{Exp}(1)$$

Let  $T$  denote the time to failure of a component or a (mechanical) system of components. Then  $T$  is continuous and can assume any value in the interval  $(0, \infty)$ . The density  $f$ , for  $T$ , is called the *failure density*. The *reliability function*,  $R$ , is defined by

$$R(t) = 1 - F(t)$$

Thus,

$$R(t) = P[T > t] = \int_t^\infty f(t) dt$$

The *force of mortality* or *hazard rate*,  $\rho$ , is defined by

$$\rho(t) = \lim_{h \rightarrow 0} \frac{P[t < T \leq t+h | T > t]}{h} \text{ for } t > 0$$

#### Theorem 4.7.2, 4.7.3

Let  $T$  be a random variable with failure density  $f$ , reliability function  $R$  and hazard rate  $\rho$ . Then

$$\rho(t) = \frac{f(t)}{R(t)} = -\frac{R'(t)}{R(t)}$$

Moreover,

$$R(t) = \exp \left( - \int_0^t \rho(s) ds \right)$$

#### Definition 4.7.2: Series system

A system whose components are arranged in such a way that the system fails whenever any of the components fail is called a series system.

#### Definition 4.7.3: Parallel system

A system whose components are arranged in such a way that the system fails only if all of its components fail is called a parallel system.

## Definition 5.2.2: Covariance

Let  $X$  and  $Y$  be random variables with means  $\mu_X$  and  $\mu_Y$  respectively. The covariance between  $X$  and  $Y$ , denoted by  $\text{Cov}[X, Y]$  or  $\sigma_{XY}$ , is given by

$$\text{Cov}[X, Y] = E[(X - \mu_X)(Y - \mu_Y)]$$

## Theorem 5.2.1: Computational formula for covariance

$$\text{Cov}[X, Y] = E[XY] - E[X]E[Y]$$

Notera att  $\text{Cov}[X, Y] = 0$  om  $X, Y$  är oberoende

Notera att

$$\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y] + 2\text{Cov}[X, Y]$$

## Definition 5.3.1: Correlation

Let  $X$  and  $Y$  be random variables with means  $\mu_X$  and  $\mu_Y$  and variances  $\sigma_X^2$  and  $\sigma_Y^2$ , respectively. The correlation between  $X$  and  $Y$ , denoted  $\rho$  or  $\rho_{XY}$ , is given by

$$\rho = \frac{\text{Cov}[X, Y]}{\sqrt{\text{Var}[X]\text{Var}[Y]}}$$

## Definition 5.4.2: Curve of regression

Let  $X$  and  $Y$  be random variables with joint density  $f$ .

1. The graph of the mean value of  $X$  given  $Y = y$ , denoted  $\mu_{X|y}$  or  $\mu_{X|Y=y}$ , is called the curve of regression of  $X$  on  $Y$ .
2. The graph of the mean value of  $Y$  given  $X = x$ , denoted  $\mu_{Y|x}$  or  $\mu_{Y|X=x}$ , is called the curve of regression of  $Y$  on  $X$ .

## Exempel: Bivariat normalfördelning

Låt  $X, Y \sim N(\mu_x, \mu_y; \sigma_x, \sigma_y, \rho)$ . Då

1.  $\mu_{Y|x} = \mu_y + \rho \frac{\sigma_y}{\sigma_x}(x - \mu_x)$
2.  $\sigma_{Y|x} = \sigma_y \sqrt{1 - \rho^2}$