

# PRAVDĚPODOBNOST A STATISTIKA OPAKOVÁNÍ, pro rozpoznávání

Václav Hlaváč

Fakulta elektrotechnická ČVUT v Praze  
katedra kybernetiky, **Centrum strojového vnímání**  
hlavac@fel.cvut.cz, <http://cmp.felk.cvut.cz/~hlavac>

---

## OBSAH PŘEDNÁŠKY

- ◆ Pravěpodobnost (definice, náhodná veličina)
- ◆ Statistika (náhodný výběr, odhad parametrů)

---

Poděkování Ing. Martinovi Urbanovi, PhD. za první verzi z podzimu 2005; prof. Ing. Mirko Navarovi, DrSc. za několik průsvitek.

# DOPORUČENÉ ČTENÍ

- ◆ M. Navara: Pravděpodobnost a matematická statistika, skriptum FEL ČVUT, Vydavatelství ČVUT, Praha 2007.
- ◆ J. Novovičová: Pravděpodobnost a matematická statistika. skriptum Fakulty dopravní ČVUT, Vydavatelství ČVUT, Praha 2002.
- ◆ A. Papoulis: Probability, Random Variables and Stochastic Processes, McGraw Hill, Edition 4, 2002.
- ◆ <http://mathworld.wolfram.com/>
- ◆ <http://www.statsoft.com/textbook/stathome.html>

## ◆ Pravděpodobnost

- Abstraktní matematický model neurčitosti.
- Modeluje děje, v nichž hraje roli náhodnost.

## ◆ Statistika

- Popisná nebo inferenční.
- Sběr, organizace a analýza dat.
- Zobecňuje z omezených / konečných vzorků.
- Odhad parametrů, testování hypotéz, atd.

# PRAVDĚPODOBNOST

## Navarův motivační příklad



- ◆ Los loterie se prodává za **cenu** 2 EUR.
  - ◆ 1 los z 1000 vyhrává 1000 EUR, ostatní nic. (Tím je dána **hodnota** losu po losování.)
  - ◆ Za kolik máme prodat los *před* losováním?
- 
- ◆ Za 2 EUR by ho koupil jen hlupák. (Nebo ne?)
  - ◆ Hodnota losu před losováním je  $\frac{1}{1000}1000 = 1$  EUR = průměrná hodnota po losování.
- 

Na to je [teorie pravděpodobnosti](#).

**Otázka “Loterie”:** Proč se přesto kupují losy a loterie fungují?

Dosud jsme předpokládali, že parametry pravděpodobnostního modelu jsou známy. To je málokdy splněno.

**Příklad (Sportka):** Na Sportce se normálně prodělává; jelikož jsou výhry stanoveny podle počtu výherců, je výhodnější sázet jinak než ostatní. K tomu potřebujeme vědět, podle jakého modelu sázejí ostatní.


**Příklad (ruleta):** U rulety se obě strany zajímají, zda padají všechna čísla se stejnou pravděpodobností, přesněji, jak velké jsou odchylky od rovnoměrného rozdělení. Ale jak to zjistit a jaké je riziko chybných závěrů?

---

Na to je [statistika](#).

Statistika poskytuje daleko víc: nástroj pro zkoumání světa, pro hledání a ověřování závislostí, které nejsou zjevné.

# NÁHODNÉ JEVY, POJMY



Náhodný pokus

Prostor elementárních jevů je neprázdná množina  $\Omega$  všech možných výsledků daného pokusu.

Elementární jevy  $\omega \in \Omega$  jsou prvky prostoru elementárních jevů (výsledky pokusu).

Jevové pole  $\mathcal{A}$  je tvořeno systémem všech podmnožin prostoru elementárních jevů  $\Omega$ .

Náhodný jev  $A \in \mathcal{A}$  je prvkem jevového pole.

---

*Poznámka: pojem náhodného jevu byl zaveden proto, aby bylo možné definovat pravděpodobnost, rozdělení pravděpodobnosti, atd.*

- ◆ **Klasická** (dnes se již nepovažuje za definici pravděpodobnosti, ale metodu odhadu pravděpodobnosti)


$$P(A) \approx \frac{N_A}{N}$$

- ◆ **Limitní** (četnostní)

$$P(A) = \lim_{N \rightarrow \infty} \frac{N_A}{N}$$

- ◆ **Axiomatická** (Andreje Kolmogorova 1930)

# AXIOMATICKÁ DEFINICE PRAVDĚPODOBNOSTI



$\Omega$  - prostor elementárních jevů

$\mathcal{A}$  - jevové pole

1.  $P(A) \geq 0, \quad A \in \mathcal{A}.$
2.  $P(\Omega) = 1.$
3. If  $A \cap B = \emptyset$  then  $P(A \cup B) = P(A) + P(B), \quad A \in \mathcal{A}, \quad B \in \mathcal{B}.$

# PRAVDĚPODOBNOST

je funkce  $P$ , která jevům přiřazuje čísla z  $\langle 0, 1 \rangle$  a splňuje podmínky

$$(P1) \quad P[true] = 1,$$

$$(P2) \quad P \left[ \bigvee_{n \in \mathbb{N}} A_n \right] = \sum_{n \in \mathbb{N}} P[A_n], \text{ pokud se jevy } A_n, n \in \mathbb{N}, \text{ navzájem vylučují.}$$

Z těchto podmínek vyplývá:

$$P[false] = 0, \quad P[\neg A] = 1 - P[A],$$

jestliže  $A \Rightarrow B$ , pak  $P[A] \leq P[B]$ .


---

Pro korektnost je potřeba, aby systém jevů splňoval určité další podmínky.

# ODVOZENÉ VZTAHY

- ◆ If  $A \subset B$  then  $P(B \setminus A) = P(B) - P(A)$ .  
Symbol  $\setminus$  označuje množinový rozdíl.
- ◆  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$ .

# PODMÍNĚNÁ PRAVDĚPODOBNOST



Máme pravděpodobnostní popis systému. Dostaneme-li dodatečnou informaci, že nastal jev  $B$ , změní se naše znalost o pravděpodobnosti jevu  $A$  na

$$P(A|B) = \frac{P(A \wedge B)}{P(B)},$$

což je *podmíněná pravděpodobnost* jevu  $A$  za podmínky  $B$ . Je definována pouze pro  $P(B) \neq 0$ .

# VLASTNOSTI PODMÍNĚNÉ PRAVDĚPODOBNOСТИ

- ◆  $P(\text{true}|B) = 1, P(\text{false}|B) = 0.$
- ◆ Pokud  $A = \bigvee_{n \in \mathbb{N}} A_n$  a jevy  $A_1, A_2, \dots$  se navzájem vylučují, pak
$$P(A|B) = \sum_{n \in \mathbb{N}} P(A_n|B).$$
- ◆ Jevy  $A, B$  jsou *nezávislé*, právě když  $P(A|B) = P(A).$
- ◆ Pokud  $B \Rightarrow A$ , pak  $P(A|B) = 1.$  Pokud  $B \Rightarrow \neg A$ , pak  $P(A|B) = 0.$

---

Jevy  $B_i, i \in I$ , tvoří *úplný systém jevů*, jestliže se navzájem vylučují a
$$\bigvee_{i \in I} B_i = \text{true}.$$

## PŘÍKLAD: podmíněná pravděpodobnost

Jeden hod kostkou. Jaká je pravděpodobnost, že padne číslo větší než 3 (jev  $A$ ) za podmínky, že padlo liché číslo (jev  $B$ ).

$$\Omega = \{1, 2, 3, 4, 5, 6\}, \quad A = \{4, 5, 6\}, \quad B = \{1, 3, 5\}$$

$$P(A) = P(B) = \frac{1}{2}$$

$$P(A \cap B) = P(\{5\}) = \frac{1}{6}$$

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{\frac{1}{6}}{\frac{1}{2}} = \frac{1}{3}$$

# VĚTA O ÚPLNÉ PRAVDĚPODOBNOSTI

Nechť  $B_i$ ,  $i \in I$ , je úplný systém jevů a  $\forall i \in I: P(B_i) \neq 0$ .

Pak pro každý jev  $A$  platí

$$P(A) = \sum_{i \in I} P(B_i) P(A|B_i).$$

---

**Důkaz:**

$$\begin{aligned} P(A) &= P\left(\left(\bigvee_{i \in I} B_i\right) \wedge A\right) = P\left(\bigvee_{i \in I} (B_i \wedge A)\right) \\ &= \sum_{i \in I} P(B_i \wedge A) = \sum_{i \in I} P(B_i) P(A|B_i). \end{aligned}$$

# BAYESOVA VĚTA

Nechť  $B_i$ ,  $i \in I$ , je úplný systém jevů a  $\forall i \in I: P(B_i) \neq 0$ .

Pak pro každý jev  $A$  splňující  $P(A) \neq 0$  platí

$$P(B_i|A) = \frac{P(B_i) P(A|B_i)}{\sum_{i \in I} P(B_i) P(A|B_i)}.$$


---

**Důkaz** (s využitím věty o úplné pravděpodobnosti):

$$P(B_i|A) = \frac{P(B_i \wedge A)}{P(A)} = \frac{P(B_i) P(A|B_i)}{\sum_{i \in I} P(B_i) P(A|B_i)}.$$

- ◆ Pravděpodobnosti  $P(A|B_i)$  odhadneme z pokusů nebo z modelu, pomocí nich určíme pravděpodobnosti  $P(B_i|A)$ , které slouží k “optimálnímu” odhadu, který z jevů  $B_i$  nastal.
- ◆ **Problém:** Ke stanovení *aposteriorní pravděpodobnosti*  $P(B_i|A)$  potřebujeme znát i *apriorní pravděpodobnost*  $P(B_i)$ .
- ◆ Podobně definujeme podmíněné rozdělení náhodné veličiny, podmíněnou hustotu spojité náhodné veličiny apod.

# PODMÍNĚNÁ NEZÁVISLOST




Náhodné jevy  $A, B$  jsou **podmíněně nezávislé** za podmínky  $C$ , jestliže

$$P(A \wedge B|C) = P(A|C) P(B|C).$$

Podobně definujeme podmíněnou nezávislost více jevů, náhodných veličin apod.

# SDRUŽENÁ PRAVDĚPODOBŇNOST



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

# NEZÁVISLÉ JEVY

Jevy  $A, B$  jsou nezávislé  $\Leftrightarrow P(A \cap B) = P(A) P(B)$ .

---

## Příklad

Jeden hod kostkou. Jevy  $A > 3$ , jev  $B$  liché číslo. Jsou jevy nezávislé?

$$\Omega = \{1, 2, 3, 4, 5, 6\}, \quad A = \{4, 5, 6\}, \quad B = \{1, 3, 5\}$$

$$P(A) = P(B) = \frac{1}{2}$$

$$P(A \cap B) = P(\{5\}) = \frac{1}{6}$$

$$P(A) P(B) = \frac{1}{2} \cdot \frac{1}{2} = \frac{1}{4}$$

$P(A \cap B) \neq P(A) P(B) \Leftrightarrow$  jevy jsou závislé.

Distribuční funkce náhodné veličiny  $X$  je funkce  $F: X \rightarrow \langle 0, 1 \rangle$  je definovaná pomocí  $F(x) = P(X \leq x)$ , kde  $P$  je pravděpodobnost.

Vlastnosti:

1.  $F(x)$  je neklesající funkce, tj. pro  $\forall$  dvojici  $x_1 < x_2$  platí  $F(x_1) \leq F(x_2)$ .
2.  $F(x)$  je zprava spojitá, tj. platí  $\lim_{h \rightarrow 0^+} F(x + h) = F(x)$ .
3. ◆ Pro každou distribuční funkci platí  $\lim_{x \rightarrow -\infty} F(x) = 0$  a  $\lim_{x \rightarrow \infty} F(x) = 1$ .  
Zapsáno zkráceně:  $F(-\infty) = 0$ ,  $F(\infty) = 1$ .
- ◆ Jestliže jsou možné hodnoty  $F(x)$  z intervalu  $(a, b)$ , pak  $F(a) = 0$ ,  $F(b) = 1$ .

---

Každou funkci splňující předchozí tři vlastnosti můžeme pokládat za distribuční funkci.

- ◆ Distribuční funkce  $F$  se nazývá absolutně spojitá, jestliže existuje nezáporná funkce  $f$  (hustota pravděpodobnosti) a platí

$$F(x) = \int_{-\infty}^x f(u) \, du \quad \text{pro každé } x \in X.$$

- ◆ Hustota splňuje

$$\int_{-\infty}^{\infty} f(x) \, dx = 1.$$


- ◆ Existuje-li derivace  $F(x)$  v bodě  $x$ , potom  $F'(x) = f(x)$ .

- ◆ Pro  $a, b \in \mathbb{R}$ ,  $a < b$  platí

$$P(a < X < b) = \int_a^b f(x) \, dx = F(b) - F(a).$$


# PŘÍKLAD, NORMÁLNÍ ROZDĚLENÍ

$$F(x)$$




Distribuční funkce

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



Hustota

# ZÁKON VELKÝCH ČÍSEL



Zákon velkých čísel říká, že při velkém počtu nezávislých pokusů je možné téměř jistě očekávat, že relativní četnost se bude blížit teoretické hodnotě pravděpodobnosti.

Jakob Bernoulli, *Ars Conjectandi: Usum & Applicationem Praecedentis Doctrinae in Civilibus, Moralibus & Oeconomicis*, 1713, Chapter 4.

# ZÁKLADNÍ CHARAKTERISTIKY NÁHODNÉ VELIČINY

Spojité rozdělení

Diskrétní rozdělení

**Střední hodnota**

$$E(x) = \int_{-\infty}^{\infty} x f(x) dx$$

$$E(x) = \sum_x x P(x)$$

**$k$ -tý obecný moment**

$$E(x^k) = \int_{-\infty}^{\infty} x^k f(x) dx$$

$$E(x) = \sum_x x^k P(x)$$

**$k$ -tý centrální moment**

$$E(x^k) = \int_{-\infty}^{\infty} (x - \mu_x)^k f(x) dx$$

$$E(x) = \sum_x x^k P(x)$$

**Rozptyl, též disperze**

$$D(x) = \int_{-\infty}^{\infty} (x - \mu_x)^2 f(x) dx$$

$$E(x) = \sum_x x^2 P(x)$$

# KOVARIANCE

Vzájemná kovariance dvou veličin  $X, Y$

$$\sigma_{xy} = E((X - \mu_x)(Y - \mu_y))$$

Kovarianční matice  $n$  veličin  $X_1, \dots, X_n$

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \dots & \sigma_{1n} \\ & \ddots & \\ \sigma_{n1} & \dots & \sigma_n^2 \end{bmatrix}$$

Kovarianční matice je symmetrická, pozitivně semidefinitní.

# KVANTILY, MEDIÁN

- ◆  $p$ -kvantil  $Q_p$

$$P(X < Q_p) = p$$

- ◆ Medián je  $p$ -kvantil pro  $p = 0,5$

$$P(X < Q_p) = 0,5$$

*Poznámka: Medián se používá jako náhrada střední hodnoty v robustní statistice.*