

Intervální odhady n.n.v.: X_1, \dots, X_n n.h. v.ř. z $N(\mu, \sigma^2)$, σ známý, odhadme μ . Závaznost $2\alpha/2 = 1-\alpha/2$. Necht' $\Phi(2\alpha/2) = 1-\alpha/2$.
 $S_n = (X_1 + \dots + X_n)/n$, $C_n = \sqrt{S_n - 2\alpha/2} \cdot \sigma/\sqrt{n}$, $S_n + 2\alpha/2 \cdot \sigma/\sqrt{n} > \mu > S_n - 2\alpha/2 \cdot \sigma/\sqrt{n}$. Pak $P(C_n > \sigma) = 1-\alpha$.
 $Y_n = \frac{S_n - \mu}{\sigma/\sqrt{n}}$, $Y_n \sim N(0,1) \rightarrow E(Y_n) = 0$, $Var(Y_n) = 1$. $P(Y > S_n + 2\alpha/2 \cdot \sigma/\sqrt{n}) = P(Y_n > 2\alpha/2) = 1 - \Phi(2\alpha/2) = \alpha/2$

Parmen. CLV: Stejně jako vlevo. Chceme: $\lim_{n \rightarrow \infty} P(C_n > \sigma) = 1-\alpha$. (Výběr nemusí být z $N(\dots)$)
 Y_n jako vlevo. CLV říká: $Y_n \xrightarrow{d} N(0,1)$. Pak platí:
 $P(Y > S_n + 2\alpha/2 \cdot \sigma/\sqrt{n}) = P(Y_n < -2\alpha/2) \xrightarrow{n \rightarrow \infty} \Phi(-2\alpha/2) = \alpha/2$

Def: Pro n.h. v.ř. $X_1, \dots, X_n \sim F_\mu$ a lib. fci g navrhne bod. odh. $\hat{\theta}_n$: resturní / bezpřehledný bod $E(\hat{\theta}_n) = g(\mu)$, asymptotický nepřehledný bod $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = g(\mu)$, konistentní bod $\hat{\theta}_n \xrightarrow{P} g(\mu)$.
 vyhodlení: bias, $(\hat{\theta}_n) - E(\hat{\theta}_n) - \mu$, $MSE_Y(\hat{\theta}_n) = E((\hat{\theta}_n - \mu)^2) | MSE(\hat{\theta}_n) = bias^2(\hat{\theta}_n) + var_Y(\hat{\theta}_n)$ | $var(\hat{\theta}_n) = var((\hat{\theta}_n - \mu)) = E((\hat{\theta}_n - \mu)^2) - (E(\hat{\theta}_n - \mu))^2$ vlevo $MSE(\hat{\theta}_n)$, vpravo $bias^2(\hat{\theta}_n)$.
 Výběrový průměr $\bar{X}_n = \frac{1}{n} \sum X_i$, $S_n^2 = \frac{1}{n} \sum (X_i - \bar{X}_n)^2$, $S_n^2 = \frac{1}{n-1} \sum (X_i - \bar{X}_n)^2$ ← Výběrový rozptyl | Thm: \bar{X}_n je konistentní resturní odhad μ , S_n^2 konistentní asymptotický resturní odhad σ^2

Momenty: $m_r(\mu) = E(X^r)$, $X \sim F_\mu$... r-tý moment, $\hat{m}_r(\bar{X}_n) = \frac{1}{n} \sum X_i^r$ pro n.h. v.ř. X_1, \dots, X_n | $\hat{m}_r(\bar{X}_n)$ je resturní konistentní odhad pro $m_r(\mu)$. S_n^2 konistentní resturní odhad σ^2 .
 Met. Max. Víra: Výjme n.h. v.ř. $X = (X_1, \dots, X_n)$ z modelu s prm. $\theta = (\theta_1, \dots, \theta_k)$ realizace v.ř. X . Pak $P_X(x; \theta) = \prod P_i(x_i; \theta_i)$ nebo $f_X(x; \theta) = \prod f_i(x_i; \theta_i)$ je $L(x; \theta)$ věrohodnost. Tedy $L(x; \theta)$ je funkce θ .
 Volíme tahová $\hat{\theta}$, pro která je $L(x; \theta)$ maxim. (vyplývá z ležet log) | Studentova t-mocovina: $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ n.n.v. Studentova t-mocovina s $n-1$ stupni je ned. n.v. $\frac{\bar{X}_n - \mu}{S_n/\sqrt{n}}$, kde $\bar{X}_n = \frac{1}{n} \sum X_i$, S_n je $\sqrt{\frac{1}{n-1} \sum (X_i - \bar{X}_n)^2}$, tedy $N(0,1)$.
 Thm: O stud. n.v. X_1, \dots, X_n n.h. v.ř. z $N(\mu, \sigma^2)$ Uvažme $\theta = (\mu, \sigma)$, ale chceme μ . Máme $\alpha \in (0,1)$. $\Psi_{n-1}(t_{\alpha/2}) = 1-\alpha/2$, $C_n = \langle \bar{X}_n - \mu, \bar{X}_n + \delta \rangle$ pro $\delta = t_{\alpha/2} \cdot \frac{S_n}{\sqrt{n}}$. Pak $P(C_n > \mu) = 1-\alpha$.

Testování hypotéz: H_0 - konvenční model, H_1 - alternativní. Bud' H_0 zámítáme (popis světa není správný), nebo nezámítáme (data jsou v souladu s H_0).
 Chyby dva druhů: 1: chybná zámítání, 2: chybná nepřijetí. Hledám významnosti α : $P(\text{chyba } 1) = \alpha$. Uváme kritický obor, zámítáme H_0 pokud $f(x_1, \dots, x_n) \in W$ (kritický obor)
 $p = P(H_0 | W) = \alpha \rightarrow 1-p$ je síla testu. Test obvykle sleduje: Opakujeme n -krát pokus, který může mít jeden z k výsledků, nezávisle. Testujeme $H_0: P(X_i) = p_i$, X_i := # pokusů s k_i výsled.
 $E_i := p_i, n$ jako $E(X_i)$. Společně Pearsonov statist. $T = \sum (E_i - X_i)^2 / E_i$. Kritická hodnota γ je kvant. fce χ^2 rozdělení s $k-1$ stupni volnosti v bodě $1-\alpha$,
 tj. $\gamma = Q(1-\alpha)$, kde $Q :=$ kvant. fce pro χ^2_{k-1} . Nulovou hypotézu zamítáme, pokud $T > \gamma$. Při tahová volba je $P(\text{chybná I. druhu}) = \alpha$.

Permutační test: Máme $X_1, \dots, X_m \sim F_X$, $Y_1, \dots, Y_n \sim F_Y$, chceme $H_0: F_X = F_Y$, $H_1: F_X \neq F_Y$ zvolíme statistiku $T: T(X_1, \dots, X_m, Y_1, \dots, Y_n)$, např.: $|\bar{X}_m - \bar{Y}_n|$
 Náhodně zpermutujeme $m+n$ čísel, pro každou permutaci vypočítáme T . Pokud by byla všechny permutace stejné, generovány se ze stejného rozdělení. Jako p -hodnotu
 vezmeme $p = 1/(m+n)!$. $\sum I(T_j > T_{(m+n)}) \rightarrow$ to je gust 1. druhu.

Generování n.v.: Náhodní výběr je inverze sampling: věta $U \sim U(0,1)$ a F dist fce. Pokud generování n.v. určitým bodem $x_0 - x_n$ s gust $f_n - f_{n-1}$, tak při nedělení
 intervalu $(0,1)$ na $p_1 - p_n$ částí při uniformním výběru $u \in (0,1)$ dostaneme správnou distribuci. Pokud si neumím vypočítat Q , použijeme rejeckou sampling.
 Tj. generuji X za pomoci Y , kde Y je nějaká známá distrib. $c > 0$ $\forall t: f_X(t) \leq c \cdot f_Y(t)$. Vygeneruji realizaci y z Y . Pokud $u \leq \frac{f_X(y)}{c \cdot f_Y(y)}$, tak $X := y$,
 jinak zahodím a postupuji znovu.

Diskrétní rozdělení: Bern(p): $P_X(x) = p, P_Y(0) = 1-p, E(X) = p, Var(X) = E(X^2) - E(X)^2 = p - p^2 = p(1-p)$ | Geom(p): $P_X(x) = (1-p)^{x-1} p, E(X) = \frac{1}{p}, Var(X) = \frac{1-p}{p^2}$ | Bin(n,p): $P_X(k) = \binom{n}{k} p^k (1-p)^{n-k}, E(X) = np, Var(X) = np(1-p)$
Hyper(N,k,n): $P_X(x) = \frac{\binom{K}{x} \binom{N-K}{n-x}}{\binom{N}{n}}, E(X) = n \frac{K}{N}, Var(X) = n \frac{K}{N} (1 - \frac{K}{N}) \frac{N-n}{N-1}$ ($E(X) = \sum E(X_i) = x \sim \text{Bern}(\frac{K}{N})$) | Pois(λ): $P_X(x) = \frac{\lambda^x}{x!} e^{-\lambda}, E(X) = \lambda, Var(X) = \lambda \rightarrow X_n \sim \text{Bin}(n, \lambda/n), X \sim \text{Pois}(\lambda) = \lim_{n \rightarrow \infty} \text{Bin}(n, \lambda/n) = P_X(\lambda)$

Spojité rozdělení: U(a,b): $f_X(x) = 1/(b-a) \cdot \mathbb{1}_{x \in [a,b]}$, jinde 0. $F_X(x) = (x-a)/(b-a), x \in [a,b], x \leq a \rightarrow 0, x \geq b \rightarrow 1, E(X) = (a+b)/2, Var(X) = (b-a)^2/12$ | Exp(λ): $f_X(x) = \lambda e^{-\lambda x}, x \geq 0$
 $E(X) = 1/\lambda, Var(X) = 1/\lambda^2$ | N(μ, σ^2): $E(X) = \mu, Var(X) = \sigma^2, f_X(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, F_X(x) = \Phi = \int \varphi$ | X ~ N(μ, σ^2), pokud $Z = (X-\mu)/\sigma$ a $Z \sim N(0,1)$. Dobuční $\mu + \sigma Z \sim N(\mu, \sigma^2)$
PNS-disk: X disk. n.v., g nel. fce $\Rightarrow E(g(X)) = \sum g(x) \cdot P(X=x)$ | $Y = g(X), E(Y) = \sum y \cdot P(Y=y)$, kde $P(Y=y) = \sum_{x: g(x)=y} P(X=x)$ | $E(X|B) = \sum x \cdot P(X=x|B)$

AIT fce: $E(X) = \sum_{x>n} P(X>n)$ | $E(X) = \sum_{k=0}^{\infty} k \cdot P(X=k) = \sum_{k=0}^{\infty} \sum_{l=k}^{\infty} P(X=l) = \sum_{l=0}^{\infty} \sum_{k=0}^l P(X=l) = \sum_{l=0}^{\infty} P(X=l)$ | Skr. hustota: $f_{X,Y}(x,y) = \partial^2 F_{X,Y}(x,y) / \partial x \partial y$
 $E(X) = \int x \cdot P(X=x), Var(X) = E((X-E(X))^2) = E(X^2) - E(X)^2, Var(aX+b) = a^2 Var(X) | Y = aX+b, Var(Y) = a^2 Var(X)$ | Cov(X,Y): $Cov(X,Y) = E((X-E(X))(Y-E(Y))) = E(X \cdot Y) - E(X) \cdot E(Y)$

Kolinearita: $e(X,Y) = cov(X,Y) / \sqrt{Var(X) \cdot Var(Y)}, -1 \leq e(X,Y) \leq 1$ | $X = \xi X_i, Var(X) = \xi \xi cov(X_i, X_i) = \xi \xi var(X) + \sum_{i \neq j} cov(X_i, X_j)$ | $E(X^2) = E(\xi \xi X_i^2) = \xi \xi E(X_i^2) = \xi \xi E(X_i) = \xi \xi E(X) (1-2)$
 $E(X \text{ spoj.}) = \int_{-\infty}^{\infty} x \cdot f_X(x) dx$ | Skr. prv. fce: $P_{X,Y}(x,y) = P(\sum_{i=1}^n \omega_i X_i = x \wedge \sum_{j=1}^m \omega_j Y_j = y)$ | Distr. fce: $F_X(x) = P(X \leq x)$, multispoj. zpmia spojité, $\lim_{x \rightarrow 0} = 0, \lim_{x \rightarrow \infty} = 1$ | $Var(X) = E((X-\mu)^2) = \int_{-\infty}^{\infty} (x-\mu)^2 f_X(x) dx$
 kde $\mu = E(X)$. Opt. Var(X) = E(X^2) - (E(X))^2, kde $E(X^2) = \int_{-\infty}^{\infty} x^2 f_X(x) dx$ | Unim. fce: $Q_X: (0,1) \rightarrow \mathbb{R}: Q_X(p) = \min \{x \in \mathbb{R}: p \leq F_X(x)\}, Q_X(p) \leq x \Leftrightarrow p \leq F_X(x)$ | Skr. dist. fce: $f_{X,Y}(x,y) = P(\sum_{i=1}^n \omega_i X_i \leq x \wedge \sum_{j=1}^m \omega_j Y_j \leq y)$

Ned. n.v. X,Y: $f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y)$ | Množ. hust.: $f_X(x) = \int_{\mathbb{R}} f_{X,Y}(x,y) dy$ | Podm. hust.: $f_{X|Y}(x|y) = (f_{X,Y}(x,y)) / f_Y(y)$ | $F_{X|B}(x) = P(X \leq x | B), f_{X|B}(x) = f_X(x) / P(B)$, kde $B = \sum_{i=1}^n \omega_i X_i \leq y$
Podm. hust. E: $E(X|B) = \int_{-\infty}^{\infty} x \cdot f_{X|B}(x) dx$, pokud B je měřit. $E(X) = E(E(X|B)), E(X) = E(E(X|Y))$ | Emp. dis. fce: $X_1, \dots, X_n \sim F$ je n.h. v.ř. Emp. dis. fce je $F_n(x) = \frac{1}{n} \sum I(X_i \leq x)$, kde $I(X_i \leq x) = 1$, pokud $X_i \leq x$, jinde 0. | $P(A|B) = P(A, B) / P(B)$

Momenty, příklad: $X_1, \dots, X_n \sim \text{Bern}(p)$, hledáme $\mu, m_1(\mu) = \mu, \hat{m}_1(\bar{X}_n) = \bar{X}_n$, tudíž bohatý odhad je \bar{X}_n . | Nm. $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, hledáme $\mu = (m_1(\mu), m_2(\mu) = E(X^2) = Var(X) + E(X)^2)$
 tedy $\mu = \bar{X}_n, \sigma^2 - p^2 = \frac{X_1^2 + \dots + X_n^2}{n} - \bar{X}_n^2 \rightarrow \hat{\mu} = \bar{X}_n, \hat{\sigma} = \sqrt{(\frac{X_1^2 + \dots + X_n^2}{n}) - \bar{X}_n^2}$

Max. víra, příklad: $X_1, \dots, X_n \sim \text{Bern}(p)$, hledáme \hat{p} . Předpokládáme, že bylo právě k pozitivních jevů. Tedy $L(x; p) = p^k (1-p)^{n-k}$, tedy $\ln L(x; p) = k \ln p + (n-k) \ln(1-p)$, uvažujeme
 a najdeme vnitřní bod: $\frac{k}{p} - \frac{n-k}{1-p}$, to dáme rovnost 0, tudíž $\frac{k}{p} = \frac{n-k}{1-p}$, tedy $p = k/n$. Což je opět \bar{X}_n .

Test. hyp., příklad: $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, σ^2 znám, zkusíme se odlišit od μ_0 . $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$ zvolíme statistiku $Z \sim (\bar{X}_n - \mu_0) / (\sigma/\sqrt{n})$. Víme, že $Z \sim N(0,1)$, pokud platí H_0 .
 Pokud zvolíme $W = \{x: |x| > z_{\alpha/2}\}$, kde $z_{\alpha/2} = \Phi^{-1}(1-\alpha/2)$, tak gust chyby 1. druhu bude přesně α . ← Toto je příklad jednoduchého testu.

Nezáv. veličiny: X, Y jsou nezáv., pokud $\forall x, y \in \mathbb{R}: f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y)$, neboli $P(X \leq x \wedge Y \leq y) = P(X \leq x) \cdot P(Y \leq y)$. Pro spoj.: $f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y)$
Hustota n.v. X: $f: \mathbb{R} \rightarrow [0, \infty)$ je hustota n.v. X , pokud $\forall x \in \mathbb{R}: P(X \leq x) = \int_{-\infty}^x f(t) dt$

Distr. fce: $F_X(x) = \int_{-\infty}^x f_X(t) dt$ | $E(X) = \int_{-\infty}^{\infty} t \cdot f(t) dt$

Integrované substituce: $\int f(g(x)) \cdot g'(x) dx = \int_{y=g(x)} f(y) dy, F(y) + c = F(g(x)) + c$

Důležité: $P(B_j|A) = P(B_j) \cdot P(A|B_j) / \sum_i P(B_i) \cdot P(A|B_i)$ $P(B_j|A) = P(B_j \cap A) / P(A) = P(B_j) \cdot P(A|B_j) / P(A)$ a $P(A) = \sum_i P(A|B_i) \cdot P(B_i)$

Pois. pan: A_1, \dots, A_n slovo ve jazyce, $P(A_i) = p_i$, $\sum p_i = 1$. Uvažujme n velkých písmen. Každé $\xi \in J_{A_i} \sim \text{Pois}(p_i)$. **Marq. rozd.** $P_X(x) = P(X=x) = \sum_y P(X=x \wedge Y=y) = \sum_y P_{X,Y}(x,y)$. **Uvažování vzorec:** $X, Y, Z = X+Y$ má psát fci $P(Z=z) = \sum_x P(X=x \wedge Y=z-x) = \sum_x g(x) \cdot f(z-x) = \sum_x g(x) \cdot f(z-x)$. $g(x,y) = x+y$, $Z = g(X,Y)$. $P_Z(z) = P(Z=z) = \sum_{x,y: g(x,y)=z} P(X=x \wedge Y=y) = \sum_{x,y: g(x,y)=z} g(x,y) \cdot P(X=x \wedge Y=y)$ | Pro X, Y n.n.v.: $E(XY) = E(X) \cdot E(Y)$

Lin. E. pro X, Y : X, Y n.v., $a, b \in \mathbb{R}$: $E(aX+bY) = a \cdot E(X) + b \cdot E(Y)$ $g(x,y) = ax+by$, $Z = g(X,Y)$. $E(Z) = 2 \cdot P_Z(z) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) = \sum_x \sum_y g(x,y) \cdot P(X=x) \cdot P(Y=y) = \sum_x g(x) \cdot P(X=x) = E(X)$

Spej. n.v. X s F_X : $P(X=x) = 0$, $P(a \leq X \leq b) = \int_a^b f_X(t) dt = P(X \leq b) - P(X \leq a) = F_X(b) - F_X(a)$ $\dots = \int_a^b f_X$. **Atud $b=x$, $a=(b-1)/n$, tak pro $n \rightarrow \infty$ přeje obsah ob. $P(a \leq X \leq b) = P(a < X < b) + P(X=a)$**

X s n.v. s $F = F_X$: $F(X) \sim U(0,1)$ $Y = F(X)$, pro $y \in (0,1)$ udme x t.j. $y = F(x)$. $P(Y \leq y) = P(F(X) \leq F(x)) = P(X \leq x) = F(x) = y$, tudíž F_Y se rovná shoduje s $U(0,1)$, tedy $Y \sim U(0,1)$

$U \sim U(0,1)$ a F distr.: Bud' Q odp. kvant. fce. Pak $Q(u)$ je n.v. s distr. fci F . $X = Q(U)$: $P(X \leq x) = P(Q(U) \leq x) = P(U \leq F_X(x)) = F_X(x)$ \rightarrow používáme pro generování veličin. Pro náhod. vzorek Q fci a udělan $Q(u)$

Past \square : $F = F_{X,Y}$, $P(X \in (a,b) \wedge Y \in (c,d)) = F(b,d) - F(a,d) - F(b,c) + F(a,c)$ **Uvaž. spej. n.v.:** $f_Z(z) = \int_{-\infty}^{\infty} f_X(x) \cdot f_Y(z-x) dx$ $E_{X,Y}(x) = 1 - e^{-xy}$, tedy $Q(p) = \log(1-p)/-x$, $Q(u) = \log(1-u)/-x$

O rozdelení hustoty: X s n.v. B_1, B_2, \dots rozdelen $\Omega \Rightarrow F_X(x) = \sum_i P(B_i) \cdot F_{X|B_i}(x)$ a $f_X(x) = \sum_i P(B_i) \cdot f_{X|B_i}(x)$ **Stojní jako:** $\int_0^1 P(A) = \sum_i P(B_i) \cdot P(A|B_i)$ $A = (A \cap B_1) \cup (A \cap B_2) \cup \dots$, tedy $P(A) = \sum_i P(A \cap B_i)$

Markovova ner. n.v. $X \geq 0$, $a \in \mathbb{R} > 0 \Rightarrow P(X \geq a) \leq \frac{E(X)}{a}$ $E(X) = P(X \geq a) E(X|X \geq a) + P(X < a) E(X|X < a) \geq P(X \geq a) \cdot a + 0$. Lze formulovat: $P(X \geq b) \cdot E(X) \leq b^2$

Čebyš. ner. X s $E(X) = \mu$, $\text{Var}(X) = \sigma^2 \Rightarrow P(|X - \mu| \geq t \cdot \sigma) \leq \frac{1}{t^2}$, tudíž $P(|X - \mu| \geq k) \leq \frac{\sigma^2}{k^2}$ $Y = (X - \mu)^2 \Rightarrow Y \geq 0$, $E(Y) = \sigma^2$ a nyní Markovova nerov.

Chernoffova ner. $X = \sum_i X_i$ n.n.v. s hodnotami ± 1 s psát $1/e \Rightarrow t > 0: P(X \leq -t \cdot \sigma) = P(X \geq t \cdot \sigma) \leq e^{-t^2/2}$, kde $\sigma = \sigma_X = \sqrt{n}$

SZVÖ: X_1, X_2, \dots stejné rozdelení n.n.v. s $E(X_i) = \mu$, $\text{Var}(X_i) = \sigma^2$. $\bar{X}_n = \sum_i X_i / n \Rightarrow \lim_{n \rightarrow \infty} \bar{X}_n = \mu$ Slovo ještě (\leq psát = 1)

SZVÖ: $\forall \varepsilon > 0: \lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| > \varepsilon) = 0$ „konverguje v průměrné hodnotě, $\bar{X}_n \xrightarrow{P} \mu$ “ $E(\bar{X}_n) = (\sum_i E(X_i)) / n = \mu$, $\text{Var}(\bar{X}_n) = (\sum_i \text{Var}(X_i)) / n^2 = \sigma^2 / n$, tedy podle Čebyš. $P(|\bar{X}_n - \mu| > \varepsilon) \leq \frac{\sigma^2 / n}{\varepsilon^2} \rightarrow$ to není jenom číslo, ale i náhod. v oděrování min. postu polusů.

CLV: X_1, X_2, \dots stejné rozdelení n.n.v. s $E(X) = \mu$, $\text{Var}(X) = \sigma^2$. Necht' $Y_n = ((\sum_i X_i) - n \cdot \mu) / (\sqrt{n} \cdot \sigma)$. Pak $Y_n \xrightarrow{D} N(0,1)$, tedy pokud F_n je distr. fce Y_n , pak $\lim_{n \rightarrow \infty} F_n(x) = \Phi(x) \forall x \in \mathbb{R}$

$E(X+Y)$ distr.: $E(X+Y) = E(X) + E(Y)$ $g(x,y) = x+y: E(g(X,Y)) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) = \sum_x \sum_y g(x,y) \cdot P(X=x) \cdot P(Y=y) = \sum_x g(x) \cdot P(X=x) + \sum_y g(y) \cdot P(Y=y) = E(X) + E(Y)$

$E(X \cdot Y)$ n.n.v.: $E(X \cdot Y) = E(X) \cdot E(Y)$ pro n.n.v. $E(X \cdot Y) = \sum_x \sum_y x \cdot y \cdot P(X=x \wedge Y=y) = \sum_x \sum_y x \cdot y \cdot P(X=x) \cdot P(Y=y) = \sum_x x \cdot P(X=x) \cdot \sum_y y \cdot P(Y=y) = E(X) \cdot E(Y)$ $\leftarrow \sum_y P(X=x \wedge Y=y) = P(X=x)$

Doplň $E(X)$: $E(X) = \sum_i P(B_i) \cdot P(X|B_i)$ $E(X) = \sum_x x \cdot P(X=x) = \sum_x x \cdot \sum_i P(B_i) \cdot P(X|B_i) = \sum_i P(B_i) \cdot \sum_x x \cdot P(X=x|B_i) = \sum_i P(B_i) \cdot E(X|B_i)$

Vlastnosti Emp. dis. fce: $E(\hat{F}_n(x)) = F(x)$, $\text{Var}(\hat{F}_n(x)) = (F(x) \cdot (1-F(x))) / n$, $\hat{F}_n(x) \xrightarrow{P} F(x)$

Ověření hustoty: Integrovat z $-\infty$ do $+\infty$ musí být rovná 1.