

# Nestranný odhad

# Parametr $\theta$

- Máme statistický (výběrový) soubor, který je realizací náhodného výběru  $X_1, X_2, X_3, \dots, X_n$  z pravděpodobnostní distribuce, která je kompletně stanovena jedním nebo více parametry – **modelové parametry**.
- Statistická veličina, která nás zajímá, odpovídá určité vlastnosti modelové distribuce, která může být sama popsána modelovými parametry.
- Taková vlastnost modelové distribuce se nazývá **parametr  $\theta$** .
- Např. v Poiss( $\lambda$ ) rozdělení je modelovým parametrem  $\lambda$ . Parametrem zájmu může být třeba samotné  $\lambda$  nebo třeba pravděpodobnost, že jev nenastane  $e^{-\lambda}$ .
- Každý parametr  $\theta$  závisí jenom na statistickém souboru.

# Odhad

ESTIMATE. An *estimate* is a value  $t$  that only depends on the dataset  $x_1, x_2, \dots, x_n$ , i.e.,  $t$  is some function of the dataset only:

$$t = h(x_1, x_2, \dots, x_n).$$

- Popis odhadu je spíše formální, ale myšlenka spočívá ve skutečnost, že funkce  $t$  spočítaná ze statistického souboru mi dá nějakou představu o parametru  $\theta$  reálné distribuce.
- Několik odhadů jsme už poznali – viz tabulka v přednášce 6 na str. 14 – jsou to tedy různé číselné hodnoty, množiny čísel nebo samotné křivky.
- Např.:
  - $\lambda$  je střední hodnota modelové distribuce, podle zákona velkých čísel je výběrový průměr  $\bar{x}_n$  přirozeným odhadem pro  $\lambda$ .
  - pro pravděpodobnost, že náhodná proměnná s rozdělením Poiss( $\lambda$ ) bude nabývat nulové hodnoty může být přirozeným odhadem četnost nul ve statistickém souboru  $\frac{\text{number of } x_i \text{ equal to zero}}{n}$  nebo odhad  $\exp(-\bar{x}_n)$

# Odhad

- Z předchozího plyne, že můžeme vymyslet několik odhadů pro daný parametr  $\theta$ .
- Kdy je jeden odhad lepší než jiný?
- Existuje nejlepší možný odhad?
- Odpověď musí být negativní, protože nemůžeme říct nic jistého o různých odhadech, protože sami jsou spočítány z náhodného statistického souboru.
- Jediné co můžeme říci je, s jakou pravděpodobností jsou jednotlivé odhady vzdáleny od parametru  $\theta$ .
- **Odhadová funkce** je vlastně metoda jak počítat odhady. Je to vlastně speciální případ výběrové charakteristiky.
- Odhad je číslo, vypočítané ze statistického souboru.

ESTIMATOR. Let  $t = h(x_1, x_2, \dots, x_n)$  be an estimate based on the dataset  $x_1, x_2, \dots, x_n$ . Then  $t$  is a realization of the random variable



$$T = h(X_1, X_2, \dots, X_n).$$

The random variable  $T$  is called an *estimator*.

# Chování odhadových funkcí

- Mějme  $\text{Poiss}(\mu)$  pravděpodobnostní rozdělení a naměříme 30 realizací náhodného výběru z  $F$ .
- Chceme odhadnout pravděpodobnost  $p_0$ , že náhodná proměnná  $x = 0$ .
- Zvolíme dvě odhadové funkce  $S$  a  $T$   $S = \frac{\text{number of } X_i \text{ equal to zero}}{n}$  and  $T = e^{-\bar{X}_n}$
- $S$  může nabývat jen hodnot:  $0, 1/30, 2/30, 3/30, \dots, 1$
- $T$  může nabývat hodnot:  $1, e^{-1/30}, e^{-2/30}, e^{-3/30}, \dots$
- Je zřejmé, že  $S$  a  $T$  nemohou dát pro 30 měření stejnou hodnotu  $p_0$ .
- Situaci můžeme nasimulovat v počítači pro  $\mu = \ln 10$  a tedy  $p_0 = 0,1$ . 500 krát zopakujeme náhodné vybrání 30 hodnot z  $\text{Poiss}(\mu)$  a máme tedy 500 hodnot pro každou  $S$  a  $T$  a vyneseme četnosti hodnot do histogramu.
- Obě odhadové funkce se pohybují kolem správné hodnoty  $p_0 = 0,1$ , kterou mají odhadovat.

# Chování odhadových funkcí



# Výběřová distribuce

- Tedy hodnoty odhadové funkce  $S$  fluktuují kolem 0,1. Je tedy žádoucí, aby střední hodnota  $S$  byla rovna 0,1.
- Navíc, chceme aby to platilo pro jakoukoli hodnotu  $p_0$ , tedy  $E[S] = p_0$ , pro  $0 < p_0 < 1$ .
- Abychom to ověřili potřebujeme znát pravděpodobnostní distribuci odhadové funkce  $S$ .
- Odhadové funkce jsou konstruovány z náhodného výběru mluvíme o **výběřové distribuci**.

THE SAMPLING DISTRIBUTION. Let  $T = h(X_1, X_2, \dots, X_n)$  be an estimator based on a random sample  $X_1, X_2, \dots, X_n$ . The probability distribution of  $T$  is called the *sampling distribution* of  $T$ .


# Výběrová distribuce

- Jak najít konkrétní výběrovou distribuci?
- Necht'  $S = Y/n$ , kde  $Y$  je počet  $X_i$  rovných nule a tedy  $Y$  je rovno počtu úspěchu v  $n$  nezávislých pokusech s pravděpodobností úspěchu  $p_0$ .
- Tedy  $Y$  musí mít  $Bin(n, p_0)$  distribuci a pak  $S = Bin(n, p_0)/n$ , s diskretní náhodnou proměnnou  $k/n$ .

$$p_S\left(\frac{k}{n}\right) = P\left(S = \frac{k}{n}\right) = P(Y = k) = \binom{n}{k} p_0^k (1 - p_0)^{n-k}$$

- Pravděpodobnostní funkce  $p_S(a)$  pro  $n = 30$  a  $p_0 = 0,1$ .
- Střední hodnota  $S$  bude:

$$E[S] = \frac{E[Y]}{n} = \frac{np_0}{n} = p_0$$





# Výběrová distribuce a nestrannost

- Tedy odhadová funkce  $S$  pro  $p_0$  má vlastnosti, že  $E[S] = p_0$ .
- To odráží fakt, že  $S$  nemá systematickou tendenci produkovat odhady, které jsou větší než  $p_0$  nebo menší než  $p_0$ . To je žádoucí vlastnost odhadové funkce!!! A taková odhadová funkce se nazývá jako **nestranná**.

DEFINITION. An estimator  $T$  is called an **unbiased** estimator for the parameter  $\theta$ , if

$$E[T] = \theta$$


irrespective of the value of  $\theta$ . The difference  **$E[T] - \theta$**  is called the **bias of  $T$** ; if this difference is nonzero, then  $T$  is called *biased*.

# Výběrová distribuce a nestrannost

$$T = e^{-\bar{X}_n}$$

- Teď stejnou proceduru provedeme i pro odhadovou funkci  $T$ .
- Můžeme ji přepsat do tvaru  $T = e^{-Z/n}$ , kde  $Z = X_1 + X_2 + \dots + X_n$ .
- Náhodná proměnná  $Z$  je součtem  $n$  nezávislých  $Poiss(\mu)$  náhodných proměnných a má distribuci  $Poiss(n\mu)$ .
- Tedy  $T$  je diskrétní náhodná proměnná nabývající hodnot  $e^{-k/n}$  s pravděpodobnostní funkcí:

$$p_T(e^{-k/n}) = P(T = e^{-k/n}) = P(Z = k) = \frac{e^{-n\mu} (n\mu)^k}{k!}.$$



- Pro  $n = 30$  a  $p_0 = 0,1$  je pravděpodobnostní funkce v grafu. Mohlo by se zdát, že  $T$  je opět nestranná odhadová funkce, ale není to pravda – důkaz Jensenova nerovnost.

# Výběrová distribuce a nestrannost

- Funkce  $\exp(-x)$  je konvexní, musí tedy platit:

$$E[T] = E \left[ e^{-\bar{X}_n} \right] > e^{-E[\bar{X}_n]}$$


- Ze zákona velkých čísel plyne, že  $E[\bar{X}_n] = \mu$ , protože  $\mu$  je střední hodnota  $\text{Poiss}(\mu)$ .
- Pak dostaneme:  $E[T] > e^{-\mu} = p_0$
- To znamená, že  $T$  je pozitivně stranné pro  $p_0$ .
- Spočítáme  $E[T]$  přesně:  $E[T] = E \left[ e^{-\bar{X}_n} \right] = e^{-n\mu(1-e^{-1/n})}$
- Protože  $n(1 - e^{-1/n}) \rightarrow 1$  pro  $n \rightarrow \infty$ , pak

$$E[T] = e^{-n\mu(1-e^{-1/n})} \rightarrow e^{-\mu} = p_0$$

- Vidíme, že strannost s rostoucím  $n$  klesá k nule.

# Výběrová distribuce a nestrannost

- V grafu je střední hodnota  $T$  pro  $n = 30$  a  $\mu = \ln 10$  a  $p_0 = 0,1$ .



- Navíc platí, že výběrový průměr a výběrový rozptyl jsou nestranné odhadové funkce pro střední hodnotu  $Poiss(\mu)$ . Tato vlastnosti odhadových funkcí  $\bar{X}_n$  a  $S_n^2$  je navíc univerzální pro jakékoliv pravděpodobnostní rozdělení.

# Nestranná odhadová funkce pro střední hodnotu a rozptyl

- Na statistickém souboru nás většinou zajímá střední hodnota a rozptyl modelové distribuce.

UNBIASED ESTIMATORS FOR EXPECTATION AND VARIANCE. Suppose  $X_1, X_2, \dots, X_n$  is a random sample from a distribution with finite expectation  $\mu$  and finite variance  $\sigma^2$ . Then

$$\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}$$

is an unbiased estimator for  $\mu$  and

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

is an unbiased estimator for  $\sigma^2$ .

# Nestranná odhadová funkce pro střední hodnotu a rozptyl

- Tvzení v definici neříká nic jiného než, že

$$E[\bar{X}_n] = \mu \text{ a } E[S_n^2] = \sigma^2. \quad E[X_i - \bar{X}_n] = E[X_i] - E[\bar{X}_n] = 0 \quad E[Y] = 0$$

$$E[S_n^2] = \frac{1}{n-1} \sum_{i=1}^n E[(X_i - \bar{X}_n)^2]$$

$$\text{Var}(Y) = E[Y^2] - (E[Y])^2 = E[Y^2]$$

$$X_i - \bar{X}_n = \frac{n-1}{n} X_i - \frac{1}{n} \sum_{j \neq i} X_j$$

$$E[(X_i - \bar{X}_n)^2] = \text{Var}(X_i - \bar{X}_n)$$

$$\begin{aligned} \text{Var}(X_i - \bar{X}_n) &= \text{Var}\left(\frac{n-1}{n} X_i - \frac{1}{n} \sum_{j \neq i} X_j\right) & E[S_n^2] &= \frac{1}{n-1} \sum_{i=1}^n E[(X_i - \bar{X}_n)^2] \\ &= \frac{(n-1)^2}{n^2} \text{Var}(X_i) + \frac{1}{n^2} \sum_{j \neq i} \text{Var}(X_j) & &= \frac{1}{n-1} \sum_{i=1}^n \text{Var}(X_i - \bar{X}_n) = \frac{1}{n-1} \cdot n \cdot \frac{n-1}{n} \sigma^2 = \sigma^2 \\ &= \left[ \frac{(n-1)^2}{n^2} + \frac{n-1}{n^2} \right] \sigma^2 = \frac{n-1}{n} \sigma^2. \end{aligned}$$

# Přenos nestrannosti

- Jaká bude odhadová funkce pro směrodatnou odchylku  $\sigma$ ? Bude to funkce  $S_n$ ?
- Podle Jensen nerovnosti to pravda nebude.

$$\sigma^2 = \text{E}[S_n^2] > (\text{E}[S_n])^2$$

- Z toho plyne, že:  $\text{E}[S_n] < \sigma$
- Obecná vlastnost: nestrannost nějaké odhadové funkce se vždy nepřenáší.
- Je-li  $T$  nestranná odhadová funkce parametru  $\theta$ , potom odhadová funkce  $g(T)$  nemusí být nestranná odhadová funkce parametru  $g(\theta)$ .

# Přenos nestrannosti

- Existuje speciální příklad nestranné odhadové funkce, kdy její nestrannost se přenesse na novou odhadovou funkci, která vznikne lineární transformací.
- Necht'  $T$  je nestranná odhadová funkce pro parametr  $\theta$  a platí, že  $E[T] = \theta$ .
- Potom transformace:  $g(T) = aT + b$  je nestranný odhad pro parametr  $a\theta + b$ .

$$E[aT + b] = aE[T] + b = a\theta + b$$



# Střední kvadratická chyba a porovnání odhadových funkcí

# Srovnání odhadových funkcí

- Nestrannost je zásadní vlastnost odhadových funkcí.
- Pokud existuje více nestranných odhadových funkcí pro daný parametr modelové distribuce, tak jak vybrat tu nejvhodnější?
- Přirozeným parametrem výběru pro nestranné odhadové funkce bude rozptyl výběrové distribuce.

# Odhadová funkce $N$

- Úkolem je odhadnout celkový počet vyrobených automobilů  $N$ , pokud náš statistický soubor obsahuje  $n$  výrobních čísel náhodně vybraných vozů.
- Označme vybraná sériová čísla  $x_1, x_2, x_3, \dots, x_n$  jako realizaci náhodných proměnných  $X_1, X_2, X_3, \dots, X_n$  reprezentující  $n$  výběrů bez vracení se stejnou pravděpodobností z množiny  $1, 2, 3, \dots, N$ .
- $X_1, X_2, X_3, \dots, X_n$  není náhodný výběr, protože náhodné proměnné jsou vzájemně závislé.
- Zkonstruujeme dvě nestranné odhadové funkce  $T_1$  a  $T_2$ .

# Odhadová funkce $N$ – výběrový průměr

- První bude založena na výběrovém průměru:

$$\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}$$

- Druhá bude založena na výběrovém maximu:

$$M_n = \max\{X_1, X_2, \dots, X_n\}$$

- Jak zkonstruovat nestrannou odhadovou funkci pro  $N$  na základě výběrového průměru?

- Spočítáme střední hodnotu  $\overline{\bar{X}_n}$ ; pravidlo součtu středních hodnot platí i pro závislé náhodné proměnné:

$$E[\bar{X}_n] = \frac{E[X_1] + E[X_2] + \dots + E[X_n]}{n}$$

# Odhadová funkce $N$ – výběrový průměr

- Snadno nahlédneme, že marginální distribuce pro každé  $X_i$  je stejná:  $P(X_i = k) = \frac{1}{N}$  for  $k = 1, 2, \dots, N$ .

- Tedy střední hodnota každého  $X_i$  je:

$$\begin{aligned} E[X_i] &= 1 \cdot \frac{1}{N} + 2 \cdot \frac{1}{N} + \dots + N \cdot \frac{1}{N} = \frac{1 + 2 + \dots + N}{N} \\ &= \frac{\frac{1}{2}N(N+1)}{N} = \frac{N+1}{2}. \end{aligned}$$

- Potom:  $E[\bar{X}_n] = \frac{E[X_1] + E[X_2] + \dots + E[X_n]}{n} = \frac{N+1}{2}$ .

- Protože střední hodnota  $T_1$  se musí rovnat hledanému parametru  $N$ , pak:  $T_1 = 2\bar{X}_n - 1$  je nestranná odhadová funkce pro  $N$ ,

protože:  $E[T_1] = E[2\bar{X}_n - 1] = 2E[\bar{X}_n] - 1 = 2 \cdot \frac{N+1}{2} - 1 = N$ .

# Odhadová funkce $N$ – výběrové maximum

- Spočítáme si střední hodnotu náhodné proměnné  $M_n$ . Potřebujeme najít její pravděpodobnostní distribuci – jaká je pravděpodobnost, že  $M_n = k$ ?
- Počet způsobů jak vybrat  $n$  čísel bez opakování z  $N$  prvkové množiny je  $\binom{N}{n}$  a každá kombinace má pravděpodobnost  $1/\binom{N}{n}$ .
- Aby se  $M_n = k$ , tak musíme mít jeden výběr rovný  $k$  a ostatních  $n-1$  výběrů z čísel  $1, 2, 3, \dots, k-1$ . Uděláme to  $\binom{k-1}{n-1}$  způsoby pro  $k = n, n+1, \dots, N$ .
- Potom pro pravděpodobnost, že  $M_n = k$  platí:

# Odhadová funkce N – výběrové maximum

$$\begin{aligned} P(M_n = k) &= \frac{\binom{k-1}{n-1}}{\binom{N}{n}} = \frac{(k-1)!}{(k-n)!(n-1)!} \cdot \frac{(N-n)!n!}{N!} \\ &= n \cdot \frac{(k-1)!}{(k-n)!} \frac{(N-n)!}{N!}. \end{aligned}$$

- A střední hodnota bude:

$$\begin{aligned} E[M_n] &= \sum_{k=n}^N k P(M_n = k) = \sum_{k=n}^N k \cdot n \cdot \frac{(k-1)!}{(k-n)!} \frac{(N-n)!}{N!} \\ &= \sum_{k=n}^N n \cdot \frac{k!}{(k-n)!} \frac{(N-n)!}{N!} \\ &= n \cdot \frac{(N-n)!}{N!} \sum_{k=n}^N \frac{k!}{(k-n)!}. \end{aligned}$$

- Jak spočítat poslední sumu? Použijeme trik.

# Odhadová funkce $N$ – výběrové maximum

- Musí platit: 
$$1 = \sum_{j=n}^N P(M_n = j) = \sum_{j=n}^N n \cdot \frac{(j-1)! (N-n)!}{(j-n)! N!},$$

- Z toho hned plyne následující rovnost, platící pro libovolné  $N$  a  $n \leq N$ :

$$\sum_{j=n}^N \frac{(j-1)!}{(j-n)!} = \frac{N!}{n(N-n)!}.$$

- Zaměňme  $N$  za  $N+1$  a  $n$  za  $n+1$ :

$$\sum_{j=n+1}^{N+1} \frac{(j-1)!}{(j-n-1)!} = \frac{(N+1)!}{(n+1)(N-n)!}.$$

- Nahradíme  $j-1 = k$ :

$$\sum_{k=n}^N \frac{k!}{(k-n)!} = \frac{(N+1)!}{(n+1)(N-n)!}.$$



# Odhadová funkce $N$ – výběrové maximum

- Teď můžeme dopočítat  $E[M_n]$ :

$$\begin{aligned} E[M_n] &= n \cdot \frac{(N-n)!}{N!} \sum_{k=n}^N \frac{k!}{(k-n)!} \\ &= n \cdot \frac{(N-n)!}{N!} \cdot \frac{(N+1)!}{(n+1)(N-n)!} = n \cdot \frac{N+1}{n+1}. \end{aligned}$$

- Protože střední hodnota  $T_2$  se musí rovnat hledanému parametru  $N$ , pak:  $T_2 = \frac{n+1}{n}M_n - 1$  je nestranná odhadová funkce pro  $N$ :


$$E[T_2] = E\left[\frac{n+1}{n}M_n - 1\right] = \frac{n+1}{n}E[M_n] - 1 = \frac{n+1}{n} \cdot \frac{n(N+1)}{n+1} - 1 = N.$$

# Odhadová funkce $N$

- Dostali jsme tedy dvě nestranné odhadové funkce pro odhad parametru  $N$ .
- Která z nich je lepší? Určíme to z toho, jak se  $T_1$  a  $T_2$  mění kolem hodnoty  $N$ .
- Udělejme simulaci:  $N = 1000$ ,  $n = 10$ , tedy vybereme bez opakování 10 čísel z 1, 2, 3, ..., 1000 a spočítáme hodnoty  $T_1$  a  $T_2$ . Celé to 2000-krát zopakujeme a těchto 2000 hodnot vyneseme do histogramu pro každou odhadovou funkci.

# Odhadová funkce N

- Vlevo histogram simulované odhadové funkce  $T_1$  a vpravo  $T_2$ .



# Odhadová funkce $N$

- Protože histogramy reprezentují pravděpodobnostní funkci, tak vidíme, že distribuce obou odhadových funkcí jsou zcela odlišné.
- Rozptyl  $T_2$  kolem hodnoty  $N$  je menší než rozptyl  $T_1$ .
- Tedy  $T_2$  odhaduje parametr  $N$  účinněji, protože odhady jsou více koncentrovány kolem  $N$  v porovnání s  $T_1$ .
- Tedy rozptyl odhadové funkce určuje její účinnost.

# Odhadová funkce N - rozptyl

EFFICIENCY. Let  $T_1$  and  $T_2$  be two unbiased estimators for the same parameter  $\theta$ . Then estimator  $T_2$  is called *more efficient* than estimator  $T_1$  if  $\text{Var}(T_2) < \text{Var}(T_1)$ , irrespective of the value of  $\theta$ .

- Spočítejme rozptyly odhadových funkcí  $T_1$  a  $T_2$ .

$$\text{Var}(T_1) = \text{Var}(2\bar{X}_n - 1) = 4\text{Var}(\bar{X}_n)$$

- Protože  $X_i$  mají všechny stejnou pravděpodobnostní distribuci, tak i páry  $(X_i, X_j)$  pro  $i \neq j$  mají stejnou distribuci.
- Potom pro rozptyl součtu náhodných proměnných platí:  $\text{Var}(X_1 + \dots + X_n) = n\text{Var}(X_1) + n(n-1)\text{Cov}(X_1, X_2)$
- Dá se ukázat, že:  $\text{Var}(X_1) = \frac{1}{12}(N-1)(N+1)$ ,  $\text{Cov}(X_1, X_2) = -\frac{1}{12}(N+1)$

# Odhadová funkce N - rozptyl

- Potom pro rozptyl  $T_1$  máme:

$$\begin{aligned}\text{Var}(T_1) &= 4\text{Var}(\bar{X}_n) = \frac{4}{n^2}\text{Var}(X_1 + \cdots + X_n) \\ &= \frac{4}{n^2} \left[ n \cdot \frac{1}{12}(N-1)(N+1) - n(n-1) \cdot \frac{1}{12}(N+1) \right] \\ &= \frac{1}{3n}(N+1)[N-1 - (n-1)] \\ &= \frac{(N+1)(N-n)}{3n}.\end{aligned}$$

- Výpočet rozptylu odhadové funkce  $T_2$  je složitější. Dá se ukázat, že platí:  $\text{Var}(M_n) = \frac{n(N+1)(N-n)}{(n+2)(n+1)^2}$
- Pozn.: použije se podobného triku jako u výpočtu  $E[M_n]$ .

# Odhadová funkce N - rozptyl

- Potom rozptyl  $T_2$  bude:

$$\text{Var}(T_2) = \text{Var}\left(\frac{n+1}{n}M_n - 1\right) = \frac{(n+1)^2}{n^2}\text{Var}(M_n) = \frac{(N+1)(N-n)}{n(n+2)}$$

- Vidíme, že  $\text{Var}(T_2) < \text{Var}(T_1)$  pro všechny  $N$  a  $n \geq 2$ . Pro  $n = 1$  jsou obě odhadové funkce rovny  $X_1$ .
- Poměr  $\text{Var}(T_1)/\text{Var}(T_2)$  se nazývá jako relativní účinnost odhadové funkce  $T_2$  s ohledem na odhadovou funkci  $T_1$ .
- V našem případě:  $\frac{\text{Var}(T_1)}{\text{Var}(T_2)} = \frac{(N+1)(N-n)}{3n} \cdot \frac{n(n+2)}{(N+1)(N-n)} = \frac{n+2}{3}$ .
- Tedy je vhodné preferovat odhadovou funkci  $T_2$  pro odhad parametru  $N$  před  $T_1$ .

# Střední kvadratická chyba

- I když je nestrannost důležitá vlastnost odhadové funkce, je třeba účinnost odhadové funkce nějak kvantifikovat i bez znalosti toho, zdali je odhadová funkce nestranná nebo není.
- Je nutné stanovit jak se „rozšiřuje“ odhadová funkce kolem hledaného parametru  $\theta$ .

DEFINITION. Let  $T$  be an estimator for a parameter  $\theta$ . The *mean squared error* of  $T$  is the number  $\text{MSE}(T) = \text{E}[(T - \theta)^2]$ .

- Střední kvadratická chyba (MSE) odhadové funkce je zobecňující parametr popisující účinnost odhadové funkce.



# Střední kvadratická chyba

- Tedy odhadová funkce  $T_1$  je účinnější než odhadová funkce  $T_2$  pokud  $\text{MSE}(T_1) < \text{MSE}(T_2)$ .
- Definiční vztah lze přepsat na:


$$\begin{aligned}\text{MSE}(T) &= \text{E}[(T - \theta)^2] \\ &= \text{E}[(T - \text{E}[T] + \text{E}[T] - \theta)^2] \\ &= \text{E}[(T - \text{E}[T])^2] + 2\text{E}[T - \text{E}[T]](\text{E}[T] - \theta) + (\text{E}[T] - \theta)^2 \\ &= \text{Var}(T) + (\text{E}[T] - \theta)^2.\end{aligned}$$

- Tedy MSE je součet rozptylu odhadové funkce a její strannosti. Pro nestranné odhadové funkce je MSE rovno  $\text{Var}(T)$ .

# Střední kvadratická chyba

- Může nastat situace, kdy stranná odhadová funkce s malým rozptylem může dávat lepší výsledek než nestranná odhadová funkce s velkým rozptylem.
- Příklad hledáme, jaká je hodnota  $\text{Poiss}(\mu)$  pro hodnotu  $X = 0$ .
- Můžeme nalézt dvě odhadové funkce:

$$S = \frac{\text{number of } X_i \text{ equal to zero}}{n} \quad T = e^{-\bar{X}_n}$$



- Nasimulujeme 1000 opakování náhodného výběru 25 prvků z  $\text{Poiss}(\mu)$  distribuce s  $\mu = 2$  – viz histogramy: vlevo odhadová funkce  $S$ , vpravo  $T$ .
- Vidíme, že stranná odhadová funkce  $T$  je blíže k hledanému parametru  $e^{-\mu} = e^{-2} = 0,1353$  než nestranná funkce  $S$ . Preferovaný výběr  $T$  je podporován skutečností, že  $\text{MSE}(T)$  je menší než  $\text{MSE}(S)$ .

Maximální věrohodnost

# Maximální věrohodnost

- Už umíme zkonstruovat odhadovou funkci pro parametry distribucí, kterým odpovídá přirozený výběrový parametr ( $E[X]$  vs.  $\overline{X}_n$ ).
- Co když taková parametrová analogie neexistuje?
- Musím nalézt univerzální princip konstrukce odhadových funkcí pro libovolný parametr.
- K tomu slouží tzv. **metoda maximální věrohodnosti**.

# Maximální věrohodnost - příklad

- Ilustrujme si princip maximální věrohodnosti na příkladu.
- Mějme dva balíky po 10 000 stejných elektronických součástek. V jednom balíku je 50% vadných součástek a v druhém balíku je 10% vadných.
- Bohužel neumíme balíky rozeznat. Který balík si máme koupit?
- Otevřu jeden balík a náhodně vyberu deset součástek, které otestuji na vadnost. Zjistím, že jedna je vadná.
- **Závěr:** vyberu si tento balík.
- V balíku s 50% defektních součástek je **více pravděpodobné**, že v 10-ti kusovém výběru se objeví více vadných součástek, zatímco u druhého balíku můžeme jednu vadnou součástku očekávat s větší pravděpodobností.

# Maximální věrohodnost

- Tedy vyberu si ten balík, kde je nejvíce pravděpodobné, že jen jedna součástka je vadná
- Toto je základní myšlenka metody maximální věrohodnosti:

THE MAXIMUM LIKELIHOOD PRINCIPLE. Given a dataset, choose the parameter(s) of interest in such a way that the data are most likely.

- **Důkaz:** necht' náhodná proměnná  $R_i = 1$  v případě, že  $i$ -tá součástka je vadná a  $R_i = 0$  v případě, že je funkční pro  $i = 1, 2, 3, \dots, 10$ .
- Tedy  $R_1, R_2, R_3, \dots, R_{10}$  je 10 nezávislých proměnných s distribucí  $Ber(p)$ , kde  $p$  je pravděpodobnost, že vybraná součástka je vadná.

$$P(R_1 = 0, R_2 = 1, R_3 = 0, \dots, R_{10} = 0) = p(1 - p)^9.$$

# Maximální věrohodnost

- Pro balík s 10% vadných součástek platí:

$$P(R_1 = 0, R_2 = 1, R_3 = 0, \dots, R_{10} = 0) = \frac{1}{10} \left( \frac{9}{10} \right)^9 = 0.039$$

- Pro balík s 50% vadných součástek platí:

$$P(R_1 = 0, R_2 = 1, R_3 = 0, \dots, R_{10} = 0) = \frac{1}{2} \left( \frac{1}{2} \right)^9 = 0.00098$$

- Tedy pravděpodobnost, že bude ve výběru právě jedna vadná součástka je asi 40 krát větší pro balík s 10% vadných součástek.

# Věrohodnostní funkce

- Mějme statistický soubor prvků  $x_1, x_2, \dots, x_n$  modelovaný jako realizaci náhodného výběru z pravděpodobnostní distribuce charakterizované parametrem  $\theta$ .
- Pravděpodobnostní funkce diskrétní náhodné proměnné je funkcí  $\theta: p_\theta(x)$ .
- Hustota pravděpodobnosti spojité náhodné proměnné je funkcí  $\theta: f_\theta(x)$ .
- Mějme příklad s diskrétní náhodnou proměnnou.
- Potom metoda maximální věrohodnosti nám říká, že parametr  $\theta$  odhadneme takovým **číslem**, pro které je funkce  $L(\theta)$  maximální.

$$L(\theta) = P(X_1 = x_1, \dots, X_n = x_n) = p_\theta(x_1) \cdots p_\theta(x_n)$$



# Věrohodnostní funkce

- Takové číslo nazýváme jako **maximální věrohodný odhad** parametru  $\theta$ .
- Funkci  $L(\theta)$  nazýváme jako **věrohodnostní funkci**.
- Pro spojitou náhodnou proměnnou je nutné  $L(\theta)$  definovat jiným způsobem, protože by se  $L(\theta) = 0$ .
- Mějme  $X$  a  $f_\theta(x)$  a malé  $\varepsilon > 0$ . Vybereme takové  $\theta$ , že pravděpodobnost

$$P(x_1 - \varepsilon \leq X_1 \leq x_1 + \varepsilon, \dots, x_n - \varepsilon \leq X_n \leq x_n + \varepsilon)$$

je maximální.

- Protože  $X_i$  jsou nezávislé, musí platit:

# Věrohodnostní funkce

$$\begin{aligned} & P(x_1 - \varepsilon \leq X_1 \leq x_1 + \varepsilon, \dots, x_n - \varepsilon \leq X_n \leq x_n + \varepsilon) \\ &= P(x_1 - \varepsilon \leq X_1 \leq x_1 + \varepsilon) \cdots P(x_n - \varepsilon \leq X_n \leq x_n + \varepsilon) \\ &\approx f_\theta(x_1) f_\theta(x_2) \cdots f_\theta(x_n) (2\varepsilon)^n, \end{aligned}$$

- kdy jsme využili známého faktu, že:

$$P(x_i - \varepsilon \leq X_i \leq x_i + \varepsilon) = \int_{x_i - \varepsilon}^{x_i + \varepsilon} f_\theta(x) dx \approx 2\varepsilon f_\theta(x_i)$$

- Tedy pravděpodobnost bude maximální pokud bude maximální funkce:  $f_\theta(x_1) f_\theta(x_2) \cdots f_\theta(x_n)$
- Tedy věrohodnostní funkce pro spojitou náhodnou proměnnou bude definována:

$$L(\theta) = f_\theta(x_1) f_\theta(x_2) \cdots f_\theta(x_n)$$

- Můžeme tedy definovat **maximální věrohodný odhad**:

# Věrohodnostní funkce

MAXIMUM LIKELIHOOD ESTIMATES. The *maximum likelihood estimate* of  $\theta$  is the value  $t = h(x_1, x_2, \dots, x_n)$  that maximizes the likelihood function  $L(\theta)$ . The corresponding random variable

$$T = h(X_1, X_2, \dots, X_n)$$

is called the *maximum likelihood estimator* for  $\theta$ .

- Př.: Mějme statistický soubor prvků  $x_1, x_2, \dots, x_n$  modelovaný jako realizaci náhodného výběru z exponenciální pravděpodobnostní distribuce  $Exp(\lambda)$  s hustotou pravděpodobnosti  $f_\lambda(x) = 0$  pro  $x < 0$  a  $f_\lambda(x) = \lambda e^{-\lambda x}$  pro  $x \geq 0$ .
- Potom věrohodnostní funkce bude dána:

# Věrohodnostní funkce

$$\begin{aligned}L(\lambda) &= f_\lambda(x_1)f_\lambda(x_2)\cdots f_\lambda(x_n) \\ &= \lambda e^{-\lambda x_1} \cdot \lambda e^{-\lambda x_2} \cdots \lambda e^{-\lambda x_n} \\ &= \lambda^n \cdot e^{-\lambda(x_1+x_2+\cdots+x_n)}.\end{aligned}$$

- Získat maximální věrohodný odhad parametru  $\lambda$  znamená nalézt maximum funkce  $L(\lambda)$ .
- Funkce má maximum v místě, kde první derivace je nulová:

$$\begin{aligned}\frac{d}{d\lambda}L(\lambda) &= n\lambda^{n-1}e^{-\lambda\sum_{i=1}^n x_i} - \lambda^n\left(\sum_{i=1}^n x_i\right)e^{-\lambda\sum_{i=1}^n x_i} \\ &= n\left(\lambda^{n-1}e^{-\lambda\sum_{i=1}^n x_i}\left(1 - \frac{\lambda}{n}\sum_{i=1}^n x_i\right)\right).\end{aligned}$$

# Věrohodnostní funkce

- Derivace  $d(L(\lambda))/d\lambda = 0$  pokud  $1 - \lambda\bar{x}_n = 0$ .
- Z toho plyne, že:  $\lambda = 1/\bar{x}_n$ .
- Tedy věrohodnostní odhadová funkce pro parametr  $\lambda$  je funkce  $1/\bar{X}_n$ .
- Z definice je vidět, že věrohodnostní funkce  $L(\theta)$  je určena součinem pravděpodobnostních funkcí.
- Maximum funkce lze ve většině případů stanovit z její první derivace. Ale derivace součinu funkcí je většinou velmi pracná, protože hledaný parametr je obsažen v každém členu.
- Řešením je logaritmování funkce  $L(\theta)$ .

# Logaritmus věrohodnostní funkce

- Logaritmus součinu funkcí je roven součtu logaritmů jednotlivých funkcí.
- Tedy místo derivování součinu funkcí budeme derivovat součet logaritmů těchto funkcí.
- Definice:  $l(\theta) = \ln(L(\theta))$ .
- Protože logaritmus je rostoucí funkce, tak funkce  $l(\theta)$  i  $L(\theta)$  nabývají maxima pro stejný parametr  $\theta$ .
- Tedy  $L(\theta)$  je maximální tehdy a jenom tehdy, když  $l(\theta)$  je maximální.

