

UNIVERZITA PALACKÉHO V OLOMOUCI
PŘÍRODOVĚDECKÁ FAKULTA
KATEDRA MATEMATICKÉ ANALÝZY A APLIKACÍ MATEMATIKY

BAKALÁŘSKÁ PRÁCE

Zákony velkých čísel



Vedoucí diplomové práce:
prof. RNDr. Ing. Lubomír Kubáček, DrSc., Dr. h. c.
Rok odevzdání: 2011
Vypracoval:
Veronika Mikolášová
MAP, III. ročník

Prohlášení

Prohlašuji, že jsem vytvořila tuto diplomovou práci samostatně za vedení prof. RNDr. Ing. Lubomíra Kubáčka, DrSc., Dr. h. c., a že jsem v seznamu použité literatury uvedla všechny zdroje použité při zpracování práce.

V Olomouci dne 4. března 2011

Poděkování

Ráda bych na tomto místě poděkovala vedoucímu bakalářské práce prof. RNDr. Ing. Lubomíru Kubáčkovi, DrSc., Dr. h. c. za cenné rady a obětavost, se kterou se mi věnoval při vytváření této práce. Také chci poděkovat mé rodině za trpělivost a laskavou pomoc po celou dobu mého studia.

Obsah

Úvod	4
1 Základní pojmy	5
1.1 Míra a integrál	5
1.1.1 Míra	5
1.1.2 Měřitelné funkce a jejich konvergence	7
1.1.3 Lebesgueův integrál	9
1.2 Pravděpodobnost	11
1.2.1 Náhodný jev, definice pravděpodobnosti	11
1.2.2 Náhodná veličina, způsob zadání, číselné charakteristiky	14
1.2.3 Náhodný vektor, nezávislé náhodné veličiny	18
1.2.4 Některá rozdělení pravděpodobností náhodných veličin	20
1.2.5 Centrální limitní věta	22
1.3 Statistika	22
2 Zákony velkých čísel	25
2.1 Slabý zákon velkých čísel	25
2.2 Silný zákon velkých čísel	28
2.3 Empirická distribuční funkce, Glivenkova věta	36
3 Příklady	41
Závěr	50
Přílohy	52

Seznam obrázků

1	Funkce f_i	42
2	Funkce g_i	44
3	Konvergence empirické distribuční funkce – χ_7^2	46
4	Konvergence empirické distribuční funkce – $Po(5)$	46
5	Konvergence aritmetických průměrů – Poissonovo rozdělení	48
6	Konvergence aritmetických průměrů – rovnoměrné rozdělení	48
7	Konvergence aritmetických průměrů – normální rozdělení	48

Úvod

Zákony velkých čísel lze právem považovat za jeden z nejdůležitějších základních poznatků teorie pravděpodobnosti. Podstatnou měrou totiž přispívají k přesvědčení o poznatelnosti světa. Uplatňují se rovněž výrazně ve dvou fundamentálních větvích matematické statistiky, zejména v Glivenkově větě o stejnoměrné konvergenci empirické distribuční funkce k jejímu teoretickému protějšku. Interference zákonů velkých čísel s reálným světem se obzvlášť projevuje při experimentálních metodách získávání znalostí o reálných jevech a procesech. Poznatek o zákonech velkých čísel tak pronikl do všech experimentálních disciplín ve formě přesvědčení, že „čím více měření bude provedeno, tím přesnější představu získáme o skutečné hodnotě měřené veličiny.“

Cílem práce je vytvořit relativně uzavřenou teorii zákonů velkých čísel na základě odborné literatury. Výchozím podkladem pro nás bude teorie míry a integrálu, která od první poloviny minulého století tvoří fundamentální metodiku teorie pravděpodobnosti. V závěrečné kapitole bude rovněž poukázáno na využití těchto zákonů v některých statistických úlohách.

1. Základní pojmy

V této části práce budou shrnuty základní pojmy a věty teorie míry a integrálu (zúžené pak na teorii pravděpodobnosti), potřebné pro samotnou práci. V závěru této kapitoly pak bude vysvětleno několik základních pojmů matematické statistiky. Mimo to práce předpokládá základní znalosti teorie množin a elementární analýzy (posloupnosti, řady reálných čísel i funkcí, jejich limita / konvergence).

1.1. Míra a integrál

1.1.1. Míra

Definice 1.1. Systém podmnožin (značíme Σ) množiny X nazveme σ -algebra nad množinou X , jestliže $\forall A_n \subset X, n \in \mathbb{N}$, platí:

$$(i) A_1 \in \Sigma \wedge A_2 \in \Sigma \Rightarrow (A_1 \setminus A_2) \in \Sigma$$

$$(ii) \{A_n\}_{n=1}^{\infty} \subset \Sigma \Rightarrow \bigcup_{n=1}^{\infty} A_n \in \Sigma$$

$$(iii) X \in \Sigma$$

Poznámka 1.1. První dvě podmínky předchozí definice lze slovně vyjádřit tak, že σ -algebra je systém množin uzavřený na operaci rozdílu a spočetného sjednocení množin.

Věta 1.1. Množinová σ -algebra Σ je uzavřená také na operaci spočetný průnik množin.

D ů k a z: Viz [1, str. 24]

Věta 1.2. Průnik libovolného systému σ -algeber Σ_i nad X , kde i je z nějaké indexové množiny I , je rovněž σ -algebra nad X .

D ů k a z: Viz [2, str. 27]; podmínka $X \in \bigcap_{i \in I} \Sigma_i$ je zřejmá.

Věta 1.3. *Nechť \mathcal{G} je libovolný systém podmnožin množiny X . Označme G systém všech σ -algeber obsahujících \mathcal{G} . Průnik tohoto systému je nejmenší σ -algebra generovaná (obsahující) \mathcal{G} .*

D ů k a z: Viz [2, str. 28]

Definice 1.2. *Nechť \mathcal{G} je systém všech otevřených množin v \mathbb{R}^n . Nejmenší σ -algebru generovanou tímto systémem nazveme σ -algebrou borelovských množin v \mathbb{R}^n a značíme \mathcal{B}_n .*

Poznámka 1.2. *V \mathbb{R}^1 je tedy σ -algebra borelovských množin definována jako minimální σ -algebra generovaná systémem všech otevřených intervalů.*

Definice 1.3. *Množinovou funkci μ na σ -algebře Σ nazveme *míra*, jestliže:*

(i) $\mu: \Sigma \rightarrow \langle 0, \infty \rangle$

(ii) $\mu(\emptyset) = 0$

(iii) *Jestliže $\{E_n\}_{n=1}^{\infty} \subset \Sigma$ a $E_i \cap E_j = \emptyset$ pro $i \neq j$, pak*

$$\mu\left(\bigcup_{n=1}^{\infty} E_n\right) = \sum_{n=1}^{\infty} \mu(E_n) \quad (\text{řekneme, že } \mu \text{ je } \sigma\text{-aditivní}).$$

Definice 1.4. *Uspořádanou trojici (X, Σ, μ) , kde X je nějaká (neprázdna) množina, Σ je σ -algebra nad X a μ je míra na Σ , nazveme *prostor s mírou* (nebo také *měřitelný prostor*.)*

Věta 1.4 (Vlastnosti míry). *Nechť (X, Σ, μ) je prostor s mírou. Pak platí:*

1. $A, B \in \Sigma, A \subset B \Rightarrow \mu(A) \leq \mu(B)$ (tzv. *monotonie míry*)

2. $A_n \in \Sigma, n = 1, 2, \dots \Rightarrow \mu\left(\bigcup_{n=1}^{\infty} A_n\right) \leq \sum_{n=1}^{\infty} \mu(A_n)$

3. $A_1 \subset A_2 \subset \dots \subset A = \bigcup_{n=1}^{\infty} A_n \Rightarrow \mu(A) = \lim_{n \rightarrow \infty} \mu(A_n)$

4. $A_1 \supset A_2 \supset \dots \supset A = \bigcap_{n=1}^{\infty} A_n \wedge \exists n : \mu(A_n) < \infty \Rightarrow \mu(A) = \lim_{n \rightarrow \infty} \mu(A_n)$

D ů k a z: Viz [1, str. 37-38]

Poznámka 1.3. Na σ -algebře borelovských množin \mathcal{B}_1 lze definovat tzv. *Lebesgueovu míru* μ_L , která vzniká rozšířením míry z okruhu generovaného zleva uzavřenými intervaly. Míra na tomto okruhu vzniká přirozeným rozšířením množinové funkce, která intervalu přiřadí jeho délku. Rozšíření míry z okruhu na minimální σ -okruh lze provést Caratheodoryho postupem pomocí tzv. vnější míry (podrobněji viz [1]).

1.1.2. Měřitelné funkce a jejich konvergence

Pokud nebude řečeno jinak, budeme nadále uvažovat měřitelný prostor (X, Σ, μ) .

Definice 1.5. Funkce $f: X \rightarrow \mathbb{R}$ se nazývá *měřitelná* (někdy také Σ -měřitelná), jestliže platí:

$$\{x \in X; f(x) < a\} \in \Sigma \quad \forall a \in \mathbb{R}$$

Poznámka 1.4. Podmínce z předchozí definice jsou ekvivalentní také tyto:

$$\forall a \in \mathbb{R}: \{x \in X; f(x) \leq a\}, \text{ resp. } \{x \in X; f(x) > a\}, \text{ resp. } \{x \in X; f(x) \geq a\}$$

Důkaz: [2, str. 72]

Poznámka 1.5. Nechť $(\mathbb{R}^n, \mathcal{B}_n, \mu)$, $n \in \mathbb{N}$ je měřitelný prostor. Funkci $f: \mathbb{R}^n \rightarrow \mathbb{R}$ nazveme *borelovsky měřitelná (borelovská)*, je-li \mathcal{B}_n -měřitelná.

Věta 1.5 (Vlastnosti měřitelných funkcí). *Nechť f a g jsou měřitelné funkce. Pak také funkce:*

1. $cf(x) \quad \forall c \in \mathbb{R}$
2. $f(x) + g(x)$ po vhodném dodefinování v bodech, kde $f(x) + g(x)$ nemá smysl
3. $|f(x)|$
4. $\max\{f(x), g(x)\}$
5. $f(x) \cdot g(x)$
6. $\frac{1}{f(x)}$ po dodefinování v bodech, kde $f(x) = 0$

jsou měřitelné funkce.

D ů k a z: Viz [2, str. 74]

Věta 1.6. *Nechť je dána posloupnost $\{f_n\}_{n=1}^{\infty}$ měřitelných funkcí. Pak také funkce $\sup_{n \in \mathbb{N}} f_n(x)$, $\inf_{n \in \mathbb{N}} f_n(x)$, $\limsup_{n \in \mathbb{N}} f_n(x)$, $\liminf_{n \in \mathbb{N}} f_n(x)$ jsou měřitelné.*

D ů k a z: Viz [1, str. 84]

Definice 1.6. Řekneme, že měřitelná funkce $s: X \rightarrow \mathbb{R}$ je *jednoduchá*, jestliže množina $s(X)$ (obor hodnot) je konečná. Takovou funkci lze také zapsat pomocí tzv. charakteristické funkce χ_A :

$$s(x) = \sum_{i=1}^n \alpha_i \chi_{A_i}(x) \quad \chi_A(x) = \begin{cases} 1 & x \in A \\ 0 & \text{jinde} \end{cases}$$

kde α_i jsou libovolné konstanty a množiny A_i jsou po dvou disjunktní takové, že $\bigcup_{i=1}^n A_i = X$.

Poznámka 1.6. Libovolnou reálnou funkci f lze rozložit na tzv. kladnou a zápornou část:

$$f^+(x) := \max\{f(x), 0\} \dots \text{kladná část funkce } f$$

$$f^-(x) := \max\{-f(x), 0\} \dots \text{záporná část funkce } f$$

Pak lze psát:

$$f = f^+ - f^- \quad |f| = f^+ + f^-$$

Věta 1.7. *Nechť f je měřitelná funkce. Pak existuje posloupnost $\{s_n\}_{n=1}^{\infty}$ jednoduchých funkcí, pro které platí:*

$$i. |s_1(x)| \leq |s_2(x)| \leq \dots \quad \forall x \in X$$

$$ii. s_n \rightarrow f \text{ na } X^1$$

¹Pro jistotu zopakujme dva základní druhy konvergence posloupnosti funkcí $\{f_n\}$:

- bodová konvergence (zn. $f_n \rightarrow f$) na M :
 $\forall \varepsilon > 0 \forall x \in M \exists n_0 \in \mathbb{N}: n \geq n_0 \Rightarrow |f_n(x) - f(x)| < \varepsilon$
- stejnoměrná konvergence (zn. $f_n \rightrightarrows f$) na M :
 $\forall \varepsilon > 0 \exists n_0 \in \mathbb{N} \forall x \in M: n \geq n_0 \Rightarrow |f_n(x) - f(x)| < \varepsilon$

iii. pro $f \geq 0$ na X lze zvolit $s_1 \leq s_2 \leq \dots$, tj. $s_n \uparrow f$

D ů k a z: [1, str. 85]

Teorie míry nám umožňuje zavést další druhy konvergence funkčních posloupností, které, jak dále uvidíme, nám poslouží jako postačující podmínky integrovatelnosti:

Definice 1.7. Řekneme, že posloupnost $\{f_n\}$ skoro všude konečných měřitelných funkcí *konverguje skoro všude na množině M* (značíme $f_n \rightarrow f$ s.v. na M), jestliže

$$\forall \varepsilon > 0 \forall x \in M \setminus M_0 \exists n_0 \in \mathbb{N} \forall n \in \mathbb{N}: n \geq n_0 \Rightarrow |f_n(x) - f(x)| < \varepsilon,$$

kde $\mu(M_0) = 0$.

Poznámka 1.7. Pojem *skoro všude* na množině znamená, že daná vlastnost neplatí pouze na takové podmnožině dané množiny, která má nulovou míru.

Definice 1.8. Řekneme, že posloupnost $\{f_n\}$ skoro všude konečných měřitelných funkcí *konverguje k funkci f podle míry* (značíme $f_n \xrightarrow{\mu} f$ s. v. na M), jestliže

$$\forall \varepsilon > 0: \lim_{n \rightarrow \infty} \mu(\{x; |f_n(x) - f(x)| \geq \varepsilon\}) = 0$$

Věta 1.8. Nechť $f_n \rightarrow f$ s.v. na M , $\mu(M) < \infty$. Pak také $f_n \xrightarrow{\mu} f$ na M .

D ů k a z: Viz [2, str. 125]

Věta 1.9. Nechť $f_n \xrightarrow{\mu} f$ na M , $\mu(M) < \infty$. Pak existuje podposloupnost $\{f_{k_n}\}_{n=1}^{\infty} \subset \{f_n\}_{n=1}^{\infty}$ taková, že $f_{k_n} \rightarrow f$ s. v. na M .

D ů k a z: Viz [2, str. 126]

1.1.3. Lebesgueův integrál

Definice 1.9. Nechť $s(x) = \sum_{i=1}^n \alpha_i \chi_{A_i}(x)$, $\mu(A_i) < \infty$, $i = 1, \dots, n$, pak *Lebesgueův integrál z jednoduché funkce s* je definován takto:

$$\int_X s(x) d\mu = \sum_{i=1}^n \alpha_i \mu(A_i)$$

Poznámka 1.8. Zřejmě:

1. $\int_X \chi_A \, d\mu = \mu(A)$
2. $\int_E s(x) \, d\mu = \int_X \chi_E s(x) \, d\mu = \int_X \sum_{i=1}^{\infty} \alpha_i \chi_{A_i} \chi_E \, d\mu = \sum_{i=1}^{\infty} \alpha_i \mu(A_i \cap E)$, kde $E \in \Sigma$

Definice 1.10. Nechť $f \geq 0$ je měřitelná funkce taková, že existuje posloupnost jednoduchých funkcí $\{s_n\}_{n=1}^{\infty}$, $s_n(x) = \sum_{i=1}^m \alpha_{n_i} \chi_{A_{n_i}}(x)$, pro kterou platí $s_n \uparrow f$ pro $n \rightarrow \infty$ a $\mu(\bigcup_{i=1}^{m(n)} A_{n_i}) < \infty \, \forall n \in \mathbb{N}$. Pak *Lebesgueův integrál z nezáporné funkce f* položíme:

$$\int_X f(x) \, d\mu = \lim_{n \rightarrow \infty} \int_X s_n(x) \, d\mu$$

Definice 1.11. Nechť f je libovolná měřitelná funkce. Pak její *Lebesgueův integrál* definujeme

$$\int_X f(x) \, d\mu = \int_X f^+(x) \, d\mu - \int_X f^-(x) \, d\mu$$

má-li tento výraz smysl.

Věta 1.10 (Monotonie integrálu). *Nechť $0 \leq f(x) \leq g(x)$ s.v. Pak*

$$0 \leq \int_X f(x) \, d\mu \leq \int_X g(x) \, d\mu$$

Důkaz z: [2, Str. 95]

Věta 1.11. *Nechť $f(x)$ je měřitelná funkce, c libovolné reálné číslo. Pak platí:*

$$\int_X cf(x) \, d\mu = c \int_X f(x) \, d\mu$$

Důkaz z: [2, str. 107]

Věta 1.12.

1. $\int_X f(x) \, d\mu < \infty \Rightarrow f < \infty$ s.v. v X

2. $\int_X f(x) d\mu > -\infty \Rightarrow f > -\infty$ s.v. v X

Důkaz: Viz [2, str. 96]

Věta 1.13. *Nechť $f(x)$ a $g(x)$ jsou měřitelné funkce, které mají konečný integrál, a nechť $h(x) = f(x) + g(x)$ a h je dodefinováno tam, kde tento součet definován není. Pak:*

$$\int_X h(x) d\mu = \int_X f(x) d\mu + \int_X g(x) d\mu$$

Důkaz: Viz [2, str. 111]

Věta 1.14. *Měřitelná funkce f má konečný Lebesgueův integrál $\Leftrightarrow f^+, f^-$ mají konečný Lebesgueův integrál $\Leftrightarrow |f|$ má konečný Lebesgueův integrál a platí $|\int_X f(x) d\mu| \leq \int_X |f(x)| d\mu$.*

Důkaz: První ekvivalence plyne přímo z definice Lebesgueova integrálu měřitelné funkce, zbytek viz [2, str. 96].

1.2. Pravděpodobnost

1.2.1. Náhodný jev, definice pravděpodobnosti

Teorie pravděpodobnosti studuje výsledky tzv. náhodných pokusů, tj. pokusů (určených pevně daným systémem podmínek), které mohou mít více různých výsledků, z nichž nastává vždy právě jeden.

Uvažujme tedy nějaký pevně zvolený pokus. Označme Ω množinu všech možných výsledků tohoto pokusu, $\omega \in \Omega$ jeden konkrétní výsledek.

Definice 1.12.

- Každá podmnožina $A \subset \Omega$ se nazývá *jev*, každá jednoprvková podmnožina $\{\omega\} \subset \Omega$ se nazývá *elementární jev*.
- Řekneme, že při realizaci náhodného pokusu *nastal jev* A , nastal-li takový výsledek ω , pro který platí $\omega \in A$, tedy nastal-li *výsledek příznivý jevu* A .

- Prázdná množina \emptyset se nazývá *nemožný jev*, množina všech výsledků Ω *jistý jev*.
- *Sjednocení jevů* A_1, \dots, A_n je jev, který nastane, jestliže nastane alespoň jeden z jevů A_1, \dots, A_n ; značíme $A_1 \cup \dots \cup A_n$ nebo $\bigcup_{i=1}^n A_i$.
- *Průnik jevů* A_1, \dots, A_n je jev, který nastane, nastanou-li všechny jevy A_1, \dots, A_n současně; značíme $A_1 \cap \dots \cap A_n$ nebo $\bigcap_{i=1}^n A_i$.
- *Rozdíl jevů* A a B je jev, který nastane, nastane-li A a zároveň nenastane B ; značí se $A \setminus B$.
- *Jev opačný (doplňěk) k jevu* A je jev $A^C = \Omega \setminus A$.
- Jevy A a B nazveme *neslučitelné* (disjunktní), nemohou-li nastat současně, tedy $A \cap B = \emptyset$.

Abychom mohli zavést na Ω funkci pravděpodobnosti, je třeba uvažovat systém jevů obsahující Ω , který je uzavřený na operaci rozdílu a spočetného sjednocení jevů – nám už známou σ -algebru.

Definice 1.13. Nechť Ω je množina výsledků náhodného pokusu. Je-li Σ σ -algebra podmnožin množiny Ω , nazývá se *jevové pole*. Prvky $A \in \Sigma$ se nazývají *náhodné jevy*.

Definice 1.14. Nechť je dána neprázdná množina Ω a na ní definovaná σ -algebra Σ . *Pravděpodobností* (pravděpodobnostní mírou) nazveme každou reálnou funkci $P(\cdot)$ definovanou na Σ , která splňuje tyto podmínky:

- (i) $P(A) \geq 0, \quad \forall A \in \Sigma$
- (ii) $P(\Omega) = 1$
- (iii) Jestliže $\{A_n\}_{n=1}^{\infty} \subset \Sigma$ a $A_i \cap A_j = \emptyset$ pro $i \neq j$, pak

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n)$$

Definice 1.15. Uspořádanou trojici $(\Omega, \Sigma, \mathbf{P})$ nazýváme *pravděpodobnostní prostor*.

Poznámka 1.9. Pokud nebude řečeno jinak, budeme v dalším textu uvažovat pravděpodobnostní prostor $(\Omega, \Sigma, \mathbf{P})$.

Věta 1.15 (Vlastnosti pravděpodobnosti). *Pro libovolné náhodné jevy $A, B \in \Sigma$, $\{A_n\}_{n=1}^{\infty} \subset \Sigma$ platí:*

$$(V.1) \quad \mathbf{P}(\emptyset) = 0$$

$$(V.2) \quad \mathbf{P}(A^C) = 1 - \mathbf{P}(A)$$

$$(V.3) \quad \mathbf{P}(A) \leq 1$$

$$(V.4) \quad A \subset B \Rightarrow \mathbf{P}(A) \leq \mathbf{P}(B)$$

$$(V.5) \quad \mathbf{P}(B \setminus A) = \mathbf{P}(B) - \mathbf{P}(A \cap B),$$

speciálně $A \subset B \Rightarrow \mathbf{P}(B \setminus A) = \mathbf{P}(B) - \mathbf{P}(A)$

$$(V.6) \quad \mathbf{P}\left(\bigcup_{n=1}^{\infty} A_n\right) \leq \sum_{n=1}^{\infty} \mathbf{P}(A_n)$$

D ů k a z: Viz [3, str. 11-14]

Poznámka 1.10. Z definičních vlastností (i) a (iii) a z tvrzení (V.1) předchozí věty je patrné, že pravděpodobnost je speciální případ míry. Rovněž lze naopak tvrdit, že míra μ , která splňuje podmínku $\mu(X) = 1$, je pravděpodobností.

Poznámka 1.11. Podle předchozí poznámky tedy lze tvrzení uvedená v sekcích 1.1. - 1.3. aplikovat i na pravděpodobnostní prostor $(\Omega, \Sigma, \mathbf{P})$. Pro některé pojmy teorie míry se však v teorii pravděpodobnosti užívají speciální názvy. Pro nás budou v dalším důležité tyto:

- a) jestliže $\mathbf{P}(X \text{ má určitou vlastnost}) = 1$, řekneme, že X má tuto vlastnost *skoro jistě* (s. j.),
- b) pojmem konvergence skoro všude a konvergence podle míry odpovídají v teorii pravděpodobnosti po řadě pojmy *konvergence skoro jistě* a *konvergence podle pravděpodobnosti*.

Definice 1.16. Náhodné jevy A, B se nazývají *nezávislé*, jestliže platí

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

Věta 1.16. Pro libovolný náhodný jev A platí, že Ω a A jsou *nezávislé*, a také \emptyset a A jsou *nezávislé*.

Důkaz: [3, str. 27]

Definice 1.17. Náhodné jevy systému $\mathcal{C} = \{A_\lambda, \lambda \in \Lambda\}$ se nazývají *nezávislé*, jestliže pro každou konečnou skupinu $\{\lambda_1, \dots, \lambda_k\} \subset \Lambda$ platí:

$$P\left(\bigcap_{i=1}^k A_{\lambda_i}\right) = \prod_{i=1}^k P(A_{\lambda_i})$$

Věta 1.17. Jestliže jsou náhodné jevy systému $\mathcal{C} = \{A_\lambda, \lambda \in \Lambda\}$ *názávislé*, pak jsou *nezávislé* náhodné jevy libovolného pod systému $\mathcal{C}_1 \subset \mathcal{C}$.

Důkaz: Plyne přímo z definice *nezávislých* náhodných jevů. ■

1.2.2. Náhodná veličina, způsob zadání, číselné charakteristiky

Definice 1.18. Reálnou funkci $X: \Omega \rightarrow \mathbb{R}^1$ nazveme *náhodnou veličinou*, jestliže je tato funkce Σ -měřitelná, to znamená, jestliže pro každé $x \in \mathbb{R}^1$ platí

$$\{\omega \in \Omega; X(\omega) \leq x\} \stackrel{\text{zn.}}{=} (X \leq x) \in \Sigma$$

Poznámka 1.12. Obdobně zavedeme pro zjednodušení zápisu toto značení:

$$\{\omega \in \Omega; X(\omega) \in B\} \stackrel{\text{zn.}}{=} (X \in B)$$

Definice 1.19. *Rozdělení pravděpodobností náhodné veličiny* X je množinová funkce $P_X(B): \mathcal{B}_1 \rightarrow \mathbb{R}^1$ definovaná vztahem:

$$P_X(B) = P(X \in B), \quad B \in \mathcal{B}_1$$

Věta 1.18. *Nechť* X *je náhodná veličina, P_X její rozdělení pravděpodobností. Pak $(\mathbb{R}^1, \mathcal{B}_1, P_X)$ tvoří pravděpodobnostní prostor.*

Důkaz: Viz [3, str. 36]

Definice 1.20. Necht X je náhodná veličina. Funkce $F_X: \mathbb{R}^1 \rightarrow \mathbb{R}^1$ definovaná předpisem

$$F_X(x) = \mathbf{P}(X < x), \quad x \in \mathbb{R}^1$$

se nazývá *distribuční funkce náhodné veličiny* X .

Věta 1.19 (Vlastnosti distribuční funkce).

1. F_X je neklesající funkce
2. $\lim_{x \rightarrow \infty} F_X(x) = 1 \quad \lim_{x \rightarrow -\infty} F_X(x) = 0$
3. F_X je zleva spojitá v každém bodě $x \in \mathbb{R}^1$

Důkaz: Viz [3, str. 37-38] ²

Definice 1.21. Distribuční funkce F_X se nazývá

- a) *diskrétní*, existuje-li (konečná či nekonečná) prostá posloupnost reálných čísel $\{x_n\}$ a jí odpovídající posloupnost kladných čísel $\{p_n\}$, $\sum p_n = 1$, pro které platí

$$F_X(x) = \sum_{n: x_n < x} p_n \quad \forall x \in \mathbb{R}^1$$

Funkci $p(x_n) = p_n$ nazýváme *pravděpodobnostní funkcí náhodné veličiny* X .

- b) *absolutně spojitá*, existuje-li nezáporná, borelovsky měřitelná funkce $f_X(x): \mathbb{R}^1 \rightarrow \mathbb{R}^1$, pro kterou platí vztah:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt \quad \forall x \in \mathbb{R}^1$$

Funkci f_X nazveme *hustotou (rozdělení pravděpodobností) náhodné veličiny* X .

Jestliže má X *diskrétní (absolutně spojitou)* distribuční funkci, pak stejně nazveme i tuto náhodnou veličinu samotnou a její rozdělení pravděpodobností.

²Tento důkaz je veden sice pro distribuční funkci definovanou předpisem $F_X(x) = \mathbf{P}(X \leq x)$, $x \in \mathbb{R}^1$, která je spojitá zprava, ovšem důkaz spojitosti zleva námi definované distribuční funkce by se s nezbytnými úpravami vedl analogicky.

Definice 1.22. Necht X je náhodná veličina. Její *střední hodnotou* rozumíme číslo

$$E(X) = \int_{\Omega} X(\omega) dP$$

Množinu všech náhodných veličin definovaných na pravděpodobnostním prostoru (Ω, Σ, P) , které mají konečnou střední hodnotu, budeme značit symbolem $L_1(\Omega, \Sigma, P)$ nebo zkráceně L_1 .

Poznámka 1.13. Praktický výpočet střední hodnoty se provádí pomocí těchto vzorců, odvozených z předešlé definice:

$$E(X) = \sum_n x_n p_n \quad \text{pro } X \text{ diskrétní,}$$

$$E(X) = \int_{\mathbb{R}} x f(x) dx \quad \text{pro } X \text{ absolutně spojitou.}$$

Věta 1.20 (Vlastnosti střední hodnoty náhodné veličiny). *Necht X, Y jsou náhodné veličiny z množiny L_1 a a, b jsou libovolná reálná čísla. Pak platí:*

1. $E(aX) = a E(X)$
2. $E(X + Y) = E(X) + E(Y)$
3. $P(X \leq Y) = 1 \Rightarrow E(X) \leq E(Y)$
4. $P(X = a) = 1 \Rightarrow E(X) = a$

D ů k a z: [3, str. 54]

Definice 1.23. *Rozptylem (variancí) náhodné veličiny X rozumíme číslo*

$$\text{var}(X) = \sigma^2(X) = E(X - E(X))^2$$

Věta 1.21 (Vlastnosti rozptylu). *Necht X má konečný rozptyl, $a, b \in \mathbb{R}$. Platí:*

1. $\text{var}(X) \geq 0$
2. $\text{var}(X) = 0 \Leftrightarrow P(X = c) = 1$

$$3. \text{ var}(a + bX) = b^2 \text{ var}(X)$$

$$4. \text{ var}(X) = \mathbf{E}(X^2) - (\mathbf{E}(X))^2$$

D ů k a z: [3, str. 58]

Věta 1.22. *Libovolnou náhodnou veličinu X lze transformovat na tzv. normovanou náhodnou veličinu, tedy takovou náhodnou veličinu Y , pro kterou platí $\mathbf{E}(Y) = 0$ a $\text{var}(Y) = 1$.*

D ů k a z: Uvažujme

$$Y = \frac{X - \mathbf{E}(X)}{\sqrt{\text{var}(X)}}$$

Platí:

$$\mathbf{E}(Y) = \mathbf{E}\left(\frac{X - \mathbf{E}(X)}{\sqrt{\text{var}(X)}}\right) = \frac{\mathbf{E}(X - \mathbf{E}(X))}{\text{var}(X)} = \frac{\mathbf{E}(X) - \mathbf{E}(X)}{\text{var}(X)} = 0$$

$$\text{var}(Y) = \text{var}\left(\frac{X - \mathbf{E}(X)}{\sqrt{\text{var}(X)}}\right) = \frac{\text{var}(X - \mathbf{E}(X))}{\text{var}(X)} = \frac{\text{var}(X)}{\text{var}(X)} = 1$$

■

Definice 1.24. Číslo $x_\alpha \in \mathbb{R}$, ($\alpha \in (0, 1)$), nazveme α -kvantil náhodné veličiny X , jestliže platí:

$$\mathbf{P}(X < x_\alpha) \leq \alpha \quad \wedge \quad \mathbf{P}(X > x_\alpha) \leq 1 - \alpha$$

Poznámka 1.14.

- Kvantily normovaného normálního rozdělení obvykle značíme u_α , $\alpha \in (0, 1)$.
- Druhou nerovnost v předešlé definici lze psát $1 - \mathbf{P}(X \leq x_\alpha) \leq 1 - \alpha$, dohromady pak $\mathbf{P}(X < x_\alpha) \leq \alpha \leq \mathbf{P}(X \leq x_\alpha)$ a tedy x_α je takové číslo, které splňuje $F_X(x_\alpha) \leq \alpha \leq F_X(x_\alpha + 0)$.
- Jestliže je X absolutně spojitá náhodná veličina, platí $\alpha = F_X(x_\alpha)$.

1.2.3. Náhodný vektor, nezávislé náhodné veličiny

Definice 1.25. Zobrazení $\mathbb{X}: \Omega \rightarrow \mathbb{R}^n$ nazveme (n -rozměrný) náhodný vektor, jestliže je Σ -měřitelné.

Poznámka 1.15. Pro zjednodušení zápisu zavedeme následující označení:

$$\mathbb{X}(\omega) \leq \mathbf{x} \Leftrightarrow X_1 \leq x_1, \dots, X_n \leq x_n, \text{ kde } \mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$$

Poznámka 1.16. Σ -měřitelnost zobrazení \mathbb{X} znamená, že platí:

- $\{\omega \in \Omega; \mathbb{X}(\omega) \leq \mathbf{x}\} \in \Sigma \quad \forall \mathbf{x} \in \mathbb{R}^n$, nebo ekvivalentně
- $\{\omega \in \Omega; \mathbb{X}(\omega) \in B\} \in \Sigma \quad \forall B \in \mathcal{B}_n$

Věta 1.23. $\mathbb{X} = (X_1, \dots, X_n): \Omega \rightarrow \mathbb{R}^n$ je náhodným vektorem právě tehdy, když X_i je náhodná veličina pro všechna $i = 1, \dots, n$.

Důkaz: [3, str. 80]

Definice 1.26. (Sdruženou) distribuční funkcí náhodného vektoru \mathbb{X} rozumíme funkci $F_{\mathbb{X}}: \mathbb{R}^n \rightarrow \mathbb{R}$ definovanou vztahem:

$$F_{\mathbb{X}}(\mathbf{x}) = F_{\mathbb{X}}(x_1, \dots, x_n) = \mathbf{P}(X_1 < x_1, \dots, X_n < x_n) = \mathbf{P}(\mathbb{X} < \mathbf{x}), \quad \mathbf{x} \in \mathbb{R}^n$$

Poznámka 1.17.

- Distribuční funkce $F_{\mathbb{X}}(x_1, \dots, x_n)$ náhodného vektoru \mathbb{X} se nazývá *diskrétní*, existuje-li prostá posloupnost $\{\mathbf{x}_m\} \subset \mathbb{R}^n$ (konečná nebo nekonečná) a jí odpovídající posloupnost kladných čísel $\{p_m\}$, $\sum p_m = 1$, takové, že platí

$$F_{\mathbb{X}}(x_1, \dots, x_n) = F_{\mathbb{X}}(\mathbf{x}) = \sum_{m: \mathbf{x}_m < \mathbf{x}} p_m, \quad \forall \mathbf{x} \in \mathbb{R}^n$$

Řekneme pak, že náhodný vektor \mathbb{X} je *diskrétní*.

- Distribuční funkce $F_{\mathbb{X}}(x_1, \dots, x_n)$ náhodného vektoru \mathbb{X} se nazývá *absolutně spojitá*, existuje-li nezáporná borelovsky měřitelná funkce $f(\mathbf{x}) = f(x_1, \dots, x_n): \mathbb{R}^n \rightarrow \mathbb{R}$ taková, že:

$$F_{\mathbb{X}}(x_1, \dots, x_n) = F_{\mathbb{X}}(\mathbf{x}) = \int_{-\infty}^{x_1} \cdots \int_{-\infty}^{x_n} f(t_1, \dots, t_n) dt_1 \dots dt_n \quad \forall \mathbf{x} \in \mathbb{R}^n$$

Funkce $f(\mathbf{x})$ se nazývá *hustota náhodného vektoru* \mathbb{X} a o vektoru \mathbb{X} rovněž říkáme, že je *absolutně spojitý*.

Definice 1.27. Náhodný vektor $(X_{i_1}, \dots, X_{i_k})$, $k = 1, \dots, n-1$; $1 \leq i_1 < \dots < i_k \leq n$, se nazývá *marginální náhodný vektor příslušný k náhodnému vektoru* \mathbb{X} a jeho distribuční funkce $F_{X_{i_1}, \dots, X_{i_k}}(x_{i_1}, \dots, x_{i_k})$ *marginální distribuční funkce* k funkci $F_{\mathbb{X}}(x_1, \dots, x_n)$.

Věta 1.24. Necht' $\mathbb{X} = (X_1, \dots, X_n)$ je náhodný vektor s distribuční funkcí $F_{\mathbb{X}}(x_1, \dots, x_n)$. Pro distribuční funkci náhodného vektoru $(X_{i_1}, \dots, X_{i_k})$, $k = 1, \dots, n-1$; $1 \leq i_1 < \dots < i_k \leq n$ platí

$$F_{X_{i_1}, \dots, X_{i_k}}(x_{i_1}, \dots, x_{i_k}) = \lim_{x_j \rightarrow \infty} \prod_{\forall j \neq i_1, \dots, i_k} F_{\mathbb{X}}(x_1, \dots, x_n)$$

D ů k a z: [3, str. 88]

Definice 1.28. Necht' $\mathcal{X} = \{X_\lambda, \lambda \in \Lambda\}$ je systém náhodných veličin. Řekneme, že náhodné veličiny tohoto systému jsou *nezávislé*, jestliže pro každou konečnou podmnožinu $\{\lambda_1, \dots, \lambda_n\} \subset \Lambda$ platí

$$F_{X_{\lambda_1}, \dots, X_{\lambda_n}}(x_1, \dots, x_n) = \prod_{j=1}^n F_{X_{\lambda_j}}(x_j) \quad \forall (x_1, \dots, x_n) \in \mathbb{R}^n$$

Věta 1.25 (Nutná a postačující podmínka nezávislosti náhodných veličin). Necht' $F_{\mathbb{X}}(\mathbf{x}) = F_{X_1, \dots, X_n}(x_1, \dots, x_n)$ je sdružená distribuční funkce náhodného vektoru $\mathbb{X} = X_1, \dots, X_n$ a $F_{X_j}(x)$, $j = 1, \dots, n$, jsou marginální distribuční funkce příslušné náhodné veličiny X_j . Náhodné veličiny X_1, \dots, X_n jsou nezávislé právě tehdy, když platí

$$F_{\mathbb{X}}(\mathbf{x}) = \prod_{j=1}^n F_{X_j}(x_j) \quad \forall \mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$$

D ů k a z: Viz [3, str. 95]

Věta 1.26. Necht' X_1, \dots, X_n jsou nezávislé náhodné veličiny a necht' $\phi_j(x): \mathbb{R}^1 \rightarrow \mathbb{R}^1$, $j = 1, \dots, n$, jsou borelovsky měřitelné funkce. Potom jsou náhodné veličiny $\mathbb{Y}_j = \phi_j(\mathbb{X}_j)$, $j = 1, \dots, n$, rovněž nezávislé.

D ů k a z: Viz [3, str. 97]

Věta 1.27. *Jsou-li X_1, \dots, X_n mezávislé náhodné veličiny s konečnými druhými momenty, potom platí:*

$$\text{var} \left(\sum_{j=1}^n X_j \right) = \sum_{j=1}^n \text{var}(X_j)$$

D ů k a z: Viz [3, str. 104]

1.2.4. Některá rozdělení pravděpodobností náhodných veličin

Definice 1.29. Řekneme, že diskrétní náhodná veličina X má *binomické rozdělení pravděpodobností s parametry n a p* , $n \in \mathbb{N}$, $p \in (0, 1)$, (značíme $X \sim Bi(n, p)$), jestliže nabývá pouze hodnot $j = 0, \dots, n$, a to s pravděpodobnostmi

$$P(X = j) = \binom{n}{j} \cdot p^j \cdot (1 - p)^{n-j}, \quad j = 0, \dots, n$$

Definice 1.30. Řekneme, že diskrétní náhodná veličina X má *Poissonovo rozdělení pravděpodobností s parametrem λ* , $\lambda > 0$, (značíme $X \sim Po(\lambda)$), jestliže nabývá pouze hodnot $j = 0, 1, \dots$ s pravděpodobnostmi

$$P(X = j) = \frac{\lambda^j}{j!} \cdot e^{-\lambda} \quad j = 0, 1, \dots$$

Poznámka 1.18. Náhodná veličina $X \sim Po(\lambda)$ má tyto charakteristiky:

$$E(X) = \lambda \quad \text{var}(X) = \lambda$$

Definice 1.31. Řekneme, že absolutně spojitá náhodná veličina X má *rovnouměrné rozdělení s parametry a a b* , $a, b \in \mathbb{R}$, jestliže má hustotu

$$f_X(x) = \begin{cases} \frac{1}{b-a} & x \in (a, b) \\ 0 & x \notin (a, b) \end{cases}$$

Poznámka 1.19. Náhodná veličina s rovnoměrným rozdělením o parametrech (a, b) má tyto charakteristiky:

$$\mathbf{E}(X) = \frac{a+b}{2} \quad \mathbf{var}(X) = \frac{(b-a)^2}{12}$$

Definice 1.32. Řekneme, že absolutně spojitá náhodná veličina X má *normální (Gaussovo) rozdělení s parametry μ a σ^2* , $\mu \in \mathbb{R}$, $\sigma^2 > 0$, jestliže má hustotu

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

Poznámka 1.20. Náhodná veličina X , která má normální rozdělení $N(\mu, \sigma^2)$, má tyto charakteristiky:

$$\mathbf{E}(X) = \mu \quad \mathbf{var}(X) = \sigma^2$$

Poznámka 1.21. Pro libovolnou náhodnou veličinu $X \sim N(\mu, \sigma^2)$ platí:

$$\mathbf{P}(\mu - \sigma < X < \mu + \sigma) \approx 68,3\%$$

$$\mathbf{P}(\mu - 2\sigma < X < \mu + 2\sigma) \approx 95,5\%$$

$$\mathbf{P}(\mu - 3\sigma < X < \mu + 3\sigma) \approx 99,7\%$$

Poslední výraz je známý pod názvem *pravidlo tří sigma* a v podstatě říká, že mimo uvedený interval se realizuje pouze velmi malý zlomek hodnot náhodné veličiny $X \sim N(\mu, \sigma^2)$.

Definice 1.33. Necht' X_1, \dots, X_k jsou nezávislé náhodné veličiny s rozdělením $N(0, 1)$. Pak řekneme, že náhodná veličina

$$Q = \sum_{k=1}^n X_k^2$$

má χ^2 -rozdělení s k stupni volnosti. Značíme $Q \sim \chi_k^2$.

1.2.5. Centrální limitní věta

Oblast centrálních limitních vět přesahuje rámec námi probírané teorie, ale s jejich využitím budeme moci snáze ilustrovat Glivenkovu větu zmiňovanou v úvodu (viz příklad 3.3). Proto alespoň okrajově zmíníme jednu z těchto vět, a to Moivre-Laplaceovu, kterou později v uvedeném příkladu použijeme.

Definice 1.34. Necht' $\{X_n\}_{n=1}^{\infty}$ je posloupnost náhodných veličin a necht' X je náhodná veličina, každá z nich definovaná na pravděpodobnostním prostoru $(\Omega, \Sigma, \mathbf{P})$. Řekneme, že posloupnost náhodných veličin $\{X_n\}$ *konverguje k X v distribuci (podle rozdělení)*, jestliže

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x) \text{ v každém bodě spojitosti funkce } F_X.$$

Značíme

$$X_n \xrightarrow{\mathcal{D}} X$$

Věta 1.28 (Moivreova-Laplaceova věta). *Mějme posloupnost $\{Y_n\}_{n=1}^{\infty}$ nezávislých náhodných veličin, $Y_n \sim Bi(n, p)$. Potom*

$$Z_n = \frac{Y_n - np}{\sqrt{np(1-p)}} \xrightarrow{\mathcal{D}} X \sim N(0, 1)$$

Řekneme, že posloupnost $\{Z_n\}$ má asymptoticky rozdělení $N(0, 1)$ (značíme $\{Z_n\} \stackrel{as}{\sim} N(0, 1)$).

D ů k a z: Viz [3, strana 128]

Poznámka 1.22. Z tvrzení předchozí věty a podle vět 1.20 a 1.21 je zřejmé, že

$$Y_n \stackrel{as}{\sim} N(np, np(1-p)), \quad \frac{Y_n}{n} \stackrel{as}{\sim} N\left(p, \frac{p(1-p)}{n}\right)$$

1.3. Statistika

V praktickém životě neznáme přesné teoretické rozdělení pravděpodobností (či distribuční funkci) zkoumané náhodné veličiny (statistického znaku) – např. pravděpodobnosti výskytu vadného výrobku, počtu mikroorganismů ve vzorku, chyby

měření. Ovšem provedením několika na sobě nezávislých pokusů lze získat představu o tom, jak teoretická distribuční funkce vypadá. Pomocí zákonů velkých čísel pak můžeme dokázat, že pokud provedeme dostatečně velké množství pokusů, můžeme se s libovolnou přesností blížit teoretickým výpočtům teorie pravděpodobnosti.

Definice 1.35. Náhodný vektor $\mathbb{X} = (X_1(\omega), \dots, X_n(\omega))$, jehož složky jsou nezávislé náhodné veličiny se stejným rozdělením pravděpodobností Q , se nazývá *náhodný výběr o rozsahu n z rozdělení Q* .

Definice 1.36. Každou borelovsky měřitelnou funkci $\phi(X_1(\omega), \dots, X_n(\omega))$ náhodného výběru $\mathbb{X} = (X_1(\omega), \dots, X_n(\omega))$ nazýváme *výběrovou funkcí* nebo také *statistikou* náhodného výběru \mathbb{X} .

Poznámka 1.23. Jednou z nejznámějších a nejužívanějších statistik náhodného výběru je tzv. *výběrový průměr* $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$.

Věta 1.29. *Nechť $\mathbb{X} = (X_1(\omega), \dots, X_n(\omega))$ je náhodný výběr z rozdělení $N(\mu, \sigma^2)$. Pak výběrový průměr \bar{X}_n má rozdělení $N\left(\mu, \frac{\sigma^2}{n}\right)$.*

Realizací náhodného výběru o rozsahu n získáme n -tici hodnot (x_1, \dots, x_n) . Vytvoříme tzv. vektor variant – získané hodnoty uspořádáme a opakující se hodnoty zahrneme pouze jednou. Vektor variant značíme $(x_{[1]}, \dots, x_{[r]})$.

Definice 1.37.

- Počet všech výskytů varianty $x_{[i]}$ v této realizaci nazveme *absolutní četností* této varianty a značíme n_i .
- Číslo $r_i = \frac{n_i}{n}$ nazveme *relativní četností* varianty $x_{[i]}$.
- Součet všech relativních četností variant menších či rovných $x_{[i]}$ nazveme *relativní kumulativní četnost* a značíme F_i .

Definice 1.38. *Empirická distribuční funkce* F je funkce definovaná tímto předpisem:

$$F(x) = \begin{cases} 0 & x \leq x_{[1]} \\ F_i & x_{[i]} < x \leq x_{[i+1]}, \quad i = 1, \dots, r-1 \\ 1 & x > x_{[r]} \end{cases}$$

Poznámka 1.24. Empirická distribuční funkce je tedy schodovitá distribuční funkce, na ose x jsou vyneseny naměřené varianty $x_{[i]}$, a skoky v nich mají velikost n_i/n , (tedy relativní četnost dané varianty).

2. Zákony velkých čísel

2.1. Slabý zákon velkých čísel

Věta 2.1 (Čebyševova nerovnost). *Nechť X je náhodná veličina se střední hodnotou $E(X)$ a rozptylem $\sigma^2(X)$. Pak $\forall \varepsilon > 0$:*

$$P(\{\omega; |X(\omega) - E(X)| \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \sigma^2(X)$$

D ů k a z: Označme $A = \{\omega; |X(\omega) - E(X)| \geq \varepsilon\}$, A^C její doplněk, tedy $A^C = \{\omega; |X(\omega) - E(X)| < \varepsilon\}$. Můžeme psát:

$$\begin{aligned} \sigma^2(X) &= \int (X - E(X))^2 dP = \int_A (X - E(X))^2 dP + \int_{A^C} (X - E(X))^2 dP \geq \\ &\geq \int_A (X - E(X))^2 dP \geq \varepsilon^2 P(A) \end{aligned}$$

Odtud přímo plyne tvrzení věty. ■

Věta 2.2 (Slabý zákon velkých čísel). *Nechť $\{X_n\}_{n=1}^\infty$ je posloupnost nezávislých náhodných veličin, která splňuje následující podmínky:*

(i) $E(X_n) = \int X_n dP = 0 \quad \forall n \in \mathbb{N}$

(ii) $\sigma^2(X_n) = \int X_n^2 dP < \infty \quad \forall n \in \mathbb{N}$

(iii) $\lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i) = 0$

Pak posloupnost aritmetických průměrů

$$\left\{ \frac{1}{n} \sum_{i=1}^n X_i \right\} \text{ konverguje k } 0 \text{ podle pravděpodobnosti.}$$

D ů k a z: Uvažujme náhodnou veličinu

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

Podívejme se na její střední hodnotu a rozptyl:

$$\mathbf{E}(X) = \mathbf{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbf{E}(X_i) = 0$$

$$\sigma^2(X) = \sigma^2\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i)$$

Použijeme Čebyševovu nerovnost:

$$\mathbf{P}(\omega; |X(\omega)| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i)$$

Tedy

$$0 \leq \lim_{n \rightarrow \infty} \mathbf{P}(\omega; |X(\omega)| \geq \varepsilon) \leq \lim_{n \rightarrow \infty} \frac{1}{\varepsilon^2} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i) = 0$$

přičemž první nerovnost plyne z definičních vlastností míry a poslední rovnost zaručuje předpoklad (iii) tvrzení věty. Odtud plyne:

$$\lim_{n \rightarrow \infty} \mathbf{P}(\omega; |X(\omega)| \geq \varepsilon) = 0$$

což znamená, že X konverguje k 0 podle pravděpodobnosti, a to je ovšem požadovaný výsledek. ■

Poznámka 2.1. První předpoklad tvrzení 2.2 lze zobecnit: stačí předpokládat, že všechny uvažované náhodné veličiny mají konečnou střední hodnotu, tedy $|\mathbf{E}(X_n)| < \infty, \forall n \in \mathbb{N}$. Pak za platnosti ostatních předpokladů věty platí:

$$\frac{1}{n} \sum_{i=1}^n (X_i - \mathbf{E}(X_i)) \xrightarrow{\mathbf{P}} 0$$

Tedy

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbf{P}} \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{E}(X_i).$$

D ů k a z: Budeme uvažovat náhodnou veličinu $Y_n = \frac{1}{n} \sum_{i=1}^n (X_i - \mathbf{E}(X_i))$. Dále využijeme stejný postup jako v předešlém důkaze:

$$\mathbf{E}(Y_n) = \mathbf{E}\left(\frac{1}{n} \sum_{i=1}^n (X_i - \mathbf{E}(X_i))\right) = \frac{1}{n} \sum_{i=1}^n (\mathbf{E}(X_i) - \mathbf{E}(X_i)) = 0$$

$$\sigma^2(Y_n) = \sigma^2\left(\frac{1}{n} \sum_{i=1}^n (X_i - \mathbf{E}(X_i))\right) = \frac{1}{n^2} \sigma^2(X_i)$$

Z Čebyševovy nerovnosti tedy:

$$0 \leq \lim_{n \rightarrow \infty} \mathbf{P}(\omega; |Y_n(\omega)| \geq \varepsilon) \leq \lim_{n \rightarrow \infty} \frac{1}{\varepsilon^2} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i) = 0$$

Odtud plyne, že $Y_n = \frac{1}{n} \sum_{i=1}^n (X_i - \mathbf{E}(X_i))$ konverguje k nule podle pravděpodobnosti. ■

Definice 2.1. Nechť $\{X_i\}$ je posloupnost náhodných veličin, pro které platí

$$\forall i \in \mathbb{N}: \sigma^2(X_i) \leq b, \quad 0 \leq b < \infty$$

Pak řekneme, že náhodné veličiny X_i mají *stejně omezené rozptyly*.

Věta 2.3 (o aritmetickém průměru). *Nechť $\{X_n\}$ je posloupnost po dvou nezávislých náhodných veličin, které mají stejně omezené rozptyly, a platí pro ně $\mathbf{E}(X_n) = a \in \mathbb{R}, \forall n \in \mathbb{N}$. Pak*

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbf{P}} a$$

D ů k a z: Předpoklad (ii) tvrzení věty 2.2 je zřejmě splněn. Rovněž platí:

$$\lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i - a) \leq \lim_{n \rightarrow \infty} \frac{b}{n} = 0$$

A podle poznámky 2.1 platí:

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbf{P}} \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n a = \lim_{n \rightarrow \infty} \frac{n \cdot a}{n} = a$$

■

Věta 2.2 vyjadřuje pouze postačující podmínky k tomu, aby posloupnost náhodných veličin splňovala slabý zákon velkých čísel. V následující větě uvidíme, že náhodné veličiny X_i nemusí za určitých podmínek být ani nezávislé.

Věta 2.4 (Markovova). *Nechť pro posloupnost náhodných veličin $\{X_n\}_{n=1}^\infty$ platí:*

$$\lim_{n \rightarrow \infty} \left[\frac{1}{n^2} \operatorname{var} \left(\sum_{j=1}^n X_j \right) \right] = 0$$

Pak posloupnost

$$\left\{ \frac{1}{n} \sum_{j=1}^n (X_j - \mathbf{E}(X_j)) \right\} \text{ konverguje k 0 podle pravěpodobnosti.}$$

D ů k a z: Použijme na posloupnost $\left\{ \frac{1}{n} \sum_{j=1}^n (X_j - \mathbf{E}(X_j)) \right\}$ Čebyševovu nerovnost:

$$\begin{aligned} 0 &\leq \mathbf{P} \left(\left| \frac{1}{n} \sum_{j=1}^n (X_j - \mathbf{E}(X_j)) \right| \geq \varepsilon \right) = \mathbf{P} \left(\left| \frac{1}{n} \sum_{j=1}^n X_j - \frac{1}{n} \sum_{j=1}^n \mathbf{E}(X_j) \right| \geq \varepsilon \right) = \\ &= \mathbf{P} \left(\left| \frac{1}{n} \sum_{j=1}^n X_j - \mathbf{E} \left(\frac{1}{n} \sum_{j=1}^n X_j \right) \right| \geq \varepsilon \right) \leq \frac{\operatorname{var} \left(\frac{1}{n} \sum_{j=1}^n X_j \right)}{\varepsilon^2} = \frac{1}{\varepsilon^2} \left[\frac{1}{n^2} \operatorname{var} \left(\sum_{j=1}^n X_j \right) \right] \end{aligned}$$

Poslední člen konverguje k 0 podle předpokladu, čímž je dokázáno tvrzení věty. ■

Pro úplnost uvedme ještě větu, která neklade žádná omezení na rozptyl uvažovaných náhodných veličin:

Věta 2.5 (Chinčinova). *Nechť $\{X_j\}$ je posloupnost nezávislých stejně rozdělených náhodných veličin, které mají konečnou střední hodnotu $\mathbf{E}(X_j) = a$, $\forall j \in \mathbb{N}$. Pak*

$$\frac{1}{n} \sum_{j=1}^n X_j \xrightarrow{\mathbf{P}} a$$

D ů k a z: Viz [3, str. 118-120]

2.2. Silný zákon velkých čísel

Věta 2.6 (Kolmogorovova nerovnost). *Nechť $\{X_i\}_{i=1}^n$ je posloupnost nezávislých náhodných veličin s nulovou střední hodnotou a konečnými rozptyly a nechť $X(\omega) = \max_{1 \leq k \leq n} \{ |\sum_{i=1}^k X_i(\omega)| \}$ (tedy $X(\omega)$ je maximum absolutních hodnot částečných součtů). Pak $\forall \varepsilon > 0$:*

$$\mathbf{P}(\{\omega; |X(\omega)| \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \sum_{k=1}^n \sigma^2(X_k)$$

D ů k a z: Označme:

$$E = \{\omega; |X(\omega)| \geq \varepsilon\} \quad (\text{hledaný jev})$$

$$s_k = \sum_{i=1}^k X_i \quad (k\text{-tý částečný součet})$$

$E_k = \{\omega; |s_k(\omega)| \geq \varepsilon\} \cap \bigcap_{1 \leq i < k} \{\omega; |s_i(\omega)| < \varepsilon\}$ (k -tý částečný součet je první, který vyskočí z epsilonového okolí nuly, tedy $E_k, k = 1, 2, \dots$ jsou neslučitelné jevy)

Platí:

$$\begin{aligned} \int_{E_k} s_n^2 d\mathbf{P} &= \int_{E_k} \left(s_k + \sum_{i=k+1}^n X_i \right)^2 d\mathbf{P} = \\ &= \int_{E_k} \left(s_k^2 + 2s_k \sum_{i=k+1}^n X_i + \sum_{i=k+1}^n X_i^2 + 2 \sum_{i=k+1}^{n-1} \sum_{j=i+1}^n X_i X_j \right) d\mathbf{P} \end{aligned}$$

Rozeberme podrobněji jednotlivé sčítance:

$$\int_{E_k} 2s_k \sum_{i=k+1}^n X_i d\mathbf{P} = \int \chi_{E_k} 2s_k \sum_{i=k+1}^n X_i d\mathbf{P} = 2 \int \chi_{E_k} s_k d\mathbf{P} \int \sum_{i=k+1}^n X_i d\mathbf{P} = 0$$

(veličiny $\chi_{E_k} \cdot s_k$ a $X_i, i \geq k+1$, jsou nezávislé, tedy integrál lze rozdělit na součin; druhý integrál je nulový podle předpokladu a z aditivity integrálu)

$$\int_{E_k} \sum_{i=k+1}^n X_i^2 d\mathbf{P} = \sum_{i=k+1}^n \int \chi_{E_k} X_i^2 d\mathbf{P} = \mathbf{P}(E_k) \sum_{i=k+1}^n \int X_i^2 d\mathbf{P}$$

(opět χ_{E_k} a $X_i, i \geq k+1$ jsou nezávislé)

$$\begin{aligned} 2 \int_{E_k} \sum_{i=k+1}^{n-1} \sum_{j=i+1}^n X_i X_j d\mathbf{P} &= 2 \sum_{i=k+1}^n \sum_{j=i+1}^n \int_{E_k} X_i X_j d\mathbf{P} = 2 \sum_{i=k+1}^n \left(\int_{E_k} X_i d\mathbf{P} \right) \cdot \\ &\cdot \sum_{j=i+1}^n \left(\int_{E_k} X_j d\mathbf{P} \right) = 2 \sum_{i=k+1}^n \left(\int \chi_{E_k} X_i d\mathbf{P} \right) \cdot \sum_{j=i+1}^n \left(\int \chi_{E_k} X_j d\mathbf{P} \right) = \\ &= 2 \sum_{i=k+1}^n \left(\mathbf{P}(E_k) \int X_i d\mathbf{P} \right) \sum_{j=i+1}^n \left(\mathbf{P}(E_k) \int X_j d\mathbf{P} \right) = 0 \end{aligned}$$

(podle předpokladů jsou náhodné veličiny X_i a X_j , $i \neq j$ nezávislé, rovněž jsou pro $i \geq k + 1$ všechny nezávislé s funkcí χ_{E_k} , střední hodnota $\int X_n d\mathbf{P} = 0$, $\forall n$, takže výsledek je nulový)

Tedy souhrnem:

$$\int_{E_k} s_n^2 d\mathbf{P} = \int_{E_k} s_k^2 d\mathbf{P} + \mathbf{P}(E_k) \sum_{i=k+1}^n \int X_i^2 d\mathbf{P} \geq \int_{E_k} s_k^2 d\mathbf{P} \geq \mathbf{P}(E_k)\varepsilon^2$$

Pak lze psát:

$$\begin{aligned} \sum_{k=1}^n \sigma^2(X_k) &= \sigma^2\left(\sum_{k=1}^n X_k\right) = \int \left(\sum_{k=1}^n X_k\right)^2 d\mathbf{P} = \int s_n^2 d\mathbf{P} \geq \sum_{k=1}^n \int_{E_k} s_n^2 d\mathbf{P} \geq \\ &\geq \sum_{k=1}^n \mathbf{P}(E_k)\varepsilon^2 = \mathbf{P}(E)\varepsilon^2 \end{aligned}$$

Odtud už přímo plyne tvrzení. ■

Věta 2.7. *Nechť $\{y_n\}$ je posloupnost reálných čísel, pro kterou je $\lim_{n \rightarrow \infty} y_n = y$ konečná. Pak také*

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n y_i = y$$

D ů k a z: Z předpokladů plyne, že

$$\forall \varepsilon > 0 \exists n_0 \in \mathbb{N} \forall n \geq n_0: |y_n - y| < \frac{\varepsilon}{2}$$

Nechť n_1 je přirozené číslo větší než n_0 takové, pro které platí:

$$\frac{1}{n_1} \sum_{i=1}^{n_0} |y_i - y| < \frac{\varepsilon}{2}$$

Pro $n > n_1$ platí:

$$\begin{aligned} \left| \frac{1}{n} \sum_{i=1}^n y_i - y \right| &= \left| \frac{1}{n} \sum_{i=1}^n y_i - \frac{1}{n} ny \right| \leq \left| \frac{1}{n} \sum_{i=1}^{n_0} (y_i - y) \right| + \left| \frac{1}{n} \sum_{i=n_0+1}^n (y_i - y) \right| < \\ &< \left| \frac{1}{n_1} \sum_{i=1}^{n_0} (y_i - y) \right| + \frac{n - n_0}{n} \frac{\varepsilon}{2} < \varepsilon \end{aligned}$$

■

Věta 2.8. *Nechť $\{y_n\}$ je posloupnost reálných čísel taková, že $\sum_{n=1}^{\infty} \frac{y_n}{n} = s < \infty$. Pak*

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n y_i = 0$$

D ů k a z: Označme:

$$s_0 = 0 \quad s_n = \sum_{i=1}^n \frac{y_i}{i} \quad t_n = \sum_{i=1}^n y_i \quad \text{pro } n \in \mathbb{N}$$

Odtud:

$$\begin{aligned} y_i &= (s_i - s_{i-1})i \\ t_{n+1} &= \sum_{i=1}^{n+1} y_i = \sum_{i=1}^{n+1} i s_i - \sum_{i=1}^{n+1} i s_{i-1} = \sum_{i=1}^{n+1} i s_i - \sum_{i=0}^n (i+1) s_i = \\ &= -s_0 + \sum_{i=1}^n (i s_i - (i+1) s_i) + (n+1) s_{n+1} = -\sum_{i=0}^n s_i + (n+1) s_{n+1} \end{aligned}$$

Rovnost vydělíme výrazem $(n+1)$:

$$\frac{t_{n+1}}{n+1} = -\frac{n}{n+1} \frac{1}{n} \sum_{i=0}^n s_i + s_{n+1}$$

Tedy:

$$\lim_{n \rightarrow \infty} \frac{t_{n+1}}{n+1} = -s + s = 0 \quad (\text{z předchozí věty})$$

■

Věta 2.9. *Nechť $\{X_n\}$ je posloupnost nezávislých náhodných veličin, pro kterou platí:*

$$(i) \int X_n d\mathbf{P} = 0 \quad \forall n \in \mathbb{N}$$

$$(ii) \sum_{n=1}^{\infty} \sigma^2(X_n) < \infty$$

Pak

$$\sum_{n=1}^{\infty} X_n \text{ konverguje skoro jistě.}$$

D ů k a z: Označme:

$$s_n(\omega) = \sum_{i=1}^n X_i(\omega)$$
$$a_m(\omega) = \sup\{|s_{m+k}(\omega) - s_m(\omega)|; k \in \mathbb{N}\}$$
$$a(\omega) = \inf\{a_m(\omega); m \in \mathbb{N}\}$$

Dokažme nejprve, že

$$\sum_{n=1}^{\infty} X_n(\omega) \text{ konverguje} \Leftrightarrow a(\omega) = 0$$

“ \Rightarrow ”

Podle Cauchy–Bolzanova kritéria konvergence řad:

$$\sum_{n=1}^{\infty} X_n \text{ konverguje} \Leftrightarrow \forall \varepsilon > 0 \exists n_0 \in \mathbb{N} \forall m \geq n_0 \forall k \in \mathbb{N}: |s_{m+k}(\omega) - s_m(\omega)| < \varepsilon$$

Tato nerovnost platí pro všechna k , tedy rovněž

$$a_m(\omega) = \sup\{|s_{m+k}(\omega) - s_m(\omega)|; k \in \mathbb{N}\} < \varepsilon$$

Tvrzení pak plyne z libovlnosti ε :

$$\inf\{\varepsilon, \varepsilon > 0\} = 0 \Rightarrow a(\omega) = \inf\{a_m(\omega), m \in \mathbb{N}\} = 0$$

“ \Leftarrow ”

Předpokládejme, že $a(\omega) = \inf\{a_m(\omega), m \in \mathbb{N}\} = 0$. Odtud vyplývá, že:

$$\forall \varepsilon > 0 \exists m_0 \in \mathbb{N}: a_{m_0}(\omega) < \varepsilon$$

tj.

$$\forall \varepsilon > 0 \exists m_0 \in \mathbb{N}: \sup\{|s_{m_0+k}(\omega) - s_{m_0}(\omega)|; k \in \mathbb{N}\} < \varepsilon$$

tj.

$$\forall \varepsilon > 0 \exists m_0 \in \mathbb{N} \forall k \in \mathbb{N}: |s_{m_0+k}(\omega) - s_{m_0}(\omega)| < \varepsilon$$

Pro libovolná přirozená čísla $n, p > m_0$ pak platí:

$$|s_n(\omega) - s_p(\omega)| \leq |s_n(\omega) - s_{m_0}(\omega)| + |s_p(\omega) - s_{m_0}(\omega)| < 2\varepsilon$$

Čímž jsme dokázali Cauchyovskost (a tedy konvergenci):

$$\forall \varepsilon > 0 \exists m_0 \in \mathbb{N} \forall n, p > m_0 : |s_n(\omega) - s_p(\omega)| < 2\varepsilon$$

Tímto je ekvivalence dokázána.

Z Kolmogorovy nerovnosti $\forall \varepsilon > 0, \forall m, n \in \mathbb{N}$:

$$\mathbb{P}(\{\omega; \sup\{|s_{m+k}(\omega) - s_m(\omega)|; k = 1, 2, \dots, n\} \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \sum_{k=m+1}^{m+n} \sigma^2(X_k)$$

Při limitním přechodu $n \rightarrow \infty$ se nerovnost nezmění:

$$\mathbb{P}(\{\omega; a_m(\omega) \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \sum_{k=m+1}^{\infty} \sigma^2(X_k)$$

Protože $a(\omega) = \inf\{a_m(\omega)\}$, zřejmě platí i nerovnost:

$$0 \leq \mathbb{P}(\{\omega; a(\omega) \geq \varepsilon\}) \leq \frac{1}{\varepsilon^2} \sum_{k=m+1}^{\infty} \sigma^2(X_k) < \infty$$

Protože řada $\sum_{n=1}^{\infty} \sigma^2(X_n)$ konverguje (a tedy posloupnost zbytků této řady konverguje k 0: $\lim_{m \rightarrow \infty} \sum_{n=m+1}^{\infty} \sigma^2(X_n) = 0$), platí:

$$0 \leq \mathbb{P}(\{\omega; a(\omega) \geq \varepsilon\}) \leq 0$$

Z libovolnosti ε pak plyne $a(\omega) = 0$ s. v., a tvrzení je tímto dokázáno. ■

Věta 2.10 (Silný zákon velkých čísel). *Nechť $\{X_n\}_{n=1}^{\infty}$ je posloupnost nezávislých náhodných veličin, která splňuje následující podmínky:*

(i) $\mathbb{E}(X_n) = \int X_n d\mathbb{P} = 0 \quad \forall n \in \mathbb{N}$

(ii) $\sigma^2(X_n) = \int X_n^2 d\mathbb{P} < \infty \quad \forall n \in \mathbb{N}$

$$(iii) \sum_{n=1}^{\infty} \frac{\sigma^2(X_n)}{n^2} < \infty$$

Pak posloupnost aritmetických průměrů

$$\left\{ \frac{1}{n} \sum_{i=1}^n X_i \right\} \text{ konverguje k 0 skoro jistě.}$$

D ů k a z: Označme $Y_n(x) = \frac{X_n(x)}{n}$. Podívejme se, zda posloupnost $\{Y_n\}$ splňuje předpoklady předchozí věty:

$$\mathbb{E}(Y_n) = \mathbb{E}\left(\frac{X_n}{n}\right) = \frac{1}{n} \mathbb{E}(X_n) = 0$$

$$\sum_{n=1}^{\infty} \sigma^2(Y_n) = \sum_{n=1}^{\infty} \sigma^2\left(\frac{X_n}{n}\right) = \sum_{n=1}^{\infty} \frac{\sigma^2(X_n)}{n^2} < \infty \text{ podle předpokladu (iii)}$$

Předpoklady věty 2.9 jsou splněny, tedy platí:

$$\sum_{n=1}^{\infty} Y_n = \sum_{n=1}^{\infty} \frac{X_n}{n} \text{ konverguje skoro jistě.}$$

Pak z věty 2.8 o posloupnostech plyne, že

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i = 0 \text{ skoro jistě}$$

a tedy tvrzení věty je dokázáno. ■

Poznámka 2.2. Předpoklad (i) předešlé věty lze rovněž zobecnit – stačí uvažovat $\mathbb{E}(X_n) < \infty, \forall n \in \mathbb{N}$. Pak

$$\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) \rightarrow 0 \text{ skoro jistě}$$

Tedy $\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i)$ s. j.

D ů k a z: Za $\{Y_n\}$ nyní vezmeme $Y_n = \frac{X_n - \mathbb{E}(X_n)}{n}$ a důkaz vedeme analogicky jako v předchozí větě. ■

Poznámka 2.3. Předpoklady silného ZVČ jsou zřejmě silnější než předpoklady slabého ZVČ.

D ů k a z:

Dokažme nejprve, že

$$\sum_{n=1}^{\infty} \frac{\sigma^2(X_n)}{n^2} < \infty \Rightarrow \lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i) = 0$$

Protože rozptyl $\sigma^2(X)$ je nezáporný, zřejmě platí:

$$\forall n, p \in \mathbb{N}: \sum_{i=1}^p \frac{\sigma^2(X_{n+i})}{(n+p)^2} \leq \sum_{i=1}^p \frac{\sigma^2(X_{n+i})}{(n+i)^2}$$

Nekonečná číselná řada $X_1 + X_2 + \dots$ konverguje právě tehdy, když posloupnost jejích částečných součtů je cauchyovská, tedy:

$$\forall \varepsilon > 0 \exists n_0 \in \mathbb{N} \forall p \in \mathbb{N}: \left| \sum_{i=n_0+1}^{n_0+p} \frac{\sigma^2(X_i)}{i^2} \right| < \varepsilon$$

Z předchozích dvou nerovností plyne:

$$\forall \varepsilon > 0 \exists n_0 \in \mathbb{N} \forall p \in \mathbb{N}: \left| \sum_{i=n_0+1}^{n_0+p} \frac{\sigma^2(X_i)}{(n_0+p)^2} \right| < \left| \sum_{i=n_0+1}^{n_0+p} \frac{\sigma^2(X_i)}{i^2} \right| < \varepsilon$$

Odtud tedy:

$$\lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(X_i) = 0$$

Příklad takové posloupnosti, která splňuje podmínky slabého ZVČ a nespĺňuje podmínky silného ZVČ, najdeme v příkladu 3.1 v další kapitole. Tím bude tvrzení poznámky dokázáno. ■

Poznámka 2.4. Rovněž předpoklady věty 2.10 jsou pouze postačujícími podmínkami, nikoli nutnými. Lze tedy například najít takovou posloupnost $\{Y_n\}$, která konverguje k 0 skoro jistě, přičemž $\sum_{n=1}^{\infty} \frac{\sigma^2(Y_n)}{n^2}$ diverguje.

Klíčem k sestrojení takové posloupnosti bude následující definice. V příkladu 3.2 pak jednu takovou posloupnost zkonstruujeme.

Definice 2.2. Řekneme, že dvě posloupnosti funkcí $\{X_n\}$ a $\{g_n\}$ jsou *ekvivalentní v Chinčínově smyslu*, jestliže

$$\sum_{n=1}^{\infty} \mathbb{P}(\{\omega; X_n(\omega) \neq Y_n(\omega)\}) < \infty$$

2.3. Empirická distribuční funkce, Glivenkova věta

Pomocí silného zákona velkých čísel si nyní dokážeme tzv. Glivenkovu větu. Ta říká, že empirická funkce $F_n(x)$ náhodného výběru z rozdělení Q konverguje skoro jistě k teoretické distribuční funkci $F(x)$ tohoto rozdělení.

$$\text{Připomeňme, že } F_n(x) = \begin{cases} 0 & x \leq x_{[1]} \\ F_i & x_{[i]} < x \leq x_{[i+1]}, \quad i = 1, \dots, r-1 \\ 1 & x > x_{[r]} \end{cases}$$

Lze tedy říct, že $F_n(x) = \frac{k}{n}$, kde k je počet realizovaných hodnot menších než x . Mějme náhodný výběr o rozsahu n z rozdělení s distribuční funkcí $F(x)$. Pravděpodobnostní funkce náhodné veličiny $Y(x): \mathbb{R} \rightarrow \{0, 1, \dots, n\}$ vyjadřující, kolik hodnot bude při libovolné realizaci tohoto náhodného výběru nalevo od bodu x , má zřejmě binomické rozdělení $Bi(n, F(x))$:

$$P(Y = k) = \binom{n}{k} (F(x))^k (1 - F(x))^{(n-k)} \quad k = 0, 1, \dots, n$$

Vypočítejme střední hodnotu a rozptyl této náhodné veličiny:

$$\begin{aligned} \mathbb{E}(Y) &= \sum_{k=0}^n k \binom{n}{k} (F(x))^k (1 - F(x))^{n-k} = \sum_{k=0}^n \frac{k \cdot n!}{k!(n-k)!} (F(x))^k (1 - F(x))^{n-k} = \\ &= \sum_{k=1}^n \frac{(n-1)!}{(k-1)!(n-k)!} (F(x))^k (1 - F(x))^{n-k} = n \sum_{k=1}^n \binom{n-1}{k-1} (F(x))^k (1 - F(x))^{n-k} = \\ &= nF(x) \sum_{k=0}^{n-1} \binom{n-1}{k} (F(x))^k (1 - F(x))^{n-k-1} = nF(x) (F(x) + (1 - F(x)))^{n-1} = nF(x) \end{aligned}$$

K určení rozptylu využijeme následujícího výpočtu:

$$\begin{aligned}
\mathbf{E}(Y(Y-1)) &= \sum_{k=0}^n k(k-1) \frac{n!}{k!(n-k)!} (F(x))^k (1-F(x))^{n-k} = \\
&= \sum_{k=2}^n \frac{n!}{(k-2)!(n-k)!} (F(x))^k (1-F(x))^{n-k} = \\
&= n(n-1) \sum_{k=2}^n \frac{(n-2)!}{(k-2)!(n-k)!} (F(x))^k (1-F(x))^{n-k} = \\
&= n(n-1) \sum_{k=0}^{n-2} \binom{n-2}{k} (F(x))^k (1-F(x))^{n-2-k} = n(n-1)F^2(x)
\end{aligned}$$

Tedy:

$$\mathbf{E}(Y^2) - \mathbf{E}(Y) = n(n-1)F^2(x) \quad \Rightarrow \quad \mathbf{E}(Y^2) = n(n-1)F^2(x) + nF(x)$$

$$\begin{aligned}
\sigma^2(Y) &= \mathbf{E}(Y^2) - \mathbf{E}^2(Y) = n(n-1)F^2(x) + nF(x) - n^2F^2(x) = \\
&= nF(x)(1-F(x))
\end{aligned}$$

Nyní uvažujme posloupnost $\{F_n(x)\}$, tedy posloupnost empirických distribučních funkcí realizací náhodného výběru o rostoucím rozsahu n a ověřme, zda splňuje předpoklady věty 2.10 ve znění poznámky 2.2:

$$\begin{aligned}
\mathbf{E}(F_n(x)) &= \mathbf{E}\left(\frac{Y}{n}\right) = \frac{\mathbf{E}(Y)}{n} = \frac{nF(x)}{n} = F(x) \\
\sigma^2(F_n(x)) &= \sigma^2\left(\frac{Y}{n}\right) = \frac{\sigma^2(Y)}{n^2} = \frac{F(x)(1-F(x))}{n}
\end{aligned}$$

Uvažujme posloupnost $\{F_n(x)\}$ tedy posloupnost empirických distribučních funkcí realizací náhodného výběru o rostoucím rozsahu n a ověřme, zda splňuje předpoklad (iii) věty 2.10 :

$$\sum_{n=1}^{\infty} \frac{\sigma^2(f_n)}{n^2} = \sum_{n=1}^{\infty} \frac{F(x)(1-F(x))}{n \cdot n^2}$$

K důkazu konvergence této řady využijeme integrální kritérium. Budeme uvažovat funkci $f(x) = \frac{1}{x^3}$, která je zřejmě na $(1, \infty)$ definovaná, nezáporná a nerostoucí, tedy splňuje předpoklady pro toto kritérium. Vypočítejme nyní integrál

$$\int_1^{\infty} \frac{1}{x^3} dx = \left[-\frac{1}{2x^2} \right]_1^{\infty} = 0 + \frac{1}{2} = \frac{1}{2} < \infty$$

Protože tento integrál konverguje, konverguje i uvažovaná řada, a tedy posloupnost empirických distribučních funkcí $\{F_n(x)\}$ splňuje předpoklady silného zákona velkých čísel a konverguje skoro všude k $F(x)$.

Nyní si tedy odvodíme jednu z podstatných vět matematické statistiky – Glivenkovu(–Cantelliho) větu. Ta nám dává podklad k tvrzení, že při dostatečném množství pozorování lze s libovolnou přesností aproximovat skutečné zastoupení pozorovaného jevu v celku.

Věta 2.11 (Glivenkova). *Nechť náhodné veličiny X_1, \dots, X_n jsou prvky náhodného výběru z rozdělení s distribuční funkcí $F(x)$. Dále nechť $F_n(x)$ značí empirickou distribuční funkci a konečně označme*

$$\Delta_n = \sup_{-\infty < x < \infty} |F_n(x) - F(x)|$$

Potom platí

$$P(\lim_{n \rightarrow \infty} \Delta_n = 0) = 1$$

D ů k a z: Pro každé $M \in \mathbb{N}$ a $k = 1, 2, \dots, M$ označme $x_{M,k}$ nejmenší takové číslo, pro které platí $F(x) \leq \frac{k}{M} \leq F(x+0)$ (kde $F(x+0) = \lim_{y \rightarrow x+} F(y)$).

Tyto body se nacházejí tam, kde $F(x) = \frac{k}{M}$, nebo v bodech nespojitosti teoretické distribuční funkce.

Označme:

$$\Delta_n^{(1)} = \max_{1 \leq k \leq M} |F_n(x_{M,k}) - F(x_{M,k})|, \Delta_n^{(2)} = \max_{1 \leq k \leq M} |F_n(x_{M,k} + 0) - F(x_{M,k} + 0)|$$

Dokažme, že pak platí:

$$\Delta_n \leq \max(\Delta_n^{(1)}, \Delta_n^{(2)}) + \frac{1}{M}$$


Uvažujme nejprve, že maximum v předchozí nerovnosti bude $\Delta_n^{(1)}$ a předpokládejme, že je této hodnoty dosaženo v bodě $x_{M,k}$. Když půjdeme od tohoto bodu doleva, rozdíl mezi empirickou a teoretickou distribuční funkcí se může zvětšovat. Ovšem maximálně do bodu, kdy se teoretická distribuční funkce sníží na (resp. pod) hodnotu $\frac{k-1}{M}$, tedy do bodu $x_{M,k-1}$. Ovšem v tom případě by uvažované maximum muselo být právě v bodě $x_{M,k-1}$, což je spor s předpokladem.

Hodnota teoretické distribuční funkce tedy může klesnout maximálně o $\frac{1}{M}$, přičemž $F_n(x)$ nemůže směrem doleva stoupat - a tedy celkově se rozdíl mezi nimi zvýší o maximálně $\frac{1}{M}$ (a tohoto maxima nelze dosáhnout).

Pokud bychom se pohybovali od bodu $x_{M,k}$ napravo, okamžitě narazíme na limitu $|F_n(x_{M,k}+0) - F(x_{M,k}+0)|$, která je podle předpokladů menší než naše maximum (a platí pro ni analogické tvrzení, že při pohybu napravo od ní nemůžeme její hodnotu přesáhnout o více než $\frac{1}{M}$).

Analogické úvahy je možno provést i v případě, že maximum v předchozí nerovnosti je $\Delta_n^{(2)}$.

Následující dva obrázky ilustrují popsanou situaci pro výběr z normovaného normálního rozdělení o rozsahu 7 pro $M = 5$. Zelenou barvou jsou vykresleny rozdíly funkčních hodnot v bodech $x_{M,k}$, resp. $x_{M,k}+0$, červenou je pak maximum rozdílu teoretické a empirické distribuční funkce na celé reálné ose.



Podle silného ZVČ (viz také předchozí příklady) platí:

$$\forall x \in \mathbb{R}: \quad \mathbf{P}\left(\lim_{n \rightarrow \infty} F_n(x) = F(x)\right) = 1 \quad \wedge \quad \mathbf{P}\left(\lim_{n \rightarrow \infty} F_n(x+0) = F(x+0)\right) = 1$$

Odtud tedy:

$$\forall x \in \mathbb{R}: \quad \mathbf{P}(\lim_{n \rightarrow \infty} |F_n(x) - F(x)| = 0) = 1 \quad \wedge \quad \mathbf{P}(\lim_{n \rightarrow \infty} |F_n(x+0) - F(x+0)|) = 1$$

Z čehož vyplývá

$$\max(\Delta_n^{(1)}, \Delta_n^{(2)}) \xrightarrow{n \rightarrow \infty} 0 \text{ s. v.} \quad \Rightarrow \quad \limsup_{n \rightarrow \infty} \Delta_n \leq \frac{1}{M} \text{ s. v.}$$

Což se dá přepsat pomocí pravděpodobnosti:

$$\mathbf{P}\left(\limsup_{n \rightarrow \infty} \Delta_n \leq \frac{1}{M}\right) = 1 \quad \Rightarrow \quad \mathbf{P}\left(\limsup_{n \rightarrow \infty} \Delta_n > \frac{1}{M}\right) = 0$$

Odtud limitním přechodem pro $M \rightarrow \infty$

$$\mathbf{P}(\limsup_{n \rightarrow \infty} \Delta_n > 0) = 0$$

Odtud už přímo plyne dokazované tvrzení. ■

3. Příklady

Příklad 3.1. Najděme příklad posloupnosti, která splňuje předpoklady slabého ZVČ a nespĺňuje silný ZVČ.

Zkonstruujme posloupnost $\{f_n\}$ nezávislých náhodných veličin, pro které $\sigma^2(f_n) = \frac{n+1}{\ln(n+1)}$. Posloupnost $\{\frac{n+1}{\ln(n+1)}\}$ je pro $n > 1$ rostoucí, tedy lze psát:

$$\lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{i=1}^n \sigma^2(f_i) \leq \lim_{n \rightarrow \infty} \frac{n(n+1)}{n^2 \ln(n+1)} = 0$$

Nyní dokažme, že řada $\sum_{n=1}^{\infty} \frac{n+1}{n^2 \ln(n+1)}$ diverguje. Využijeme k tomu obměněné majorantní kritérium a integrální kritérium.

$$\sum_{n=1}^{\infty} \frac{n+1}{n^2 \ln(n+1)} = \sum_{n=1}^{\infty} \left(\frac{n}{n^2 \ln(n+1)} + \frac{1}{n^2 \ln(n+1)} \right) \geq \sum_{n=1}^{\infty} \frac{1}{n \ln(n+1)}$$

Na tuto řadu aplikujeme integrální kritérium:

Mějme funkci $f(x) = \frac{1}{x \ln(x)}$. Ta je zřejmě pro $x \in (1, \infty)$ definovaná, nezáporná a nerostoucí, a tedy splňuje předpoklady integrálního kritéria.

Uvažujme nyní funkci $F(x) = \ln(\ln(x))$. Její derivace podle x má tvar:

$$\frac{dF(x)}{dx} = \frac{1}{x \ln(x)} \Rightarrow \int \frac{1}{x \ln(x)} dx = \ln(\ln(x)) = F(x)$$

Protože ovšem $F(\infty) = \infty$ a $F(1) = -\infty$, integrál $\int_1^{\infty} \frac{1}{x \ln(x)} dx$ zřejmě diverguje, proto divergují i obě řady:

$$\sum_{n=1}^{\infty} \frac{1}{n \ln(n+1)} \text{ a } \sum_{n=1}^{\infty} \frac{n+1}{n^2 \ln(n+1)}$$


Příklad 3.2. Najděme příklad takové posloupnosti, která konverguje skoro všude k 0, a přitom nesplňuje předpoklady silného ZVČ.

Jak už bylo řečeno, k sestavení této posloupnosti využijeme definici 2.2.

Nejprve definujme posloupnost $\{f_n(x)\}$ na intervalu $\langle 0, 1 \rangle$:

$$f_n(x) = \begin{cases} 1 & \text{pro } x \in \langle 0, \frac{1}{2^n} \rangle = A_n^1 \\ -1 & \text{pro } x \in \langle 1 - \frac{1}{2^n}, 1 \rangle = A_n^2 \\ 0 & \text{jinde ... označme } A_n^c \end{cases}$$

Toto je posloupnost náhodných veličin definovaných na pravděpodobnostním prostoru (J, \mathcal{B}_J, P) , kde $J = \langle 0, 1 \rangle$, \mathcal{B}_J je systém průniků borelovských množin \mathcal{B}_1 s J a P je Lebesgueova míra (viz poznámka 1.3) na \mathbb{R}^1 ($P(J) = 1$, tedy P je pravděpodobnostní míra).



Obrázek 1: Grafy prvních čtyř členů posloupnosti $\{f_n(x)\}$

Ukažme, že tato posloupnost splňuje podmínky věty 2.10, a tedy konverguje skoro všude k 0:

$$\begin{aligned} E(f_n) &= \int f_n \, d\mathbf{P} = \int_0^1 f_n \, d\mathbf{P} = \mathbf{P}(A_n^1) \cdot 1 + \mathbf{P}(A_n^2) \cdot (-1) + \mathbf{P}(A_n^c) \cdot 0 = \\ &= \frac{1}{2^n} - \frac{1}{2^n} + 0 = 0 \\ \sigma^2(f_n) &= \int f_n^2 \, d\mathbf{P} = \int_0^1 f_n^2 \, d\mathbf{P} = \mathbf{P}(A_n^1) \cdot 1^2 + \mathbf{P}(A_n^2) \cdot (-1)^2 + \mathbf{P}(A_n^c) \cdot 0^2 = \\ &= 2 \cdot \frac{1}{2^n} < \infty \\ \sum_{n=1}^{\infty} \frac{\sigma^2(f_n)}{n^2} &= \sum_{n=1}^{\infty} \frac{2}{2^n n^2} < \sum_{n=1}^{\infty} \frac{2}{n^2} < \infty \end{aligned}$$

Nyní sestrojme posloupnost $\{g_n\}$, která je k $\{f_n\}$ ekvivalentní v Chinčinově smyslu:

$$g_n(x) = \begin{cases} e^n & \text{pro } x \in A_n^1 \\ -e^n & \text{pro } x \in A_n^2 \\ 0 & \text{pro } x \in A_n^c \end{cases}$$

Dokažme, že je tato posloupnost je opravdu ekvivalentní s $\{f_n\}$:

$$\sum_{n=1}^{\infty} \mathbf{P}(\{x; f_n(x) \neq g_n(x)\}) = \sum_{n=1}^{\infty} \mathbf{P}(A_n^1 \cup A_n^2) = \sum_{n=1}^{\infty} \frac{2}{2^n} = \frac{1}{1 - \frac{1}{2}} = 2 < \infty$$

Platí:


$$\forall \varepsilon > 0 \, \forall x \in (0, 1) \, \exists n_0 \in \mathbb{N} \, \forall n \in \mathbb{N} : n \geq n_0 \Rightarrow g_n(x) = 0 \Rightarrow |g_n(x) - 0| = 0 < \varepsilon$$

Odtud plyne, že posloupnost $\{g_n\}$ nekonverguje pouze v bodech 0 a 1, přičemž $\mathbf{P}(\{0, 1\}) = 0$, a tedy

$$\{g_n\} \rightarrow 0 \text{ s. v.}$$

Nyní dokažme, že posloupnost $\{g_n\}$ nesplňuje podmínku (iii) silného ZVČ.

$$\sigma^2(g_n^2) = \int_0^1 g_n^2 \, d\mathbf{P} = 2 \cdot \mathbf{P}(A_n^1) \cdot e^{2n} = \frac{2e^{2n}}{2^n}$$



Obrázek 2: Grafy prvních čtyř členů posloupnosti $\{g_n(x)\}$

$$\sum_{n=1}^{\infty} \frac{\sigma^2(g_n)}{n^2} = \sum_{n=1}^{\infty} \frac{2e^{2n}}{2^n n^2} > \sum_{n=1}^{\infty} \frac{e^{2n}}{2^n n^2}$$

Tato řada diverguje podle limitního Cauchyova odmocninového kritéria:

$$\lim_{n \rightarrow \infty} \sqrt[n]{\frac{e^{2n}}{2^n n^2}} = \lim_{n \rightarrow \infty} \frac{e^2}{2 \sqrt[n]{n^2}} = \frac{e^2}{2} \lim_{n \rightarrow \infty} \frac{1}{\sqrt[n]{n^2}} = \frac{e^2}{2} > 1$$

Příklad 3.3. Graficky ukažme, že empirická distribuční funkce náhodného výběru z rozdělení a) chí-kvadrát, b) Poissonova, skutečně konverguje k teoretické distribuční funkci toho rozdělení.

Z výpočtů v sekci 2.3. víme, že náhodná veličina Y_n vyjadřující počet naměřených hodnot vyskytujících se při realizaci náhodného výběru rozsahu n nalevo od bodu x má binomické rozdělení $Bi(n, F(x))$. Dále víme, že

$$\mathbb{E}(F_n(x)) = \mathbb{E}\left(\frac{Y_n}{n}(x)\right) = F(x), \quad \text{var}(F_n(x)) = \frac{p(1-p)}{n}$$


Rovněž z poznámky za větou 1.28 víme, že náhodná veličina $\frac{Y_n}{n}$ má asymptoticky rozdělení $N\left(F(x), \frac{F(x)(1-F(x))}{n}\right)$, tedy

$$\frac{F_n(x) - F(x)}{\sqrt{F(x)(1-F(x))}\sqrt{n}} \sim N(0, 1)$$


Pro každé $x \in \mathbb{R}$ můžeme sestrojít interval, v němž se bude hodnota $F_n(x)$ pohybovat s pravděpodobností 95% (95% interval spolehlivosti):

$$\begin{aligned} & \mathbb{P}\left(u_{0,025} \leq \frac{F_n(x) - F(x)}{\sqrt{F(x)(1-F(x))}\sqrt{n}} \leq u_{0,975}\right) = \\ & = \mathbb{P}\left(F(x) - u_{0,975} \frac{\sqrt{F(x)(1-F(x))}}{\sqrt{n}} \leq F_n(x) \leq F(x) + u_{0,975} \frac{\sqrt{F(x)(1-F(x))}}{\sqrt{n}}\right) \end{aligned}$$

Grafy pro Poissonovo a χ^2 rozdělení vytvoříme v programu Matlab (použitý zdrojový kód viz příloha). Červenou barvou je vyznačena teoretická distribuční funkce daného rozdělení, zelenou hranice výše uvedeného intervalu a modrou empirická distribuční funkce pro jednu vygenerovanou realizaci náhodného výběru z tohoto rozdělení.



Obrázek 3: Konvergence empirické distribuční funkce – χ_7^2



Obrázek 4: Konvergence empirické distribuční funkce – $Po(5)$

Z obrázků je jasně patrné, že interval spolehlivosti se pro rostoucí n zužuje, což lze ostatně jednoduše dokázat výpočtem:

$$l(x) = F(x) + u_{0,975} \frac{\sqrt{F(x)(1-F(x))}}{\sqrt{n}} - \left(F(x) - u_{0,975} \frac{\sqrt{F(x)(1-F(x))}}{\sqrt{n}} \right) =$$

$$2 \cdot u_{0,975} \frac{\sqrt{F(x)(1-F(x))}}{\sqrt{n}} \text{ což pro } n \text{ rostoucí klesá}$$

Rovněž je zřejmé, že limitu horní i dolní hranice intervalu tvoří teoretická distribuční funkce $F(x)$:

$$\lim_{n \rightarrow \infty} \left(F(x) - u_{0,975} \frac{\sqrt{F(x)(1-F(x))}}{\sqrt{n}} \right) = F(x) - u_{0,975} \sqrt{F(x)(1-F(x))} \lim_{n \rightarrow \infty} \frac{1}{\sqrt{n}} = F(x)$$

Příklad 3.4. Pro Poissonovo, rovnoměrné a normální rozdělení, pro které platí a) $E = 1$, $\text{var} \doteq 1$, b) $E = 6$, $\text{var} \doteq 6$, graficky znázorněte konvergenci aritmetických průměrů náhodných výběrů o rostoucím rozsahu k teoretické střední hodnotě E daného rozdělení.

V programu Matlab nasimulujeme provádění náhodného pokusu z daného rozdělení, tím nám vznikne posloupnost čísel, kterou označíme $\{x_j\}$. Hodnotu aritmetického průměru naměřených hodnot budeme vyšetřovat vždy po k (ve zdrojovém kódu uvedeném v přílohách se tato proměnná nazývá *krok*) měřeních a tyto průměry vyneseme do grafu s vyznačenou teoretickou střední hodnotou daného rozdělení. Tento výpočet provedeme celkem n -krát (v Matlabu n nazýváme *pocet*). Maximální rozsah souboru tedy bude roven $n \cdot k$.

Jak je vidět z níže vyobrazených grafů, pro rozdělení s rozptylem 1 bylo obecně třeba mnohem menší rozsah náhodného výběru, aby se jeho průměr ustálil v intervalu $\langle E - 0, 1; E + 0, 1 \rangle$.


Porovnání všech tří zadaných typů rozdělení přináší poměrně zajímavé zjištění – totiž že „nejméně korektní“ vlastnosti vykazuje normální rozdělení: aritmetický průměr se k teoretické střední hodnotě blíží relativně nejpomaleji a má největší výkyvy.

Ovšem podle věty 1.29 platí $\bar{X}_n \sim N(\mu, \frac{\sigma^2}{n})$. Výběrový průměr má tedy normální rozdělení a lze použít *pravidlo tří sigma* (poznámka 1.21): hodnoty náhodné veličiny \bar{X}_n se budou s pravděpodobností zhruba 0.997 pohybovat v intervalu


$$I_n = \left\langle E(\bar{X}_n) - 3\sqrt{\text{var}(\bar{X}_n)}, E(\bar{X}_n) + 3\sqrt{\text{var}(\bar{X}_n)} \right\rangle$$

Tento interval se pro $n \rightarrow \infty$ zužuje až k jedinému bodu – $E(\bar{X}_n) = \mu$. Když hranice tohoto intervalu vykreslíme do grafu (zelenou barvou), vidíme, že hodnoty aritmetického průměru se v tomto intervalu vesměs pohybují.


Poznámka 3.1. *Pravidlo tří sigma* nám v tomto případě zaručuje, že pro každý rozsah $k \cdot i$, $i = 1, \dots, n$ je pravděpodobnost, že křížek označující aritmetický průměr realizace náhodného výběru $\bar{x}_{k \cdot i}$ bude uvnitř intervalu $I_{k \cdot i}$, rovna 0.997, nikoli,



Obrázek 5: Konvergence aritmetických průměrů – Poissonovo rozdělení



Obrázek 6: Konvergence aritmetických průměrů – rovnoměrné rozdělení



Obrázek 7: Konvergence aritmetických průměrů – normální rozdělení

že je to pravděpodobnost počtu křížků vyskytujících se uvnitř oblasti vyznačené hranicemi I_n v rámci jednoho pozorování (simulace).

Poznámka 3.2. Obdobné intervaly I_n by se daly vykreslit i pro ostatní rozdělení, ovšem k jejich sestrojení je třeba další teorie, která není předmětem této práce.

Závěr

V rámci této bakalářské práce jsem se zabývala zákony velkých čísel. Na základě literatury jsem dokázala základní znění slabého a silného zákona velkých čísel, i některé jejich obecnější varianty, a na příkladě ukázala jejich rozdílnost. Práce rovněž obsahuje důkaz Glivenkovy věty o stejnoměrné konvergenci empirické distribuční funkce k teoretické, jejíž platnost je pak také demonstrována na příkladu. Dále jsem se zabývala vyšetřováním konvergence aritmetických průměrů náhodného výběru z určitého rozdělení ke střední hodnotě tohoto rozdělení v závislosti na jeho typu - konkrétně jsem zkoumala normální, Poissonovo a rovnoměrné rozdělení. Z příkladu je patrné, že nejpomalejší konvergenci v tomto smyslu jeví normální rozdělení, ale i u něj se s rostoucím rozsahem náhodného výběru tato konvergence projevuje.

Reference

- [1] Halmos, Paul R. Measure Theory. Springer Verlag, New York Inc., 1974
- [2] Jarník, Vojtěch. Integrální počet II. Academia. Praha. 1984
- [3] Kunderová, Pavla. Úvod do teorie pravděpodobnosti a matematické statistiky. 2. vydání. Olomouc: VUP. 2004
- [4] Rényi, Alfred. Teorie pravděpodobnosti. Praha: Academia. 1972

Seznam příloh

- **Příloha A.** Zdrojový kód k příkladu 3.3 52
- **Příloha B.** Příklad zdrojového kódu k příkladu 3.4 54

Přílohy

Příloha A. Zdrojové kódy pro tvorbu grafů ilustrujících konvergenci empirické distribuční funkce k teoretické (příklad 3.3) v programu Matlab :

```
function poissem(n, lambda)
R = poissrnd(lambda,[1 n]);
[f,Rf]=ecdf(R);
stairs(Rf,f);
x = 0:0.2:15;
F = poisscdf(x,lambda);
hold on;
stairs(x,F,'r')
inf=F-1.96*sqrt(F.*(1-F)/n);
sup=F+1.96*sqrt(F.*(1-F)/n);
stairs(x,inf,'g-')
stairs(x,sup,'g-')
hold off;
```

```
function chi2emp(n, st)
R = chi2rnd(st,[1 n]);
[f,Rf]=ecdf(R);
stairs(Rf,f);
x = 0:0.2:15;
F = chi2cdf(x,st);
hold on;
plot(x,F,'r')
inf=F-1.96*sqrt(F.*(1-F)/n);
sup=F+1.96*sqrt(F.*(1-F)/n);
plot(x,inf,'g-')
plot(x,sup,'g-')
```

```
hold off;
```

Příklad volání:

```
poissem(10, 5)  
title('Po(5), n = 10', 'fontsize', 14)
```

Příloha B. Příklad zdrojového kódu funkcí pro tvorbu grafů konvergence aritmetických průměrů náhodného výběru k teoretické střední hodnotě (příklad 3.4). Normální rozdělení (ostatní obdobně):

```
function normalni(E, var, pocet, krok)

max=pocet*krok;
x=0:0.1:max;
plot(x,E,'Color', 'Red');
axis([0,max+1,E-1.3,E+1.3])
set(gca,'YTick', [E-1:0.5:E+1])
set(gca,'YTickLabel', [E-1:0.5:E+1], 'fontsize', 14)
hold on
plot(x, E-0.1, 'Color', 'Yellow');
plot(x, E+0.1, 'Color', 'Yellow');

prumer=zeros(1,pocet);
vyber=normrnd(E,var,[pocet krok]);
for i=1:pocet
    suma(i)=sum([vyber(i,:)]);
    prumer(i)=sum(suma)/(i*krok);
    xove(i)=i*krok;
    yove(i)=3*sqrt(var/(i*krok));
end

plot(xove,prumer,'b+');
plot(xove,E+yove,'Color', 'green');
plot(xove,E-yove,'Color', 'green');
```