

**MATEMATICKO-FYZIKÁLNÍ  
FAKULTA**  
Univerzita Karlova

**BAKALÁŘSKÁ PRÁCE**

Albert Zejda

**Rozdělení typu  $(a, b, 0)$  v neživotním  
pojištění**

Katedra pravděpodobnosti a matematické statistiky

Vedoucí bakalářské práce: Mgr. Ing. Pavel Kříž, Ph.D.

Studijní program: Matematika

Studijní obor: Finanční matematika

Praha 2023

Prohlašuji, že jsem tuto bakalářskou práci vypracoval(a) samostatně a výhradně s použitím citovaných pramenů, literatury a dalších odborných zdrojů. Tato práce nebyla využita k získání jiného nebo stejného titulu.

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 má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle §60 odst. 1 autorského zákona.

V ..... dne .....

Podpis autora

Děkuji panu Mgr. Ing. Pavlovi Křížovi, Ph.D. za ochotu a nespočet věcných připomínek.

Název práce: Rozdělení typu  $(a, b, 0)$  v neživotním pojištění

Autor: Albert Zejda

Katedra: Katedra pravděpodobnosti a matematické statistiky

Vedoucí bakalářské práce: Mgr. Ing. Pavel Kříž, Ph.D., Katedra pravděpodobnosti a matematické statistiky

Abstrakt: Nejprve je představena definice rozdělení typu  $(a, b, 0)$ . Následně je ukázáno, která známá rozdělení definici splňují, které parametry  $a$ ,  $b$  jim přísluší a jsou určeny konkrétní množiny parametrů pro každé z rozdělení. Potom je dokázáno, že žádná další rozdělení tuto definici splňovat nemohou. Je představena metoda maximální věrohodnosti odhadu parametrů  $a$ ,  $b$  přímo z dat. Na závěr je vypracována simulační studie, ve které se porovnávají pravděpodobnosti z odhadnutého rozdělení typu  $(a, b, 0)$  z konkrétních dat metodou maximální věrohodnosti s empirickými relativními četnostmi spočítanými z dat.

Klíčová slova: diskrétní rozdělení, neživotní pojištění, třída  $(a, b, 0)$ , odhad parametrů.

Title: Distributions of  $(a, b, 0)$  type in non-life insurance

Author: Albert Zejda

Department: Department of Probability and Mathematical Statistics

Supervisor: Mgr. Ing. Pavel Kříž, Ph.D., Department of Probability and Mathematical Statistics

Abstract: First, a definition of the distribution type  $(a, b, 0)$  is introduced. Next, it is shown which known distributions satisfy this definition, the parameters  $a$  and  $b$  that correspond to them, and specific sets of parameters for each of the distributions are determined. Then, it is proven that no other distributions can satisfy this definition. A maximum likelihood estimation method for estimating the parameters  $a$  and  $b$  directly from the data is presented. Finally, a simulation study is conducted, in which the probabilities from the estimated distribution type  $(a, b, 0)$  from specific data using the maximum likelihood method are compared with the empirical relative frequencies calculated from the data.

Keywords: discrete distributions, non-life insurance,  $(a, b, 0)$  class, parameter estimation.

# Obsah

Úvod	3
<b>1 Třída rozdělení <math>(a, b, 0)</math></b>	<b>4</b>
1.1 Definice	4
1.2 Rozdělení náležící třídě $(a, b, 0)$	4
1.2.1 Poissonovo rozdělení	4
1.2.2 Negativně binomické rozdělení	5
1.2.3 Binomické rozdělení	5
1.2.4 Geometrické rozdělení	6
1.2.5 Shrnutí první kapitoly	6
<b>2 Hodnoty parametrů <math>(a, b, 0)</math></b>	<b>7</b>
2.1 Motivace	7
2.2 Množiny parametrů rozdělení	7
2.2.1 Poissonovo Rozdělení	7
2.2.2 Negativně binomické rozdělení	8
2.2.3 Binomické Rozdělení	9
2.3 Pravděpodobnostní funkce na doplňku $M$	9
2.3.1 Množina $M_1$	10
2.3.2 Množina $M_2$	10
2.3.3 Množina $M_3$	10
2.3.4 Množina $M_4$	11
2.4 Přejchod z $M_{dist}$ k původní parametrizaci	11
2.4.1 Poissonovo rozdělení	12
2.4.2 Negativně binomické rozdělení	12
2.4.3 Binomické rozdělení	13
<b>3 Odhady parametrů <math>a, b</math></b>	<b>16</b>
3.1 Vyjádření pravděpodobnostní funkce	16
3.2 Metoda maximální věrohodnosti	16
3.2.1 MLE pro Poissonovo rozdělení	18
3.2.2 MLE pro negativně binomické rozdělení	18
3.2.3 MLE pro binomické rozdělení	20
<b>4 Simulační studie</b>	<b>22</b>
4.1 Data z Poissonova rozdělení	22
4.2 Data z negativně binomického rozdělení	23
4.3 Data z binomického rozdělení	23
<b>Závěr</b>	<b>25</b>
<b>Seznam použité literatury</b>	<b>26</b>
<b>Seznam obrázků</b>	<b>27</b>
<b>Seznam tabulek</b>	<b>28</b>

<b>A Přílohy</b>	<b>29</b>
A.1 Kód pro data z Poissonova rozdělení . . . . .	29
A.2 Kód pro data z negativně binomického rozdělení . . . . .	30
A.3 Kód pro data z binomického rozdělení . . . . .	31

# Úvod

Poissonovo, binomické, negativně binomické a geometrické rozdělení jsou rozdělení, která se využívají k modelování počtu škod v pojišťovnictví. Jelikož není vždy jasné, které z rozdělení bude pro modelování konkrétního případu ideální, tak vyjádřím všechna tato rozdělení jedním známým vztahem, se kterým bychom mohli dále pracovat a volba rozdělení při modelování počtu škod byla přímočařejší. V první části práce definuji vztah, kterým jsou rozdělení patřící do třídy  $(a, b, 0)$  určeny a poté dokazuji, že Poissonovo, binomické, negativně binomické i geometrické rozdělení do třídy  $(a, b, 0)$  náleží. Ve druhé části rozdělují parametry  $a, b$  do množin přípustných hodnot pro každé rozdělení a dokazuji, že parametry, které nenáležejí do množiny přípustných hodnot žádného z rozdělení nemohou určovat rozdělení. V poslední teoretické kapitole se soustřeďuji na odhad parametrů  $a, b$  a to konkrétně metodou maximální věrohodnosti. Věrohodnost maximalizuji přes všechny množiny přípustných hodnot parametrů a vybírám optimální řešení. Na konci je ukázána simulační studie odhadů parametrů pomocí mnou zvolené metody maximální věrohodnosti.

Vlastním přínosem v práci je velké množství vlastních výpočtů, odvozování a obrázků uvedených v bakalářské práci a také závěrečná simulační studie. Mezi vlastní odvozování a výpočty patří především: důkaz tvrzení 2, výpočty v podkapitole 1.2, obrázky v podkapitole 2.2 a obrázky v kapitole 4.

# 1. Třída rozdělení $(a, b, 0)$

Základní vlastnosti rozdělení náležících tříd  $(a, b, 0)$  včetně definice jsou popsány v knize Klugman a kol. (2019).

## 1.1 Definice

**Definice 1.** Diskrétní rozdělení náhodných veličin s pravděpodobnostní funkcí  $\{p_k, k = 0, 1, \dots\}$  náleží třídě  $(a, b, 0)$  za předpokladu, že existují konstanty  $a, b$  takové, že:

$$p_k = \left(a + \frac{b}{k}\right) p_{k-1}, \quad k = 1, 2, \dots, \quad p_0 > 0. \quad (1.1)$$

Pravděpodobnost  $p_0$  se dá získat zpětně z rekurzivní rovnice, protože se pravděpodobnosti musí sčítat na 1.

Pro rozdělení pravděpodobnosti diskrétní náhodné veličiny platí:

$$\sum_{k=0}^{\infty} p_k = 1.$$

Z čehož pro  $p_0$  vyplývá:

$$p_0 = 1 - \sum_{k=1}^{\infty} p_k.$$

## 1.2 Rozdělení náležících tříd $(a, b, 0)$

Do rozdělení náležících tříd  $(a, b, 0)$  počítáme Poissonovo, negativně binomické, binomické a speciální případ negativně binomického - geometrické rozdělení.

V této kapitole budu dokazovat, že tato rozdělení do třídy  $(a, b, 0)$  patří a odvozovat jaké parametry  $a, b$  jim přísluší.

### 1.2.1 Poissonovo rozdělení

Poissonovo rozdělení má pravděpodobnostní funkci zadanou ve tvaru:

$$p_k = \frac{\lambda^k}{k!} e^{-\lambda}, \quad k = 1, 2, \dots, \quad \lambda > 0.$$

Z toho vytknutím  $\frac{\lambda}{k}$ :

$$p_k = \frac{\lambda}{k} \frac{\lambda^{k-1}}{(k-1)!} e^{-\lambda}.$$

Jelikož chci vyjádřit rekurzivní vztah, napíšu si, jak vypadá  $p_{k-1}$ :

$$p_{k-1} = \frac{\lambda^{k-1}}{(k-1)!} e^{-\lambda}.$$



Z toho dohromady pro  $p_k$  plyne:

$$p_k = \frac{\lambda}{k} p_{k-1}.$$

Takže Poissonovo rozdělení patří podle rovnice (1.1) do třídy rozdělení  $(a, b, 0)$  a pro parametry platí:

$$a = 0, \quad b = \lambda.$$

Pro Poissonovo rozdělení navíc platí  $p_0 = e^{-\lambda}$ .

## 1.2.2 Negativně binomické rozdělení

Pravděpodobnostní funkce negativně binomického rozdělení je dána ve tvaru:

$$p_k = \binom{h+k-1}{k} \left(\frac{1}{\beta+1}\right)^h \left(\frac{\beta}{\beta+1}\right)^k, \quad k = 1, 2, \dots, \quad \beta > 0, \quad h > 0.$$

Jelikož v kombinačním čísle se může vyskytnout i jiné než přirozené číslo, definuji kombinační čísla pro reálná čísla. Vycházet budu z Klugman a kol. (2019, str. 85).

**Definice 2.** Necht  $r \in \mathbb{R}$  a  $k \in \mathbb{N}_0$ , pak

$$\binom{r}{k} = \frac{r(r-1)\dots(r-k+1)}{k!}$$

nazýváme kombinačním číslem  $r$  nad  $k$ .

Pravděpodobnostní funkci upravím na rekurzivní tvar:

$$p_k = \frac{h+k-1}{k} \frac{\beta}{1+\beta} \binom{h+k-2}{k-1} \left(\frac{1}{\beta+1}\right)^h \left(\frac{\beta}{\beta+1}\right)^{(k-1)},$$

$$p_k = \left(1 + \frac{h-1}{k}\right) \frac{\beta}{1+\beta} p_{k-1}.$$

Negativně binomické rozdělení také splňuje rovnici (1.1) s parametry:

$$a = \frac{\beta}{1+\beta}, \quad b = (h-1) \frac{\beta}{1+\beta}.$$

Doplním  $p_0 = (1+\beta)^{-h}$ .

## 1.2.3 Binomické rozdělení

Pro pravděpodobnostní funkci binomického rozdělení platí:

$$p_k = \binom{m}{k} p^k (1-p)^{m-k}, \quad k = 1, 2, \dots, \quad 0 < p < 1, \quad m \in \mathbb{N}.$$

Znovu upravím na tvar splňující rovnici (1.1):

$$p_k = \frac{m-k+1}{k} \frac{p}{1-p} \binom{m}{k-1} p^{k-1} (1-p)^{m-(k-1)},$$

$$p_k = \left(-1 + \frac{m+1}{k}\right) \frac{p}{1-p} p_{k-1}.$$

Z čehož vyplývá, že binomické rozdělení patří do třídy (a,b,0) s parametry:

$$a = -\frac{p}{1-p}, \quad b = (m+1) \frac{p}{1-p}.$$

Také platí, že  $p_0 = (1-p)^m$ .

### 1.2.4 Geometrické rozdělení

Pravděpodobnostní funkce geometrického rozdělení má tvar:

$$p_k = \frac{1}{1+\beta} \left(\frac{\beta}{\beta+1}\right)^k, \quad k = 1, 2, \dots, \beta > 0.$$

Upravím na tvar, který splňuje rovnici (1.1):

$$p_k = \frac{\beta}{(1+\beta)^2} \left(\frac{\beta}{\beta+1}\right)^{k-1},$$

$$p_k = \frac{\beta}{(1+\beta)} p_{k-1}.$$

Parametry geometrického rozdělení jsou:

$$a = \frac{\beta}{(1+\beta)}, \quad b = 0.$$

Platí  $p_0 = \frac{1}{1+\beta}$ .

### 1.2.5 Shrnutí první kapitoly

Dokázal jsem, že Poissonovo, negativně binomické, binomické a geometrické rozdělení jsou typy rozdělení, jejichž společným znakem je, že splňují rovnici (1.1). V následující tabulce napíšu všechny parametry, které jsem pro tato rozdělení určil.

Rozdělení	$a$	$b$	$p_0$
Poissonovo	0	$\lambda$	$e^{-\lambda}$
Negativně binomické	$\frac{\beta}{1+\beta}$	$(h-1) \frac{\beta}{1+\beta}$	$(1+\beta)^{-h}$
Binomické	$-\frac{p}{1-p}$	$(m+1) \frac{p}{1-p}$	$(1-p)^m$
Geometrické	$\frac{\beta}{1+\beta}$	0	$(1+\beta)^{-1}$

Tabulka 1.1: Parametry charakterizující rozdělení patřící do třídy  $(a, b, 0)$

## 2. Hodnoty parametrů $(a, b, 0)$

### 2.1 Motivace

V předchozí kapitole jsem ukázal, že Poissonovo, negativně binomické, binomické a geometrické rozdělení splňují rovnici (1.1), což implikuje, že podle definice (1) patří do třídy rozdělení  $(a, b, 0)$ . V této kapitole bych chtěl ukázat, že tato rozdělení jsou jediná, které splňují rovnici (1.1), neboli jsou jediná, které do třídy rozdělení typu  $(a, b, 0)$  patří.

Struktura této kapitoly tedy bude:

- Určení množin parametrů rozdělení.
- Důkaz toho, že pokud parametry  $a, b$  nebudou náležet žádné z množin, pak neurčují rozdělení.
- Přejít z množin parametrů  $(a, b, 0)$  k původní parametrizaci.

### 2.2 Množiny parametrů rozdělení

V této kapitole budu Poissonovo, negativně binomické, binomické a geometrické rozdělení vnímat jako rozdělení typu  $(a, b, 0)$  s parametry  $a$  a  $b$ .

Označím  $M_{dist}$ ,  $dist \in \{Poisson, Binom, NegBinom\}$  množiny všech přípustných hodnot parametrů  $a, b$  určující dané rozdělení a množinu  $M$  jako:

$$M = M_{Poisson} \cup M_{NegBinom} \cup M_{Binom}$$


#### 2.2.1 Poissonovo Rozdělení

Poissonovo rozdělení budu nyní vnímat jako rozdělení typu  $(a, b, 0)$  s parametry  $a = 0$  a  $b = \lambda$ . Pro Poissonovo rozdělení platí, že  $\lambda > 0$ .

Množina  $M_{Poisson}$  tedy bude vypadat následovně:

$$M_{Poisson} = \{(a, b) : a = 0, b > 0\}.$$

Vykreslím množinu  $M_{Poisson}$ .



Obrázek 2.1:  $M_{Poiss}$

## 2.2.2 Negativně binomické rozdělení

Jelikož geometrické rozdělení je speciálním případem negativně binomického rozdělení pro  $h = 1$ , parametry budu vymezovat pouze obecně pro negativně binomické rozdělení.

Podle tabulky 1.1 pro negativně binomické rozdělení  $a = \frac{\beta}{1+\beta}$  a  $b = (h-1)\frac{\beta}{1+\beta}$ .

Vyjádřím parametr  $b$  v závislosti na  $a$ . Dostávám  $b = (h-1)a$ .


Pro výraz  $\frac{\beta}{1+\beta}$  platí, že jeho oborem hodnot je interval  $(0,1)$ .

Také platí, že  $h > 0$ , a proto  $h-1 > -1$ .

Dohromady:  $a \in (0,1) \wedge b > -a$ .

$$M_{NegBinom} = \{(a,b) : 0 < a < 1, b > -a\}.$$

Obrázek 2.1 rozšířím o množinu všech přípustných hodnot parametrů definující negativně binomické rozdělení.



Obrázek 2.2:  $M_{Poiss} \cup M_{NegBinom}$


### 2.2.3 Binomické Rozdělení

Pro binomické rozdělení parametr  $a = -\frac{p}{1-p}$  a  $b = (m+1)\frac{p}{1-p}$  tedy  $b$  v závislosti na  $a$  vyjádřím znovu jednoduše:  $b = -(m+1)a$ .

Pro  $p$  je obor hodnot interval  $(0,1)$ , a proto pro  $a$  je obor hodnot  $(-\infty,0)$  a zároveň  $m \in \mathbb{N}$ .

$$M_{Binom} = \{(a,b) : a < 0, b = -(m+1)a, m \in \mathbb{N}\}$$

Do obrázku 2.2 přidáme množinu  $M_{Binom}$ .



Obrázek 2.3:  $M_{Pois} \cup M_{NegBinom} \cup M_{Binom}$

## 2.3 Pravděpodobnostní funkce na doplňku $M$

V této kapitole dokážu, že množiny  $M_{Pois}$ ,  $M_{NegBinom}$  a  $M_{Binom}$  obsahují všechny možné dvojice parametrů, které určují pravděpodobnostní funkci. Tedy: Necht  $(a,b) \notin (M_{Pois} \cup M_{NegBinom} \cup M_{Binom})$ , pak  $p_k$  není nedegenerovaná (ani jedna z pravděpodobností  $p_k$ ,  $k \in 0, 1, 2, \dots$  nemá hodnotu 1) pravděpodobnostní funkce.

Zprvu musím definovat doplněk k  $M$ . Z obrázku 4.3 to bude sjednocení následujících množin:

- $M_1 = \{(a,b) : a + b = 0\}$ .
- $M_2 = \{(a,b) : a + b < 0\}$ .
- $M_3 = \{(a,b) : a < 0, b = -ar, r \in (n, n+1), n \in \mathbb{N}\}$ .
- $M_4 = \{(a,b) : a > 1, a + b > 0\}$ .

### 2.3.1 Množina $M_1$

Tato množina na obrázku 2.3 vyznačuje přímkou  $b = -a$ .

Pro  $p_1$  platí vztah:

$$p_1 = (a + b)p_0.$$

Jelikož  $a + b = 0$ :

$$p_1 = 0 \implies p_2, p_3, \dots = 0.$$

Z toho vyplývá, že  $p_0 = 1$ , což porušuje předpoklad nedegenerovanosti.

### 2.3.2 Množina $M_2$

Množina  $M_2 = \{(a, b) : a + b < 0\}$  je na obrázku 2.3 polorovina s hraniční přímkou  $a = b$ .

Pro  $p_1$  platí:

$$p_1 = (a + b)p_0 \implies p_1 < 0.$$

Což znamená, že  $p_k$  není pravděpodobnostní funkce.

### 2.3.3 Množina $M_3$

Na obrázku 2.3 je množina  $M_3 = \{(a, b) : a < 0, b = -ar, r \in (n, n + 1)\}$  kužel, který má jako strany sousední polopřímky, jež však tato množina neobsahuje.

$$p_k = \left(a - \frac{ar}{k}\right) p_{k-1}.$$

Z toho vyplývá

$$p_k = a \left(1 - \frac{r}{k}\right) p_{k-1}.$$

$a < 0$ , aby tedy  $p_k$  mohla být pravděpodobnostní funkce musí platit:

$$\left(1 - \frac{r}{k}\right) < 0.$$

Za předpokladu existence pravděpodobnostní funkce dostávám vztah:

$$k \leq r.$$

Jelikož  $r \in (n, n + 1)$ :

$$k \leq n.$$

Pro  $p_k$ , kde  $k \leq n$  za předpokladu  $p_0 > 0$  platí:

$$p_k = a \left(1 - \frac{r}{k}\right) p_{k-1} > 0.$$

Pro  $p_{n+1}$  platí:

$$p_{n+1} = a \left(1 - \frac{r}{n+1}\right) p_n.$$

Jelikož  $n + 1 > r$ , tak  $p_{n+1} < 0$  a  $p_k$  proto nemůže být pravděpodobnostní funkce.

### 2.3.4 Množina $M_4$

Na obrázku 2.3 je množina  $M_4 = \{(a,b) : a > 1, a + b > 0\}$  posunutý kužel se stranami definované přímkami  $b = -a$  a  $a = 1$ , které však tato množina neobsahuje.

Z definice 1:

$$p_k = \left(a + \frac{b}{k}\right) p_{k-1}.$$

Ten upravím přičtením a odečtením  $\frac{a}{k}$ :

$$p_k = \left(a + \frac{b}{k} + \frac{a}{k} - \frac{a}{k}\right) p_{k-1}.$$

Z toho vyplývá, že:

$$p_k = \left(\frac{1}{k}(a+b) + a\left(1 - \frac{1}{k}\right)\right) p_{k-1}.$$

Po roznásobení závorek vyjde:

$$p_k = (a+b)\frac{p_{k-1}}{k} + a\frac{k-1}{k}p_{k-1}.$$

Protože první člen je kladný, tak:

$$p_k \geq a\frac{k-1}{k}p_{k-1}.$$

Díky platnosti podmínky, že  $a > 1$  platí:

$$p_k \geq \frac{k-1}{k}p_{k-1}.$$

Rozepíšu pravou stranu:

$$p_k \geq \frac{k-1}{k} \frac{k-2}{k-1} \frac{k-3}{k-2} \cdots \frac{1}{2} p_1.$$

Pokrátí se vše až na  $\frac{p_1}{k}$ , tedy:

$$p_k \geq \frac{p_1}{k}.$$

Pro sumu pravděpodobností platí:

$$\sum_{k=1}^{\infty} p_k \geq p_1 \sum_{k=1}^{\infty} 1/k = \infty.$$

Čímž jsem dokázal, že  $p_k$  není pravděpodobnostní funkce.

## 2.4 Přejchod z $M_{dist}$ k původní parametrizaci

V této kapitole dokážu, že libovolné rozdělení typu  $(a, b, 0)$ , jehož parametry náleží množině  $M_{dist}$ , musí být nutně typu  $dist$ . To sice plyne z úvah v předchozích kapitolách, ale v této kapitole jsem udělal alternativní a především přímý důkaz.

### 2.4.1 Poissonovo rozdělení

Předpokládám, že  $(a,b) \in M_{Poisson} = \{(a,b) : a = 0, b > 0\}$ .

Pro  $p_1$  a  $p_2$  platí:

$$p_1 = bp_0, \quad p_2 = \frac{b^2}{2}p_0.$$

Lehce si uvědomím, že:

$$p_k = \frac{b^k}{k!}p_0.$$

Pro sumu  $p_k$  mám:

$$\sum_{k=0}^{\infty} p_k = p_0 \sum_{k=0}^{\infty} \frac{b^k}{k!} = 1.$$

Z toho pro  $p_0$  vyplývá:

$$p_0 = \left( \sum_{k=0}^{\infty} \frac{b^k}{k!} \right)^{-1}.$$

Suma je však rovna Taylorovu rozvoji  $e^b$ , tedy:

$$p_0 = e^{-b}.$$

Celkem:

$$p_k = \frac{b^k}{k!}p_0 = \frac{b^k}{k!}e^{-b}.$$

Takže jsem dokázal, že pokud  $(a,b) \in M_{Poisson}$ , tak  $p_k$  je pravděpodobnostní funkce Poissonova rozdělení.

### 2.4.2 Negativně binomické rozdělení

Nyní předpokládám, že  $a,b \in M_{NegBinom} = \{(a,b) : 0 < a < 1, b > -a\}$ .

$$p_1 = (a+b)p_0 = a \left( 1 + \frac{b}{a} \right) p_0,$$

$$p_2 = \left( a + \frac{b}{2} \right) (a+b)p_0 = a \left( 1 + \frac{b}{2a} \right) a \left( 1 + \frac{b}{a} \right) p_0,$$

$$\begin{aligned} p_3 &= a \left( 1 + \frac{b}{3a} \right) a \left( 1 + \frac{b}{2a} \right) a \left( 1 + \frac{b}{a} \right) p_0 \\ &= a^3 \frac{1}{3} \left( 3 + \frac{b}{a} \right) \frac{1}{2} \left( 2 + \frac{b}{a} \right) \left( 1 + \frac{b}{a} \right) p_0. \end{aligned}$$

Pro  $p_k$  platí:

$$p_k = a^k \frac{\left( k + \frac{b}{a} \right) \left( k - 1 + \frac{b}{a} \right) \dots \left( 1 + \frac{b}{a} \right)}{k!} p_0 = a^k \binom{k + \frac{b}{a}}{k} p_0.$$



Ke každému členu přičtu a odečtu 1:

$$p_k = a^k \frac{\left(k + \frac{b}{a} + 1 - 1\right) \left(k - 1 + \frac{b}{a} + 1 - 1\right) \dots \left(\frac{b}{a} + 1\right)}{k!} p_0,$$

$$p_k = a^k \frac{(-1)(-\frac{b}{a} - 1) \dots (-1) \left(-k - \frac{b}{a} - 1 + 1\right)}{k!} p_0.$$

Což upravím na:

$$p_k = a^k (-1)^k \binom{-\frac{b}{a} - 1}{k} p_0.$$

Pro sumu pravděpodobostí platí:

$$\sum_{k=0}^{\infty} p_k = p_0 \sum_{k=0}^{\infty} (-a)^k \binom{-\frac{b}{a} - 1}{k} = 1.$$

Při formulaci následujícího tvrzení budu vycházet z Lang (1999)(str.57,58).

**Tvrzení 1.** *Nechť  $r \in \mathbb{R}$  a  $k \in \mathbb{N}_0$ , potom platí:*

$$(1+x)^r = \sum_{k=0}^{\infty} \binom{r}{k} x^k, \quad -1 < x < 1.$$

Z tvrzení 1 vyplývá:

$$p_0 (1-a)^{-\frac{b}{a}-1} = 1.$$

Pro  $p_0$  tedy:

$$p_0 = (1-a)^{\frac{b}{a}+1}. \quad (2.1)$$

Celkem:

$$p_k = \binom{k + \frac{b}{a} - 1}{k} a^k (1-a)^{\frac{b}{a}+1}.$$

Pro  $\beta = \frac{1-a}{a}$  a  $h = \frac{b}{a}$  to je negativně binomické rozdělení.

### 2.4.3 Binomické rozdělení

Nyní uvažuji  $(a,b) \in M_{Binom} = \{(a,b) : a < 0, b = -(m+1)a, m \in \mathbb{N}\}$ .

První ukážu, že pro  $k > m$  je  $p_k = 0$ :

$$p_{m+1} = \left(a + \frac{-(m+1)a}{m+1}\right) p_m = 0 \implies p_k = 0 \quad k > m,$$

$$p_k = \left(a + \frac{-a(m+1)}{k}\right) p_{k-1} = -a \left(\frac{m - (k-1)}{k}\right) p_{k-1}.$$

Pro první členy:

$$\begin{aligned} p_1 &= -a m p_0, \\ p_2 &= -a \frac{m-1}{2} p_1 = (-a)^2 \frac{m(m-1)}{2} p_0, \\ p_3 &= -a \frac{m-2}{3} p_2 = (-a)^3 \frac{m(m-1)(m-2)}{3 * 2} p_0. \end{aligned}$$

Pro  $p_k$  tedy platí:

$$p_k = (-a)^k \frac{m(m-1)\dots(m-k+1)}{k!} p_0.$$

Což je přesně:

$$p_k = (-a)^k \binom{m}{k} p_0.$$

Pro sumu pravděpodobností platí:

$$\sum_{k=0}^{\infty} p_k = \sum_{k=0}^m p_k = p_0 \sum_{k=0}^m (-a)^k \binom{m}{k} = 1.$$

Tedy:

$$p_0 = \left( \sum_{k=0}^m (-a)^k \binom{m}{k} \right)^{-1}.$$

Z rovnice (2.1) vím, že pro negativně binomické rozdělení  $p_0 = (1-a)^{\frac{b+a}{a}}$ . Teď ukážu, že tento vztah platí i na  $M_{Binom}$  a dodefinuji ho na  $M_{Poiiss}$ .

**Tvrzení 2.** *Nechť existuje nedegenerovaná pravděpodobnostní funkce  $p_k$  definovaná dle definice 1, pak*

$$p_0 = (1-a)^{\frac{b+a}{a}}, \quad (a,b) \in M, \quad a \neq 0,$$

$$p_0 = \lim_{a \rightarrow 0} (1-a)^{\frac{b+a}{a}} = e^{-b}, \quad (a,b) \in M, \quad a = 0.$$

*Důkaz.* Jelikož vím, že  $p_k$  je nedegenerovaná pravděpodobnostní funkce, tak díky poznatkům z kapitoly 2 můžu říct, že  $p_k$  je pravděpodobnostní funkce binomického, negativně binomického nebo Poissonova rozdělení. U těch znám  $a, b$  a  $p_0$  z tabulky 1.1. Pro Poissonovo rozdělení  $a = 0, b = \lambda, p_0 = e^{-\lambda}$ . Podle tvrzení:

$$p_0 = e^{-b} = e^{-\lambda}.$$

Jelikož se  $p_0$  spočítané z rovnice v tvrzení shoduje s  $p_0$  pro Poissonovo rozdělení, tak vidím, že pro Poissonovo rozdělení tvrzení platí.

Pro negativně binomické  $a = \frac{\beta}{\beta+1}, b = (h-1)\frac{\beta}{\beta+1}, p_0 = (1+\beta)^{-h}$ . Dosadím do rovnice z tvrzení:

$$p_0 = (1-a)^{\frac{b+a}{a}} = \left(1 - \frac{\beta}{\beta+1}\right)^{\frac{\frac{\beta}{\beta+1}(1+(h-1))}{\frac{\beta}{\beta+1}}} = \left(\frac{1}{\beta+1}\right)^h = (1+\beta)^{-h}.$$

Znovu docházím k závěru, že  $p_0$  se shodují.

Pro binomické rozdělení  $a = -\frac{p}{1-p}$ ,  $b = (m+1)\frac{p}{1-p}$ ,  $p_0 = (1-p)^m$ .

$$p_0 = \left(1 + \frac{p}{1-p}\right)^{\frac{\frac{p}{1-p}m}{-\frac{p}{1-p}}} = (1-p)^m.$$

Jelikož  $p_0$  jsou znovu shodné, tak tvrzení platí na celém  $M$  a je tedy dokázané.  $\square$

dle tvrzení 2:

$$p_0 = \left((1-a)^{\frac{-a(m+1)+a}{a}}\right)^{-1}.$$

Celkem:

$$p_k = \binom{m}{k} (-a)^k \left((1-a)^{-1}\right)^m.$$

Což je binomické rozdělení s parametrem  $p = \frac{a}{a-1}$ .

## 3. Odhady parametrů $a, b$

### 3.1 Vyjádření pravděpodobnostní funkce

Z definice vím, že pro rozdělení typu  $(a, b, 0)$  platí:

$$p_k = p_{k-1} \left( a + \frac{b}{k} \right).$$

Odvodím vztah pro  $k=n$   
pro  $k=1$

$$p_1 = p_0(a + b).$$

pro  $k=2$

$$p_2 = p_1 \left( a + \frac{b}{2} \right).$$

kde však vím, že  $p_1 = p_0(a + b)$ , tedy:

$$p_2 = p_0(a + b) \left( a + \frac{b}{2} \right).$$

Vidím, že pro  $p_n$  platí:

$$p_n = p_0 \prod_{k=1}^n \left( a + \frac{b}{k} \right).$$

### 3.2 Metoda maximální věrohodnosti

Metoda maximální věrohodnosti je standardní metoda hledání odhadu parametrů. V literatuře je popsána například v knize Anděl (2007).

**Definice 3.** *Nechť  $X_1, X_2 \dots X_n$  je náhodný výběr z rozdělení s hustotou  $f(x|\theta_0)$  vzhledem k míře  $\mu$  náležících do parametrického modelu  $\mathcal{F} = \{\text{rozdělení s hustotou } f(x|\theta), \theta \in \Theta \subseteq \mathbb{R}^d\}$ . Předpokládáme, že různým hodnotám parametrů  $\theta_1 \neq \theta_2$  odpovídají různé hustoty  $f(\cdot|\theta_1) \neq f(\cdot|\theta_2)$ . Náhodnou funkci*

$$L_n(\theta) = \prod_{i=1}^n f(X_i|\theta)$$

*nazýváme věrohodnostní funkcí (věrohodností) pro parametr  $\theta$  v modelu  $\mathcal{F}$ .*

**Definice 4.** *Maximálně věrohodný odhad parametru  $\theta$  v modelu  $\mathcal{F}$  je definován jako*

$$\hat{\theta}_n = \arg \max_{\theta \in \Theta} L_n(\theta).$$

**Definice 5.** *Náhodnou funkci*

$$l_n(\theta) = \log(L_n(\theta)) = \sum_{i=1}^n \log f(X_i|\theta)$$

*nazýváme logaritmickou věrohodností.*

**Definice 6.** *Náhodný vektor*

$$U(\theta|X) = \sum_{i=1}^n \frac{\partial}{\partial \theta} \log f(X_i|\theta)$$

*nazýváme skórovou statistikou.*

Pro náhodný výběr  $X_1, X_2 \dots X_n$  z rozdělení typu  $(a, b, 0)$  platí:

$$L_n(a, b) = \prod_{i=1}^n (p_{X_i}).$$

Dosadím pozorování z minulého kroku:

$$L_n(a, b) = \prod_{i=1}^n \left( p_0 \prod_{k=1}^{X_i} \left( a + \frac{b}{k} \right) \right).$$

Napišu a upravím logaritmickou věrohodnostní funkci:

$$\begin{aligned} l_n(a, b) &= \sum_{i=1}^n \left( \log \left( p_0 \prod_{k=1}^{X_i} \left( a + \frac{b}{k} \right) \right) \right), \\ l_n(a, b) &= \sum_{i=1}^n \left( \log(p_0) + \sum_{k=1}^{X_i} \log \left( a + \frac{b}{k} \right) \right), \\ l_n(a, b) &= n \log(p_0) + \sum_{i=1}^n \sum_{k=1}^{X_i} \log \left( a + \frac{b}{k} \right). \end{aligned}$$

Dosadím  $p_0$  z tvrzení 2 s tím, že pro  $a = 0$  je rovnice dodefinovaná limitně:

$$\begin{aligned} l_n(a, b) &= n \log(1 - a)^{\frac{b+a}{a}} + \sum_{i=1}^n \sum_{k=1}^{X_i} \log \left( a + \frac{b}{k} \right), \\ l_n(a, b) &= \frac{n(b+a)}{a} \log(1 - a) + \sum_{i=1}^n \sum_{k=1}^{X_i} \log \left( a + \frac{b}{k} \right). \end{aligned} \quad (3.1)$$

Odhadování parametrů  $a, b$  z (3.1) by bylo velmi obtížné. Jelikož se pokusím najít maximálně věrohodný odhad  $a, b$ , tedy pokusím se maximalizovat věrohodnostní funkci na celém  $M$ , spočítám maximální logaritmické věrohodnosti pro jednotlivé  $M_{dist}$ , spočítám odhady parametrů a vyberu tu, jejíž funkční hodnota v odhadnutých parametrech bude maximální. Protože metoda maximální věrohodnosti nezáleží na parametrizaci, tak budeme pro potřeby maximalizace věrohodnosti používat původní parametrizaci a potom dopočítám odhady pro parametry  $a, b$ .

### 3.2.1 MLE pro Poissonovo rozdělení

Nechť  $(a,b) \in M_{Poiiss}$ , pak:

$$p_k = \frac{\lambda^k}{k!} e^{-\lambda} \quad k = 1, 2, \dots, \quad \lambda > 0.$$

Předpokládám, že mám soubor dat obsahující  $n$  pozorování  $X_1, X_2, \dots, X_n$ , o kterých předpokládám, že jsou nezávislé a stejně rozdělené (i.i.d.) náhodné veličiny z Poissonova rozdělení s parametrem  $\lambda$ . Potom:

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

Z toho získám logaritmickou věrohodnostní funkci:

$$l_n(\lambda) = \sum_{i=1}^n [-\lambda + X_i \log(\lambda) - \log(X_i!)].$$

Tedy pro maximálně věrohodný odhad  $\lambda$ :

$$l_{Poiiss} = \sum_{i=1}^n [-\hat{\lambda} + X_i \log(\hat{\lambda}) - \log(X_i!)].$$

Abych zjistil maximálně věrohodný odhad  $\lambda$ , musím zderivovat podle  $\lambda$ .

$$\frac{\partial l_{Poiiss}}{\partial \lambda} = \sum_{i=1}^n \left[ -1 + \frac{X_i}{\lambda} \right] = 0.$$

Upravím, abych vyřešil pro  $\lambda$ :

$$\sum_{i=1}^n X_i = n\lambda$$

Maximálně věrohodný odhad pro  $\lambda$  je:

$$\hat{\lambda} = \frac{\sum_{i=1}^n X_i}{n} = \overline{X}_n.$$

Pokud tedy funkce  $l_{Poiiss}$  bude mít větší funkční hodnotu než  $l_{NegBinom}$  a  $l_{Binom}$ , budu odhadovat parametry  $a, b$  podle MLE pro Poissonovo rozdělení, tedy  $a = 0$  a maximálně věrohodným odhadem  $b$  bude:

$$\hat{b} = \hat{\lambda} = \overline{X}_n.$$

### 3.2.2 MLE pro negativně binomické rozdělení

Nechť  $(a,b) \in M_{NegBinom}$ , pak:

$$p_k = \binom{h+k-1}{k} \left( \frac{1}{\beta+1} \right)^h \left( \frac{\beta}{\beta+1} \right)^k, \quad k = 1, 2, \dots, \quad \beta > 0, \quad h > 0.$$

Protože pro negativně binomické rozdělení  $E(N) = h\beta$  a  $Var(N) = h\beta(1+\beta)$ , budu uvažovat negativně binomické rozdělení jako vhodného kandidáta na odhad parametrů pouze tehdy, když výběrový průměr bude menší než výběrový rozptyl.

Předpokládám, že mám soubor dat obsahující  $n$  pozorování  $X_1, X_2, \dots, X_n$ , o kterých předpokládám, že jsou nezávislé a stejně rozdělené (i.i.d.) náhodné veličiny z negativně binomického rozdělení s parametry  $h$  a  $\beta$ . Potom:

$$L_n = \prod_{i=1}^n p_{X_i} = \prod_{i=1}^n \binom{h + X_i - 1}{X_i} \left(\frac{1}{\beta + 1}\right)^h \left(\frac{\beta}{\beta + 1}\right)^{X_i}.$$

Z toho získám logaritmickou věrohodnostní funkci:

$$l_n(h, \beta) = \sum_{i=1}^n \log \binom{h + X_i - 1}{X_i} + h \log \left(\frac{1}{\beta + 1}\right) + X_i \log \left(\frac{\beta}{\beta + 1}\right).$$

Tu upravím následovně:

$$l_n(h, \beta) = \sum_{i=1}^n \log \binom{h + X_i - 1}{X_i} - h \log(\beta + 1) + X_i \log(\beta) - X_i \log(\beta + 1).$$

Celkem pro maximálně věrohodné odhady  $\beta$  a  $h$ :

$$l_{NegBinom} = \sum_{i=1}^n \log \binom{\hat{h} + X_i - 1}{X_i} - \hat{h} \log(\hat{\beta} + 1) + X_i \log(\hat{\beta}) - X_i \log(\hat{\beta} + 1).$$

Spočítám a upravím parciální derivace.

$$\begin{aligned} \frac{\partial l_n(h, \beta)}{\partial h} &= - \sum_{i=1}^n \log(1 + \beta) + \sum_{i=1}^n \frac{\partial}{\partial h} \log \left( \frac{(h + X_i - 1) \dots h}{X_i!} \right) \\ \frac{\partial l_n(h, \beta)}{\partial h} &= -n \log(1 + \beta) + \sum_{i=1}^n \left( \frac{\partial}{\partial h} \log \prod_{m=1}^{X_i} (h + X_i - m) - \frac{\partial}{\partial h} \log X_i! \right), \\ \frac{\partial l_n(h, \beta)}{\partial h} &= -n \log(1 + \beta) + \sum_{i=1}^n \sum_{m=1}^{X_i} \frac{1}{(h + X_i - m)}, \\ \frac{\partial l_n(h, \beta)}{\partial \beta} &= \sum_{i=1}^n \left[ \frac{X_i}{\beta} - \frac{h + X_i}{\beta + 1} \right]. \end{aligned}$$

Položím rovnici derivovanou podle  $\beta$  rovnou nule a upravím:

$$\frac{1}{\beta} \sum_{i=1}^n X_i - \frac{1}{\beta + 1} \sum_{i=1}^n X_i - \frac{nh}{\beta + 1} = 0,$$

$$\frac{\beta + 1}{\beta} \sum_{i=1}^n X_i - \sum_{i=1}^n X_i - nh = 0,$$

$$\sum_{i=1}^n X_i \left( \frac{\beta + 1}{\beta} - 1 \right) = nh,$$

$$\frac{1}{\beta} \sum_{i=1}^n X_i = nh,$$

$$\frac{1}{h\beta} = n \left( \sum_{i=1}^n X_i \right)^{-1}.$$

Dostávám:

$$\beta h = \overline{X_n}.$$

Z rovnice derivované podle  $h$ :

$$n \log(1 + \beta) = \sum_{i=1}^n \sum_{m=1}^{X_i} \frac{1}{(h + X_i - m)}.$$

Rovnice se dají vyřešit numericky nahrazením  $\hat{\beta} = \frac{\overline{X_n}}{\hat{h}}$  ve druhé rovnici:

$$H(\hat{h}) = n \log \left( 1 + \frac{\overline{X_n}}{\hat{h}} \right) - \sum_{i=1}^n \sum_{m=1}^{X_i} \frac{1}{(\hat{h} + X_i - m)} = 0.$$

Budu řešit numericky Newtonovou metodou. Pro  $k$ -tou iteraci mám vztah:

$$h_k = h_{k-1} - \frac{H(h_{k-1})}{H'(h_{k-1})}.$$

Pokud tedy funkce  $l_{NegBinom}$  bude mít větší funkční hodnotu než  $l_{Pois}$  a  $l_{Binom}$ , hodnoty parametrů budou:

$$a = \frac{\overline{X_n}}{\hat{h} + \overline{X_n}}, b = \frac{(\hat{h} - 1)\overline{X_n}}{\hat{h} + \overline{X_n}}.$$

### 3.2.3 MLE pro binomické rozdělení

Nechť  $(a, b) \in M_{Binom}$  potom:

$$p_k = \binom{m}{k} p^k (1-p)^{m-k}, \quad k = 1, 2, \dots, \quad 0 < p < 1, \quad m \in \mathbb{N}.$$

Protože pro binomické rozdělení  $E(N) = mp$  a  $Var(N) = mp(1-p)$  budu uvažovat binomické rozdělení jako vhodného kandidáta na odhad parametrů pouze tehdy, když bude výběrový průměr větší než výběrový rozptyl.

Pro soubor dat, který obsahuje  $n$  pozorování:  $X_1, X_2, \dots, X_n$ , o kterých předpokládám, že jsou nezávislé a stejně rozdělené (i.i.d.) náhodné veličiny z binomického rozdělení s  $p$  a  $m$ . Platí:

$$L_n(p, m) = \prod_{i=1}^n \left[ \binom{m}{X_i} p^{X_i} (1-p)^{m-X_i} \right].$$

Logaritmická věrohodnostní funkce je:

$$l_n(p, m) = \sum_{i=1}^n \left[ \log \binom{m}{X_i} + X_i \log(p) + (m - X_i) \log(1-p) \right].$$

Pro maximálně věrohodné odhady  $m$  a  $p$ :

$$l_{Binom} = \sum_{i=1}^n \left[ \log \binom{\hat{m}}{X_i} + X_i \log(\hat{p}) + (\hat{m} - X_i) \log(1-\hat{p}) \right].$$

Z logaritmické věrohodnostní rovnice s parametry  $p$  a  $m$  vyjádřím maximálně věrohodný odhad  $p$ .



$$\frac{\partial l_n(p, m)}{\partial p} = \sum_{i=1}^n \left[ \frac{X_i}{p} - \frac{m - X_i}{1 - p} \right],$$

Položím rovno 0 a vyřeším pro  $p$ :

$$\frac{1}{p} \sum_{i=1}^n X_i + \frac{1}{1-p} \sum_{i=1}^n X_i - \frac{nm}{1-p} = 0,$$

$$\frac{1-p}{p} \sum_{i=1}^n X_i + \sum_{i=1}^n X_i = nm,$$

$$\frac{1}{p} \sum_{i=1}^n X_i = nm,$$

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

Celkem:

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

Kde  $\hat{m}$  získáme tímto způsobem:

- Začnu pro  $\hat{m}$ , jako s největší napozorovanou hodnotou.
- Spočítám  $\hat{p}$ .
- Spočítám  $l_{Binom}$  pro tyto hodnoty.
- Zvětším  $\hat{m}$  o 1.
- Opakuju předešlé kroky, dokud nenajdu lokální maximum. Tedy vyberu poslední takové parametry, pro které předchozí výpočet  $l_{Binom}$  měl menší hodnotu.

Pokud bude  $l_{Binom}$  větší než  $l_{Poiss}$  a  $l_{NegBinom}$ , tak pro  $\hat{a}$  platí:

$$\hat{a} = \frac{\overline{X}_n}{-\hat{m} + \overline{X}_n}.$$

a pro  $\hat{b}$ :

$$\hat{b} = \frac{\overline{X}_n(\hat{m} + 1)}{\hat{m} - \overline{X}_n}.$$

## 4. Simulační studie

V rámci simulační studie vygeneruji data, jejichž rozdělení budu brát jako neznámé, z Poissonova, negativně binomického a binomického rozdělení. Vypočítám si všechny  $l_{dist}$ ,  $dist \in \{Poiss, Binom, NegBinom\}$  (pokud to bude dávat smysl) pro každá data zvlášť. Vyberu pro každý soubor dat  $l_{dist}$ , které bude maximální a odhadnu pro něj parametry  $a$  a  $b$ . Simulační studii budu dělat v programu Wolfram Mathematica 12.3.

### 4.1 Data z Poissonova rozdělení

Kód pro tuto podkapitolu je v příloze A.1. Jako první jsem určil vztah mezi výběrovým rozptylem a výběrovým průměrem. Zjistil jsem, že pro vygenerované data je větší výběrový rozptyl, takže jsem se snažil najít hodnoty  $l_{Poiss}$  a  $l_{NegBinom}$ . Abych odhadl  $l_{Poiss}$ , tak jsem první musel najít maximálně věrohodný odhad  $\lambda$ . Vyšlo:

$$\hat{\lambda} = 9.972.$$

Celkem pro  $l_{Poiss}$ :

$$l_{Poiss} = -2574.47.$$

Pro to abych určil hodnotu  $l_{NegBinom}$  musím najít maximálně věrohodný odhad  $h$  a  $\beta$ . Vyšlo:

$$\hat{h} = 298.951 \quad , \quad \hat{\beta} = 0.0333566.$$


Celkem:

$$l_{NegBinom} = -4522.27.$$

Jelikož  $l_{Poiss}$  s odhadem parametru  $\hat{\lambda} = 9.972$  má větší hodnotu než  $l_{NegBinom}$  spočítám  $a$  a  $b$  pro  $M_{Poiss}$ :

$$\hat{a} = 0 \quad , \quad \hat{b} = 9.972.$$

V grafu porovnám napozorovaná data s odhadnutou pravděpodobnostní funkcí.



Obrázek 4.1: Porovnání odhadu s daty z Poissonova rozdělení

## 4.2 Data z negativně binomického rozdělení

Kód pro tuto podkapitolu je v příloze A.2. Znovu jsem jako první určil vztah mezi výběrovým rozptylem a výběrovým průměrem. Znovu jsem také zjistil, že pro vygenerované data je větší výběrový rozptyl, takže jsem se snažil najít hodnoty  $l_{Poiiss}$  a  $l_{NegBinom}$ . Abych odhadl  $l_{Poiiss}$ , musel jsem najít maximálně věrohodný odhad  $\lambda$ . Vyšlo:

$$\hat{\lambda} = 8.303.$$

Celkem pro  $l_{Poiiss}$ :

$$l_{Poiiss} = -4321.62.$$

Abych určil hodnotu  $l_{NegBinom}$ , musím najít maximálně věrohodný odhad  $h$  a  $\beta$ . Vyšlo:

$$\hat{h} = 1.95432. \quad , \quad \hat{\beta} = 4.24853.$$


Celkem:

$$l_{NegBinom} = -3102.63.$$

Jelikož  $l_{NegBinom}$  s odhadnutými parametry má větší hodnotu než  $l_{Poiiss}$ , spočítám  $a$  a  $b$  pro  $M_{NegBinom}$ :

$$\hat{a} = 0.80947 \quad , \quad \hat{b} = 0.772497.$$

V grafu porovnám napozorovaná data a odhadnutou pravděpodobnostní funkci.



Obrázek 4.2: Porovnání odhadu s daty z negativně binomického rozdělení

## 4.3 Data z binomického rozdělení

Kód pro tuto podkapitolu je v příloze A.3. Výběrový průměr je tentokrát větší než výběrový rozptyl. Tentokrát jsem tedy hledal hodnoty  $l_{Poiiss}$  a  $l_{Binom}$ . Maximálně věrohodný odhad  $\lambda$  vyšel:

$$\hat{\lambda} = 24.122.$$

Celkem pro  $l_{Poiiss}$ :

$$l_{Poiiss} = -2716.06.$$

Pro maximálně věrohodné odhady  $m$  a  $p$  vyšlo:

$$\hat{m} = 41 \quad , \quad \hat{p} = 0.588341.$$


Celkem:

$$l_{Binom} = -2566.74.$$

Jelikož  $l_{Binom}$  s odhadnutými parametry má větší hodnotu než  $l_{Poiss}$ , spočítám  $a$  a  $b$  pro  $M_{Binom}$ :

$$\hat{a} = -1.4292 \quad , \quad \hat{b} = 60.0263.$$

V grafu porovnám napozorovaná data a odhadnutou pravděpodobnostní funkci.



Obrázek 4.3: Porovnání odhadu s daty z binomického rozdělení

# Závěr

V práci jsem zprvu dokázal, že Poissonovo, negativně binomické i binomické rozdělení do třídy  $(a, b, 0)$  náleží. Poté jsem provedl úplný rozklad množiny přípustných hodnot parametrů  $a, b$ , včetně charakterizace, kterým typům rozdělení jednotlivé podmnožiny náleží. Následně jsem prozkoumal použití metody maximální věrohodnosti pro odhad parametrů  $a, b$ . Odvodil jsem logaritmickou věrohodnostní funkci, z níž jsem kvůli složitosti neodhadl parametry  $a, b$  a udělal metodu maximální věrohodnosti na množinách přípustných hodnot pro jednotlivá rozdělení. Nakonec jsem udělal simulační studii, ve které jsem využíval předešlých pozorování o odhadech pomocí metody maximální věrohodnosti.

# Seznam použité literatury

ANDĚL, J. (2007). *Základy matematické statistiky*. Druhé opravené vydání. Matfyzpress, Praha. ISBN 80-7378-001-1.

KLUGMAN, S. A., PANJER, H. H. a E., W. G. (2019). *Loss Models: From Data to Decisions*. Fifth Edition. John Wiley and Sons, Inc., Hoboken. ISBN 9781119523734.

LANG, S. (1999). *Complex Analysis*. Fourth Edition. Springer Science & Business Media, New York. ISBN 978-1-4757-3083-8.

# Seznam obrázků

2.1	$M_{Pois}$ . . . . .	8
2.2	$M_{Pois} \cup M_{NegBinom}$ . . . . .	8
2.3	$M_{Pois} \cup M_{NegBinom} \cup M_{Binom}$ . . . . .	9
4.1	Porovnání odhadu s daty z Poissonova rozdělení . . . . .	22
4.2	Porovnání odhadu s daty z negativně binomického rozdělení . . .	23
4.3	Porovnání odhadu s daty z binomického rozdělení . . . . .	24

# Seznam tabulek

1.1	Parametry chakaracterizující rozdělení patřící do třídy $(a, b, 0)$ . .	6
-----	---	---



# A. Přílohy

## A.1 Kód pro data z Poissonova rozdělení

```
SeedRandom[101]
data = RandomVariate[PoissonDistribution[10], 1000];

Variance[data] > Mean[data]

lPois [lambda_] := Sum[-lambda + data[[i]] Log[lambda] -
Log[data[[i]]!], {i, 1, Length[data]}]

lNegBinom[h_, Beta_] := Sum[Log[Binomial[h + data[[i]] - 1, data[[i]]]]
-h Log[Beta + 1] + data[[i]] Log[Beta] - Log[data[[i]] (Beta + 1)],
{i, 1, Length[data]}]

odhadlambda = N[Mean[data]]

m1 = Max[data];

momenthodhadh = N[Mean[data]/( Variance[data]/Mean[data] - 1)]

Newton[H_, h0_, n_] := NestList[# - H[#]/H'[#] &, h0, n]

H[h_] = Length[data] Log[1 + Mean[data]/h] -
Sum[Sum[1/(h + data[[i]] - m), {m, 1, data[[i]]}], {i, 1,
Length[data]}];

odhadhseznam = Newton[H, momenthodhadh, 10] // N;

odhadh = odhadhseznam[[10]]

HodnotaPois = lPois[odhadlambda]

odhadbeta = (1 - (1/(Mean[data]/odhadh + 1)))/(1/(Mean[data]/odhadh +
1))

HodnotaNegBinom = lNegBinom[odhadh, odhadbeta]

odhadb = N[Mean[data]]

odhada = 0

Show[Histogram[data, Automatic, "Probability"],
DiscretePlot[
Table[PDF[PoissonDistribution[\[Lambda]],
k], {\[Lambda], {9.972}}] // Evaluate, {k, 0, 30},
```

```
PlotRange -> All, PlotMarkers -> Automatic]]
```

## A.2 Kód pro data z negativně binomického rozdělení

```
SeedRandom[101]
data = RandomVariate[NegativeBinomialDistribution[2, 0.2], 1000];

Variance[data] > Mean[data]

lPoisson[lambda_] :=
  Sum[-lambda + data[[i]] Log[lambda] - Log[data[[i]]!], {i, 1,
    Length[data]}]

lNegBinom[h_, Beta_] :=
  Sum[Log[Binomial[h + data[[i]] - 1, data[[i]]]] - h Log[Beta + 1] +
    data[[i]] Log[Beta] - data[[i]] Log[(Beta + 1)], {i, 1,
    Length[data]}]

odhadlambda = N[Mean[data]]

momenthodhadh = N[Mean[data]/(Variance[data]/Mean[data] - 1)]

Newton[H_, h0_, n_] := NestList[# - H[#]/H'[#] &, h0, n]

H[h_] = Length[data] Log[1 + Mean[data]/h] -
  Sum[Sum[1/(h + data[[i]] - m), {m, 1, data[[i]]}], {i, 1,
    Length[data]}];

odhadhseznam = Newton[H, momenthodhadh, 10] // N;

odhadh = odhadhseznam[[10]]

HodnotaPoisson = lPoisson[odhadlambda]

odhadbeta = (1 - (1/(Mean[data]/odhadh + 1)))/(1/(Mean[data]/odhadh +
  1))

HodnotaNegBinom = lNegBinom[2, odhadbeta]

odhada = Mean[data]/(odhadhseznam[[10]] + Mean[data])

odhadb = odhada (odhadhseznam[[10]] - 1)

Show[Histogram[data, Automatic, "Probability"],
```

```

DiscretePlot[
  Table[PDF[NegativeBinomialDistribution[h, 1/(odhadbeta + 1)],
    k], {h, {1.9543238862436016}}] // Evaluate, {k, 0, 30},
  PlotRange -> All, PlotMarkers -> Automatic]]

```

### A.3 Kód pro data z binomického rozdělení

```

SeedRandom[101]
data = RandomVariate[BinomialDistribution[40, 0.6], 1000];

Mean[data] > Variance[data]

lPoiss [lambda_] :=
  Sum[-lambda + data[[i]] Log[lambda] - Log[data[[i]]!], {i, 1,
    Length[data]}]

lBinom[p_, m_] :=
  Sum[Log[Binomial[m, data[[i]]]] +
    data[[i]] Log[p] + (m - data[[i]]) Log[1 - p], {i, 1,
    Length[data]}]

odhadlambda = N[Mean[data]]

m1 = Max[data];

odhadp[m_] := N[Mean[data]/m]

HodnotaPoiss = lPoiss[odhadlambda]

HodnotaBinom =
  N[Maximize[{lBinom[odhadp[odhadm], odhadm], odhadm >= m1,
    odhadm \[Element] Integers}, odhadm]]

odhadm = 41;

odhada = N[Mean[data]/(Mean[data] - odhadm)]

odhadb = N[Mean[data] (odhadm + 1)/(-Mean[data] + odhadm)]

Show[Histogram[data, Automatic, "Probability"],
  DiscretePlot[
    Table[PDF[BinomialDistribution[41, p],
      k], {p, {0.5819513536725999}}] // Evaluate, {k, 0, 30},
    PlotRange -> All, PlotMarkers -> Automatic]]

```