

Střední hodnota mat. veličiny

a) diskrétní

$$E(X) = \sum_i x_i p_i$$

b) spojitá

běžné označení

$$E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx \quad (= \mu)$$

# ROZPTYL (DISPERZE, VARIANCE) NÁHODNÉ VELIČINY

Def.  $D(X) = E(X - E(X))^2 (= \sigma^2)$  <sup>var.</sup>

a) diskrétní náh. prom.

$$D(X) = \sum_i (x_i - E(X))^2 \cdot p_i$$

b) spojité náh. prom.

$$D(X) = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx$$

Průklad: 1.) Hrací kocka - 1 hod

$$E(X) = 3,5$$

$$D(X) = \frac{1}{6} \left[ (1-3,5)^2 + (2-3,5)^2 + \dots \right. \\ \left. \dots + (6-3,5)^2 \right] = 2,9$$

2.) Alternativní hodění

$$E(X) = p$$

$$D(X) = (1-p)^2 \cdot p + (0-p)^2 (1-p) \\ = p(1-p)$$

3.) Binomické modelu pravděpodobnosti

$$E(X) = n \cdot p$$

$$D(X) = \sum_{k=0}^n (k - np)^2 \binom{n}{k} p^k (1-p)^{n-k} =$$

$$= \dots = n \cdot p \cdot (1-p)$$

4.) Poisson

$$E(X) = \lambda$$

$$D(X) = \sum_{k=0}^{\infty} (k - \lambda)^2 \cdot \frac{\lambda^k}{k!} \cdot e^{-\lambda} = \dots$$

$$\dots = \lambda$$

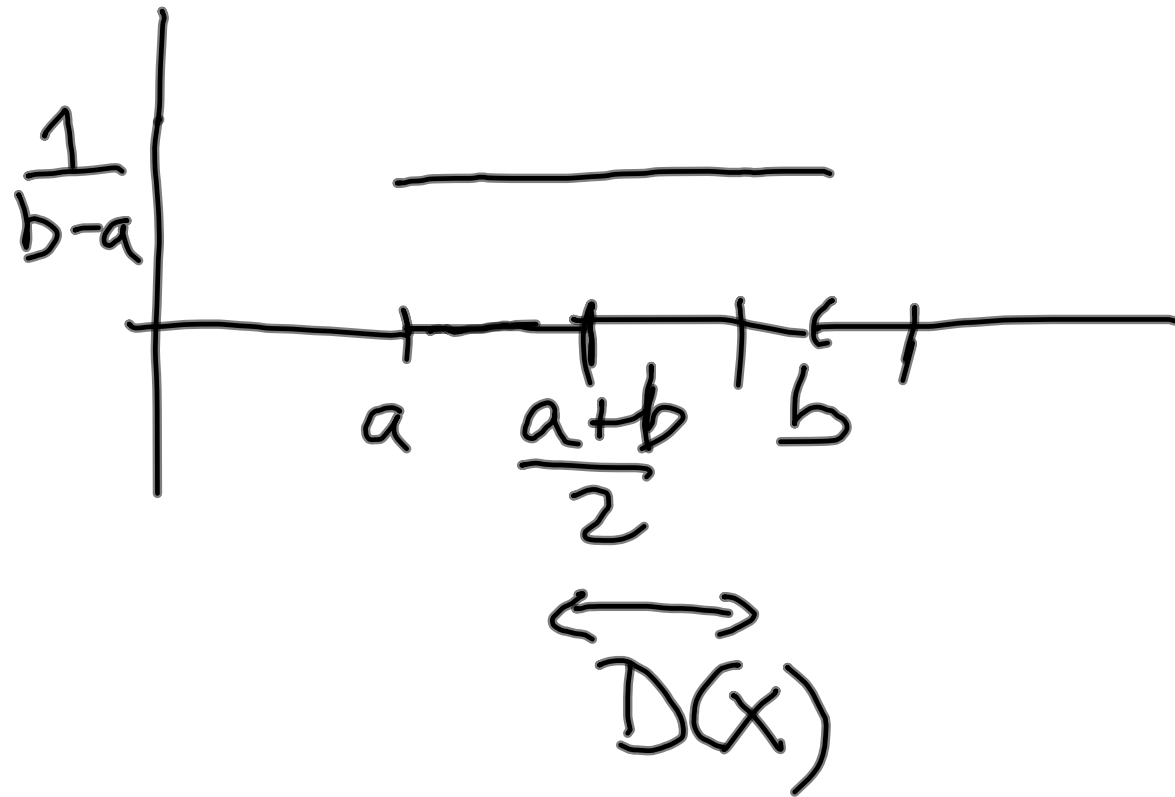
5.) Rovnoměrní rozdělení

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

$$D(X) = \int_{-\infty}^{\infty} \left(x - \frac{a+b}{2}\right)^2 \cdot \frac{1}{b-a} dx$$

$$x \in \langle a, b \rangle$$

$$D(X) = \int_a^b \left(x - \frac{a+b}{2}\right)^2 \cdot \frac{1}{b-a} dx = \frac{(b-a)^2}{12}$$




6.) Exponencialul vordeleu'

$$f(x) = \frac{1}{\lambda} e^{-\lambda x}, \lambda > 0, x \geq 0$$

$$E(X) = \lambda$$

$$D(X) = \int_0^{\infty} (x - \lambda)^2 \cdot \frac{1}{\lambda} e^{-\lambda x} dx = \lambda^2$$





7.) Normalni (Gaussovo) rozdeleni  
pravdepodobnosti

$$E(X) = \mu$$

$$D(X) = \int_{-\infty}^{\infty} (x - \mu)^2 \cdot \frac{1}{\sigma \sqrt{2\pi}} \cdot e^{-\frac{(x - \mu)^2}{2\sigma^2}} dx$$

$$\dots = \sigma^2$$

# ČEBYŠEVOVA NEROVNOST

Věta, Necht  $\bar{X}$  máh. prom.  $X$   
má rozptyl  $D(X)$ . Pak pro  
libovolné  $\varepsilon > 0$  je

$$P(|X - E(X)| \geq \varepsilon) \leq \frac{D(X)}{\varepsilon^2}$$

Důkaz. Pro spojitou náh. prom.

$$\underline{D(X)} = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx \geq$$

$$\geq \int_{-\infty}^{\mu - \varepsilon} \dots + \int_{\mu + \varepsilon}^{\infty} \dots \geq \varepsilon^2 \int_{-\infty}^{\mu - \varepsilon} f(x) dx +$$

$$+ \varepsilon^2 \int_{\mu + \varepsilon}^{\infty} f(x) dx = \varepsilon^2 \underbrace{P(|X - E(X)| \geq \varepsilon)}$$

Ted koverdure :


1.)  $\varepsilon = \sigma$  (stredni koverdura  
odchylka)

$$P(|X - \mu| \geq \sigma) \leq \frac{\sigma^2}{\sigma^2} = 1$$

2.)  $\varepsilon = 3\sigma$

$$P(|X - \mu| \geq 3\sigma) \leq \frac{\sigma^2}{(3\sigma)^2} = \frac{1}{9}$$

$$P(|X - \mu| < 3\sigma) \geq \frac{8}{9}$$




Když bychom věděli, že  $X$  má  
normální rozdělení  $N(\mu, \sigma^2)$

$$P(|X - \mu| < 3\sigma) =$$

$$= P(\mu - 3\sigma < X < \mu + 3\sigma) =$$

$$= F(\mu + 3\sigma) - F(\mu - 3\sigma) = \dots$$

transformace na  $N(0, 1)$





Označme - li distribučnú funkciu  
 normalizovaného Gaussova  
 rozdelení  $\phi(x)$ , pak  $\Phi$

$$F(x) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$


Puvē?  $\int_{-\infty}^x \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(s-\mu)^2}{2\sigma^2}} ds = \int_{-\infty}^{\frac{x-\mu}{\sigma}} \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$

$$\frac{s - \mu}{\sigma} = t$$

$$\text{Porovnání... } F(\mu+3\sigma) - F(\mu-3\sigma) =$$

$$= \Phi\left(\frac{\mu+3\sigma-\mu}{\sigma}\right) - \Phi\left(\frac{\mu-3\sigma-\mu}{\sigma}\right) =$$

$$= \Phi(3) - \Phi(-3) = \Phi(3) - 1 + \Phi(3)$$



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

$$= 2\Phi(3) - 1$$

$$= 2 \cdot 0,99865 - 1$$


$$= 0,9973$$

# REGRESNÍ PŘÍMKY

## A KORELAČNÍ KOEFICIENT

n bodů


$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$



Jak se měří  $\alpha, \beta$ ?

$$\sum_{i=1}^n (y_i - \alpha x_i - \beta)^2 \leq \sum_{i=1}^n (y_i - ax_i - b)^2$$

$a, b \in \mathbb{R}$



Je třeba najít

$$\min(f(a, b) = \sum_{i=1}^n (y_i - ax_i - b)^2)$$

Platí:  $\exists i, j: x_i \neq x_j$

Rovnice regrese má tvar


$$y - \bar{y} = \frac{k}{s_x^2} (x - \bar{x})$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad ; \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

$$s_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

,



2. regresní přímka

$$x - \bar{x} = \frac{k}{s_y^2} (y - \bar{y})$$

Když známe  $r = \frac{k}{s_x \cdot s_y}$  korelační koeficient

1. regresní přímka:

$$y - \bar{y} = r \frac{s_y}{s_x} (x - \bar{x})$$

2. regresní přímka

$$y - \bar{y} = \frac{1}{r} \frac{s_y}{s_x} (x - \bar{x})$$



Je-li  $|r|=1$ , je  $y = kx + q$   
(~~to~~ regresní přímky  
jsou totožné)

Když  $|r| < 1$  vyjadřuje  
míru lineární závislosti mezi  
 $x$  a  $y$ .