

Intervalové odhady n.m.v.: X_1, \dots, X_n mohou vypadat z $N(\mu, \sigma^2)$, ale zároveň mohou mít jiný rozložení než $N(\mu, \sigma^2)$. Nechť $\bar{X} = (2_{\text{ave}}) = 1 - \alpha/2$.
 $S_n = (X_1 + \dots + X_n)/n$, $C_n = \langle S_n - 2_{\text{ave}}, S_n + 2_{\text{ave}} \rangle$. Pak $P(C_n \geq \bar{X}) = 1 - \alpha$.

$\boxed{Y_n = \frac{\sum_{i=1}^n X_i}{\sqrt{n}} \sim N(0,1) \Rightarrow E(Y_n) = 0, \text{Var}(Y_n) = 1, P(Y_n > S_n + 2_{\text{ave}}/\sqrt{n}) = P(Y_n < -2_{\text{ave}}) = \bar{X}}$

Def: Pro mnoho různých $X_1, \dots, X_n \sim F_X$ a lib. fkt. g můžeme říct, že $\hat{\theta}_n = \text{estimace}/\text{mugyfikace}$ podle $E(\hat{\theta}_n) = g(r)$, asymptotický mugyfikacní podle $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = g(r)$, konzistentní podle $\hat{\theta}_n \xrightarrow{P} g(r)$.

rychlosť: $bias_g(\hat{\theta}_n) = E(\hat{\theta}_n) - r$, $MSE_g(\hat{\theta}_n) = E((\hat{\theta}_n - r)^2)$ | $MSE_g(\hat{\theta}_n) = bias_g(\hat{\theta}_n)^2 + var(\hat{\theta}_n)$ | $\text{var}(\hat{\theta}_n) = \text{var}(\hat{\theta}_n - r) = E((\hat{\theta}_n - r)^2) - E(\hat{\theta}_n - r)^2$.

Výklenkový princip: $\bar{X}_n = \frac{1}{n} \cdot \sum_{i=1}^n X_i$, $\bar{S}_n^2 = \frac{1}{n-1} \sum_{i=1}^{n-1} (X_i - \bar{X}_n)^2$ ← Výklenkový princip | Then \bar{X}_n je konzistentní rozložením základu μ , \bar{S}_n^2 konzistentní mugyfikací měření σ^2 .

Momenty: $m_r(r) := E(X^r)$: $X \sim F_X$... r-tý moment, $m_r(\bar{x}) := \frac{1}{n} \sum_{i=1}^n X_i^r$ pro mnoho různých X_1, \dots, X_n | $m_r(\bar{x})$ je rozložený konzistentním základem pro $m_r(r)$.

Met. Max. Veroj: Mírné mnoho různých $X = (X_1, \dots, X_n)$ mohou s prav. r : x_1, \dots, x_n realizovat různý X . Pak $L(X; \bar{x}) = \prod_{i=1}^n f_{X_i}(x_i; \bar{x})$ nebo $f_X(x; \bar{x}) = \prod_{i=1}^n f_{X_i}(x_i; \bar{x})$ je $L(X; \bar{x})$ výrobčem. Tedy $L(X; \bar{x})$ je funkce \bar{x} .

Volného takového \bar{x} , pro který je $L(\bar{x}; \bar{x})$ maximální (vypočítá se Metodou logaritmu): $X_1, \dots, X_n \sim N(\mu, \sigma^2)$ mnoho X : $L(X; \bar{x}) = \prod_{i=1}^n f_{X_i}(x_i; \bar{x}, \mu, \sigma^2)$ mnoho \bar{x} : $L(\bar{x}; \bar{x}, \mu, \sigma^2)$ má mnoho \bar{x} , když $\bar{x} = \bar{x}_0$, pak máme $\bar{x}_0 = \bar{x}_0(\mu, \sigma^2)$.

$\boxed{\bar{X}_n - \bar{\mu} < \mu < \bar{X}_n + \bar{\sigma} \Rightarrow -\bar{\sigma} < \bar{X}_n - \mu < \bar{\sigma} \Rightarrow -\frac{\bar{\sigma}}{\sqrt{n}} < \frac{\bar{X}_n - \mu}{\sqrt{n}} < \frac{\bar{\sigma}}{\sqrt{n}}$ pro $\delta = \frac{\bar{\sigma}}{\sqrt{n}}$, pak $P(C_n \geq \delta) = 1 - \alpha$.

Testování hypotézy: H_0 - konzistentní měření, H_1 - alternativa. Podle H_0 zaměňujeme (případně neplatí), měření rozložené (dále jen v souhlu s H_0)

Obvyklý důkaz: 1: obecný důkaz, 2: obecný příklad. Hlavní rozdímnost: $\alpha: P(\text{obz} > 1 - \alpha)$. Uvažme konkrétní obor, zaměňujeme H_0 , pakže $H_0: X_1, \dots, X_n \sim W$ (konkrétní obor).

$\beta = P(\text{obz} \notin W; H_1) \Rightarrow 1 - \beta$ je slib testu. | Test obz. shoduj: Odpovídající měření pokud být může na jeden z k výsledků, množství. Testujeme $H_1: P(X_i) = p_i$, $X_i := \# \text{pokusů s } k_i$ vysel.

$E_i := P_i$, n jehož $E(X_i)$. Speciálně Pearsonova statistik: $T = \sum_{i=1}^n (E_i - X_i)^2 / E_i$. Konkrétní hodnota τ je konkr. fce X^n rozložení s $k-1$ stupni volnosti v bocí $1-\alpha$, $f_j: \tau = Q(1-\alpha)$, kde $Q :=$ konkr. fce pro X_{k-1}^2 . Mírnou hypotézu zaměňujeme, pakže $T > \tau$. Při takovém výsledku je $P(\text{obz. I. důkaz}) = \infty$.

Permutační test: Máme $X_1, \dots, X_n \sim F_X, Y_1, \dots, Y_n \sim F_Y$, chcieme $H_0: F_X = F_Y, H_1: F_X \neq F_Y$. Zvolíme statistiku $T: T(X_1, \dots, X_n, Y_1, \dots, Y_n)$, např.: $\bar{X}_n - \bar{Y}_n / \sqrt{\text{var}(X)} / \sqrt{\text{var}(Y)}$.

Náhodná zpravidlost je mnoho výsledků, pro každou poskytuje výsledek T . Předpoklad je, že tyto výsledky poskytují stejnou generaci se z dležitou rozložení. Jako p-hodnota vypočteme $p = 1/(\text{mnoho})!$ | $I(T_j > T_{\text{prev}}) \rightarrow$ to je první I. důkaz.

Generační r.v.: Základní myšlenka je inverse sampling: větla $U \sim U(0,1)$ a F dležit fce. Poloha pravděpodobnosti m.r.v. mohou mít význam x_1, \dots, x_n s počtem n_1, \dots, n_k , takže nezáleží interval $(0,1)$ na p_1, \dots, p_k , kde je uniformní výběr m.r.v. $(0,1)$ dostat správnou distribuci. Poloha se nezmění vyprávění Q , pouze je reprezentace sampling.

Tj. generuj: X ze pouzdro Y , kde Y je nějaká rozměř. blížba: $c > 0$ | $H: f_X(t) \leq c f_Y(t)$. Významné realizace y z Y . Předpoklad $n \leq \frac{f_X(y)}{c f_Y(y)}$, kde $X := y$, jinak základní a poskytují zrovna.

Diskrétní rozložení: Bern(p): $p_X(i) = p, p_{\bar{X}}(i) = 1-p, E(X) = p, \text{Var}(X) = E(X^2) - E(X)^2 = p - p^2 = p(1-p)$ | Geom(p): $p_X(k) = (1-p)^{k-1} p, E(X) = \frac{1}{p}, \text{Var}(X) = \frac{1-p}{p^2} \text{Bin}(n, p): p_X(k) = \binom{n}{k} p^k (1-p)^{n-k}, E(X) = np, \text{Var}(X) = np(1-p)$

Hyper(N, k, n): $p_X(k) = \binom{k}{n} \binom{n-k}{n} / \binom{n}{n}, E(X) = n \frac{k}{n} = k, \text{Var}(X) = n \frac{k}{n} \left(1 - \frac{k}{n}\right) \frac{n-1}{n-1} \quad (\text{EX} = \mathbb{E}(X) : Y \sim \text{Bin}(\frac{n}{k}))$ | Pois(k): $p_X(k) = \frac{\lambda^k}{k!} e^{-\lambda}, E(X) = \lambda, \text{Var}(X) = \lambda \rightarrow X \sim \text{Bin}(n, \lambda/n), X \sim Pois(\lambda): \lim_{n \rightarrow \infty} p_X(k) = p_X(k)$

Spojité rozložení: $U(a, b): f_{X,a,b}(x) = 1/(b-a) : x \in (a, b)$, jinde 0. $F_X(x) = (x-a)/(b-a)$, $x \leq a = 0, x \geq b = 1, E(X) = (a+b)/2, \text{Var}(X) = (b-a)^2/12$ | Exp(λ): $F_X(x) = 1 - e^{-\lambda x}: x \geq 0$, jinde 0. $f_X(x) = \lambda e^{-\lambda x}: x \geq 0$

$E(X) = \bar{Y}_1, \text{Var}(X) = \frac{1}{n^2} \sum_{i=1}^n N(\mu, \sigma^2): E(X) = \mu, \text{Var}(X) = \sigma^2, f_X(x) = \varphi: \varphi(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-x^2/2}, F_X(x) = \Phi \left[\frac{x-\mu}{\sigma} \right] \text{prob. 2} = (X-\mu)/\sigma \sim N(0, 1)$. Dále $\mu + \sigma/2 \sim N(\mu, \sigma^2)$

PNS-disk.: X disk. m.r.v., g nelze fce $\Rightarrow E(g(X)) = \int g(x) \cdot P(X=x) \mid Y = g(X), E(Y) = \mathbb{E} Y \cdot \mathbb{P}(Y=g)$, kde $P(Y=g) = \int_{x: g(x)=g} P(X=x) \mid E(X|B) = \mathbb{E} X \cdot P(X=X|B)$

AH: $EY = \int_{x: g(x)=g} P(X=x) \mid E(X) = \sum_{x: g(x)=g} p_x \cdot P(X=x) = \sum_{x: g(x)=g} p_x \cdot P(X=x) \mid \text{Str. hustota: } f_{X,Y}(x,g) = \frac{\partial^2 F_{X,Y}(x,g)}{\partial x \partial g}$

$E(X) := \mathbb{E} X \cdot P(X=x), \text{Var}(X) = E(X^2) - E(X)^2, Var(X) = \sigma^2 \text{Var}(X) \neq 0 \Rightarrow Y = g(X) \sim N(\mu, \sigma^2) \mid Cov(X, Y) = E((X-E(X))(Y-E(Y))) = E(XY) - EX \cdot EY$

Kolmanský: $e(X, Y) = cov(X, Y) / \sqrt{\text{var}(X) \cdot \text{var}(Y)}, -1 \leq cov(X, Y) \leq 1 \mid X = \mathbb{E} X, Y = \mathbb{E} Y \cdot cov(X, Y) = \mathbb{E} \text{var}(X) + \mathbb{E} cov(X, Y) \mid E(X^2) = \mathbb{E} (\mathbb{E} X)^2 - E(\mathbb{E} X)^2 = \mathbb{E} (\mathbb{E} X)^2 - \mathbb{E} (\mathbb{E} X \cdot \mathbb{E} X) = \mathbb{E} (\mathbb{E} X)^2 - \mathbb{E} (\mathbb{E} X) \cdot \mathbb{E} X = \mathbb{E} X \cdot \mathbb{E} X - \mathbb{E} X \cdot \mathbb{E} X = 0$

$E(X) \text{ spoj. } \int_{-\infty}^{+\infty} x f_X(x) dx \mid \text{Str. prav. fce: } P_{X,Y}(x,y) = P(\{X=x \wedge Y=y\}) \mid \text{Distr. fce: } F_X(x) = P(X \leq x), \text{ následná, zpravidla správná, fce: } \lim_{x \rightarrow \infty} F_X(x) = 1 \mid \text{Var}(X) = E((X-\mu)^2) = \int_{-\infty}^{+\infty} (x-\mu)^2 f_X(x) dx$

Int. m.r.v. $E(X|Y)$: $f_{X|Y}(x|y) = f_{X,Y}(x,y) / f_Y(y)$ | $\text{Podm. hust. } f_{X|Y}(x|y) = (f_{X,Y}(x,y) / f_Y(y)) \mid F_{X|Y}(x|y) = P(X \leq x \mid Y=y), f_{X|Y}(x|y) = f_X(x) / P_{X|Y}(y)$, kde $B = \{x \in \mathbb{R} : X \in B \mid Y=y\}$

Podm. hust. $E(X|B) = \int_{x \in B} x f_{X|Y}(x|y) dx$, pakže $E(X) = \mathbb{E} X \cdot P(X \in B) \mid E(X|B) = \mathbb{E} X \cdot P(B) = \mathbb{E} X \cdot P(A, B) / P(B)$

= $(\mathbb{E} X \cdot P(X \in B)) / P(B)$, kde $I(X \in B) = 1$, pakže $X \in B$, jinde 0. $| P(A|B) = P(A, B) / P(B)$

Momenty, pravidla: $X_1, \dots, X_n \sim \text{Bern}(p)$, hledáme $X, m_p(r) = \bar{X}_n$, tedy končící základem je \bar{X}_n . | Myšlení $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, hledáme $\bar{X} = (\mu, \sigma)$. Tedy $m_p(r) = \mu, m_p(r) = E(X^2) - \text{Var}(X) = E(X^2) - \mu^2$.

tedy $\mu = \bar{X}_n, \sigma^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \rightarrow \mu = \bar{X}_n, \sigma^2 = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2} = \bar{X}_n$

Max. Veroj. pravidlo: $X_1, \dots, X_n \sim \text{Bern}(p)$, hledáme \bar{Y}_1 . Předpokládáme, že bylo práv. k pozitivním jist. Tedy $L(X; \bar{x}) = \bar{x}^k (1-\bar{x})^{n-k}$ tedy $k \cdot \log(\bar{x}) + (n-k) \cdot \log(1-\bar{x})$, myšlení základně

a myšlení množiny bodů: $\frac{d}{dx} \log(\bar{x}) = \frac{1-x}{x^2}, \text{ to dále množ. } Q, \text{ tedy } \bar{x} = \frac{n-Q}{n}$, tedy $\bar{x} = \bar{Y}_1$. Což je práv. \bar{X}_n .

Test. hyp. pravidlo: $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, σ^2 známo a základně obecné prav. $H_0: \bar{X}_n = \mu, H_1: \bar{X}_n \neq \mu \pm \sigma/\sqrt{n}$, pakže platí H_0 .

Poloha vzdále $W - \mathbb{E} X: |X - \mu| > 2 \sigma/\sqrt{n}$, kde $Z = \frac{1}{\sigma/\sqrt{n}} (X - \mu)$, tedy první obecný 1. důkaz bude přesně $\alpha \leftarrow$ Toto je příklad jednorázového testu.

Necit. reliabilita: X, Y jsou nezávislé, pakže $H: f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y)$, množ. $P(X \leq x \wedge Y \leq y) = P(X \leq x) \cdot P(Y \leq y)$. Pro zápl.: $f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y)$

Hustota m.r.v.: $f: \mathbb{R} \rightarrow (0, \infty)$ je hustota m.r.v. X , pakže $H: P(X \leq x) = \int_x^{\infty} f(t) dt$

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

Integrovaná substitucia: $\int f(g(x)) \cdot g'(x) dx = \int \frac{y = g(x)}{dy = g'(x) dx} f(y) dy = \int f(y) dy, F(y) + C = F(g(x)) + C$

Bayesovo: $P(B_j|A) = P(B_j) \cdot P(A|B_j) / \sum_i P(B_i) \cdot P(A|B_i)$ | $P(A|B_j) = P(B_j|A) \cdot P(A) / P(B_j)$ a $P(A) \neq P(B_j|A)$ je jisté všechny celi. post.

Pois. prav.: A_1, \dots, A_n súrovné, $P(A_i) = p_i$, $\sum_i p_i = 1$. Nechaj "u velykým" B_0 mali $B_0 \in J_{A_1} \cup J_{A_2} \cup \dots \cup J_{A_n}$. | Marginal: $P_X(x) = P(X=x) = \sum_y P(X=x \wedge Y=y) = \sum_y p_{x,y} f_{X,Y}(x,y)$ | Umožňuje učinit: $X, Y, \dots, Z = X+Y$

má pošti funkciu $P(2=2) = \sum_x P(X=x \wedge Y=2-x) = g(x,y) = x+y$. $2 = g(X,Y)$. $p_2(z) = P(2=z) = \sum_{x,y} g(x,y) = z \cdot P(X=x \wedge Y=y) = z \cdot \sum_{x,y} p_{x,y} f_{X,Y}(x,y) \rightarrow$ to je ale dezávanie funkcií, ktoré nazývame. Hlavné ješou nezávislé.

Lín. E pre XY: X, Y n.r., ak je $E(aX+bY) = aE(X)+bE(Y)$ | $g(x,y) = ax+by$. $E(2) = 2 \cdot p_2(z) = 2 \cdot \sum_{x,y} p_{x,y} f_{X,Y}(x,y) = \sum_x x \cdot \sum_y y \cdot p_{x,y} f_{X,Y}(x,y)$ | $P(X=x \wedge Y=y) = \frac{1}{xy} \dots$

Správ. n.r. X, Y: $P(X=x) = \int_a^b f_X(t) dt = P(X \leq b) - P(X \leq a) = F_X(b) - F_X(a) = \dots = \int_a^b f_X(x) dx$. Ak má $b=x$, $a=b-1/n$, tak má $n \rightarrow \infty$ počet oblastí do 0. $P(a \leq X \leq b) = P(a \leq X \leq b) + P(X=x)$

X s.r.v. s F: $F(X) \sim U(0,1)$ | $Y=F(X)$, pre $y \in (0,1)$ máme $x = F^{-1}(y)$. $P(Y \leq y) = P(F(X) \leq F^{-1}(y)) = P(X \leq x) = F(x) = y$, teda F_Y sa rávne s $U(0,1)$, teda $Y \sim U(0,1)$

(X ~ U(0,1) a F distri. Buvú Q ako konstant. fce. Patrí Q(U) je n.r. s def. fce. F. | $X = Q(U) : P(X=x) = P(Q(U) \leq x) = P(U \leq F_x) = F_x \rightarrow$ použijeme pre generálnu rovnica. Pre rozdiel n.r. v rámci Q(fce) a Q(u)

Post □ : $F = F_{X,Y}, P(X \geq a, b > Y \geq c, d) = F(b,d) - F(a,d) - F(b,c) + F(a,c)$ | Naopak: $f_Z(z) = \int_{-\infty}^z f_X(x) f_Y(z-x) dx$ | $\text{Exp}(x) \text{ na } F_x = 1 - e^{-x}$, teda $Q(p) = \log(1-p) / -\lambda$, $Q(U) = \log(1-U) / -\lambda$

O rozkladu hustoty X s.r.v. B_{11}, B_{12} vektor $J_2 = \{F_X(x) = \sum_i P(B_i) F_{X|B_i}(x)\}$ a $f_X(x) = \sum_i P(B_i) f_{X|B_i}(x)$ | Stepný zloženie: $P(A) = \sum_i P(B_i) \cdot P(A|B_i) / A = (A \cap B_1) \cup (A \cap B_2) \cup \dots$, teda $P(A) = \sum_i P(A|B_i)$

Markovova ner. n.r. $X \geq 0$, $a \in \mathbb{R} > 0 \Rightarrow P(X \geq a) \leq \frac{EX}{a}$ | $EX = P(X \geq a)(E(X) \geq a) + P(X < a)E(X|X < a) \geq P(X \geq a) \cdot a + 0$, teda formálne: $P(X \geq a, E(X)) \leq \frac{1}{a}$

Čebjs. ner. $X \leq E(X)=\mu$, $V(X)=\sigma^2 \Rightarrow P(|X-\mu| \geq \sigma) \leq \frac{1}{2}\sigma^2$, mali $P(|X-\mu| \geq k) \leq \frac{\sigma^2}{k^2} \Rightarrow Y=(X-\mu)^2 \Rightarrow Y \geq 0$, $E(Y)=\sigma^2$ a myšli Markovova nerov.

Chernoffova ner.: $X = \sum_i X_i$ n.r.v s hodnotami ± 1 a pošti $1/2 \Rightarrow \Pr[X \geq \sigma] = \Pr[X \geq \sigma] \leq e^{-\sigma^2/2}$, kde $\sigma = \sigma_X = \sqrt{V}$

SZVČ: X_1, X_2, \dots súrovné n.r.v.s $E(X_i) = \mu_i$, $V(X_i) = \sigma_i^2$, $\bar{X}_n = \frac{1}{n} \sum_i X_i \rightarrow \lim_{n \rightarrow \infty} \bar{X}_n = \mu$. Skon. ještě ($\sigma^2 \rightarrow 0$)

WZVG: $-1 \leq \epsilon \leq 1$: $\Pr[|\bar{X}_n - \mu| > \epsilon] = 0$ konverguje v pravdepodobnosti, $\bar{X}_n \xrightarrow{P} \mu$ | $E(\bar{X}_n) = (\sum_i E(X_i))/n = \mu$, ještě ještě $\Rightarrow V(\bar{X}_n) = (\sum_i V(X_i))/n^2 = \sigma^2/n$, teda počle čebzicu: $\Pr[|\bar{X}_n - \mu| > \epsilon] \leq \frac{\sigma^2}{n \epsilon^2} \rightarrow$ to má ňešený dôkaz, ale i nájdme akteromini min. počtu počtu.

CLV: X_1, X_2, \dots súrovné n.r.v.s $E(X) = \mu$, $V(X) = \sigma^2$. Nechaj $Y_n = ((\sum_i X_i) - n\mu) / (\sqrt{n} \cdot \sigma)$. Patří $Y_n \xrightarrow{D} N(0,1)$, teda počet $F_n(x) = \Pr[Y_n \leq x] = \Pr[\sum_i X_i \leq n\mu + \sqrt{n}x]$.

E(X+Y) dôkaz: $E(X+Y) = E(X) + E(Y) \neq g(x,y) = E(g(X,Y)) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) + \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y \neq y) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) + \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y \neq y) = \sum_x \sum_y g(x,y) \cdot P(X=x \wedge Y=y) = EX + EY$

E(X \cdot Y) n.r.v.: $E(X \cdot Y) = E(X) \cdot E(Y)$ pre n.r.v. $E(X \cdot Y) = \sum_x \sum_y x \cdot y \cdot P(X=x \wedge Y=y) = \sum_x \sum_y x \cdot P(X=x) \cdot y \cdot P(Y=y) = \sum_x x \cdot P(X=x) \cdot \sum_y y \cdot P(Y=y) = EX \cdot EY$ | $\Pr[X=x \wedge Y=y] = P(X=x) \cdot P(Y=y) = P(X=x) \cdot P(Y=y) = P(X=x \wedge Y=y) = P(X=x)$

Dôplní E(X): $E(X) = \sum_i P(B_i) \cdot P(X|B_i)$ | $E(X) = \sum_i x \cdot P(X=x) = \sum_i x \cdot \sum_j P(B_j) \cdot P(X|B_j) = \sum_i x \cdot P(B_i) \cdot \sum_j P(X=x|B_j) = \sum_i x \cdot P(B_i) \cdot E(X|B_i) = \sum_i x \cdot P(B_i) \cdot P(X=x|B_i)$

Vlastnosti E(X) a dis. fce: $E(F_n(x)) = F(x)$, $V(F_n(x)) = (F(x) \cdot (1-F(x))) / n$, $\Pr[F_n(x) \leq x] \rightarrow F(x)$

Overom hustoty: Integraľ 2 $- \infty \rightarrow \infty$ musí byť menší 1.