

<i>Bern</i> (p)	$\mathbb{E}(X) = p$	$var(X) = (1 - p)p$	Bayes $P(B_j A) = \frac{P(B_j)P(A B_j)}{P(A)}$
<i>Bin</i> (n, p)	$p_X(x) = \binom{n}{k} p^k (1 - p)^{n-k}$	$\mathbb{E}(X) = np$	VOUP $P(A) = \sum_i P(B_i)P(A B_j)$
<i>Geom</i> (p)	$p_X(k) = (1 - p)^{k-1} p$	$\mathbb{E}(X) = 1/p$	LOTUS $\mathbb{E}(g(X)) = \sum_{x \in Im(X)} g(x)P(X = x)$
<i>Hyper</i> (N, K, n)	$p_X(k) = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}}$	$\mathbb{E}(X) = n \frac{K}{N}$	$\{w Y(w) = y\} = \bigcup_{x \in Im(X) g(x)=y} \{w X(w) = x\}$
<i>Pois</i> (λ)	$p_X(k) = \frac{\lambda^k}{k!} e^{-\lambda}$	$\mathbb{E}(X) = \lambda$ $var(X) = \lambda$	

<i>Exp</i> (λ)	$f_X(x) = \lambda e^{-\lambda x}$	$F_X(x) = 1 - e^{-\lambda x}$	$\mathbb{E}(X) = 1/\lambda$	$var(X) = 1/\lambda^2$	$U(0, 1)$	$var(X) = \frac{1}{12}(b-a)^2$
<i>N</i> (μ, σ^2)	$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}(\frac{x-\mu}{\sigma})^2}$	$\mathbb{E}(X) = \mu$	$var(X) = \sigma^2$			
<i>Gamma</i> (w, λ)	$f_X(x) = \begin{cases} 0 & x \leq 0 \\ \frac{1}{\Gamma(w)} \lambda^w x^{w-1} e^{-\lambda x} & x \geq 0 \end{cases}$	$\mathbb{E}(X) = \frac{w}{\lambda}$	$var(X) = \frac{w}{\lambda^2}$			

= součet w n.n.v. *Exp*(λ)

1) Nechť X n.v. s dist. funkcí F (spojitou) pak $F(X) \sim U(0, 1)$	$F_X(x) = P(Q(U) \leq x) = P(U \leq F(x)) = F(x)$	$\forall F, Q: Q(p) \leq x \iff F(x) \geq p \in \{0, 1\}$
$F_Y(y) = P(F(X) \leq y) = P(X \leq x) = F(x) = y$ rostoucnost		2) F dist. funkce, Q odpovídající kvantilová Nechť $X = Q(U(0, 1))$. Pak $F_X = F$.

X_1, \dots, X_n n.n.v. se stř. hodnotou μ a rozptylem σ^2 .
 $S_n = (X_1 + \dots + X_n)/n$. Pak $\forall \varepsilon$ platí:

$$\lim_{n \rightarrow \infty} P(|S_n - \mu| \geq \varepsilon) = 0$$

Přes linearitu spočítáme střední hodnotu S_n .
Poté spočítáme varianci S_n , kde zbyde ve jm. n .
Nakonec dosadíme do Čebyševa a zlimitíme.

spojitý LOTUS

$$\mathbb{E}(g(X, Y)) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f_{X,Y}(x, y) dx dy$$

kovariance

$$cov(X, Y) = \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y)))$$

$$= \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)$$

Cauchyho $\mathbb{E}(XY) \leq \sqrt{\mathbb{E}(X^2)\mathbb{E}(Y^2)}$

Markovova X je nezáporné
 $P(X \geq a) \leq \frac{\mathbb{E}(X)}{a}$ přes větu o úplné stř. h.

Čebyševova $P(|X - \mu| \geq a \cdot \sigma) \leq \frac{1}{a^2}$ $Y = (X - \mu)^2$ pak přes Markova

X_1, \dots, X_n n.n.v. se stř. hodnotou μ a rozptylem σ^2 .
Nechť $Y_n = ((X_1 + \dots + X_n) - n\mu)/(\sqrt{n} \cdot \sigma)$.
Pak Y_n konverguje k $N(0, 1)$, neboli pokud F_n je dist. funkce k Y_n tak se se zvětšujícím n blíží $F_{N(0,1)}$.

korelace

$$\rho(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X)var(Y)}}$$

quantilová funkce
 $Q_X(p) = \min\{x \in \mathbb{R} : p \leq F_X(x)\}$

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

$L(x; \vartheta) = L(x_1; \vartheta) \cdot \dots \cdot L(x_n; \vartheta)$

nestranný: $\vartheta = \mathbb{E}(\hat{\Theta}_n)$

konzistentní: $\hat{\Theta}_n \xrightarrow{P} \vartheta$

bias (vychýl.): $\mathbb{E}(\hat{\Theta}_n) - \vartheta$

$MSE = \mathbb{E}((\hat{\Theta}_n - \vartheta)^2)$

kons. nest. odhad μ

$$\bar{S}_n = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_n)^2$$

kons. as. nest. odhad σ^2

$$\hat{S}_n = \frac{1}{n-1} \sum_{i=1}^n (X_i - \hat{X}_n)^2$$

kons. nest. odhad σ^2

$\ell(x; \vartheta) = \ell(x_1; \vartheta) + \dots + \ell(x_n; \vartheta)$

$\ell(x; \vartheta) = \log(L(x; \vartheta))$

podm. prav. $P(A|B) = \frac{P(A \cap B)}{P(B)}$

náhodná veličina $\forall x : \{\omega \in \Omega : X(\omega) \leq x\} \in \mathcal{F}$

diskrétní: pokud obor hodnot X je spočetný
 spojitá: pokud existuje nezáporná reál. f_X t.ž.

$P(A \cap B) = P(A)P(B)$

pmf $p_X(x) = P(X = x) = P(\{\omega \in \Omega | X(\omega) = x\})$

$F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(t) dt$
 = cdf = pdf

n.n.v. $\forall x, y$ $P(X = x, Y = y) = P(X = x)P(Y = y)$

n.n.v. $\forall x, y$ $P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y)$

margin. roz. $p_X(x) = \sum_{Y \in Im(Y)} p_{X,Y}(x, y)$

margin. hus. $f_X(x) = \int_{y \in \mathbb{R}} f_{X,Y}(x, y) dy$

$\mathbb{E}(X) = \sum_{x \in Im(X)} x \cdot P(X = x)$

podm. hustota $p_{X|Y}(x|y) = \frac{P(X = x, Y = y)}{P(Y = y)} = \frac{p_{X,Y}(x, y)}{p_Y(y)}$

platí i pro spojitě v.

$\mathbb{E}(X) = \int_{-\infty}^{\infty} x \cdot f_X(x) dx$

pro diskrétní $Z = X+Y$ platí důkaz rozepsání z def.

$P(Z = z) = \sum_{x \in Im(X)} P(X = x, Y = z - x)$

$f_Z(z) = \int_{-\infty}^{\infty} f_X(x) f_Y(z - x) dx$ $f_{Z|X}(z|x) = f_Y(z - x)$

$var(X) \geq 0$ $var(aX) = a^2 var(X)$ $var(X + a) = var(X)$

oboje je rozepsání stří. h. z definice a hraní se sumama nebo integrálama

$var(X) \stackrel{def.}{=} \mathbb{E}((X - \mathbb{E}(X))^2) \stackrel{ez.}{=} \mathbb{E}(X^2) - \mathbb{E}(X)^2$

$\mathbb{E}(X) = \sum_i \mathbb{E}(X | B_i) P(B_i)$

pro n.n.v. $var(X_1 + \dots + X_n) = var(X_1) + \dots + var(X_n)$

empirická $\hat{F}_n(X) = \frac{\sum_{i=1}^n I(X_i \leq x)}{n}$

$E_i = n\vartheta_i$

$\chi^2 = T = \sum_{i=1}^k \frac{(X_i - E_i)^2}{E_i}$

$Q \sim \chi_{k-1}^2$

o rozkladu hustoty $F_X(x) = \sum_i P(B_i) F_{X|B_i}(x)$

platí i pro f_X

$P(\hat{\Theta}^- \leq \vartheta \leq \hat{\Theta}^+) \geq 1 - \alpha$

zamítneme, když $T > F_Q^{-1}(1 - \alpha)$

$m_r(\vartheta) = \mathbb{E}(X^r)$

$\widehat{m_r(\vartheta)} = \frac{1}{n} \sum_{i=1}^n X_i^r$

$\mathbb{E}(X) = \mu$ stř.

$\mathbb{E}(X^2) = \sigma^2 + \mu^2$ var.

