

MUNI

Zkušenost: Statistická indukce

CORE004 Matematika jako součást kultury

Zdeněk Pospíšil

707@mail.muni.cz

Masarykova univerzita

11. listopadu 2021

Obsah

Maximální věrohodnost

Využití variability

Bayesovská inference

Princip maximální věrohodnosti

„Jest zcela nezpochybnitelným faktem, že nemůžeme-li poznat nejpravdivější soudy, musíme se řídit soudy nejpravděpodobnějšími.“

René Descartes, Rozprava o metodě

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

Lincolnova-Petersonova metoda, mark-recatch

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

Lincolnova-Petersonova metoda, mark-recatch

- Odchytíme a označujeme m jedinců.
- Po dostatečném čase, ale ne příliš dlouhém, odchytíme dostatečné množství dalších jedinců a spočítáme počet označených mezi nimi.

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
neznámý počet jedinců v populaci: n

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

počet možností, jak z m označených jedinců vybrat k : $c(m, k) = \binom{m}{k}$

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

počet možností, jak z m označených jedinců vybrat k : $c(m, k) = \binom{m}{k}$

počet možností, jak z $n - m$ neoznačených jedinců vybrat $r - k$:

$$c(n - m, r - k) = \binom{n - m}{r - k}$$

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
 neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

počet možností, jak z m označených jedinců vybrat k : $c(m, k) = \binom{m}{k}$

počet možností, jak z $n - m$ neoznačených jedinců vybrat $r - k$:

$$c(n - m, r - k) = \binom{n - m}{r - k}$$

A_n^{mrk} ... jev: populace je tvořena n jedinci, mezi nimi je m označených a při druhém odchytu mezi r ulovenými jedinci bylo k označených

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
 neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

počet možností, jak z m označených jedinců vybrat k : $c(m, k) = \binom{m}{k}$

počet možností, jak z $n - m$ neoznačených jedinců vybrat $r - k$:

$$c(n - m, r - k) = \binom{n - m}{r - k}$$

A_n^{mrk} ... jev: populace je tvořena n jedinci, mezi nimi je m označených a při druhém odchytu mezi r ulovenými jedinci bylo k označených

$$P(A_n^{mrk}) = \frac{\binom{m}{k} \binom{n - m}{r - k}}{\binom{n}{r}}$$

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
 neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

počet možností, jak z m označených jedinců vybrat k : $c(m, k) = \binom{m}{k}$

počet možností, jak z $n - m$ neoznačených jedinců vybrat $r - k$:

$$c(n - m, r - k) = \binom{n - m}{r - k}$$

A_n^{mrk} ... jev: populace je tvořena n jedinci, mezi nimi je m označených a při druhém odchytu mezi r ulovenými jedinci bylo k označených

$$P(A_n^{mrk}) = \frac{\binom{m}{k} \binom{n - m}{r - k}}{\binom{n}{r}}$$

Hledáme takové n , aby při daných m, r, k byla hodnota $P(A_n^{mrk})$ maximální.

Princip maximální věrohodnosti

Aplikace: Odhad počtu jedinců volně žijící populace

počet nově ulovených jedinců: r počet označených jedinců mezi nimi: k
 neznámý počet jedinců v populaci: n ; určitě je $n \geq \max\{m, r\}$

počet možností, jak mezi n jedinci vybrat r : $c(n, r) = \binom{n}{r}$

počet možností, jak z m označených jedinců vybrat k : $c(m, k) = \binom{m}{k}$

počet možností, jak z $n - m$ neoznačených jedinců vybrat $r - k$:

$$c(n - m, r - k) = \binom{n - m}{r - k}$$

A_n^{mrk} ... jev: populace je tvořena n jedinci, mezi nimi je m označených a při druhém odchytu mezi r ulovenými jedinci bylo k označených

$$P(A_n^{mrk}) = \frac{\binom{m}{k} \binom{n - m}{r - k}}{\binom{n}{r}}$$

Hledáme takové n , aby při daných m, r, k byla hodnota $P(A_n^{mrk})$ maximální.

Je $n \in \left\langle \frac{mr}{k}, \frac{mr}{k} + 1 \right\rangle$.

Rozložení náhodné veličiny

Konkrétní případ: binomické rozdělení (Bernoulliovo)

Pravděpodobnost úspěchu v nějakém pokusu je rovna p .

Pokus zopakujeme n -krát. Jaká je pravděpodobnost jevu B_n^k , že úspěch nastane právě k -krát?

Počet možností výběru k pořadových čísel úspěšných pokusů mezi n provedenými:

$$c(n, k) = \binom{n}{k}$$


Pravděpodobnost k úspěchů a $n - k$ neúspěchů:

$$p^k(1 - p)^{n-k}$$

Celkem:

$$P(B_n^k) = \binom{n}{k} p^k(1 - p)^{n-k}$$


Bayesův vzorec



Bayesův vzorec

Inverzní pravděpodobnost:


$$P(H|A) = \frac{P(H \cap A)}{P(A)} = \frac{P(A \cap H)P(H)}{P(H)P(A)} = \frac{P(H)}{P(A)}P(A|H)$$



Bayesův vzorec

Inverzní pravděpodobnost:

$$P(H|A) = \frac{P(H \cap A)}{P(A)} = \frac{P(A \cap H)P(H)}{P(H)P(A)} = \frac{P(H)}{P(A)}P(A|H)$$




Celková pravděpodobnost:

$$\begin{aligned} P(A) &= P((A \cap H_1) \cup (A \cap H_2)) = P(A \cap H_1) + P(A \cap H_2) = \\ &= P(H_1)P(A|H_1) + P(H_2)P(A|H_2) \end{aligned}$$

Bayesův vzorec

Inverzní pravděpodobnost:

$$P(H|A) = \frac{P(H)}{P(A)} P(A|H)$$




Celková pravděpodobnost:

$$P(A) = P(H_1)P(A|H_1) + P(H_2)P(A|H_2)$$

Bayesův vzorec

Inverzní pravděpodobnost:

$$P(H|A) = \frac{P(H)}{P(A)} P(A|H)$$



Celková pravděpodobnost:

$$P(A) = P(H_1)P(A|H_1) + P(H_2)P(A|H_2)$$

$$P(H_1|A) = \frac{P(H_1)P(A|H_1)}{P(H_1)P(A|H_1) + P(H_2)P(A|H_2)}$$

Bayesův vzorec

Aplikace: Diagnostické testy

Vyšetřovaný objekt buď zjišťovanou charakteristiku (chorobu) má nebo nemá.

Test je postup, který dá právě jeden ze dvou možných výsledků:

- + pozitivní, choroba zjištěna
- negativní, choroba nezjištěna

Bayesův vzorec

Aplikace: Diagnostické testy

Vyšetřovaný objekt buď zjišťovanou charakteristiku (chorobu) má nebo nemá.

Test je postup, který dá právě jeden ze dvou možných výsledků:

- + pozitivní, choroba zjištěna
- negativní, choroba nezjištěna

Vlastnosti testu:

- Senzitivita – podíl pozitivních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) mají.
- Specifická – podíl negativních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) nemají.

Bayesův vzorec

Aplikace: Diagnostické testy

Vyšetřovaný objekt buď zjišťovanou charakteristiku (chorobu) má nebo nemá.

Test je postup, který dá právě jeden ze dvou možných výsledků:

- + pozitivní, choroba zjištěna
- negativní, choroba nezjištěna

Vlastnosti testu:

Senzitivita – podíl pozitivních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) mají.

Specifická – podíl negativních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) nemají.

Předpokládáme, že známe pravděpodobnost výskytu zjišťované charakteristiky.

incidence ... počet nových případů choroby za časovou jednotku

prevalence ... celkový počet nemocných

Bayesův vzorec

Aplikace: Diagnostické testy

Vyšetřovaný objekt buď zjišťovanou charakteristiku (chorobu) má nebo nemá.

Test je postup, který dá právě jeden ze dvou možných výsledků:

- + pozitivní, choroba zjištěna
- negativní, choroba nezjištěna

Vlastnosti testu:

Senzitivita – podíl pozitivních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) mají.

Specifická – podíl negativních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) nemají.

Předpokládáme, že známe pravděpodobnost výskytu zjišťované charakteristiky.

incidence ... počet nových případů choroby za časovou jednotku

prevalence ... celkový počet nemocných

Otázka: jaká je pravděpodobnost, že vyšetřovaný objekt příslušnou charakteristiku vykazuje (má chorobu), pokud test dal pozitivní výsledek? $P(H|+)$ =?

Bayesův vzorec

Aplikace: Diagnostické testy

Vyšetřovaný objekt buď zjišťovanou charakteristiku (chorobu) má nebo nemá.

Test je postup, který dá právě jeden ze dvou možných výsledků:

- + pozitivní, choroba zjištěna
- negativní, choroba nezjištěna

Vlastnosti testu:

Senzitivita – podíl pozitivních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) mají. $p = P(+|H)$

Specifická – podíl negativních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) nemají. $q = P(-|H')$

Předpokládáme, že známe pravděpodobnost výskytu zjišťované charakteristiky $r = P(H)$.

incidence ... počet nových případů choroby za časovou jednotku

prevalence ... celkový počet nemocných

Otázka: jaká je pravděpodobnost, že vyšetřovaný objekt příslušnou charakteristiku vykazuje (má chorobu), pokud test dal pozitivní výsledek? $P(H|+) = ?$

Označení jevů: H ... objekt vykazuje charakteristiku (má chorobu)

H' ... objekt nevykazuje charakteristiku (nemá chorobu)

Bayesův vzorec

Aplikace: Diagnostické testy

Vyšetřovaný objekt buď zjišťovanou charakteristiku (chorobu) má nebo nemá.
Test je postup, který dá právě jeden ze dvou možných výsledků:

- + pozitivní, choroba zjištěna
- negativní, choroba nezjištěna

Vlastnosti testu:

- Senzitivita – podíl pozitivních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) mají. $p = P(+|H)$
- Specifická – podíl negativních výsledků testu mezi všemi výsledky při testování osob, které sledovanou charakteristiku (chorobu) nemají. $q = P(-|H')$

Předpokládáme, že známe pravděpodobnost výskytu zjišťované charakteristiky $r = P(H)$.
 incidence ... počet nových případů choroby za časovou jednotku
 prevalence ... celkový počet nemocných

Otázka: jaká je pravděpodobnost, že vyšetřovaný objekt příslušnou charakteristiku vykazuje (má chorobu), pokud test dal pozitivní výsledek? $P(H|+) = ?$

Označení jevů: H ... objekt vykazuje charakteristiku (má chorobu)
 H' ... objekt nevykazuje charakteristiku (nemá chorobu)

Jevy $+$ a $-$, H a H' jsou komplementární:

$$P(H') = 1 - r, P(+|H') = 1 - q, P(-|H) = 1 - p$$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll} P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\ P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q \end{array}$$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll} P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\ P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q \end{array}$$

Bayesův vzorec:

$$P(H|+) = \frac{P(H)P(+|H)}{P(H)P(+|H) + P(H')P(+|H')} = \frac{rp}{rp + (1 - q)(1 - r)} = \frac{rp}{1 - r - q + rp + rq}$$

$$P(H|-) = \frac{P(H)P(-|H)}{P(H)P(-|H) + P(H')P(-|H')} = \frac{r(1 - p)}{r(1 - p) + (1 - r)q} = \frac{r(1 - p)}{r + q - rq - rp}$$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll}
 P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\
 P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q
 \end{array}$$

Bayesův vzorec:

$$P(H|+) = \frac{rp}{1 - r - q + rp + rq}$$

$$P(H|-) = \frac{r(1 - p)}{r + q - rq - rp}$$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll}
 P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\
 P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q
 \end{array}$$

Bayesův vzorec:

$$P(H|+) = \frac{rp}{1 - r - q + rp + rq}$$

$$P(H|-) = \frac{r(1 - p)}{r + q - rq - rp}$$

Příklad: AIDS incidence $r = 0,001$
 senzitivita $p = 0,998$
 specificita $q = 0,99$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll} P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\ P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q \end{array}$$

Bayesův vzorec:

$$P(H|+) = \frac{rp}{1 - r - q + rp + rq}$$

$$P(H|-) = \frac{r(1 - p)}{r + q - rq - rp}$$

Příklad: AIDS incidence $r = 0,001$
 senzitivita $p = 0,998$
 specificita $q = 0,99$

$$P(H|+) = 0,091$$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll} P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\ P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q \end{array}$$

Bayesův vzorec:

$$P(H|+) = \frac{rp}{1 - r - q + rp + rq}$$

$$P(H|-) = \frac{r(1 - p)}{r + q - rq - rp}$$

Příklad: AIDS incidence $r = 0,001$
 senzitivita $p = 0,998$
 specificita $q = 0,99$

$$P(H|+) = 0,091$$

Kumulace zkušenosti: osoby s pozitivním výsledkem otestujeme znovu

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll} P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\ P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q \end{array}$$

Bayesův vzorec:

$$P(H|+) = \frac{rp}{1 - r - q + rp + rq}$$

$$P(H|-) = \frac{r(1 - p)}{r + q - rq - rp}$$

Příklad: AIDS incidence $r = 0,001$
 senzitivita $p = 0,998$
 specificita $q = 0,99$

$$P(H|+) = 0,091$$

Kumulace zkušenosti: osoby s pozitivním výsledkem otestujeme znovu

$$r_1 = 0,091 : \quad P(H|++) = 0,909$$

Bayesův vzorec

Aplikace: Diagnostické testy

$$\begin{array}{lll}
 P(H) = r & P(+|H) = p & P(-|H) = 1 - p \\
 P(H') = 1 - r & P(+|H') = 1 - q & P(-|H') = q
 \end{array}$$

Bayesův vzorec:

$$\begin{aligned}
 P(H|+) &= \frac{rp}{1 - r - q + rp + rq} \\
 P(H|-) &= \frac{r(1 - p)}{r + q - rq - rp}
 \end{aligned}$$

Příklad: AIDS incidence $r = 0,001$
 senzitivita $p = 0,998$
 specificita $q = 0,99$

$$P(H|+) = 0,091$$

Kumulace zkušenosti: osoby s pozitivním výsledkem otestujeme znovu

$$r_1 = 0,091 : P(H|++) = 0,909$$

$$r_2 = 0,909 : P(H|+++)= 0,999, P(H|++-)= 0,020$$

**MASARYKOVA
UNIVERZITA**