

7. Konvergence na pravděpodobnostním prostoru

V této kapitole se budeme zabývat zavedením konvergence na $\{\Omega, \mathfrak{A}, P\}$ - pravděpodobnostním prostoru. Budeme studovat vlastnosti vybraných druhů konvergence, jejich vlastnosti, omezení a způsoby využití především při studiu zákonů velkých čísel a centrálních limitních vět.

7.1 Konvergence v distribuci

Přirozený způsob zavedení konvergence náhodných veličin založený na bodové konvergenci distribučních funkcí.

Definice 7.1

Nechť X, X_1, X_2, \dots jsou náhodné veličiny a k nim příslušné distribuční funkce necht' jsou F, F_1, F_2, \dots . Řekneme, že posloupnost $\{X_n\}$ náhodných veličin **konverguje v distribuci** k náhodné veličině $X \Leftrightarrow \lim_{n \rightarrow \infty} F_n(x) = F(x)$ ve všech bodech x spojitosti funkce

F. Tento vztah zapisujeme takto: $X_n \xrightarrow{D} X$.

Velmi důležitá pro vyšetřování daného typu konvergence je následující věta.

Věta 7.2

- $X_n \xrightarrow{D} X \Leftrightarrow \lim_{n \rightarrow \infty} E(f(X_n)) = E(f(X))$, pro f spojitě zobrazení na \mathbb{R}_1
- $X_n \xrightarrow{D} X \Leftrightarrow \varphi_n(t) \rightarrow \varphi(t)$, $t \in \mathbb{R}_1$ a $\varphi, \varphi_1, \varphi_2, \dots$ jsou charakteristické funkce náhodných veličin X, X_1, X_2, \dots
- $X_n \xrightarrow{D} X, Y_n \xrightarrow{D} Y \Rightarrow X_n + Y_n \xrightarrow{D} X + Y$
- $X_n \xrightarrow{D} X, X_n \xrightarrow{D} Y \Rightarrow X = Y$

Důkaz:

Nebudeme provádět, protože se vymyká obsahu tohoto textu. Celkově je uveden v část IV. V [1].

Poznámka 7.3

Podobně můžeme definovat konvergenci v distribuci pro náhodné vektory a to po složkách.

Příklad 7.4

Nechť $\{X_n\}$ je posloupnost náhodných veličin typu $N(0,1)$. Necht' dále je $Y_n = \frac{\sum_{i=1}^n X_i}{\sqrt{n}}$

. Potom $Y_n \xrightarrow{D} N(0,1)$. Důkaz provedeme pomocí části 2. ve větě 7.2. Nejdříve zjistíme charakteristickou funkci φ_n náhodné veličiny Y_n . Podle věty 6.5 má náhodná veličina X_n

charakteristickou funkci rovnou $\varphi_{X_n}(t) = e^{-\frac{t^2}{2}}$, tedy podle věty 6.3 je $\varphi_{Y_n}(t) = e^{-n \cdot \frac{\left(\frac{t}{\sqrt{n}}\right)^2}{2}} = e^{-\frac{t^2}{2}}$.

Všechny charakteristické funkce Y_n jsou shodné a jsou rovny charakteristické funkci $N(0,1)$.

Tedy $Y_n \xrightarrow{D} N(0,1)$.

Příklad 7.5

Nechť $\{ X_n \}$ je posloupnost náhodných veličin typu $\mathbf{N}(\mu, \sigma^2)$. Necht' dále je

$Y_n = \frac{\sum_{i=1}^n X_i - n \cdot \mu}{\sigma \cdot \sqrt{n}}$, potom $Y_n \xrightarrow{D} N(0,1)$. Nejdříve podle věty 6.5 nalezneme charakteristickou

funkci $\varphi_{X_n}(t) = e^{i \cdot t \cdot \mu} \cdot e^{-\frac{(t \cdot \sigma)^2}{2}}$, charakteristická funkce náhodné veličiny $Z_n = \sum_{i=1}^n X_i$ je rovna

$\varphi_{Z_n}(t) = e^{i \cdot n \cdot t \cdot \mu} \cdot e^{-n \cdot \frac{(t \cdot \sigma)^2}{2}}$, tedy podle věty 6.3 je $\varphi_{Y_n}(t) = e^{-i \cdot t \cdot \sqrt{n} \cdot \frac{\mu}{\sigma}} \cdot e^{i \cdot n \cdot \frac{1}{\sigma \cdot \sqrt{n}} \cdot \mu} \cdot e^{-n \cdot \frac{\left(\frac{t}{\sigma \cdot \sqrt{n}}\right)^2}{2}} = e^{-\frac{t^2}{2}}$, tedy

opět $Y_n \xrightarrow{D} N(0,1)$.

Příklad 7.6

Nechť $\{ X_n \}$ je posloupnost náhodných veličin typu $X_n \sim \mathbf{N}(\mu_n, \sigma_n^2)$. Necht' dále je,

$Y_n = \frac{\sum_{i=1}^n X_i - \sum_{i=1}^n \mu_i}{\sqrt{\sum_{i=1}^n \sigma_i^2}}$ potom $Y_n \xrightarrow{D} N(0,1)$. Dokažte sami stejnou metodou jako v předchozím!

Příklad 7.7

Nechť $\{ X_n \}$ je posloupnost náhodných veličin typu $X_n \sim \mathbf{Po}(\lambda_n)$ Necht' dále

je $Y_n = \frac{X_n - \lambda_n}{\sqrt{\lambda_n}}, n=1,2,\dots$, potom $Y_n \xrightarrow{D} N(0,1)$. Podle (6.8) je charakteristická funkce X_n

rovna $\varphi_{X_n}(t) = e^{\lambda_n(e^{i \cdot t} - 1)}$, k dalšímu výpočtu použijeme opět věty 6.3, tím získáme vztah pro

charakteristickou funkci Y_n . $\varphi_{Y_n}(t) = e^{-i \cdot \sqrt{\lambda_n} \cdot t} \cdot e^{\lambda_n \cdot \left(e^{i \cdot \frac{t}{\sqrt{\lambda_n}}} - 1 \right)} = e^{\lambda_n \cdot \left(e^{i \cdot \frac{t}{\sqrt{\lambda_n}}} - 1 - \frac{i \cdot t}{\sqrt{\lambda_n}} \right)}$,

ukážeme, že tato charakteristická funkce konverguje k charakteristické funkci $\mathbf{N}(0,1)$. Proto

stačí dokázat, že $\lambda_n \cdot \left(e^{i \cdot \frac{t}{\sqrt{\lambda_n}}} - 1 - \frac{i \cdot t}{\sqrt{\lambda_n}} + \frac{t^2}{2 \cdot \lambda_n} \right) \rightarrow 0$, ale podle (6.9) platí odhad:

$$\lambda_n \cdot \left| \left(e^{i \cdot \frac{t}{\sqrt{\lambda_n}}} - 1 - \frac{i \cdot t}{\sqrt{\lambda_n}} + \frac{t^2}{2 \cdot \lambda_n} \right) \right| \leq \frac{\lambda_n \cdot |t|^3}{6 \cdot \sqrt{\lambda_n^3}} = \frac{|t|^3}{6 \cdot \sqrt{\lambda_n}},$$

protože pro $n \rightarrow +\infty$ je $\frac{|t|^3}{6 \cdot \sqrt{\lambda_n}} \rightarrow 0$. Odtud je tedy $Y_n \xrightarrow{D} N(0,1)$.

Příklad 7.8

Nechť $\{X_n\}$ je posloupnost náhodných veličin typu $\mathbf{A}(p)$ (alternativní rozdělení

s parametrem p). Necht' dále je $Y_n = \frac{\sum_{i=1}^n X_i - n \cdot \mu}{\sigma \cdot \sqrt{n}}$, potom $Y_n \xrightarrow{D} N(0,1)$. Dokažte sami,

uvědomte si, že náhodná veličina $\sum_{i=1}^n X_i$ je typu binomické rozdělení s parametry (n,p) .

K výpočtu dále využijte vztahu (6.3) a (6.7) a větu 6.3.

7.2 Konvergence skoro jistě

Definice 7.9

Nechť $\{X_n\}$ je posloupnost náhodných veličin. Řekneme, že posloupnost $\{X_n\}$ **konverguje skoro jistě** k náhodné veličině X , jestliže existuje množina $A \in \mathfrak{F}$, $P(A) = 1$ taková, že existuje konečná $\lim_{n \rightarrow \infty} X_n(\omega), \omega \in A$ a je $\lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)$. Tento způsob

konvergence budeme označovat $X_n \xrightarrow{s.j.} X$.

Následující věta dává ekvivalentní definici konvergence skoro jistě a zároveň je posouzena jednoznačnost konvergence.

Věta 7.10

1. Necht' X je náhodná veličina a $\{X_n\}$ je posloupnost náhodných veličin. Potom

$$X_n \xrightarrow{s.j.} X \Leftrightarrow P\left(\omega; \bigcap_{\varepsilon > 0} \bigcup_{k=1}^{+\infty} \bigcap_{n=k}^{+\infty} [|X_n(\omega) - X(\omega)| \leq \varepsilon]\right) = 1$$

2. Jsou-li X, Y náhodné veličiny takové, že $X_n \xrightarrow{s.j.} X, X_n \xrightarrow{s.j.} Y \Rightarrow X = Y$

Důkaz:

1. Podle definice 7.9 je

$$A = \left(\omega; \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\right) = \left(\omega; \bigcap_{\varepsilon > 0} \bigcup_{k=1}^{+\infty} \bigcap_{n=k}^{+\infty} [|X_n(\omega) - X(\omega)| \leq \varepsilon]\right) \text{ a navíc } P(A) = 1$$

2. $(\omega; X(\omega) = Y(\omega)) \supset (\omega; \lim_{n \rightarrow +\infty} X_n = X) \cap (\omega; \lim_{n \rightarrow +\infty} X_n = Y) = C$, avšak podle definice konvergence s.j.7.9 je jev C jistý tedy $P(C) = 1$

Q.E.D.

Další věta umožňuje porovnání navzájem různých způsobů konvergence.

Věta 7.11

Jegorovova

Nechť X, X_1, X_2, \dots jsou náhodné veličiny. Potom $X_n \xrightarrow{s.j.} X$ právě tehdy, když pro každé $\varepsilon > 0$ existuje množina $A_\varepsilon \in \mathfrak{F}$, $P(A_\varepsilon) > 1 - \varepsilon$ a $X_n \xrightarrow{\rightarrow} X$ na A_ε .

Důkaz:

a) Nejdříve dokážeme implikaci zprava doleva. Použijeme-li označení ze znění věty

$$\text{je } \left\{ \omega; \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega) \right\} \supset \bigcup_{n=1}^{+\infty} A_{\frac{1}{n}} = A \text{ a jistě } P(A) = 1.$$

b) Budeme dokazovat opačnou implikaci. Potom podle definice je :

$$\forall_{\varepsilon > 0} \exists_{\{n_i\} \subset \mathbb{N}} ; P\left(\bigcap_{n \geq n_i} \left[|X_n - X| \leq \frac{1}{i}\right]\right) \geq 1 - \frac{\varepsilon}{2^i} . \text{ Tento výrok vyplývá ze spojitosti}$$

zdola pravděpodobnosti viz (1.15). Zvolíme potom

$$A_\varepsilon = \bigcap_{i=1}^{+\infty} \bigcap_{n=n_i}^{+\infty} \left[|X_n - X| \leq \frac{1}{i}\right] . \text{ Označme } A_n^i = \left\{ \omega; \forall_{m \geq n} |X_m(\omega) - X(\omega)| \leq \frac{1}{i} \right\}$$

Potom platí:

$$a) \bigcup_{i=1}^{+\infty} A_n^i = A \quad a \quad P(A) = 1$$

$$b) A_n^i \subset A_{n+1}^i$$

$$c) \forall_{j \in \mathbb{N}} \exists_{n_j \in \mathbb{N}} P(A_{n_j}) > P(A) - \frac{\varepsilon}{2^j}$$

$$d) \overline{A_\varepsilon} = \Omega \setminus \bigcap_{i=1}^{\infty} \bigcap_{n=n_i}^{\infty} \left[|X_n - X| \leq \frac{1}{i}\right] = \bigcup_{i=1}^{\infty} \left(\Omega \setminus \bigcap_{n=n_i}^{\infty} \left[|X_n - X| \leq \frac{1}{i}\right] \right) = \bigcup_{i=1}^{\infty} \overline{A_{n_i}^i}$$

$$e) P(\overline{A_\varepsilon}) \leq \sum_{i=1}^{\infty} P(\overline{A_{n_i}^i}) \leq \sum_{i=1}^{\infty} \frac{\varepsilon}{2^i} = \varepsilon , \text{ protože } P(A_{n_i}^i) \geq P(A) - \frac{\varepsilon}{2^i}$$

Q.E.D.

Velmi důležitá je následující věta , která dokazuje zaměnitelnost pojmu spojitosti a konvergence skoro jistě.

Věta 7.12

Nechť $\{X_n\}$ je posloupnost náhodných veličin , nechť dále je $X_n \xrightarrow{s.j.} X$, kde X je náhodná veličina. Nechť dále je $f: R_1 \rightarrow R_1$ je spojitá funkce. Potom také platí $f \circ X_n \xrightarrow{s.j.} f \circ X$.

Důkaz:

Protože je f spojitá reálná funkce platí

$$\forall_{\varepsilon > 0} \exists_{\delta > 0} ; |t_n - t| < \delta \Rightarrow |f(t_n) - f(t)| < \varepsilon , \text{ tedy také je}$$

$$\forall_{\varepsilon > 0} \exists_{\delta(\varepsilon) > 0} ; |X_n - X| < \delta(\varepsilon) \Rightarrow |f(X_n) - f(X)| < \varepsilon . \text{ Podle}$$

věty 7.10 část 1 je

$$P\left(\bigcap_{\varepsilon > 0} \bigcup_{k=1}^{\infty} \bigcap_{n=k}^{\infty} [|X_n - X| \leq \varepsilon]\right) = 1 = P\left(\bigcap_{\delta(\varepsilon) > 0} \bigcup_{k=1}^{\infty} \bigcap_{n=k}^{\infty} [|X_n - X| \leq \varepsilon]\right) \Rightarrow$$

$$P\left(\bigcap_{\varepsilon>0} \bigcup_{k=1}^{\infty} \bigcap_{n=k}^{\infty} [|f(X_n) - f(X)| \leq \varepsilon]\right) = 1$$
, neboť jednotlivý člen v posledním průniku je nadmnožinou členu v předcházejícím průniku a uvedená rovnost dále vyplývá jednoduše z monotonie pravděpodobnosti uvedené v .

Q.E.D.

Poznámka 7.13

1. Podobně jako v definici 7.9 můžeme definovat konvergenci skoro jistě pro posloupnost náhodných vektorů takto:

Nechť $\{X_n\}$ je posloupnost náhodných vektorů a X je náhodný vektor, řekneme, že tato posloupnost konverguje skoro jistě k vektoru X , jestliže

$$X_n = (X_n^1, X_n^2, \dots, X_n^k) \xrightarrow{s.j.} X = (X^1, X^2, \dots, X^k) \Leftrightarrow \stackrel{def}{\forall_{i=1,2,\dots,k}} X_n^i \xrightarrow{s.j.} X^i$$

2. Můžeme potom vyslovit i „vícezměrnou“ verzi věty 7.12 pro případ posloupnosti náhodných vektorů $\{X_n\}$, které konvergují skoro jistě k náhodnému vektoru X a spojitě funkce $f: R_k \rightarrow R_1$.

3. Vhodnou volbou funkce f je možno dokázat, že konvergence skoro jistě je uzavřená vůči operacím sčítání náhodných veličin a násobení náhodných veličin vzhledem ke konstantám i vzhledem k sobě samým.

Důkazy těchto tvrzení jsou uvedeny v [2], kapitola o konvergenci náhodných veličin.

7.3 Konvergence podle pravděpodobnosti

Definice 7.14

Buďte X, X_1, X_2, \dots náhodné veličiny. Řekneme, že posloupnost $\{X_n\}$ náhodných veličin **konverguje k náhodné veličině X podle pravděpodobnosti**, jestliže pro libovolné kladné ε je $\lim_{n \rightarrow \infty} P(|X_n - X| \geq \varepsilon) = 0$.

Tuto konvergenci budeme značit $X_n \xrightarrow{P} X$.

V následující větě jsou shrnuty základní vlastnosti konvergence v pravděpodobnosti a zároveň jsou vyjádřeny vztahy k oběma již dříve definovaným konvergencím.

Věta 7.15

1. Předchozí limita existuje nejvýše jedna

2. Jestliže $X_n \xrightarrow{s.j.} X \Rightarrow X_n \xrightarrow{P} X$

3. Nechť $X_n \xrightarrow{P} X$. Potom existuje vybraná posloupnost $\{X_{n_i}\}$ taková, že

$$X_{n_i} \xrightarrow{s.j.} X \text{ (tzv. Rieszova věta)}$$

4. Nechť X, X_n jsou náhodné veličiny. Potom $X_n \xrightarrow{P} X$ právě tehdy, když z každé podposloupnosti $\{X_{n_i}\}$ lze vybrat podposloupnost $\{X_{n_{i_j}}\}$ takovou, že $X_{n_{i_j}} \xrightarrow{s.j.} X$

5. Buďte $X_n = (X_n^1, \dots, X_n^k)$ a $X = (X^1, \dots, X^k)$ náhodné vektory takové, že $X_n \xrightarrow{P} X$ (tj. konvergence je definovaná po složkách tedy pro všechna $i = 1, \dots, k$ je $X_n^i \xrightarrow{P} X^i$), necht' $f: R_k \rightarrow R_1$ spojitá funkce, potom $f \circ X_n \xrightarrow{P} f \circ X$
6. Necht' $\mathbf{X}, \{ \mathbf{X}_n \}$ jsou náhodné vektory takové, že $X_n \xrightarrow{P} X$. Potom $X_n \xrightarrow{D} X$.

Důkaz:

1. Necht' tedy $X_n \xrightarrow{P} X$ a $X_n \xrightarrow{P} Y$. Potom jistě pro X, Y, X_n a libovolné kladné ε platí :

$$P(|X - Y| \geq \varepsilon) \leq P\left(|X - X_n| \geq \frac{\varepsilon}{2}\right) + P\left(|X_n - Y| \geq \frac{\varepsilon}{2}\right),$$
 tedy vzhledem ke konvergenci X_n podle pravděpodobnosti k \mathbf{X} , Y je po limitním přechodu v předchozím vztahu : $P(|X - Y| \geq \varepsilon) \leq 0 + 0 = 0$

2. Necht' tedy $X_n \xrightarrow{s.j.} X$, potom zvolíme – li ε pevné kladné reálné číslo máme z věty

7.10 část 1 (využijeme doplňkový jev) $P\left(\bigcap_{n=1}^{\infty} \bigcup_{j=n}^{\infty} |X_j - X| \geq \varepsilon\right) = 0$, vzhledem

k polospojivosti zdola pravděpodobnosti .. a monotonie pravděpodobnosti platí

$P(|X_n - X| \geq \varepsilon) \leq P\left(\bigcup_{j=n}^{\infty} |X_j - X| \geq \varepsilon\right)$. Při limitním přechodu je v této poslední

nerovnosti na pravé straně hodnota nula!

3. Vzhledem k složitosti nebudeme důkaz provádět, odkazují na větu III.1.4 uvedenou v monografii [2]

4. Část 3 této věty řeší situaci implikace zleva doprava. Budeme tedy dále dokazovat opačnou implikaci, důkaz provedeme sporem. Jestliže není pravda, že $X_n \xrightarrow{P} X$, potom podle definice musí existovat kladné reálné číslo ε a rostoucí posloupnost přirozených čísel $\{i\}$ taková, že $P(|X_i - X| \geq \varepsilon) \geq a > 0$, kde a je kladné reálné číslo.

Tato vybraná posloupnost $\{X_i\}$ není konvergentní k \mathbf{X} podle pravděpodobnosti, tedy nemůže být podle části 1 této věty konvergentní k \mathbf{X} skoro jistě.

5. Podle části 1 této věty existuje vybraná podposloupnost $\{X_{n_i}\}$ z posloupnosti

$\{X_n\}$ taková, že $X_{n_i} \xrightarrow{s.j.} X$, tedy podle věty 7.12 je i $f \circ X_{n_i} \xrightarrow{s.j.} f \circ X$, proto dále

$f \circ X_{n_i} \xrightarrow{P} f \circ X$ a odtud tedy $f \circ X_n \xrightarrow{P} f \circ X$.

6. Důkaz tohoto tvrzení nebudeme pro jeho náročnost provádět odkazujeme opět na [2] větu III.4.9

Q.E.D.

Poznámka 7.16

Z předchozích tvrzení vyplývá, že konvergence skoro jistě je nejsilnějším typem konvergence ze tří typů, probíraných v této kapitole, konvergence podle

pravděpodobnosti je druhým nejsilnějším typem a nejslabším typem konvergence náhodných veličin nebo vektorů probíraným v této kapitole je konvergence v distribuci. Konvergence skoro jistě se někdy označuje jako **silná** a konvergence podle pravděpodobnosti jako **slabá**. Výsledky této kapitoly využijeme především u tvrzení typu zákony velkých čísel nebo centrální limitní věta probírané v následujících kapitolách.