

Univerzita Karlova v Praze

Pedagogická fakulta

## BAKALÁŘSKÁ PRÁCE



Bc. Barbora Šimková

## Odhady parametrů rozdělení náhodných veličin

Katedra matematiky a didaktiky matematiky

Vedoucí bakalářské práce: RNDr. František Mošna, Dr.

Studijní program: Specializace v pedagogice

Studijní obor: Matematika se zaměřením na vzdělávání  
a technická a informační výchova se  
zaměřením na vzdělávání

Praha 2013

Na tomto místě bych ráda poděkovala RNDr. Františku Mošnovi, Dr., vedoucímu mé bakalářské práce. Především za odborné vedení, věnovaný čas a cenné rady. Děkuji také svým rodičům, kteří mě vždy podporovali ve studiu.

Prohlašuji, že jsem tuto bakalářskou práci vypracoval(a) samostatně a výhradně s použitím citovaných pramenů, literatury a dalších odborných zdrojů.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona v platném znění, zejména skutečnost, že Univerzita Karlova v Praze má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle §60 odst. 1 autorského zákona.

V Praze dne 3.5.2013

Bc. Barbora Šimková

Název práce: Odhady parametrů rozdělení náhodných veličin

Autor: Bc. Barbora Šimková

Katedra: Katedra matematiky a didaktiky matematiky

Vedoucí bakalářské práce: RNDr. František Mošna, Dr.

Abstrakt: Předmětem této bakalářské práce je porovnání základních metod, kterými je možné spočítat bodové odhady spojitých a diskrétních pravděpodobnostních rozdělení. Práce se zabývá rozborem dvou metod, jedná se o momentovou metodu a metodu maximální věrohodnosti. Tyto metody se používají pro odhad bodových parametrů pravděpodobnostních rozdělení. Momentovou metodou rozumíme porovnání teoretických a výběrových momentů náhodné veličiny. Metodu maximální věrohodnosti bereme jako další alternativu při výpočtech bodových odhadů, která využívá klasický postup hledání maxima funkce s využitím vlastností náhodného výběru. Způsoby výpočtů vychází ze statistických metod a mohly by být vhodné jako zajímavé rozšíření výuky základního kurzu pravděpodobnosti a statistiky na PedF UK. Práce je přehledem odhadů parametrů základních distribucí a srovnání kvality dvou základních metod pro jejich určení.

Klíčová slova: odhady parametrů, rozdělení náhodné veličiny, metoda maximální věrohodnosti, momentová metoda

Title: Parameter estimation of random variables distribution

Author: Bc. Barbora Šimková

Department: Department of Mathematics and Mathematical Education

Supervisor: RNDr. František Mošna, Dr.

Abstract: The subject of this thesis is to compare basic methods by which it is possible to calculate point estimates of discrete and continuous probability distributions. The work deals with the analysis of the two methods - the method of moments and maximum likelihood method. These methods are used for point estimates of probability distributions parameters. The method of moments studies the comparison between the theoretical and sample moments of a random variable. The method of maximum likelihood is another alternative for the calculation of point estimates, which uses the classical approach of finding the maximum of a function, using the properties of random selection. These methods of calculation are based on statistical methods and could be used as an interesting extension of the basic course on probability and statistics at Charles University's Faculty of Education. The work is an overview of the estimated parameters of the basic distribution and compares the quality of two basic methods for their estimation.

Keywords: parameter estimation, distribution of random variables, maximum likelihood method, method of moments

# Obsah

Úvod	3
<b>1 Základní pojmy</b>	<b>5</b>
1.1 Pravděpodobnost . . . . .	5
1.2 Statistika . . . . .	9
<b>2 Metody bodového odhadu v parametrických modelech</b>	<b>12</b>
2.1 Bodové odhady parametrů . . . . .	12
2.2 Metody hledání bodových odhadů . . . . .	12
2.2.1 Momentová metoda . . . . .	13
2.2.2 Metoda maximální věrohodnosti . . . . .	14
<b>3 Bodové odhady pro různá spojitá rozdělení</b>	<b>17</b>
3.1 Normální rozdělení . . . . .	17
3.1.1 Momentová metoda . . . . .	17
3.1.2 Metoda maximální věrohodnosti . . . . .	18
3.1.3 Vlastnosti odhadů . . . . .	20
3.2 Gama rozdělení . . . . .	22
3.2.1 Momentová metoda . . . . .	22
3.2.2 Metoda maximální věrohodnosti . . . . .	23
3.3 Logaritnicko-normální rozdělení . . . . .	25
3.4 Exponenciální rozdělení . . . . .	29
3.4.1 Momentová metoda . . . . .	29
3.4.2 Metoda maximální věrohodnosti . . . . .	29
3.4.3 Vlastnosti odhadů . . . . .	30
3.5 Rovnoměrné rozdělení . . . . .	30
3.5.1 Momentová metoda . . . . .	30
3.5.2 Metoda maximální věrohodnosti . . . . .	31
3.5.3 Vlastnosti odhadů . . . . .	32
<b>4 Bodové odhady pro různá diskrétní rozdělení</b>	<b>33</b>
4.1 Geometrické rozdělení . . . . .	33
4.1.1 Momentová metoda . . . . .	33
4.1.2 Metoda maximální věrohodnosti . . . . .	33
4.1.3 Vlastnosti odhadů . . . . .	34
4.2 Poissonovo rozdělení . . . . .	34
4.2.1 Momentová metoda . . . . .	34
4.2.2 Metoda maximální věrohodnosti . . . . .	34
4.2.3 Vlastnosti odhadů . . . . .	35
4.3 Binomické rozdělení . . . . .	35
4.3.1 Momentová metoda . . . . .	35
4.3.2 Metoda maximální věrohodnosti . . . . .	36
4.3.3 Vlastnosti odhadů . . . . .	36
<b>5 Přehled bodových odhadů</b>	<b>38</b>

Závěr	41
Seznam použité literatury	42

# Úvod

V současném světě se setkáváme se statistikou, jejími důsledky a aplikacemi prakticky každý den, ať už při studiu, v zaměstnání, při čtení denního tisku, při volbě hypotéky nebo při vybírání dovolené. Statistika nám pomáhá pochopit nej-různější vztahy obklopující nás napříč vědními obory. Nejčastěji je spojována s matematikou, fyzikou, informatikou a ekonomikou. Neméně ji využívají i humanitní obory jako je psychologie a sociologie. Statistika je naprosto nepostradatelnou součástí naší společnosti a bude tomu tak i v budoucnu.

Tato bakalářská práce se zaměřuje na metody, kterými lze odhadnout parametry pravděpodobnostních rozdělení. Metody použité v této práci se aplikují pro odhadování parametrů náhodných veličin a vektorů v široké škále reálných statistických, ekonomických, geografických, pojišťovnických a dalších úloh či problémů.

První kapitola popisuje základní pojmy z pravděpodobnosti a statistiky, jako jsou náhodné veličiny, základní druhy pravděpodobnostních rozdělení. Podrobněji definuje rozdělení, která budou používána v dalších kapitolách, pomocí jejich hustoty nebo pravděpodobnostní funkce i s jejich základními momenty. Klíčovými pojmy matematické statistiky jsou náhodný výběr, parametrický model, bodový odhad parametru a jeho vlastnosti, které jsou ve statistické části této kapitoly. Definice pojmů čerpáme hlavně z literatury [1] a [7].

Ve druhé kapitole bakalářské práce se zaměříme na teoretické odvození výpočtů bodových odhadů metodami, které jsou používány pro odhadování bodových parametrů v parametrických modelech. K odhadu parametrů budeme používat metodu maximální věrohodnosti (maximum-likelihood estimation) a metodu momentů (method of moments). Pro obě metody sepíšeme předpoklady pro jejich použití a podrobný postup výpočtu. Vysvětlíme zde výběrové a teoretické momenty náhodných veličin, věrohodnostní funkci a způsob nalezení maximálně věrohodného odhadu.

Po vysvětlení teoretické a popisné stránky dané oblasti se ve třetí kapitole věnujeme výpočtu odhadů bodových parametrů náhodného výběru spojitých pravděpodobnostních rozdělení. Dále je zde uveden postup ověření základních vlastností jednotlivých odhadů a jejich následné srovnání. Ve výpočtech požadovaných odhadů uvažujeme pouze náhodné výběry o rozsahu  $n$ , jejichž náhodné veličiny mají spojitě rozdělení (normální, gamma, logaritmicke-normální, exponenciální a spojitě rozdělení).

Čtvrtá kapitola je věnovaná diskrétním pravděpodobnostním rozdělením, přesněji geometrickému rozdělení, Poissonovu rozdělení a binomickému rozdělení. Pro tato rozdělení odhadneme jejich parametry metodou momentů a metodou maximální věrohodnosti a ověříme vlastnosti těchto odhadů.

V páté kapitole uvádíme přehled všech odhadů parametrů spojitých a diskrétních náhodných včetně jejich vlastností, které v bakalářské práci počítáme. Mimo

jiné jsou zde tabulky, kde je pro každé rozdělení uvedené v této práci srovnání obou odhadů s doplněním vlastností těchto odhadů.



# 1. Základní pojmy

V této kapitole uvedeme některé pojmy z pravděpodobnosti a statistiky, které budeme používat v dalších částech bakalářské práce. Vysvětlíme si zde, co je náhodná veličina, jak se popisuje její rozdělení, uvedeme některé druhy pravděpodobnostních rozdělení, a to jak spojitých, tak i diskrétních náhodných veličin a k nim jejich dva hlavní momenty. Ze statistiky si definujeme pojmy náhodný výběr, parametrický model, výběrový prostor, bodový odhad, vlastnosti bodového odhadu a další.

Předpokládáme, že čtenář je již seznámen se základními pojmy z matematické analýzy a absolvoval základní kurz pravděpodobnosti a matematické statistiky. Definované pojmy a tvrzení v této kapitole jsou čtenáři známé, umí s nimi pracovat, používat je a rozumí jim. Pokud by čtenáři této práce nebyly zcela srozumitelné pojmy, které jsou používány v definicích a tvrzeních jako pojem  $\sigma$ -algebra, výběrový prostor, měřitelné zobrazení, konvergence nebo gama funkce, doporučujeme prostudovat literaturu [1] a [7]. Zároveň je tato literatura vhodná i pro rozšíření pojmů a pohledu do hlubších problémů statistiky. Při definování vycházíme přitom ze zdrojů: [1], [2], [4], [6] a [7]. Citace je uváděna za odstavcem, který je citovaný. Kde citace není, je autorčina volná interpretace.

## 1.1 Pravděpodobnost

Není-li výsledek nějakého pokusu nebo děje jednoznačně určen podmínkami, za nichž se odehrává, můžeme různé možné výsledky považovat za elementární jevy. Označujeme je symbolem  $\omega$  s případnými indexy. Množinu všech elementárních jevů označujeme  $\Omega$  a nazýváme ji prostor elementárních jevů. Většinou se nezajímáme o jednotlivé elementární jevy, ale i určité jejich množiny [1].

### Pravděpodobnostní prostor

Trojice  $(\Omega, \mathcal{A}, \mathcal{P})$  se nazývá pravděpodobnostní prostor, kde  $\Omega$  je prostor elementárních jevů,  $\mathcal{A}$  je  $\sigma$ -algebra a  $\mathcal{P}$  je pravděpodobnost [1].

### Náhodná veličina

Nechť je dán pravděpodobnostní prostor  $(\Omega, \mathcal{A}, \mathcal{P})$ . Měřitelné zobrazení  $X : (\Omega, \mathcal{A}, \mathcal{P}) \rightarrow (\mathcal{X}, \mathcal{B})$ , kde  $\mathcal{X}$  je nějaká množina a  $\mathcal{B}$  nějaká  $\sigma$ -algebra na  $\mathcal{X}$ , nazveme náhodnou veličinou. Množinu  $\mathcal{X}$  nazýváme výběrový prostor [4]. V práci budeme uvažovat pouze reálné náhodné veličiny, tedy za výběrový prostor budeme dosazovat množinu reálných čísel  $\mathbb{R}$ . Uvažujeme tedy náhodnou veličinu  $X : (\Omega, \mathcal{A}, \mathcal{P}) \rightarrow (\mathbb{R}, \mathcal{B})$ .

## Rozdělení náhodné veličiny

Rozdělením náhodné veličiny  $X : (\Omega, \mathcal{A}) \rightarrow (\mathcal{X}, \mathcal{B})$  rozumíme indukovanou pravděpodobnostní míru  $P_X$  na  $(\mathcal{X}, \mathcal{B})$  definovanou vztahem

$$P_X(B) = P(\{\omega \in \Omega : X(\omega) \in B\}) = P(X^{-1}(B)), \quad B \in \mathcal{B}.$$

Pravděpodobnostní prostor  $(\Omega, \mathcal{A}, P)$  se pro danou náhodnou veličinu transformuje na pravděpodobnostní prostor  $(\mathcal{X}, \mathcal{B}, P_X)$  [4].

## Distribuční funkce

Funkci  $F_X : \mathbb{R} \rightarrow \mathbb{R}$  definovanou vztahem  $F_X(x) = P[X \leq x]$  nazýváme distribuční funkcí náhodné veličiny  $X$ . Distribuční funkce  $F_X$  jednoznačně charakterizuje rozdělení  $X$ , viz [4].

## Druhy náhodných veličin

Náhodné veličiny dělíme na různé druhy. V matematické statistice mají nejdůležitější uplatnění následující dva typy rozdělení.

- Distribuční funkce  $F$  je funkce skoků. V tomto případě říkáme, že jde o diskrétní rozdělení. Připomeňme, že bodů nespojitosti může být nejvýš spočetně mnoho, a tak můžeme označit  $x_1, x_2, \dots$ . Nechť  $p_k$  je velikost skoku funkce  $F$  v bodě  $x_k$ . Platí  $p_k = P\{X = x_k\}$ .
- Existuje taková funkce  $f(x)$ , že platí  $F_X(x) = \int_{-\infty}^x f_X(t) dt$ . Pak jde o spojitě rozdělení. Protože  $F$  je neklesající, musí platit  $f(x) \geq 0$ .

Vlastnosti diskrétních a spojitých rozdělení jsou podrobněji popsány v [1], odkud jsme také citovali. Funkci  $f_X(x)$  jednoznačně určuje rozdělení náhodné veličiny a nazývá se hustotou náhodné veličiny  $X$  a dále ji v textu budeme značit  $f(x)$ .

## Momenty náhodné veličiny

Ve statistice se často používají integrály náhodných veličin. Používá se pro ně symbol  $E$ . Říkáme, že

$$EX = \int_{\Omega} X(\omega) dP_X(\omega),$$

je střední hodnota náhodné veličiny  $X$ , pokud uvedený integrál existuje. Protože obvykle bývá známa jenom distribuční funkce, většinou se provádí konkrétní výpočet podle vzorce

$$EX = \int_{\mathbb{R}} x dF_X(x).$$

Je-li  $a$  nějaká konstanta, pak  $Ea = a$  [1]. Tuto vlastnost střední hodnoty, budeme používat při dokazování vlastností odhadů bodových odhadů a to především u nestrannosti. V práci střední hodnotu značíme  $\mu'$  nebo  $EX$ .

Rozptyl  $\text{Var}X$  náhodné veličiny  $X$  je její druhý centrální moment. Je definován následujícím vzorcem  $\text{Var}X = E(X - EX)^2$  [4] a budeme ho značit podle potřeby  $\sigma^2$  nebo  $\text{Var}X$ .

## Pravděpodobnostní rozdělení

V práci se zaměřujeme pouze na náhodné veličiny se spojitým nebo diskrétním rozdělením (spojité nebo diskrétní náhodné veličiny). Nyní si některé definujeme pomocí jejich hustot, či pravděpodobnostních funkcí. U každého rozdělení se pokusíme čtenáři přiblížit, co si pod tímto rozdělením představit nebo jaké jevy mohou reprezentovat toto rozdělení.

### Spojitá rozdělení

Nyní si zdefinujeme některá spojitá rozdělení se kterými budeme později pracovat. Definice spojitých rozdělení jsme čerpali z [1].

### Spojitě rovnoměrné rozdělení

Nechť  $(\mu - h, \mu + h)$  je konečný nedegegovaný interval. Rovnoměrné rozdělení  $R(\mu - h, \mu + h)$  má hustotu

$$f(x) = \frac{1}{2h}, \text{ pro } \mu - h < x < \mu + h,$$

a platí pro něj  $\mu' = \mu$ ,  $\sigma^2 = \frac{h^2}{3}$ . Interpretace tohoto rozdělení je jednoduchá, jednotková pravděpodobnost na intervalu  $(\mu - h, \mu + h)$  je rovnoměrně rozprostřena.

### Gama rozdělení

Nechť  $a > 0$ ,  $p > 0$ . Gama rozdělení  $\text{Ga}(a, p)$  má hustotu

$$f(x) = \frac{a^p}{\Gamma(p)} e^{-ax} x^{p-1}, \quad x > 0$$

a platí, že střední hodnota je  $\mu' = \frac{p}{a}$  a rozptyl  $\sigma^2 = \frac{p}{a^2}$ . Gama rozdělení se používá v teorii spolehlivosti.

### Exponenciální rozdělení

Nechť  $\lambda > 0$  je parametr. Exponenciální rozdělení, které značíme  $\text{Ex}(\lambda)$  má hustotu

$$f(x) = \frac{1}{\lambda} \exp\left[-\frac{x}{\lambda}\right], \quad x > 0.$$

Má střední hodnotu  $\mu' = \lambda$  a rozptyl  $\sigma^2 = \lambda^2$ . Exponenciální funkci v textu značíme buď  $\exp[x]$  nebo  $e^x$ . Exponenciální rozdělení  $\text{Ex}(\lambda)$  je speciální případ gama rozdělení  $\text{Ga}(a, p)$ , kde za parametry dosadíme  $a = \frac{1}{\lambda}$  a  $p = 1$ .

## Normální rozdělení

Nechť  $\mu \in \mathbb{R}$ ,  $\sigma^2 > 0$  jsou dané konstanty (parametry). Normální rozdělení je určeno hustotou

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[ -\frac{(x - \mu)^2}{2\sigma^2} \right]$$

a označuje se symbolem  $N(\mu, \sigma^2)$  a platí, že střední hodnota je  $\mu$ , a rozptyl  $\sigma^2$ . Toto rozdělení hraje hlavní roli ve statistice, neboť za určitých okolností aproximuje celou řadu diskrétních i spojitých rozdělení. Náhodné chyby (chyby měření, které jsou způsobené velkým počtem neznámých) jsou nejběžnějším typem normálně rozdělených náhodných veličin.

## Logaritmicko-normální rozdělení

Nechť  $\mu \in \mathbb{R}$  a  $\sigma^2 > 0$  jsou dané parametry. Hustota logaritmicko-normálního rozdělení  $LN(\mu, \sigma^2)$  je definována

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma x} \exp \left[ -\frac{(\ln x - \mu)^2}{2\sigma^2} \right], \text{ pro } x > 0.$$

Dále platí, že střední hodnota je  $\mu' = e^{\mu + \frac{\sigma^2}{2}}$  a rozptyl  $\sigma^2 = (e^{\sigma^2} - 1) e^{2\mu + \sigma^2}$ .

## Diskrétní rozdělení

Diskrétní rozdělení definujeme z literatury [1] a [7].

## Geometrické rozdělení

Geometrické rozdělení  $Ge(p)$  má náhodná veličina  $X$ , která je dána jako počet pokusů, které musíme provést, aby nastal náhodný jev  $A$ , kde  $P(A) = p$ ,  $0 < p < 1$ . Náhodná veličina  $X$  mající geometrické rozdělení má pravděpodobnostní funkci  $p$ , která je definována vztahem

$$P(X = k) = p(1 - p)^{k-1}, \quad k \in \mathbb{N}.$$

Pro základní číselné charakteristiky platí, že střední hodnota je  $\mu' = \frac{1}{p}$  a rozptyl  $\sigma^2 = \frac{1}{p} \left( \frac{1}{p} - 1 \right)$ , viz literatura [1]. Náhodná veličina  $X$ , která má geometrické rozdělení udává počet neúspěchů před prvním úspěchem.

## Binomické rozdělení

Binomické rozdělení  $Bi(m, p)$  má pravděpodobnostní funkci

$$P(X = x) = \binom{m}{x} p^x (1 - p)^{m-x}, \quad x = 0, 1, \dots, m$$

a střední hodnota je  $\mu' = mp$  a rozptyl  $\sigma^2 = mp(1 - p)$  definice je z [7]. Náhodnou veličinu  $X$ , která má binomické rozdělení  $Bi(m, p)$  si můžeme představit jako udávající počet zdarů v  $m$  pokusech.

## Poissonovo rozdělení

Předpokládejme, že veličina  $X$  nabývá pouze hodnot  $0, 1, \dots$ , a to s pravděpodobnostmi

$$P(X = x) = \frac{\lambda^x}{x!} \exp^{-\lambda}, \quad x = 0, 1, \dots,$$

kde  $\lambda > 0$  je dané číslo. Pak říkáme, že  $X$  má Poissonovo rozdělení  $\text{Po}(\lambda)$  s parametrem  $\lambda$ . Platí, že střední hodnota je  $\mu' = \lambda$  a rozptyl  $\sigma^2 = \lambda$ , viz [7]. Jako příklad Poissonova rozdělení si můžeme uvést počet listů na stromech nebo počet havárií za časovou jednotku.

## 1.2 Statistika

### Náhodný výběr

Posloupnost  $X_1, X_2, \dots, X_n$  nezávislých stejně rozdělených náhodných veličin s distribuční funkcí  $F_0$  se nazývá náhodný výběr z rozdělení  $F_0$  [4]. Výběr pořizujeme proto, abychom se dozvěděli více o souboru dat, se kterými budeme pracovat. Budeme se soustředit na situaci, kdy budeme znát rozdělení souboru až na jeden nebo více parametrů (např. víme, že máme náhodně rozdělené náhodné veličiny, ale neznáme jejich střední hodnotu případně i rozptyl).

### Model a parametr

Distribuční funkci  $F_0$  neznáme. Chceme použít pozorování  $X_1, \dots, X_n$  k tomu, abychom se o ní něco potřebného dozvěděli. O distribuční funkci  $F_0$  však předpokládáme, že patří do nějaké množiny rozdělení  $\mathcal{F}$ , které říkáme model pro data  $X_1, \dots, X_n$ .

To, co se chceme o rozdělení  $F_0$  dozvědět, nazýváme parametr. Vždy se jedná o nějakou konstantu, kterou bychom uměli zjistit, kdybychom znali  $F_0$ . Obecně tedy parametr budeme zapisovat  $\theta_0 \equiv t(F_0)$ , kde  $t$  je nějaký funkcionál. Obvykle je  $\theta_0 \in \mathbb{R}^k$  pro  $k \geq 1$  více o modelech v literatuře [4].

### Parametrický model

Množina  $\mathcal{F}$  je množina všech rozdělení s hustotami tvaru  $f(x; \theta)$  nebo pravděpodobnostními funkcemi  $p(x; \theta)$  pro  $\theta \in \Theta \subseteq \mathbb{R}^k$ , kde  $f(\cdot; \cdot)$  resp.  $p(\cdot; \cdot)$  je známá funkce a  $\theta$  je neznámá konstanta (např. všechna exponenciální, normální, geometrická rozdělení). Tyto modely nazýváme parametrické. Parametry, které chceme odhadovat, jsou funkce složek  $\theta$ . Definice parametrického modelu je z [4], kde je parametrický model uváděn pouze pro rozdělení s hustotami. Tato definice je rozšířena, jak na rozdělení definované pomocí hustoty, tak na rozdělení definované pomocí pravděpodobnostních funkcí.

### Bodový odhad a jeho vlastnosti

Máme data  $X_1, X_2, \dots, X_n$ , model  $\mathcal{F}$  a parametr  $\theta = t(F)$  pro  $F \in \mathcal{F}$ , který chceme v daném modelu odhadnout. Označme  $\mathbf{X} = (X_1, \dots, X_n)^T$  (všechna da-

ta sestavená do jednoho vektoru). Necht'  $F_0 \in \mathcal{F}$  je skutečné rozdělení náhodné veličiny  $X_i$  a  $\theta_0 \equiv t(F_0)$  je skutečná hodnota hledaného parametru. Odhadem parametru  $\theta_0 \equiv t(F_0) \in \mathbb{R}^k$  rozumíme libovolnou měřitelnou funkci dat  $\hat{\theta}_n \equiv \mathbf{T}_n(\mathbf{X}) \equiv \mathbf{T}_n(X_1, \dots, X_n)$  z [4].

Jinými slovy nám tato definice říká, že pro každou novou realizaci výběru obdržíme jiný bodový odhad. Bodový odhad nebývá početně náročný a obvykle ho používáme v případě, je-li rozsah výběrového souboru vzhledem k rozsahu základního souboru dostatečně velký.

Vlastnosti bodového odhadu  $\hat{\theta}$  vypovídají o vhodnosti použité statistiky k odhadu hodnoty parametru  $\theta$ . Dobrý bodový odhad musí splňovat určité vlastnosti: nestrannost (nevychýlenost, nezkleslenost), konzistenci, vydatnost (eficience) a dostatečnost.

### Nestrannost

Odhad  $\hat{\theta}_n \equiv \mathbf{T}_n(\mathbf{X})$  nazveme nestranným odhadem (unbiased estimator) parametru  $\theta_0$ , právě když  $E\hat{\theta}_n = \theta_0$  pro každé  $n$ , viz [4]. Jinak řečeno, bodový odhad parametru  $\theta$  je nestranný, jestliže jeho střední hodnota se rovná tomuto parametru. Nestrannost říká, že odhad je "v průměru" (rozumíme přes všechny možné výběry) přesný.

Slabší formou nestrannosti je asymptotická nestrannost. Řekneme, že odhad je asymptoticky nestranný, pokud  $\lim_{n \rightarrow \infty} E\hat{\theta}_n = \theta_0$ .

### Konzistence

Odhad  $\hat{\theta}_n \equiv \mathbf{T}_n(\mathbf{X})$  nazveme konzistentním odhadem (consistent estimator) parametru  $\theta_0$ , právě když  $\hat{\theta}_n \xrightarrow{P} \theta_0$  pro každé  $n \rightarrow \infty$  [4]. Značkou  $\xrightarrow{P}$  chápeme konvergenci v pravděpodobnosti k náhodné veličině, která je definována následovně:  $X_n \xrightarrow{P} X$  pro  $n \rightarrow \infty$

$$\lim_{n \rightarrow \infty} [P \|X_n - X\| > \varepsilon] = 0 \text{ pro } \forall \varepsilon > 0.$$

Definice konzistence nám říká, že odhad je konzistentní, pokud se s rostoucím rozsahem výběru zpřesňuje. Konzistence je asymptotická vlastnost, která nic neříká o kvalitě odhadu při konečném  $n$ .

Postačující podmínky pro ověření konzistence odhadu  $\hat{\theta}$  definujme následovně. Necht'  $E\hat{\theta}^2 < \infty$  pro každé přirozené  $n$ . Platí-li  $\hat{\theta}$  je nestranný odhad nebo alespoň asymptoticky nestranný odhad parametru  $\theta$  a  $\lim_{n \rightarrow \infty} \text{Var } \hat{\theta} = 0$ . Pak  $\hat{\theta}$  je konzistentním odhadem parametru  $\theta$ . Důkaz tohoto tvrzení je uveden v [1].

### Vydatnost

Vydatný odhad (efficient estimator) je takový odhad  $\hat{\theta}$ , který má nejmenší rozptyl ze všech nestranných odhadů  $\hat{\theta}_i$  parametru  $\theta$ , tedy  $\text{Var } \hat{\theta} \leq \text{Var } \hat{\theta}_i$ , kde  $i = 1, \dots, l$ , kde  $l$  je počet nestranných odhadů parametru  $\theta$ , viz literatura [2].

## Dostatečnost

Odhad je dostatečný, pokud obsahuje veškerou informaci o sledovaném parametru, kterou výběrový soubor poskytuje [2].

Vlastnosti vydatnost a dostatečnost v této práci nebudeme ověřovat u bodových odhadů parametrů. Tyto vlastnosti se ověřují, pokud máme více odhadů a porovnáváme mezi nimi.

## 2. Metody bodového odhadu v parametrických modelech

Tato kapitola je teoretickým úvodem k metodám, kterými odhadujeme bodové odhady. Nejprve si představíme a podrobně popíšeme úlohu, kterou řešíme, pokud odhadujeme bodový odhad. Dále v podkapitolách 2.2.1 a 2.2.2 si sepíšeme postupy obou metod, kterými provádíme bodové odhady. Tato kapitola by měla sloužit k tomu, pokud student nebo řešitel dostane rozdělení, u kterého má odhadnout bodový odhad, tak by měl být schopen spočítat bodový odhad parametrů daného rozdělení oběma metodami.

Text je v této kapitole volně převzat, kde je explicitní citace, tak je uvedena za citovaným odstavcem. Metodologie momentové metody je autorčina interpretace, pouze první odstavec je citován. Podkapitola 2.2.2 je volně převzatá z literatury [4] a [7], citované zde jsou vzorce a základní pojmy metody. Autorčina práce v této kapitole je sumarizace pojmů a vzorců do srozumitelné podoby pro pochopení počítání těchto metod. Další autorčin přínos je rozšíření obou metod i pro diskrétní náhodné veličiny, které se v dané literatuře nevyskytuje.

### 2.1 Bodové odhady parametrů

Na základě hodnot náhodného výběru z rozdělení určitého typu odhadujeme parametry tohoto rozdělení, tak aby co nejlépe odpovídaly hodnotám náhodného výběru. Formulujeme tudíž úlohu, ve které hledáme odhady neznámých parametrů rozdělení.

#### Formulace úlohy

Předpokládáme, že je dán náhodný výběr  $X_1, \dots, X_n$  z rozdělení s hustotou  $f(x, \boldsymbol{\theta})$  nebo pravděpodobnostní funkcí  $p(x, \boldsymbol{\theta})$ , kde  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_m)^T$  jsou parametry rozdělení. Na základě hodnot náhodného výběru odhadujeme parametry rozdělení. Odhad provádíme pomocí vhodně zvolené funkce náhodného výběru. O takové úloze mluvíme jako o bodovém odhadu parametrů.

### 2.2 Metody hledání bodových odhadů

Pro konstrukci bodových odhadů se nejčastěji používají dvě metody, a to metoda maximální věrohodnosti (maximum likelihood method) a momentová metoda (method of moments), jinak nazývaná metoda momentů.

U obou metod předpokládáme, že náhodné veličiny jsou spojité nebo diskrétní, a budeme uvažovat parametrický model, kde máme náhodný výběr  $\mathbf{X} = (X_1, \dots, X_n)$  z rozdělení s hustotou  $f(x; \boldsymbol{\theta})$  či pravděpodobnostní funkcí  $p(x, \boldsymbol{\theta})$ , kde tvar funkce  $f(\cdot; \cdot)$  nebo  $p(\cdot; \cdot)$  je známý a  $\boldsymbol{\theta}$  je neznámý (vektorový) parametr,



jenž leží v parametrickém prostoru  $\Theta \subseteq \mathbb{R}^m$ ,  $m \geq 1$ . Pro spojité náhodné veličiny pracujeme tedy s modelem

$$\mathcal{F} = \{\text{rozdělení s hustotou } f(x; \boldsymbol{\theta}), \boldsymbol{\theta} \in \Theta \subseteq \mathbb{R}^m\},$$

pro diskrétní náhodné veličiny s modelem

$$\mathcal{F} = \{\text{rozdělení s pravděpodobnostní funkcí } p(x; \boldsymbol{\theta}), \boldsymbol{\theta} \in \Theta \subseteq \mathbb{R}^m\}.$$

Při definici modelu jsme vycházeli z [4].

## 2.2.1 Momentová metoda

Metoda je založena na porovnání výběrových momentů s odpovídajícími teoretickými momenty předpokládaného rozdělení pravděpodobnosti. Pro porovnání si lze zvolit jakékoliv momenty. V praxi se ale nejvíce používají, tyto tři první, druhý počáteční moment a druhý centrální moment, které porovnáváme s odpovídajícími výběrovými momenty. Využíváme faktu, že máme k dispozici konzistentní odhady momentů, což jsou výběrové momenty, a že momenty rozdělení  $X_i$  obvykle umíme vyjádřit jako funkce neznámých parametrů [4].

### Metodologie

Mějme náhodný výběr  $\mathbf{X} = (X_1, \dots, X_n)$  o rozsahu  $n$  z rozdělení ze třídy hustot  $\{f(x; \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta \subseteq \mathbb{R}^m\}$ , či třídy pravděpodobnostních funkcí  $\{p(x; \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta \subseteq \mathbb{R}^m\}$  a hledáme odhad parametru  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_m)^T \in \Theta \subseteq \mathbb{R}^m$ .

Pro odhad jednorozměrného parametru stačí předpokládat, že existuje prvních  $m \geq 1$  teoretických počátečních momentů, které jsou pro spojitou náhodnou proměnnou definovány

$$\mu'_k = E(X^k), \quad k = 1, \dots, m.$$

Počáteční moment prvního řádu  $\mu'_1$  je roven střední hodnotě rozdělení  $EX$ . Pokud odhadujeme parametry porovnáním centrálních momentů, musíme přidat další předpoklad a to existenci prvních  $m \geq 1$  teoretických centrálních momentů. Centrální moment  $k$ -tého řádu je definován

$$\mu_k = E(X - EX)^k, \quad k = 1, \dots, m.$$

Teoretický centrální moment druhého řádu je roven rozptylu rozdělení  $\text{Var}X$ . Je zřejmé, že momenty jsou funkcemi  $\boldsymbol{\theta}$ , píšeme proto  $\mu'_k = \mu'_k(\boldsymbol{\theta})$  a  $\mu_k = \mu_k(\boldsymbol{\theta})$ .

Pro porovnání s teoretickými momenty potřebujeme výběrové momenty. Označme  $M'_k$   $k$ -tý počáteční výběrový moment

$$M'_k = \frac{1}{n} \sum_{i=1}^n (X_i)^k, \quad k = 1, \dots, m.$$

První počáteční výběrový moment  $M'_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n$  nazýváme výběrový průměr někdy též aritmetický průměr. Výběrový centrální moment  $M_k$   $k$ -tého řádu je definován

$$M_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^k, \quad k = 1, \dots, m.$$

Druhý výběrový centrální moment  $M_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  je označován jako empirický rozptyl. Momentovou metodou chceme odhadnout parametr  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_m)^T$  tak, že budeme řešit soustavu rovnic

$$\begin{aligned} M'_k &= \mu'_k(\theta_1, \dots, \theta_m), \quad k = 1, \dots, m, \\ M_k &= \mu_k(\theta_1, \dots, \theta_m), \quad k = 1, \dots, m. \end{aligned} \quad (2.1)$$

Řešením soustavy  $(\hat{\theta}_1, \dots, \hat{\theta}_k)^T$  nazveme momentový odhad parametru  $\boldsymbol{\theta}$ , zřejmě  $\hat{\theta}_i = \hat{\theta}_i(M'_1, \dots, M'_m)$ ,  $i = 1, \dots, m$ . K odhadu je třeba získat tolik rovnic, kolik odhadujeme neznámých parametrů rozdělení. Nestačí-li  $m$  rovnic k jednoznačnému řešení soustavy (2.1), přidáme další rovnice pro  $k = m + 1, m + 2, \dots$

Výhodou momentové metody je její jednoduchost. Nevýhodou je často nízká eficeience (velký rozptyl) výsledných odhadů. Tyto odhady se někdy používají např. jako počáteční aproximace pro jiné odhadovací metody.

## 2.2.2 Metoda maximální věrohodnosti

Metoda maximální věrohodnosti je obecná metoda pro konstrukci bodových odhadů parametrů. Používáme ji pro odhad parametrů, které určují rozdělení, např. střední hodnota a rozptyl normálního rozdělení, pravděpodobnost nastoupení jevu alternativního rozdělení apod. Princip metody maximální věrohodnosti spočívá v tom, že za odhad neznámého parametru vezmeme tu jeho hodnotu, ve které tzv. věrohodnostní funkce nabývá svého maxima, viz literatura [6]. Vzorce pro metodu maximální věrohodnosti a postup výpočtu jsou volně interpretované z [4] a [7], kde je daná metoda ukázána pouze pro spojité náhodné veličiny.

### Metodologie

Předpokládejme, že náhodný výběr byl pořízen z rozdělení, které je charakterizováno hustotou  $f(x; \boldsymbol{\theta})$  nebo pravděpodobnostní funkcí  $p(x; \boldsymbol{\theta})$ . Sdružená hustota náhodného výběru  $\mathbf{X} = (X_1, \dots, X_n)$  je vzhledem k předpokládané nezávislosti dána předpisem

$$f(x_1, x_2, \dots, x_n; \boldsymbol{\theta}) = f(\mathbf{x}; \boldsymbol{\theta}) = \prod_{i=1}^n f(x_i; \boldsymbol{\theta})$$

a sdružená pravděpodobnostní funkce je

$$p(x_1, x_2, \dots, x_n; \boldsymbol{\theta}) = p(\mathbf{x}; \boldsymbol{\theta}) = \prod_{i=1}^n p(x_i; \boldsymbol{\theta}),$$

neboť složky náhodného výběru jsou nezávislé náhodné veličiny.

Pokud vyšetřujeme sdruženou hustotu  $f(\mathbf{x}; \boldsymbol{\theta})$  jako funkci  $\boldsymbol{\theta}$  pro pevné  $\mathbf{x}$ , nazýváme ji věrohodnostní funkcí a značíme ji symbolem  $L(\boldsymbol{\theta})$ , tedy místo  $x$  píšeme ve funkci  $X$

$$L(\boldsymbol{\theta}) = \prod_{i=1}^n f(X_i; \boldsymbol{\theta}).$$

Analogicky v případě diskrétního rozdělení náhodného výběru charakterizovaného sdruženou pravděpodobnostní funkcí  $p(\mathbf{x}; \boldsymbol{\theta})$ , definujeme věrohodnostní funkci jako

$$L(\boldsymbol{\theta}) = \prod_{i=1}^n p(X_i; \boldsymbol{\theta}).$$

Zpravidla je technicky výhodnější a při praktických výpočtech se místo věrohodnostní funkce pracuje s přirozeným logaritmem věrohodnostní funkce. Logaritmická věrohodnostní funkce je

$$l(\boldsymbol{\theta}) = \ln L(\boldsymbol{\theta}) = \sum_{i=1}^n \ln f(X_i; \boldsymbol{\theta}),$$

$$l(\boldsymbol{\theta}) = \ln L(\boldsymbol{\theta}) = \sum_{i=1}^n \ln p(X_i; \boldsymbol{\theta}),$$

přičemž tam, kde je  $f(x) = 0$  nebo  $p(x) = 0$ , definujeme  $l(\boldsymbol{\theta}) = -\infty$ .

Věrohodnostní funkce nebo logaritmická věrohodnostní funkce je funkcí neznámého parametru  $\boldsymbol{\theta}$ , proto je nyní naším úkolem najít  $\hat{\boldsymbol{\theta}}$  tak, aby se maximalizovala hodnota věrohodnostní funkce. Vyjádřeno vzorcem dostáváme

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta} \in \Theta} L(\boldsymbol{\theta}) = \arg \max_{\boldsymbol{\theta} \in \Theta} l(\boldsymbol{\theta}).$$

Tento odhad nazýváme maximálně věrohodný odhad parametru  $\boldsymbol{\theta}$  (maximum likelihood estimator). Tedy maximálně věrohodný odhad  $\hat{\boldsymbol{\theta}}$  parametru  $\boldsymbol{\theta}$  je takový bod z  $\Theta$ , který maximalizuje (přes všechny  $\boldsymbol{\theta} \in \Theta$ ) sdruženou hustotu či sdruženou pravděpodobnostní funkci spočítanou v pozorovaných hodnotách  $X_1, \dots, X_n$ .

Funkci  $L(\boldsymbol{\theta})$  s proměnnou  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_m)^T$  se snažíme maximalizovat, a proto ji budeme postupně derivovat podle jednotlivých složek, jimiž rozumíme  $\theta_j$ , kde  $j = 1, \dots, m$ . Tyto výrazy upravíme a položíme rovny nule a řešíme vzniklé rovnice. Tento postup můžeme vyjádřit matematicky a označit ho jako systémem věrohodnostních rovnic, který je pro spojité i diskrétní náhodné veličiny

$$\frac{\partial L(\boldsymbol{\theta})}{\partial \theta_j} = 0, \quad j = 1, \dots, m.$$

Řešení této soustavy se obvykle hledá numericky. Řešení však nemusí existovat a ne každé řešení je maximálně věrohodný odhad.

## Odhad jednorozměrného parametru

Pro lepší pochopení metody maximální věrohodnosti si ukážeme její princip na jednorozměrném parametru  $\theta$ . Funkce  $L(\theta)$  proměnné  $\theta$  se při pevném  $\mathbf{x}$  nazývá věrohodnostní funkce. Pro odhad parametru  $\theta$  řešíme rovnici

$$\frac{\partial L(\theta)}{\partial \theta} = 0.$$

Poslední podkapitola nám zhruba říká, že klasický postup hledání maxima funkce  $L(\theta)$  pomocí derivace vede s pravděpodobností blížící se jedné k maximálně věrohodnému odhadu [1].

# 3. Bodové odhady pro různá spojitá rozdělení

V této části bakalářské práce se zaměříme na některá spojitá pravděpodobnostní rozdělení a odhadneme jejich parametry. Nejprve momentovou metodou a následně metodou maximální věrohodnosti, pokud tak lze učinit. Přitom budeme postupovat podle metodologie z druhé kapitoly této práce. Metody si nejdříve ukážeme na normálním rozdělení, u kterého lze použít k odhadu jeho parametrů obě metody. Ověříme nestrannost a konzistenci u odhadů. Rozepíšeme podrobně postup výpočtu odhadů i postup ověřování vlastností těchto odhadů. U dalších rozdělení budeme výpočet zkracovat a vlastnosti budeme zapisovat, postup ověření těchto vlastností je nad rámec této práce a většinou se u něj používají složité tvrzení. Všechny odvození a výpočty jsou prací autorky. Nečíslujeme všechny vzorce, pouze ty na, které se v práci odvoláváme, činíme tak z důvodu větší přehlednosti.

## 3.1 Normální rozdělení

### 3.1.1 Momentová metoda

Je dán náhodný výběr  $X_1, \dots, X_n$  pocházející z normálního rozdělení. Hustota normálního rozdělení je tvaru

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[ -\frac{(x - \mu)^2}{2\sigma^2} \right], \text{ kde } \mu \in \mathbb{R}, \sigma^2 > 0.$$

Momentovou metodou odhadneme parametry  $\mu$  a  $\sigma^2$ . U tohoto rozdělení víme, že parametr  $\mu$  je střední hodnota, tj. počáteční (teoretický) moment prvního řádu a parametr  $\sigma^2$  značí rozptyl, tedy teoretický centrální moment druhého řádu. Vyjádřeno matematicky počáteční moment prvního řádu normálního rozdělení je

$$\mu'_1(\mu, \sigma^2) = \mu$$

a centrální moment druhého řádu normálního rozdělení je

$$\mu_2(\mu, \sigma^2) = \sigma^2$$

Z druhé kapitoly víme, že první počáteční výběrový moment

$$M'_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n$$

a druhý centrální výběrový moment

$$M_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

Porovnáním odpovídajících momentů, dostáváme soustavu rovnic

$$\begin{aligned} M_1' &= \mu_1'(\mu, \sigma^2) \\ M_2 &= \mu_2(\mu, \sigma^2). \end{aligned}$$

Dosadíme za momenty a řešíme soustavu rovnic

$$\begin{aligned} \bar{X}_n &= \mu, \\ \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 &= \sigma^2. \end{aligned}$$

Odhad parametru  $\theta = (\mu, \sigma^2)$  momentovou metodou je

$$\begin{aligned} \hat{\mu} &= \bar{X}_n, \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2. \end{aligned}$$

### 3.1.2 Metoda maximální věrohodnosti

Uvažujme opět náhodný výběr o rozsahu  $n$ , tedy máme nezávislé, stejně rozdělené náhodné veličiny pocházející z normálního rozdělení  $N(\mu, \sigma^2)$ , v němž budeme odhadovat oba neznámé parametry  $\mu$  a  $\sigma^2$ . Hustota normálního rozdělení je

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right], \text{ kde } \mu \in \mathbb{R}, \sigma^2 > 0.$$

Sdružená hustota je ve tvaru

$$f(x_1, x_2, \dots, x_n; \mu, \sigma^2) = \prod_{i=1}^n f(x_i; \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x_i-\mu)^2}{2\sigma^2}\right].$$

Věrohodnostní funkce je definována

$$L(\mu, \sigma^2) = \prod_{i=1}^n f(X_i, \mu, \sigma^2),$$

po dosazení

$$L(\mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(X_i-\mu)^2}{2\sigma^2}\right].$$

Logaritmická věrohodnostní funkce je definována jako

$$l(\mu, \sigma^2) = \ln L(\mu, \sigma^2),$$

po dosazení dostáváme

$$l(\mu, \sigma^2) = \ln \left( \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(X_i-\mu)^2}{2\sigma^2}\right] \right).$$

Z vlastností logaritmů víme, že logaritmus součinu je součet logaritmů jednotlivých činitelů, upravíme si logaritmickou věrohodnostní funkci na co nejjednodušší tvar tedy

$$\begin{aligned} l(\mu, \sigma^2) &= \sum_{i=1}^n \left( \ln(2\pi\sigma^2)^{-\frac{1}{2}} - \frac{(X_i - \mu)^2}{2\sigma^2} \right) = \\ &= -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu)^2 = \\ &= -\frac{n}{2} \ln \sigma^2 - n \ln \sqrt{2\pi} - \frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu)^2. \end{aligned}$$

Tuto věrohodnostní funkci s proměnnými  $\mu$  a  $\sigma^2$  chceme maximalizovat, proto ji budeme derivovat nejprve podle  $\mu$  a poté podle proměnné  $\sigma^2$ . Je potřeba si uvědomit, že druhá partiální derivace je podle  $\sigma^2$ . Derivováním dostáváme

$$\begin{aligned} \frac{\partial l(\mu, \sigma^2)}{\partial \mu} &= -\frac{1}{2\sigma^2} \sum_{i=1}^n (-2)(X_i - \mu) = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu) \\ \frac{\partial l(\mu, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (X_i - \mu)^2. \end{aligned}$$

Obě upravené derivace si položíme rovny nule a vyjádříme si z nich odhady parametrů  $\mu$  a  $\sigma^2$ . Z první rovnice úpravami získáme odhad střední hodnoty  $\mu$  normálního rozdělení

$$\begin{aligned} \frac{1}{\hat{\sigma}^2} \sum_{i=1}^n (X_i - \hat{\mu}) &= 0 \\ \sum_{i=1}^n X_i - n\hat{\mu} &= 0 \\ \hat{\mu} &= \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n. \end{aligned} \tag{3.1}$$

Z druhé rovnice úpravami a dosazením odhadu (3.1) získáme odhad rozptylu  $\sigma^2$  normálního rozdělení

$$\begin{aligned} -\frac{n}{2} \frac{1}{\hat{\sigma}^2} + \frac{1}{2\hat{\sigma}^4} \sum_{i=1}^n (X_i - \hat{\mu})^2 &= 0 \\ \sum_{i=1}^n (X_i - \hat{\mu})^2 &= \frac{n}{2\hat{\sigma}^2} \frac{2\hat{\sigma}^4}{1} \\ \sum_{i=1}^n (X_i - \hat{\mu})^2 &= n\hat{\sigma}^2 \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2. \end{aligned}$$

Metodou maximální věrohodnosti dostáváme odhady parametrů  $\mu$  a  $\sigma^2$ .

$$\begin{aligned}\hat{\mu} &= \bar{X}_n, \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2.\end{aligned}$$

Oběma metodami jsme dostali stejné odhady. Nyní se zaměříme na vlastnosti těchto odhadů.

### 3.1.3 Vlastnosti odhadů

Z první kapitoly víme, že bodové odhady mají své vlastnosti. Jak již jsme zmínili, v této práci budeme věnovat pozornost zejména ověřování nestrannosti a konzistenci. Tyto vlastnosti si nejdříve ověříme u odhadu střední hodnoty, který

je roven  $\hat{\mu} = \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  a nazývá se výběrový průměr.

#### Nestrannost

Při zjišťování této vlastnosti, spočítáme střední hodnotu odhadu  $\hat{\mu}$ , a tím ověříme, zda je odhad nestranný či nikoliv. Využijeme přitom vlastnost střední hodnoty  $E(a + bX) = a + bEX$ ,  $\forall a, b \in \mathbb{R}$ .

$$E\bar{X}_n = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} n\mu = \mu,$$

platí, že střední hodnota odhadu se rovná střední hodnotě rozdělení, a tedy výběrový průměr je nestranným odhadem střední hodnoty.

#### Konzistence

Tato vlastnost se ověřuje pomocí zákona velkých čísel, a to nejlépe pomocí Chinčínova slabého zákona velkých čísel, který definujeme v následující větě. Nechť máme  $X_1, \dots, X_n$  posloupnost nezávislých stejně rozdělených náhodných veličin s  $EX_i = c < \infty$ , kde  $c$  je konstanta, potom  $\bar{X}_n \xrightarrow{P} c$  [4]. Důkaz tohoto tvrzení lze nalézt [1].

V našem případě máme náhodný výběr z normálního rozdělení, což zaručuje stejně rozdělené náhodné veličiny, jehož prvky mají střední hodnotu rovno nějaké konstantě  $\mu$ , tím máme splněny předpoklady Chinčínova slabého zákona velkých čísel. Tedy výběrový průměr je konzistentním odhadem střední hodnoty.

#### Dostatečnost a vydatnost

Výběrový průměr je dostatečným i vydatným odhadem střední hodnoty, viz literatura [2].



Následně určíme vlastnosti empirického odhadu rozptylu, který nám vyšel

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

### Nestrannost

Výpočet provádíme za pomoci vlastností střední hodnoty, které jsme využili při ověřování nestrannosti výběrového průměru a dále faktu, že se jedná o nezávislé náhodné veličiny.

$$\begin{aligned} E\hat{\sigma}^2 &= E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right) = E\left(\frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i\bar{X}_n + \bar{X}_n^2)\right) = \\ &= E\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - 2\frac{1}{n} \sum_{i=1}^n X_i\bar{X}_n + \frac{1}{n} \sum_{i=1}^n \bar{X}_n^2\right) = \\ &= E\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X}_n^2 + \frac{n}{n}\bar{X}_n^2\right) = \\ &= E\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}_n^2\right) = E\frac{1}{n} \sum_{i=1}^n X_i^2 - E\bar{X}_n^2 = \\ &= EX_i^2 - \frac{1}{n^2} E\left(\sum_{i=1}^n X_i\right)^2 = EX_i^2 - \frac{1}{n^2} E\left(\sum_{i=1}^n \sum_{j=1}^n X_i X_j\right) \stackrel{\text{nezávislost}}{=} \\ &= EX_i^2 - \frac{1}{n^2} \left(\sum_{i=1}^n EX_i^2 + n(n-1)\mu^2\right) = \\ &= EX_i^2 - \frac{1}{n} EX_i^2 - \frac{n-1}{n} \mu^2 = \\ &= \frac{n-1}{n} EX_i^2 - \frac{n-1}{n} \mu^2 = \frac{n-1}{n} \sigma^2. \end{aligned}$$

Vidíme, že  $E\hat{\sigma}^2 \neq \sigma^2$ , tedy empirický výběrový rozptyl není nestranným odhadem rozptylu. Další způsob ověření této vlastnosti je za pomoci triku (přičtení a odečtení  $\mu$ ).

$$\begin{aligned} E\hat{\sigma}^2 &= E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right) = \\ &= E\left(\frac{1}{n} \left(\sum_{i=1}^n (X_i - \mu)^2 - n(\bar{X}_n - \mu)^2\right)\right) = \\ &= \frac{1}{n} \sum_{i=1}^n E(X_i - \mu)^2 - \frac{n}{n} E(\bar{X}_n - \mu)^2 \stackrel{\text{nezávislost}}{=} \\ &= \frac{1}{n} n\sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2, \end{aligned}$$

i tímto způsobem výpočtu jsme zjistili, že empirický výběrový rozptyl není nestranným odhadem parametru  $\sigma^2$ .

Ověříme ještě asymptotickou nestrannost odhadu  $\hat{\sigma}^2$

$$\lim_{n \rightarrow \infty} E\hat{\sigma}^2 = \lim_{n \rightarrow \infty} \frac{n-1}{n} \sigma^2 = \sigma^2.$$

Docházíme k závěru, že odhad rozptylu  $\sigma^2$  je asymptoticky nestranný.

## Konzistence

Jednoduchých výpočtem ověříme, že empirický odhad rozptylu je konzistentním odhadem

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}_n^2 \xrightarrow{P} \sigma^2.$$

## 3.2 Gama rozdělení

### 3.2.1 Momentová metoda

Je dán výběr  $X_1, \dots, X_n$  pocházející z gama rozdělení, jak již víme z první kapitoly gama rozdělení  $\text{Ga}(a, p)$ , které má parametry  $a > 0$ ,  $p > 0$ , má hustotu danou vzorcem

$$f(x) = \frac{a^p}{\Gamma(p)} e^{-ax} x^{p-1}, \quad x > 0, \quad (3.2)$$

střední hodnota je  $\mu'_1 = \frac{p}{a}$  a rozptyl  $\sigma^2 = \frac{p}{a^2}$  z [1].

Výpočet momentových odhadů provedeme v následujících krocích, kde nebude porovnávat druhý centrální moment s empirickým rozptylem, ale druhý centrální moment s výběrovým rozptylem  $S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ , nazýván vypočtený rozptyl. Činíme z důvodu jednodušších výpočtů a lepších výsledků. Tedy pro první počáteční moment a druhý centrální moment gama rozdělení platí

$$\begin{aligned} \mu'_1(a, p) &= \frac{p}{a}, \\ \mu_2(a, p) &= \frac{p}{a^2}. \end{aligned}$$

První počáteční výběrový moment a druhý centrální výběrový moment jsou tvaru

$$\begin{aligned} M'_1 &= \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n, \\ M_2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = S_n^2. \end{aligned} \quad (3.3)$$

Řešíme soustavu rovnic

$$\begin{aligned} \bar{X}_n &= \frac{p}{a}, \\ S_n^2 &= \frac{p}{a^2}. \end{aligned}$$

Nejdříve si spočítáme odhad parametru  $a$

$$\frac{\bar{X}_n}{S_n^2} = \frac{\hat{p}}{\hat{a}^2} = \hat{a},$$

následně odhad parametru  $p$

$$\hat{p} = \bar{X}_n \hat{a} = \bar{X}_n \frac{\bar{X}_n}{S_n^2} = \frac{\bar{X}_n^2}{S_n^2}.$$

Metodou momentů dostáváme pro parametr  $\theta = (a, p)$  odhady

$$\begin{aligned}\hat{a} &= \frac{\bar{X}_n}{S_n^2}, \\ \hat{p} &= \frac{\bar{X}_n^2}{S_n^2}.\end{aligned}$$

### 3.2.2 Metoda maximální věrohodnosti

Odhadneme parametry  $a$  a  $p$  gama rozdělení metodou maximální věrohodnosti. Hustota gama rozdělení je již uvedena v (3.2). Rovnou píšeme sdruženou hustotu

$$f(x_1, x_2, \dots, x_n; a, p) = \prod_{i=1}^n \frac{a^p}{\Gamma(p)} e^{-ax_i} x_i^{p-1}.$$

Maximálně věrohodné odhady parametrů  $a$  a  $p$  dostaneme pomocí věrohodnostní funkce

$$L(a, p) = \prod_{i=1}^n \frac{a^p}{\Gamma(p)} e^{-aX_i} X_i^{p-1}.$$

Pro její logaritmus dostaneme vyjádření

$$\begin{aligned}l(a, p) &= \ln \left( \prod_{i=1}^n \frac{a^p}{\Gamma(p)} e^{-aX_i} X_i^{p-1} \right) = \\ &= \sum_{i=1}^n (p \ln a - \ln \Gamma(p) + (p-1) \ln X_i - aX_i).\end{aligned}$$

Derivací dostáváme

$$\begin{aligned}\frac{\partial l(a, p)}{\partial a} &= \sum_{i=1}^n \left( \frac{p}{a} - X_i \right) = n \frac{p}{a} - \sum_{i=1}^n X_i \\ \frac{\partial l(a, p)}{\partial p} &= \sum_{i=1}^n \left( \ln a - \frac{\Gamma'(p)}{\Gamma(p)} + \ln X_i \right) \\ &= n (\ln a - \psi(p)) + \sum_{i=1}^n \ln X_i,\end{aligned}$$

kde  $\psi(p)$  nazýváme digama funkcí. První derivace položíme rovnu nule a vyjádříme si z ní odhad parametru  $a$

$$\begin{aligned} n \frac{\hat{p}}{\hat{a}} - \sum_{i=1}^n X_i &= 0 \\ \frac{\hat{p}}{\hat{a}} &= \frac{1}{n} \sum_{i=1}^n X_i \\ \hat{a} &= \frac{\hat{p}}{\bar{X}_n}. \end{aligned} \quad (3.4)$$

Derivaci podle parametru  $p$  taktéž položíme rovnu nule a upravíme si ji

$$\begin{aligned} n (\ln \hat{a} - \psi(\hat{p})) + \sum_{i=1}^n \ln X_i &= 0 \\ -\ln \hat{a} + \psi(\hat{p}) &= \frac{1}{n} \sum_{i=1}^n \ln X_i \end{aligned} \quad (3.5)$$

Nyní si rovnici (3.4) zlogaritmujeme. Dostáváme tak

$$-\ln \hat{a} = \ln \bar{X}_n - \ln \hat{p} \quad (3.6)$$

Rovnost (3.6) dosadíme do (3.5), dostáváme

$$\ln \bar{X}_n - \ln \hat{p} + \psi(\hat{p}) = \frac{1}{n} \sum_{i=1}^n \ln X_i.$$

Na jednu stranu si dáme prvky, které obsahují odhadnutý parametr  $\hat{p}$  a rovnost si upravíme

$$\begin{aligned} \ln \hat{p} - \psi(\hat{p}) &= \ln \bar{X}_n - \frac{1}{n} \sum_{i=1}^n \ln X_i = \\ &= \ln \bar{X}_n - \frac{1}{n} \ln \left( \prod_{i=1}^n X_i \right) = \\ &= \ln \frac{\bar{X}_n}{\sqrt[n]{\prod_{i=1}^n X_i}}. \end{aligned}$$

Pokud bychom chtěli vědět přesnou hodnotu odhadu  $\hat{p}$ , tak bychom využili nějaký program, který by odhad dopočítal numericky.

### Vlastnosti odhadů gama rozdělení

Každou metodou nám vyšly jiné odhady. U metody maximální věrohodnosti vyšly odhady, které se musí softwarem dopočítat, proto ověříme, jaké vlastnosti mají odhady odhadnuté pomocí metody momentů. Ověření nestrannosti odhadu  $\hat{a}$  i odhadu  $\hat{p}$  je velice rozsáhlé a je nad rámec této práce. Výpočet se stává ze složitých výpočtů a lze se k němu pomocí [1] dopracovat. Napíšeme tedy tyto vlastnosti bez ověření s odkazem na literaturu.

## Nestrannost

Odhad parametru  $a$

$$\hat{a} = \frac{\bar{X}_n}{S_n^2}$$

je nestranným odhadem parametru  $a$  [1].

## Konzistence

Z vlastností výběrového průměru, výběrového rozptylu a se splněním podmínek zákona velkých čísel dostáváme  $\hat{a} \xrightarrow{P} a$ , jedná se o konzistentní odhad.

## Nestrannost

Střední hodnota odhadu

$$\hat{p} = \frac{\bar{X}_n^2}{S_n^2}$$

se rovná

$$E\hat{p} = \frac{1 + np}{n},$$

čili odhad  $\hat{p}$  není nestranný [1]. Ověříme tedy asymptotickou nestrannost

$$\lim_{n \rightarrow \infty} E\hat{p} = \lim_{n \rightarrow \infty} \frac{1 + np}{n} = p.$$

Tedy odhad parametru  $p$  metodou momentů je asymptoticky nestranný.

## Konzistence

Platí  $\hat{p} \xrightarrow{P} p$ , a tedy tento odhad je konzistentním odhadem parametru  $p$ .

## 3.3 Logaritmicko-normální rozdělení

### Momentová metoda

Logaritmicko-normální rozdělení je příkladem, kdy se nepoužívá k výpočtu parametrů momentová metoda. Toto rozdělení nemá omezené momenty, a tedy není zaručen jednoznačně vzájemný vztah mezi posloupností momentů a hustotou rozdělení. Přesto vypočítáme tyto odhady i pomocí metody momentů, kde porovnáme teoretické a výběrové momenty logaritmicko-normálního rozdělení. Dostaneme vzorce pro odhady těchto parametrů, ale bude se jednat pouze o formální výpočet rovnic, jejichž řešení nemusí odpovídat skutečnosti.

Logaritmicko-normální rozdělení  $LN(\mu, \sigma^2)$  se dvěma parametry  $\mu \in \mathbb{R}$  a  $\sigma^2 > 0$ , které má náhodná veličina  $X$  jejíž transformace  $\ln X$  má normální rozdělení  $N(\mu, \sigma^2)$ . Pro její hustotu dostaneme vyjádření ve tvaru

$$f(x) = \frac{1}{\sqrt{2\pi\sigma x}} \exp\left[-\frac{(\ln x - \mu)^2}{2\sigma^2}\right], \text{ pro } x > 0.$$

Počáteční moment prvního řádu a centrální moment druhého řádu tohoto rozdělení je

$$\begin{aligned}\mu'_1(\mu, \sigma^2) &= \exp\left[\mu + \frac{\sigma^2}{2}\right], \\ \mu_2(\mu, \sigma^2) &= (\exp[\sigma^2] - 1) \exp[2\mu + \sigma^2].\end{aligned}$$

Výběrový průměr a empirický rozptyl jsou

$$\begin{aligned}M'_1 &= \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n, \\ M_2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2.\end{aligned}$$

Dostáváme na porovnáním rovnice, ve kterých pro zjednodušení a zkrácení vzorců nebudeme vyjadřovat hodnoty  $M'_1$  a  $M_2$

$$\begin{aligned}\bar{X}_n &= \exp\left[\mu + \frac{\sigma^2}{2}\right] = M'_1, \\ \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 &= (\exp[\sigma^2] - 1) \exp[2\mu + \sigma^2] = M_2.\end{aligned}\quad (3.7)$$

První rovnici zlogaritmuji a vyjádřím si z ní  $\mu$

$$\begin{aligned}\ln M'_1 &= \mu + \frac{\sigma^2}{2} \\ \mu &= \ln M'_1 - \frac{\sigma^2}{2}.\end{aligned}\quad (3.8)$$

Druhou rovnici ze soustavy (3.7) si také zlogaritmuji a dosadím za  $2\mu + \sigma^2$  výraz  $2 \ln M'_1$  dostáváme tak

$$\begin{aligned}\ln M_2 &= \ln(\exp[\sigma^2] - 1) + 2\mu + \sigma^2 \\ \ln M_2 &= \ln(\exp[\sigma^2] - 1) + 2 \ln M'_1\end{aligned}\quad (3.9)$$

postupně si z (3.9) vyjádřím  $\sigma^2$

$$\begin{aligned}\exp[\ln M_2] \exp[-2 \ln M'_1] &= \exp[\sigma^2] - 1 \\ \frac{M_2}{(M'_1)^2} + 1 &= \exp[\sigma^2] \\ \sigma^2 &= \ln\left(\frac{M_2}{(M'_1)^2} + 1\right)\end{aligned}\quad (3.10)$$

Pro vyjádření odhadu parametru  $\mu$  dosadíme (3.10) do první zlogaritmované rovnice (3.8), čili dostáváme

$$\begin{aligned}\ln M'_1 &= \mu \frac{1}{2} \ln\left(\frac{M_2}{(M'_1)^2} + 1\right) \\ \mu &= \ln M'_1 - \frac{1}{2} \ln\left(\frac{M_2}{(M'_1)^2} + 1\right)\end{aligned}$$

Pro náhodný výběr o rozsahu  $n$ , jehož náhodné veličiny mají logaritmicke-normální rozdělení, dostáváme metodou momentů odhady pro jeho parametry

$$\hat{\mu} = \ln(M'_1) - \frac{1}{2} \ln\left(1 + \frac{M_2}{(M'_1)^2}\right),$$

$$\hat{\sigma}^2 = \ln\left(1 + \frac{M_2}{M'_1}\right).$$

### Metoda maximální věrohodnosti

Nyní máme za úkol určit odhad parametrů náhodné veličiny  $X$ , která má logaritmicke-normální rozdělení s neznámými parametry  $\mu \in \mathbb{R}$  a  $\sigma^2 > 0$ , pomocí metody maximální věrohodnosti. Rovnou napíšeme sdruženou hustotu

$$f(x_1, x_2, \dots, x_n; \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma}x_i} \exp\left[-\frac{(\ln x_i - \mu)^2}{2\sigma^2}\right].$$

Věrohodnostní funkce

$$L(\mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma}X_i} \exp\left[-\frac{(\ln X_i - \mu)^2}{2\sigma^2}\right].$$

Dostáváme se k logaritmicke věrohodnostní funkci, kterou máme definovanou  $l(\mu, \sigma^2) = \ln L(\mu, \sigma^2)$

$$l(\mu, \sigma^2) = \ln\left(\prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma}X_i} \exp\left[-\frac{(\ln X_i - \mu)^2}{2\sigma^2}\right]\right),$$

postupně upravujeme

$$\begin{aligned} l(\mu, \sigma^2) &= \sum_{i=1}^n \left( \ln \frac{1}{\sqrt{2\pi\sigma}X_i} + \ln \left( \exp \left[ \frac{(\ln X_i - \mu)^2}{2\sigma^2} \right] \right) \right) = \\ &= \sum_{i=1}^n \left( -\ln \sqrt{2\pi} - \ln \sigma - \ln X_i - \frac{(\ln X_i - \mu)^2}{2\sigma^2} \right) = \\ &= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \sum_{i=1}^n \ln X_i - \frac{1}{2\sigma^2} \sum_{i=1}^n (\ln X_i - \mu)^2. \end{aligned}$$

Soustavu věrohodnostních rovnic derivujeme podle parametrů  $\mu$  a  $\sigma^2$

$$\begin{aligned} \frac{\partial l(\mu, \sigma^2)}{\partial \mu} &= -\frac{1}{2\sigma^2} \sum_{i=1}^n 2(\ln X_i - \mu)(-1) = \frac{1}{\sigma^2} \sum_{i=1}^n (\ln X_i - \mu) \\ \frac{\partial l(\mu, \sigma^2)}{\partial \sigma^2} &= -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (\ln X_i - \mu)^2. \end{aligned}$$

Derivace položíme rovno nule a vyjádříme si z nich odhady parametrů  $\mu$  a  $\sigma^2$

$$\begin{aligned}\frac{1}{\hat{\sigma}^2} \sum_{i=1}^n (\ln X_i - \hat{\mu}) &= 0 \\ \sum_{i=1}^n \ln X_i - n\hat{\mu} &= 0 \\ \hat{\mu} &= \frac{1}{n} \sum_{i=1}^n \ln X_i\end{aligned}$$

a pro odhad  $\sigma^2$  dostáváme

$$\begin{aligned}-\frac{n}{2\hat{\sigma}^2} + \frac{1}{2\hat{\sigma}^4} \sum_{i=1}^n (\ln X_i - \hat{\mu})^2 &= 0 \\ \sum_{i=1}^n (\ln X_i - \hat{\mu})^2 &= \frac{n}{2\hat{\sigma}^2} \frac{2\hat{\sigma}^4}{1} \\ \sum_{i=1}^n (\ln X_i - \hat{\mu})^2 &= n\hat{\sigma}^2 \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (\ln X_i - \hat{\mu})^2.\end{aligned}$$

Metodou maximální věrohodnosti jsme dostali tyto odhady

$$\begin{aligned}\hat{\mu} &= \frac{1}{n} \sum_{i=1}^n \ln X_i, \\ \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (\ln X_i - \hat{\mu})^2.\end{aligned}$$

### Vlastnosti odhadů vypočítané metodou maximální věrohodnosti

Ověříme jaké vlastnosti má odhad  $\hat{\mu}$  spočtený metodou maximální věrohodnosti.

#### Nestrannost

$$E(\hat{\mu}) = E\left(\frac{1}{n} \sum_{i=1}^n \ln X_i\right) = \frac{1}{n} \sum_{i=1}^n E(\ln X_i) = \frac{1}{n} n\mu = \mu,$$

tedy odhad  $\hat{\mu}$  je nestranným odhadem parametru  $\mu$ .



## Konzistence

Tuto vlastnost ověřujeme za pomoci Chinčinova slabého zákona velkých čísel. Jeho předpoklady máme splněny, jelikož máme náhodný výběr z rozdělení, které má střední hodnotu rovnou nějaké konstantě a tedy odhad  $\hat{\mu}$  je konzistentním odhadem parametru  $\mu$ .

## 3.4 Exponenciální rozdělení

### 3.4.1 Momentová metoda

Exponenciální rozdělení  $\text{Ex}(\lambda)$ , kde  $\lambda > 0$  má hustotu definovanou

$$f(x) = \frac{1}{\lambda} \exp\left[-\frac{x}{\lambda}\right], \quad x > 0,$$

střední hodnota  $\mu' = \lambda$ . Metodou momentů budeme odhadovat parametr  $\lambda$ . Odhad parametru  $\lambda$  získáme z porovnání prvního počátečního momentu s prvním výběrovým momentem  $M'_1 = \mu'_1$ , kde  $M'_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n$ . Odhadem parametru  $\lambda$  je výběrový průměr

$$\hat{\lambda} = \bar{X}_n.$$

### 3.4.2 Metoda maximální věrohodnosti

Věrohodnostní funkce je rovna

$$L(\lambda) = \prod_{i=1}^n \frac{1}{\lambda} \exp\left[-\frac{X_i}{\lambda}\right]$$

a její logaritmická věrohodnostní funkce je rovna

$$\begin{aligned} l(\lambda) &= \ln\left(\prod_{i=1}^n \frac{1}{\lambda} \exp\left[-\frac{X_i}{\lambda}\right]\right) = \\ &= \sum_{i=1}^n \left(-\ln \lambda - \frac{1}{\lambda} X_i\right) = -n \ln \lambda - \frac{1}{\lambda} \sum_{i=1}^n X_i. \end{aligned}$$

Odtud dostáváme věrohodnostní rovnici

$$\frac{\partial l(\lambda)}{\partial \lambda} = -\frac{n}{\lambda} + \frac{1}{\lambda^2} \sum_{i=1}^n X_i.$$

Derivaci položíme rovnu nule a úpravami dostáváme maximálně věrohodný odhad parametru  $\lambda$

$$\begin{aligned}
-\frac{n}{\widehat{\lambda}} + \frac{1}{\widehat{\lambda}^2} \sum_{i=1}^n X_i &= 0 \\
\frac{n}{\widehat{\lambda}} &= \frac{1}{\widehat{\lambda}^2} \sum_{i=1}^n X_i \\
\widehat{\lambda} &= \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.
\end{aligned}$$

### 3.4.3 Vlastnosti odhadů

Oběma metodami nám vyšly stejné odhady. Odhad střední hodnoty je výběrový průměr, jehož vlastnosti jsme již ověřili v části (3.1.3) a víme, že tento odhad je nestranný a konzistentní.

## 3.5 Rovnoměrné rozdělení

### 3.5.1 Momentová metoda

U této metody si můžeme zvolit, jaké teoretické momenty budeme porovnávat s výběrovými momenty. Tedy u tohoto rozdělení nebude porovnávat druhý centrální moment s empirickým rozptylem, ale využijeme druhý výběrový moment  $M'_2$ , který nám usnadní výpočet.

Rovnoměrné rozdělení je definované na intervalu  $(\mu - h, \mu + h)$  a má hustotu danou výrazem

$$f(x) = \frac{1}{2h}, \quad \mu - h < x < \mu + h.$$

První a druhý teoretický počáteční moment je

$$\begin{aligned}
\mu'_1(\mu, h) &= \mu, \\
\mu'_2(\mu, h) &= \mu^2 + \frac{h^2}{3}.
\end{aligned}$$

První a druhý výběrový moment je

$$\begin{aligned}
M'_1 &= \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n, \\
M'_2 &= \frac{1}{n} \sum_{i=1}^n X_i^2.
\end{aligned}$$

Porovnáním prvního momentu s výběrovým průměrem a druhého momentu s druhým výběrovým momentem získáme odhady parametrů  $\mu$  a  $h$ . Budeme tedy vycházet z následující soustavy rovnic

$$\begin{aligned}
M'_1 &= \mu'_1(\mu, h) \\
M'_2 &= \mu'_2(\mu, h).
\end{aligned}$$

Dosadíme a dostáváme odhad parametru  $\mu$

$$\hat{\mu} = \bar{X}_n,$$

a s využitím odhadu  $\hat{\mu}$  vypočítáme odhad pro parametr  $h$

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n X_i^2 &= \hat{\mu}^2 + \frac{\hat{h}^2}{3} \\ \frac{1}{n} \sum_{i=1}^n X_i^2 &= (\bar{X}_n)^2 + \frac{\hat{h}^2}{3} \\ \hat{h}^2 &= 3 \left( \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2 \right) \\ \hat{h} &= \sqrt{3 \left( \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2 \right)}. \end{aligned}$$

### 3.5.2 Metoda maximální věrohodnosti

U této metody nejprve budeme uvažovat rovnoměrné rozdělení na intervalu  $(0, h)$ , kde  $h > 0$  a odhadneme neznámý parametr  $h$ . Hustota je

$$f(x) = \frac{1}{h}, \text{ kde } 0 \leq x \leq h.$$

Sdružená hustota

$$f(x_1, x_2, \dots, x_n; h) = \prod_{i=1}^n \frac{1}{h}, \text{ kde } 0 \leq x_i \leq h \text{ (} i = 1, \dots, n \text{)}$$

Věrohodnostní funkce je

$$L(\mu, h) = \prod_{i=1}^n \frac{1}{h} = \frac{1}{h^n} = h^{-n}, \text{ pro } 0 \leq x_i \leq h \text{ (} i = 1, \dots, n \text{)}.$$

Vidíme, že maximálně věrohodný odhad  $h$  musí mít hodnotu pro kterou platí  $h \leq x_i$  pro  $i = 1, \dots, n$  a která maximalizuje  $\frac{1}{h^n}$  přes všechny možné hodnoty. Funkce  $h^{-n}$  je klesající funkcí proměnné  $h$  na intervalu  $(0, \infty)$ . Tedy odhad bude nejmenší možná hodnota  $h$  pro kterou platí, že  $h \leq x_i$  pro  $i = 1, \dots, n$ . Tedy hodnota  $h = \max(x_1, \dots, x_n)$ , a tedy maximálně věrohodný odhad  $h$  je

$$\hat{h} = \max \{X_i; 1 \leq i \leq n\}.$$

Podrobněji můžeme tento výsledek ještě zdůvodnit takto:  $0 < x_n \leq h$ , proto

$$\frac{1}{h^n} \leq \frac{1}{x_n^n} = \frac{1}{\hat{h}^n}.$$

Nyní uvažujme rovnoměrné rozdělení na intervalu  $(\mu - h, \mu + h)$ , kde  $h > 0$  a opět odhadneme neznámý parametr  $h$ . Provedeme opět stejnou úvahu jako výše.

Některé již zřejmé fakta budeme vynechávat. Věrohodnostní funkce pro náhodný výběr  $X_1, \dots, X_n$  z rovnoměrného rozdělení je rovna

$$L(\mu, h) = \prod_{i=1}^n \frac{1}{2h} = \frac{1}{(2h)^n}$$

její logaritmus je roven

$$l(\mu, h) = \ln \frac{1}{(2h)^n} = -n \ln(2h).$$

Protože funkce  $l(\mu, h) = -n \ln(2h)$  je klesající. Věrohodnostní funkce  $L(\mu, h)$  nabývá své maximální hodnoty pro minimální hodnotu parametru  $h$ . Maximálně věrohodný odhad parametru  $h$  je roven

$$\hat{h} = \frac{1}{2} (\max \{X_i; 1 \leq i \leq n\} - \min \{X_i; 1 \leq i \leq n\}).$$

Maximálně věrohodný odhad parametru  $\mu$  dostaneme tak, že spočítáme klasický průměr. Parametr  $\mu$  je střední hodnota a její maximálně věrohodný odhad je

$$\hat{\mu} = \frac{1}{2} (\max \{X_i; 1 \leq i \leq n\} + \min \{X_i; 1 \leq i \leq n\}),$$

pro důkaz, že se jedná o maximálně věrohodný odhad nemáme matematický aparát. Za pomoci literatury [1] a hlubšího poznání statistiky se nejedná o těžký důkaz.

Momentovou metodou i metodou maximální věrohodnosti jsme získali odlišné odhady a nelze s určitostí říci, která z obou metod je lepší pro počítání odhadů parametru spojitého rovnoměrného rozdělení.

### 3.5.3 Vlastnosti odhadů

U odhadu spočtené metodou maximální věrohodnosti jsme obdrželi odhad  $\hat{\mu}$ , který je nestranný odhad a u odhadu parametru  $h$  ověříme nestrannost. Ověření provedeme pomocným tvrzením, které zní: odhad  $\hat{h}$  není nestranný, čili  $E(\hat{h}) \neq h$ .

Důkaz tohoto tvzení provedeme sporem, tedy předpokládáme, že  $E(\hat{h}) = h$ . Spočítáme si

$$E(\hat{h}^2) = E\left(3 \left(\frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2\right)\right) = 3 \frac{n-1}{n} \sigma^2 = \frac{n-1}{n} h^2.$$

Nyní si spočítáme rozptyl odhadu  $\hat{h}$

$$\text{Var}(\hat{h}) = E(\hat{h}^2) - (E(\hat{h}))^2 = \frac{n-1}{n} h^2 - h^2 = -\frac{1}{n} h^2,$$

jelikož  $h > 0$ , vychází rozptyl záporné číslo a to je spor s definicí rozptylu. Docházím tedy ke sporu v důkazu tvrzení. Ověřili jsme, že odhad  $\hat{h}$  parametru  $h$  není nestranným odhadem. Ověříme ještě asymptotickou nestrannost

$$\lim_{n \rightarrow \infty} E\hat{h} = h.$$

tedy odhad  $\hat{h}$  je asymptoticky nestranný a oba odhady jsou konzistentní, viz [3].

# 4. Bodové odhady pro různá diskrétní rozdělení

Tato kapitola se věnuje odhadům parametrů diskrétních pravděpodobnostních rozdělení. Podobně jako ve třetí kapitole odhadneme parametry momentovou metodou a metodou maximální věrohodnosti. Ověření vlastností odhadů je většinou s odvoláním na předchozí výpočty, které byly provedeny v této bakalářské práci ve třetí kapitole. Spočítáme odhady parametrů geometrického rozdělení, Poissonova rozdělení, binomického rozdělení.

## 4.1 Geometrické rozdělení

### 4.1.1 Momentová metoda

Náhodná veličina  $X$  má geometrické rozdělení definované pravděpodobnostní funkcí

$$P(X = x) = p(1 - p)^{x-1}, \quad x \in \mathbb{N}.$$

Pro základní číselné charakteristiky platí, že střední hodnota je  $\mu' = \frac{1}{p}$  a rozptyl je  $\sigma^2 = \frac{1}{p} \left( \frac{1}{p} - 1 \right)$ . Je-li  $X_1, X_2, \dots, X_n$  náhodný výběr z geometrického rozdělení, tak metodou momentů porovnáváme pouze výběrový průměr a střední hodnotu geometrického rozdělení, protože pro geometrické rozdělení odhadujeme jeden parametr  $p$ . Matematicky vyjádřeno

$$M'_1 = \mu'_1,$$

dosadíme za  $\mu'_1 = \frac{1}{p}$  a za  $M'_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n$ . Porovnáním těchto momentů dostaneme odhad parametru  $p$ , který je

$$\hat{p} = \frac{1}{\bar{X}_n}.$$

### 4.1.2 Metoda maximální věrohodnosti

Rovnou píšeme věrohodnostní funkci a maximálně věrohodný odhad spočítáme z této věrohodnostní funkce, která je

$$L(p) = \prod_{i=1}^n p(1 - p)^{X_i - 1}, \quad \text{kde } X_i \in \mathbb{N}.$$

Logaritmická věrohodnostní funkce je rovna

$$\begin{aligned} l(p) &= \ln \left( \prod_{i=1}^n p(1 - p)^{X_i - 1} \right) = \sum_{i=1}^n \left( \ln p + \ln (1 - p)^{X_i - 1} \right) = \\ &= \sum_{i=1}^n (\ln p + (X_i - 1) \ln (1 - p)) = n \ln p + \left( \sum_{i=1}^n X_i - n \right) \ln (1 - p), \end{aligned}$$

tudíž věrohodnostní rovnice

$$\frac{\partial l(p)}{\partial p} = \frac{n}{p} - \left( \sum_{i=1}^n X_i - n \right) \frac{1}{1-p}.$$

Derivaci položíme rovnu nule, abychom mohli najít maximálně věrohodný odhad parametru  $p$

$$\begin{aligned} \frac{n}{\hat{p}} - \left( \sum_{i=1}^n X_i - n \right) \frac{1}{1-\hat{p}} &= 0 \\ \left( \sum_{i=1}^n X_i - n \right) \frac{1}{1-\hat{p}} &= \frac{n}{\hat{p}} \\ \hat{p} \left( \sum_{i=1}^n X_i - n \right) &= n - n\hat{p} \\ \hat{p} &= \frac{n}{\sum_{i=1}^n X_i} = \frac{n}{\frac{n}{n} \sum_{i=1}^n X_i} = \frac{1}{\bar{X}_n}. \end{aligned}$$

### 4.1.3 Vlastnosti odhadů

Metodou momentů i metodou maximální věrohodnosti nám vyšel stejný odhad parametru  $p$ , a to převrácená hodnota výběrového průměru. Odhad je nestranný a konzistentním odhadem střední hodnoty, viz literatura [1].

## 4.2 Poissonovo rozdělení

### 4.2.1 Momentová metoda

Předpokládejme, že veličina  $X$  nabývá pouze hodnot  $0, 1, \dots$ , a to s pravděpodobnostmi

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

kde  $\lambda > 0$  je dané číslo. Pak říkáme, že  $X$  má Poissonovo rozdělení  $Po(\lambda)$  s parametrem  $\lambda$ . Platí, že střední hodnota Poissonova rozdělení je  $\mu' = \lambda$ . Abychom získali odhad parametru  $\lambda$ , porovnáme střední hodnotu s výběrovým průměrem  $\mu'_1 = M'_1$ . Po dosazení odhadem parametru  $\lambda$  je odhad

$$\hat{\lambda} = \bar{X}_n.$$

### 4.2.2 Metoda maximální věrohodnosti

Věrohodnostní funkce pro Poissonovo rozdělení je rovna

$$L(\lambda) = \prod_{i=1}^n \frac{\lambda^{X_i}}{X_i!} e^{-\lambda}$$

a její logaritmus je roven

$$\begin{aligned} l(\lambda) &= \ln \left( \prod_{i=1}^n \frac{\lambda^{X_i}}{X_i!} e^{-\lambda} \right) = \sum_{i=1}^n (\ln \lambda^{X_i} - \ln(X_i!) - \lambda) = \\ &= \ln \lambda \sum_{i=1}^n X_i - \sum_{i=1}^n \ln(X_i!) - n\lambda. \end{aligned}$$

Derivováním logaritmické věrohodnostní funkce dostáváme věrohodnostní rovnici

$$\frac{\partial l}{\partial \lambda} = \frac{1}{\lambda} \sum_{i=1}^n X_i - n.$$

Derivaci položíme rovnu nule a dostaneme maximálně věrohodný odhad parametru  $\lambda$ , který je roven

$$\begin{aligned} \frac{1}{\hat{\lambda}} \sum_{i=1}^n X_i - n &= 0 \\ \hat{\lambda} &= \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n. \end{aligned}$$

### 4.2.3 Vlastnosti odhadů

Oběma metodami nám vyšly stejné odhady parametru  $\lambda$ . Odhad střední hodnoty je výběrový průměr, jehož vlastnosti jsme již ověřili ve třetí kapitole u vlastností odhadu normálního rozdělení a víme, že tento odhad je nestranný a konzistentní.

## 4.3 Binomické rozdělení

### 4.3.1 Momentová metoda

Binomické rozdělení  $\text{Bi}(m, p)$  je definované pravděpodobnostní funkcí, která je

$$P(X = x) = \binom{m}{x} p^x (1-p)^{m-x}, \quad x = 0, 1, \dots, m,$$

střední hodnota binomického rozdělení je  $\mu' = mp$  a rozptyl je  $\sigma^2 = mp(1-p)$ . Metodou momentů porovnáme  $M'_1 = \mu'_1$ , tedy

$$\bar{X}_n = mp,$$

odtud dostaneme odhad parametru  $p$

$$\hat{p} = \frac{\bar{X}_n}{m} = \frac{1}{nm} \sum_{i=1}^n X_i.$$

### 4.3.2 Metoda maximální věrohodnosti

Věrohodnostní funkce binomického rozdělení je rovna

$$L(n, p) = \prod_{i=1}^n \binom{m}{X_i} p^{X_i} (1-p)^{m-X_i}.$$

Logaritmická věrohodnostní funkce je

$$\begin{aligned} l(m, p) &= \ln \left( \prod_{i=1}^n \binom{m}{X_i} p^{X_i} (1-p)^{m-X_i} \right) = \\ &= \ln \left( \prod_{i=1}^n \binom{m}{X_i} \right) + \ln p \sum_{i=1}^n X_i + \ln(1-p) \sum_{i=1}^n (m-X_i) = \\ &= \ln \left( \prod_{i=1}^n \binom{m}{X_i} \right) + \ln p \sum_{i=1}^n X_i + \ln(1-p) \left( mn - \sum_{i=1}^n X_i \right). \end{aligned}$$

Protože je

$$\lim_{p \rightarrow 0^+} l(m, p) = \lim_{p \rightarrow 1^-} l(m, p) = -\infty,$$

má věrohodnostní funkce maximum ve stacionárním bodě. Pro něj dostaneme věrohodnostní rovnici

$$\frac{\partial l(m, p)}{\partial p} = \frac{\sum_{i=1}^n X_i}{p} - \frac{mn - \sum_{i=1}^n X_i}{1-p}.$$

Zderivovanou a upravenou logaritmickou věrohodnostní funkci položíme rovnu nule a vyjádříme si maximálně věrohodný odhad parametru  $p$

$$\begin{aligned} \frac{\sum_{i=1}^n X_i}{\hat{p}} - \frac{mn - \sum_{i=1}^n X_i}{1-\hat{p}} &= 0 \\ \frac{\sum_{i=1}^n X_i}{\hat{p}} &= \frac{mn - \sum_{i=1}^n X_i}{1-\hat{p}} \\ \sum_{i=1}^n X_i - \hat{p} \sum_{i=1}^n X_i &= \hat{p}mn - \hat{p} \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i &= \hat{p}mn \\ \hat{p} &= \frac{1}{mn} \sum_{i=1}^n X_i = \frac{\bar{X}_n}{m}. \end{aligned}$$

### 4.3.3 Vlastnosti odhadů

Oběma metodami nám vyšly stejné odhady parametru  $p$ . U odhadu  $\hat{p}$  ověříme nestrannost, spočítáme střední hodnotu tohoto odhadu



$$E\hat{p} = E\frac{\bar{X}_n}{m} = \frac{1}{m}E\left(\frac{1}{n}\sum_{i=1}^n X_i\right) = \frac{\frac{1}{n}nEX_i}{m} = \frac{mp}{m} = p,$$

tedy odhad parametru  $p$  je nestranný. Ověříme konzistenci tohoto odhadu pomocí postačujících podmínek pro ověření konzistence, které jsme napsali v první kapitole. Připomeňme si ho a postupujme v ověřování podmínek. Nechť  $E\hat{\theta}^2 < \infty$  pro každé přirozené  $n$ . Platí-li  $\hat{\theta}$  je nestranný odhad nebo alespoň asymptoticky nestanný odhad parametru  $\theta$  a  $\lim_{n \rightarrow \infty} \text{Var} \hat{\theta} = 0$ . Pak  $\hat{\theta}$  je konzistentním odhadem parametru  $\theta$ . Máme odhad parametru  $p$ , který je nestranný a  $E\hat{p} < \infty$ , spočítejme rozptyl tohoto odhadu. Využijeme přitom vlastnost rozptylu, která je  $\text{Var}(aX) = a^2\text{Var}X$ , kde  $a$  je konstanta, viz literatura [4]. Důkaz této vlastnosti lze nalézt v [7].

$$\text{Var}(\hat{p}) = \text{Var}\left(\frac{\bar{X}_n}{m}\right) = \frac{1}{m^2}\text{Var}\left(\frac{1}{n}\sum_{i=1}^n X_i\right) = \frac{1}{m^2}\frac{1}{n^2}nmp(1-p) = \frac{p(1-p)}{mn},$$

spočítáme limitu

$$\lim_{n \rightarrow \infty} \text{Var}(\hat{p}) = \lim_{n \rightarrow \infty} \frac{p(1-p)}{mn} = 0.$$

Tedy po splnění postačujících podmínek pro ověření konzistence, docházíme k závěru, že odhad  $\hat{p}$  je konzistentní.

## 5. Přehled bodových odhadů

Tato kapitola bude shrnutím všech odhadů parametrů, které jsme spočítali. V tabulkách bude vždy určité rozdělení a pro něj uvedeny odhady metodou momentů, kterou budeme značit MM a metodu maximální věrohodnosti označíme jako MMV. U těch odhadů u kterých jsme ověřili nestrannost uvedeme tuto vlastnost v tabulce. Všechny odhady, která jsem spočítali jsou konzistentní.

### Spojité rozdělení

U normálního rozdělení nám vyšly oběma metodami stejné odhady pro oba parametry. Odhad  $\hat{\mu}$  se nazývá výběrový průměr a odhad  $\hat{\sigma}^2$  je empirický rozptyl.

Rozdělení	MM	MMV	Nestrannost
$N(\mu, \sigma^2)$	$\hat{\mu} = \bar{X}_n$	$\hat{\mu} = \bar{X}_n$	ano
$N(\mu, \sigma^2)$	$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$	$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$	ne

Tabulka A: Normální rozdělení.

Pro gama rozdělení nám vyšly rozdílné odhady a navíc pro výpočet odhadů parametrů  $a$  a  $p$  metodou maximální věrohodnosti potřebujeme software, který by nám numericky dopočítal hodnoty těchto odhadů. Tedy pro gama rozdělení je vhodnější použití momentové metody.

Rozdělení	MM	Nestrannost	MMV
$\text{Ga}(a, p)$	$\hat{a} = \frac{X_n}{S_n^2}$	ano	$\hat{a} = \frac{\hat{p}}{\bar{X}_n}$
$\text{Ga}(a, p)$	$\hat{p} = \frac{X_n^2}{S_n^2}$	ne	$\ln \hat{p} - \psi(\hat{p}) = \ln \frac{X_n}{\sqrt{n! \prod_{i=1}^n X_i}}$

Tabulka B: Gama rozdělení.

U logaritmicke-normálního rozdělení nám vyšly různé odhady parametrů  $\mu$  a  $\sigma^2$  a pro toto rozdělení je lepší použití metody maximální věrohodnosti. Pro parametr  $\mu$  dává metoda maximální věrohodnosti nestranný odhad, ale odhad parametru  $\sigma^2$  není nestranný.

Rozdělení	MM	MMV
$\text{LN}(\mu, \sigma^2)$	$\hat{\mu} = \ln(M'_1) - \frac{1}{2} \ln\left(1 + \frac{M_2}{(M'_1)^2}\right)$	$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n \ln X_i$
$\text{LN}(\mu, \sigma^2)$	$\hat{\sigma}^2 = \ln\left(1 + \frac{M_2}{M'_1}\right)$	$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (\ln X_i - \hat{\mu})^2$

Tabulka C: Logaritmicke-normální rozdělení.

Pro exponenciální rozdělení jsme odhadovali parametr  $\lambda$  a u obou metod nám vyšel výběrový průměr. Tedy obě metody jsou stejně vhodné pro výpočet tohoto odhadu.

Rozdělení	MM	Nestrannost	MMV	Nestrannost
$\text{Ex}(\lambda)$	$\hat{\lambda} = \bar{X}_n$	ano	$\hat{\lambda} = \bar{X}_n$	ano

Tabulka D: Exponenciální rozdělení.

Momentovou metodou nám pro rovnoměrné rozdělení vyšly odhad  $\hat{\mu}$ , který je nestranný a odhad  $\hat{h}$  není nestranný. U odhadů metodou maximální věrohodnosti musí pro  $X_i$  platit  $1 \leq i \leq n$ .

Rozdělení	MM	MMV
$R(\mu, h)$	$\hat{\mu} = \bar{X}_n$	$\hat{h} = \frac{1}{2} (\max \{X_i\} - \min \{X_i\})$
$R(\mu, h)$	$\hat{h} = \sqrt{3 \left( \frac{1}{n} \sum_{i=1}^n X_i^2 + (\bar{X}_n)^2 \right)}$	$\hat{\mu} = \frac{1}{2} (\max \{X_i\} - \min \{X_i\})$

Tabulka E: Rovnoměrné rozdělení.

## Diskrétní rozdělení

U geometrického rozdělení odhad parametru  $p$  vyšla převrácená hodnota výběrového průměru.

Rozdělení	MM	Nestrannost	MMV	Nestrannost
$\text{Ge}(p)$	$\hat{p} = \frac{1}{\bar{X}_n}$	ano	$\hat{p} = \frac{1}{\bar{X}_n}$	ano

Tabulka F: Geometrické rozdělení.

Poissonovo rozdělení má parametr  $\lambda$  a odhad tohoto parametru je výběrový průměr, který vyšel oběma metodami.

Rozdělení	MM	Nestrannost	MMV	Nestrannost
Po( $\lambda$ )	$\hat{\lambda} = \bar{X}_n$	ano	$\hat{\lambda} = \bar{X}_n$	ano

Tabulka G: Poissonovo rozdělení.

Pro parametr binomického rozdělení dává metoda momentů i metoda maximální věrohodnosti stejný výsledek.

Rozdělení	MM	Nestrannost	MMV	Nestrannost
Bi( $m, p$ )	$\hat{p} = \frac{X_n}{m}$	ano	$\hat{p} = \frac{X_n}{m}$	ano

Tabulka H: Binomické rozdělení.

# Závěr

V první kapitole jsme se seznámili s tím, co jsou to rozdělení, jak mohou vypadat některé jejich hustoty, a zadefinovali jsme si základní pojmy týkající se bodového odhadu. V další kapitole jsme si představili, jak lze odhadovat parametry spojitých distribucí. Ukázali jsme, že lze pro bodový odhad použít momentovou metodu nebo metodu maximální věrohodnosti. V třetí kapitole jsme spočítali odhady parametrů spojitých rozdělení pomocí dvou dříve zmíněných metod a zjistili jsme, že i přes velkou početní náročnost metody maximální věrohodnosti existuje efektivní řešení odhadování parametrů v podobě metody momentů. Čtvrtá kapitola zahrnuje totéž jako třetí kapitola, pouze s tím rozdílem, že se věnujeme diskrétním náhodným veličinám. Pátá kapitola je přehledem spočítaných odhadů.

Pro základní rozdělení dávají obě metody skoro vždy shodné výsledky, výjimkou je gama rozdělení, logaritmicko-normální rozdělení a rovnoměrné rozdělení. Nelze jednoznačně rozhodnout, která z metod poskytuje lepší výsledky. Rozhodování provádíme podle dané situace, nejčastěji rozhoduje jednoduchost získaných vzorců. Metoda momentů zohledňuje všechna data z výběru a volíme ji v případech, kdy je soustava věrohodnostních rovnic obtížně řešitelná.

Informace, dostupné v této bakalářské práci, lze využít při rozhodování, kterou metodu pro bodový odhad použít, neboť u zmíněných metod je postup výpočtu a základní princip. Bude záležet jen na rozhodnutí odhadujícího pracovníka, kterou metodu použije a která splňuje dané požadavky.

Z této práce vyplývají poznatky o tom, že je nutné aby student nebo pracovník, který bude pracovat s daty a provádět odhad, měl základní představu o pravděpodobnostním rozdělení dat, o příkladu nebo o analýze, kterou bude řešit a ovládá problematiku daného oboru. Pokud tomu tak nebude a obtížnost projektu bude odhadovat řádně nepoučená osoba, může to vést ke špatným výsledkům a nesplnitelným odhadům.

Téma této bakalářské práce pro mne bylo velkou výzvou, neboť jsem o problematice odhadování bodových parametrů slyšela, ale doposud jsem je nikde nenašla spočítané odhady, abych se seznámila s funkčností metod. Poznání metod je pro mě velkým přínosem, především vhodnost jejich použití. Metoda maximální věrohodnosti mne oslovila především svou jednoduchostí a poměrně přesnými výsledky.

# Seznam použité literatury

- [1] ANDĚL, Jiří: *Základy matematické statistiky*, Praha: Matfyzpress, 2011, 358 s., ISBN 978-80-7378-162-0
- [2] BISKUP, Roman: *Bodový odhad parametrů rozdělení*, Praha, 2012, <http://home.ef.jcu.cz/birom/stat/>
- [3] FRANK Jakub: *Odhady parametrů vícerozměrného Studentova rozdělení*, Brno, 2009. 41 s. Diplomová práce. Masarykova Univerzita v Brně.
- [4] KULICH, Michal: *Malý větníček*, Praha, 2013, <http://www.karlin.mff.cuni.cz/kulich/>
- [5] REISS Martin: *Odhady parametrů některých rozdělení pravděpodobnosti a jejich vlastnosti*, Brno, 2011. 32 s. Bakalářská práce. Masarykova univerzita.
- [6] VAŇKÁTOVÁ Kristýna: *Metody odhadu regresních parametrů*, Olomouc, 2012. 95 s. Bakalářská práce. Univerzita Palackého v Olomouci.
- [7] ZVÁRA, Karel; ŠTĚPÁN, Josef: *Pravděpodobnost a matematická statistika*, Praha : Matfyzpress, 2006. 230 s., ISBN 80-86732-71-7