

Rozpoznávanie obrazcov

šk.r. 2019-20

Pravdepodobnosť

Doc. RNDr. Milan Ftáčnik, CSc.

Odbočka do matematiky



Pravdepodobnosť

- Abstraktný matematický model neurčitosti
- Modeluje deje, v ktorých hrá úlohu náhodnosť
- Dedukcia: usudzovanie zo všeobecného na konkrétne
- Populáciu poznáme – čo môžeme povedať o konkrétnej vzorke (výbere)?

Štatistika

- Zber, organizácia a analýza dát
- Zovšeobecňuje z konečných vzoriek
- Odhad parametrov, testovanie hypotéz
- Indukcia: usudzovanie z konkrétneho na všeobecné
- Vzorku poznáme - čo môžeme povedať o populácii?
- Tak fungujú experimentálne vedy

Pravdepodobnosť vs. štatistika

- Ktorú otázku si kladie pravdepodobnosť a ktorú štatistika?
- Ak sme už kúpili niekoľko rovnakých výrobkov a niektoré sa pokazili, čo vieme povedať o tomto type výrobku vo všeobecnosti?
- Ak poznáme kazivosť daného typu výrobku, čo vieme povedať o konkrétnom výrobku, ktorý si kupujeme?

História pravdepodobnosti

- Hľadanie úspechu v hazardných hrách
- Hra: Hod férovou kockou
 - Ak padne 2,3 alebo 4, vyhráte 1 Euro
 - Ak padne 5, vyhráte 2 Eurá
 - Ak padne 1 alebo 6, prehráte 3 Eurá
- Kto by hral takúto hru?

Definícia pravdepodobnosti

- Klasická (Laplaceova): Relatívna početnosť výsledku A v N pokusoch

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

- Limitná: Relatívna početnosť v nekonečne veľkom počte pokusov

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

Definícia pravdepodobnosti II

- Axiomatická (Kolmogorovova):
- Pole javov \mathcal{A} je σ -algebra na Ω , t.j. je to systém podmnožín priestoru Ω obsahujúci Ω a uzavretý voči doplnku a zjednoteniu, čiže

$$1. \Omega \in \mathcal{A},$$

$$2. A \in \mathcal{A} \Rightarrow A^c \in \mathcal{A}$$

$$3. (\forall n \in \mathbb{N}: A_n \in \mathcal{A}) \Rightarrow \bigcup_{n \in \mathbb{N}} A_n \in \mathcal{A}$$

Definícia pravdepodobnosti III

- Pravdepodobnosť je funkcia

$P: \mathcal{A} \rightarrow \langle 0,1 \rangle$, ktorá spĺňa

$$P(\Omega) = 1,$$

$$P(\bigcup_{n \in \mathbb{N}} A_n) = \sum_{n \in \mathbb{N}} P(A_n),$$

ak javy A_n sú po dvoch disjunktné.


- Pravdepodobnostný priestor označujeme (Ω, \mathcal{A}, P)

Ukážka

Množina všetkých možných výstupov =
výberový priestor

Jednotlivé prvky = elementárne javy

Podmnožina výberového priestoru =
(náhodný) jav



Javy

- ***Diskrétne:*** (napr. hod kockou alebo mincou, počet detí v rodine, ...)
- ***Spojité:*** (napr. rozmer výrobku, výška hráčov, ...)
- ***Kvantitatívne:*** (vyjadrujúce množstvo: 17, 42, 11)
- ***Kvalitatívne:*** (vyjadrujúce kvalitu – červený, Škoda, Slovensko)

Príklady

- 1. Tri hody mincou – výberový priestor $\Omega = \{HHH, HHO, HOH, HOO, OHH, OHO, OOH, OOO\}$, javy sú
 - A – aspoň 2x hlava, B – práve 2x orol
- 2. Jeden hod kockou – výberový priestor $\Omega = \{1,2,3,4,5,6\}$, javy sú
 - A – párne čísla, B – čísla menšie ako 5

Operácie


- Zjednotenie $A \cup B$ nastane práve vtedy, keď nastane aspoň jeden z javov
- Opačný jav k A , A^C sa nazýva aj doplnkový/komplementárny ($\Omega \setminus A$)
- Prienik $A \cap B$ nastane práve vtedy, keď nastanú oba javy A a B
- Nezlučiteľné javy – keď A a B nemajú ani jeden spoločný elementárny jav

Rozklad

- **Rozkladom výberového priestoru** nazývame súbor vzájomne disjunktných neprázdnych javov, ktorých zjednotením je celý výberový priestor
- $\{A_i\}_{i=1}^M$
- $\forall i, j: A_i \cap A_j = \emptyset$
- $\bigcup_{i=1}^M A_i = \Omega$

Príklad

- Počet hláv v 10 hodoch mincou
- $A = \{0, 2, 4, 6, 8, 10\}$
- $B = \{1, 3, 5, 7, 9\}$
- $C = \{0, 1, 2, 3, 4, 5\}$
- $A \cup B = \Omega$
- $A \cap B = \emptyset$
- $A \cap C = \{0, 2, 4\}$, $C^C = \{6, 7, 8, 9, 10\}$



Vlastnosti

$$P(\emptyset) = 0$$

$$P(A^C) = 1 - P(A)$$

$$A \subseteq B \Rightarrow P(A) \leq P(B)$$

$$P(B \setminus A) = P(B) - P(A \cap B)$$

$$A \subset B \Rightarrow P(B \setminus A) = P(B) - P(A)$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

$$A \cap B = \emptyset \Rightarrow P(A \cup B) = P(A) + P(B)$$

$$P(A \cup B) = 1 - P((A \cup B)^C) = 1 - P(A^C \cap B^C)$$

$$P(A \cap B) = 1 - P((A \cap B)^C) = 1 - P(A^C \cup B^C)$$

- Javy A a B nazveme nezávislé, ak platí
$$P(A \cap B) = P(A) \cdot P(B)$$

Príklad

- Aká je pravdepodobnosť, že pri hode mincou padne hlava 2x za sebou?
- $P(H) = 0,5$

Príklad

- Aká je pravdepodobnosť, že pri hode mincou padne hlava 2x za sebou?
- $P(H) = 0,5$
- Výsledok druhého hodu B je nezávislý od výsledku prvého hodu A
- Preto výsledná pravdepodobnosť je
$$P(A \cap B) = P(A) \cdot P(B) = 0.5 \cdot 0.5 = 0,25$$

Podmienená pravdepodobnosť

- Pravdepodobnosť, že nastane jav A za podmienky, že nastal jav B


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

- $A = \{0, 2, 4, 6, 8, 10\}$

- $B = \{4, 5, 7, 8, 9\}$

- $A \cap B = \{4, 8\}$

- $P(A \cap B) = \frac{2}{11}, P(B) = \frac{5}{11}, P(A|B) = \frac{2}{5}$



Príklad

- V krabici sa nachádza 10 červených a 5 modrých ponožiek. Ak náhodne vytiahneme dve ponožky, aká je pravdepodobnosť, že ako druhú sme vytiahli modrú?
- Nejde o nezávislé javy
- A = jav, kedy ako prvá bola červená
- B = jav, kedy ako prvá bola modrá
- C = ako druhá vytiahnutá bola modrá ponožka

Príklad II

$$P(A) = \frac{10}{15}, P(B) = \frac{5}{15},$$

$$P(C) = P((C \cap A) \cup (C \cap B))$$

$$P(C) = P(C \cap A) + P(C \cap B)$$

$$P(C|A) = P(C \cap A)/P(A)$$

$$P(C|B) = P(C \cap B)/P(B)$$

$$P(C) = P(C|A) \cdot P(A) + P(C|B) \cdot P(B) =$$

$$\frac{5}{14} \cdot \frac{10}{15} + \frac{4}{14} \cdot \frac{5}{15} = \frac{70}{210} = \frac{1}{3}$$

Veta o úplnej pravdepodobnosti

- Nech $\{A_i\}_{i=1}^M$ je rozklad priestoru $\Omega \Rightarrow \sum_{i=1}^M P(A_i) = 1$. Potom platí

$$P(B) = \sum_{i=1}^M P(B|A_i) \cdot P(A_i)$$

Dôkaz: Ľubovoľný jav $B \in \Omega$ je zjednotením javov $(B \cap A_1), \dots, (B \cap A_M)$. Tieto javy sú disjunktné, preto platí

Veta o úplnej pravdepodobnosti II

$$P(B) = \sum_{i=1}^M P(B \cap A_i).$$

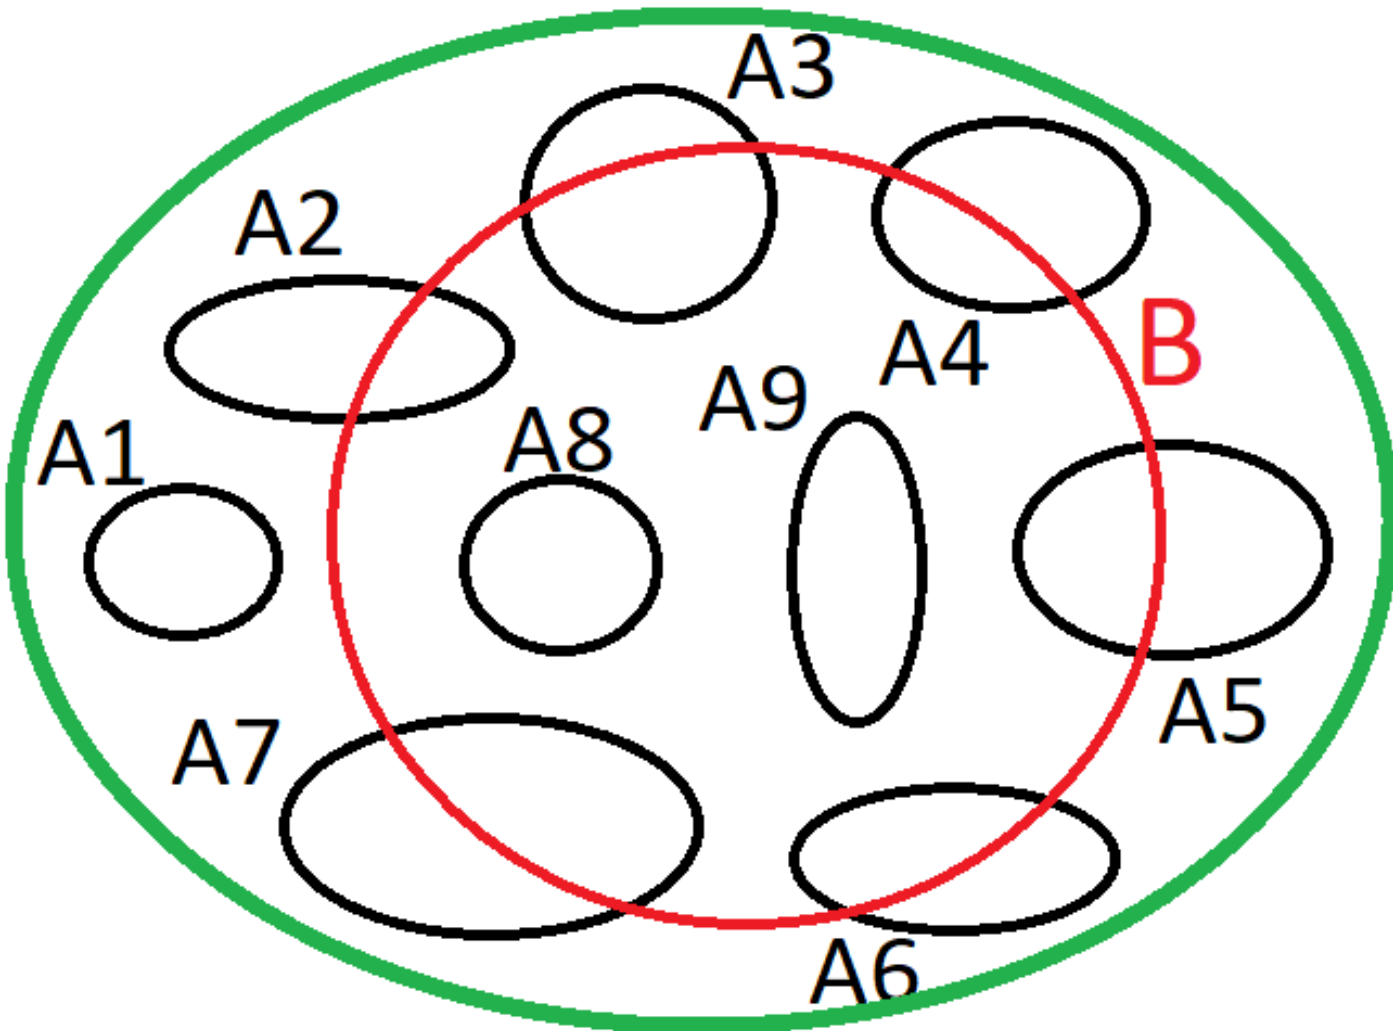
Pretože

$$P(B|A) = \frac{P(B \cap A)}{P(A)}, \text{ spojením dostaneme}$$

$$P(B) = \sum_{i=1}^M P(B|A_i) \cdot P(A_i), \text{ čo sme mali dokázať.}$$

Vieme si to predstaviť?

Veta o úplnej pravdepodobnosti II



Bayesov vzorec

- Ak poznáme $P(B|A_i)$ a $P(A_i)$, ako určíme pravdepodobnosť, že nastane jav A_i za podmienky, že nastalo B ?
- Odpoveďou je Bayesov vzorec

$$P(A_i|B) = \frac{P(B|A_i) \cdot P(A_i)}{P(B)},$$
 kde menovateľ je určený podľa vety o úplnej pravdepodobnosti.

Príklad

- Na konci linky je tester, ktorá s pravdepodobnosťou 0,999 vyradí chybný výrobok.
- S pravdepodobnosťou 0,01 vyradí aj kvalitný výrobok.
- Kazivosť výrobku je 0,1 (jeden z desiatich je chybný).
- Aká je pravdepodobnosť, že vyradený výrobok je naozaj chybný?

Príklad - riešenie

$$P(A_{ch}) = 0,1$$

$$P(A_{kv}) = 0,9$$

Vyradenie výrobku je jav B

$$P(B|A_{ch}) = 0,999$$

$$P(B|A_{kv}) = 0,01.$$

Potom

$$P(A_{ch}|B) = \frac{P(B|A_{ch}) \cdot P(A_{ch})}{P(B|A_{ch}) \cdot P(A_{ch}) + P(B|A_{kv}) \cdot P(A_{kv})}$$

Náhodná premenná



- Pojmom náhodná premenná (veličina) označujeme funkciu, ktorej hodnota je určená výsledkom náhodného pokusu.
- Priraduje číselnú hodnotu každému elementárnemu javu
- Hodnota funkcie sa nedá pred pokusom určiť, ale dokážeme ju popísať rozdelením pravdepodobnosti.

Distribučná funkcia

- Rozdelenie pravdepodobnosti náhodnej premennej definovanej na priestore (Ω, \mathcal{A}, P) opisujeme pomocou distribučnej funkcie $F: \mathbb{R} \rightarrow \langle 0,1 \rangle$
- $F(x) = P(X < x)$
- Distribučná funkcia je neklesajúca a zľava spojitá a platí

Distribučná funkcia II

- $\lim_{x \rightarrow -\infty} F(x) = 0$
- $\lim_{x \rightarrow \infty} F(x) = 1$



Vzťahy medzi P a DF



$$\forall a < b; a, b \in \mathbb{R}$$

$$P(X \geq a) = 1 - F(a) = \int_a^{\infty} f(x) dx$$

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

$$P(X = a) = \lim_{x \rightarrow a^+} F(x) - F(a) = 0$$





Vztáhy mezi P a DF II



Vzťahy medzi P a DF III

- Distribučnú funkciu určíme ako
- $F(X) = \sum_{x_i < X} P(x_i)$
- $F(X) = \int_{-\infty}^X f(t) dt$, kde $f(t)$ je hustota rozdelenia pravdepodobnosti
- $\int_{-\infty}^{\infty} f(x) dx = 1$
- $\lim_{x \rightarrow -\infty} f(x) = 0$ a $\lim_{x \rightarrow \infty} f(x) = 0$

Vztáhy mezi P a DF IV





Diskrétny príklad

- Máme dva stroje (nezávislé na sebe), jeden sa pokazí s pravdepodobnosťou 20% a druhý 30%
- Náhodná premenná X označuje počet pokazených strojov, popíšte ju.
- $\Omega = \{0,1,2\}$, $P(S1) = 0,2$ a $P(S2) = 0,3$
- $P(X = 0) = P(S1^c \cap S2^c) = 0,8 \cdot 0,7 = 0,56$
- $P(X = 1) = P\left((S1 \cap S2^c) \cup (S1^c \cap S2)\right) = 0,38$
- $P(X = 2) = P(S1 \cap S2) = 0,2 \cdot 0,3 = 0,06$

Diskrétny príklad II

x_i	$P(X = x_i)$
0	0,56
1	0,38
2	0,06
Σ	1,00



x	$F(x)$
$(-\infty; 0)$	0
$(0; 1)$	0,56
$(1; 2)$	0,94
$(2; \infty)$	1



Spojité prípad

- Nech X je spojitá náhodná premenná definovaná hustotou pravdepodobnosti

$$f(x) = \begin{cases} 0,75(1-x)(1+x) = 0,75(1-x^2) & -1 < x < 1 \\ 0 & \text{jinde.} \end{cases}$$



$$F(x) = \begin{cases} 0 & x \in (-\infty; -1) \\ \frac{1}{4}(-x^3 + 3x + 2) & x \in \langle -1; 1 \rangle \\ 1 & x \in \langle 1; \infty \rangle \end{cases}$$

$$F(x) = \int_{-\infty}^x f(t) dt$$

Rozdelenia pravdepodobnosti

- **Diskrétne:** Alternatívne, Binomické, Hypergeometrické, Geometrické, Negatívne binomické (Pascalove), Poissonove
- **Spojité:** Rovnomerné, Exponenciálne. Weibullove, Gama-Erlangove, Triangulárne-Simpsonove, Cauchyho, Beta, Raleighove, Normálne, Normované normálne, Logaritmicko-normálne

Rozdelenia pravdepodobnosti II


- **Špecifické (výberové):**
 - χ^2 (chí kvadrát) rozdelenie
 - Studentovo t - rozdelenie
 - Fischerovo F - rozdelenie

Binomické rozdelenie

- Bernoulliho pokusy – postupnosť nezávislých pokusov, kde pravdepodobnosť úspechu je p
- n – celkový počet pokusov
- p – pravdepodobnosť úspechu

$Bi(n, p)$

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



Binomické rozdelenie - použitie

- Pravdepodobnosť, že nastane k úspešných pokusov z n pokusov
 - Počet chlapcov medzi 10.000 novorodencami
 - Počet chybných výrobkov medzi 30 testovanými
 - Počet nevyrastených rastlín zo 100 zasadených cibuliek

Iné diskkrétne rozdelenia

- Alternatívne – binomické pre $n = 1$
- Hypergeometrické – modeluje závislé pokusy
- Geometrické – počet Bernoulliho pokusov do prvého úspechu (niekedy vrátane)
- Pascalove – počet Bernoulliho pokusov do k -teho úspechu (niekedy vrátane)
- Poissonove – počet náhodných udalostí v nejakom pevnom časovom intervale

Iné rozdelenia – použitie



- Hypergeometrické = Toto rozdelenie slúži aj ako pravdepodobnostný model niektorých hazardných hier. Spočítajme pravdepodobnosť s akou bude študent pri skúške vedieť práve jednu z troch náhodne vybraných otázok, ak sa naučil iba päť otázok z dvadsiaticich.
- Geometrické = počet volaní nutných k tomu, aby sme sa dovolali do televíznej súťaže

Iné rozdelenia – použitie II


- Pascalove = počtu cestujúcich, ktorých musí revízor skontrolovať do chvíle, než nájde 10 čiernych pasažierov
- Poissonove = počet pacientov ošetrovaných počas dopoludňajších ordinačných hodín (nahrádza binomické pre veľké n a malé p). Aproximuje málo pravdepodobné udalosti pri veľkom počte nezávislých opakovaní

Spojité: Normálne rozdelenie

- $X \sim N(\mu, \sigma)$ $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$



$$F(x) = \frac{1}{\sigma\sqrt{(2\pi)}} \cdot \int_{-\infty}^x e^{-\frac{t-\mu}{\sqrt{2\sigma}}} dt$$



Odbočka: Gaussova krivka

- Vyjadruje hustotu (početnosť) normálneho rozdelenia pravdepodobnosti
- Má dve premenné, strednú hodnotu μ a smerodajnú odchýlku σ
- Vzťah opisujúci Gaussovu krivku je

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

Odbočka: Gaussova funkcia

- Všeobecná Gaussova funkcia má tvar

$$f(x) = ae^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

- Ak to má byť funkcia hustoty pravdepodobnosti, potom jej integrál sa musí rovnať jednej, čiže $\int_{-\infty}^{\infty} f(x)dx = 1$
- Túto normalizačnú podmienku splníme vhodnou voľbou a

Odbočka: Gaussova funkcia II

- Najjednoduchšia Gaussova funkcia má tvar

$$f(x) = e^{-x^2}$$

- Jej integrál sa rovná $\sqrt{\pi}$, čiže normalizovaná verzia má tvar $f(x) = \frac{1}{\sqrt{\pi}} e^{-x^2}$

- Parameter μ nemá vplyv na hodnotu integrálu, iba posúva funkciu pozdĺž osi x
- Parameter σ graf funkcie rozširuje

Odbočka: Gaussova funkcia III

- Pri rozširovaní grafu sa zväčšuje integrál faktorom $\sigma\sqrt{2}$
- Potom všeobecná normalizovaná verzia Gaussovej funkcie musí mať tvar

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

- Parameter μ má potom význam strednej hodnoty a parameter σ smerodajnej odchýlky

Odbočka: Gaussova funkcia IV

- Potom platí:

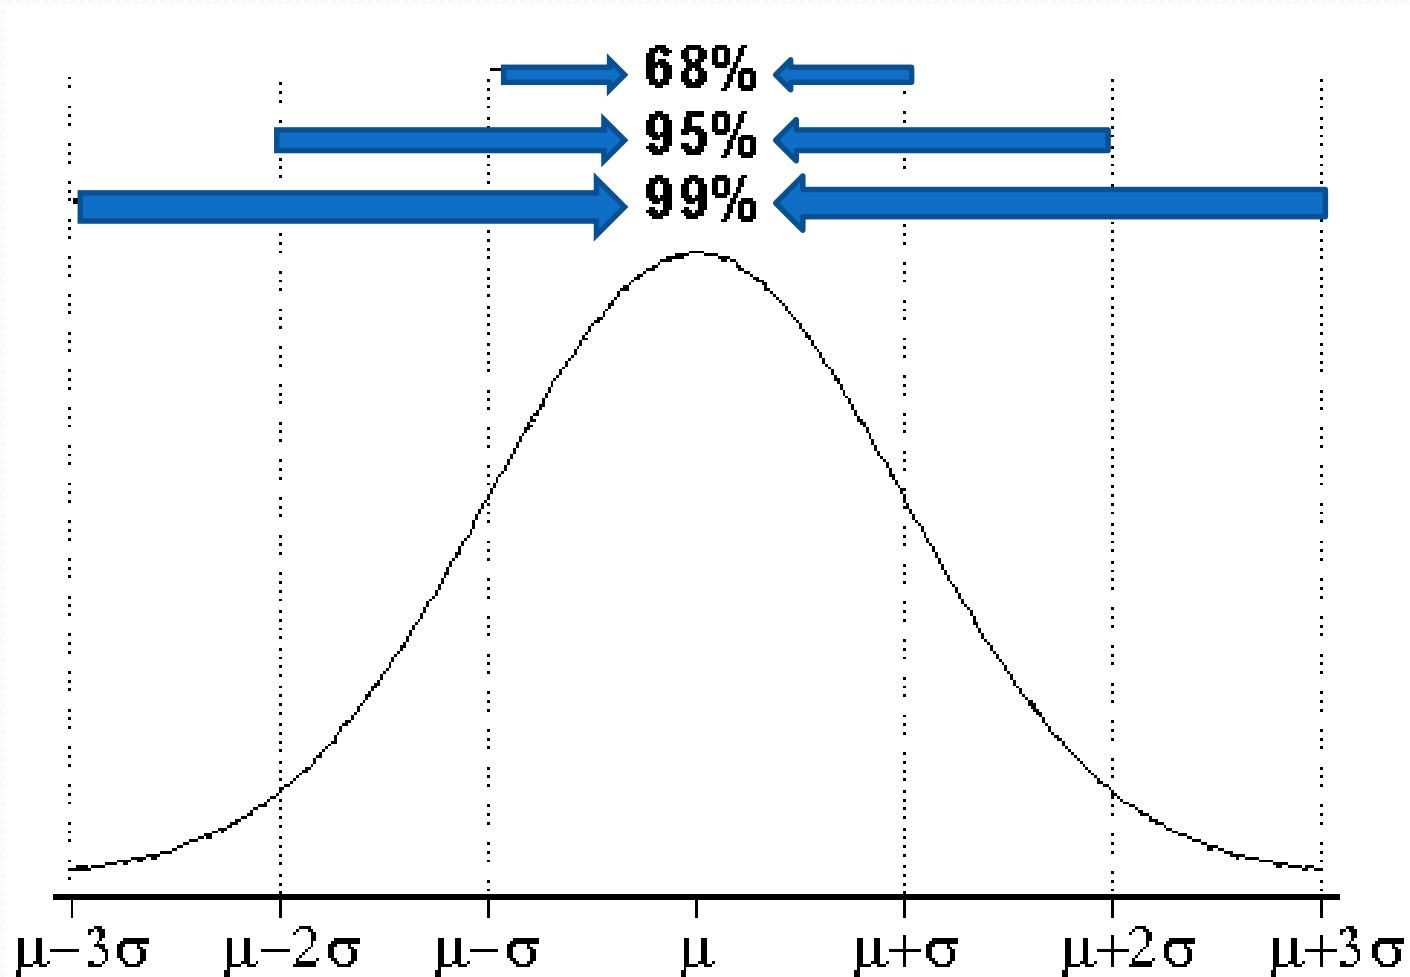
- Pre $x = \sigma$ je $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}}$

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

- Pre $x = 3\sigma$ je $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{9}{2}}$

- Pre $x = 4\sigma$ je $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-8}$

Pravidlo 3 σ





(68,26%, 95,45%,99,73%)

Rovnomerné rozdelenie

- $R(a;b)$ interval (a,b)

$$f(x) = \begin{cases} \frac{1}{b-a} & x \in (a; b) \\ 0 & x \notin (a; b) \end{cases}$$

$$F(x) = \begin{cases} 0 & x \in (-\infty; a) \\ \frac{x-a}{b-a}, & x \in (a; b) \\ 1 & x \in \langle b; \infty \rangle \end{cases}$$



Iné spojité rozdelenia

- Exponenciálne – pravdepodobnosť dĺžky časového intervalu medzi dvoma udalosťami v Poissonovom procese
- Erlangove – čas do výskytu k-tej udalosti v Poissonovom procese
- Logaritmicko-normálne – pre jednostranne ohraničené údaje, ktorých prirodzený logaritmus má normálne rozdelenie

Špeciálne rozdelenia

- Chí kvadrát s n stupňami voľnosti

$$\chi_n^2 - X = X_1^2 + X_2^2 + \dots + X_n^2 \quad X_i \sim N(0,1)$$

- Stredná hodnota je n a rozptyl $2n$
- Graf hustoty tohto rozdelenia je pre malé n nesymetrický, ale pre hodnoty väčšie ako 30 môžeme hustotu aproximovať hustotou normovaného normálneho rozdelenia $N(0,1)$

Špeciálne rozdelenia II

Studentove - $\frac{X}{\sqrt{\frac{Y}{N}}}$ $X \sim N(0,1)$ a $Y \sim \chi_n^2$

Fischerove - $\frac{\frac{X}{n}}{\frac{Y}{m}}$ $X \sim \chi_n^2$ a $Y \sim \chi_m^2$

Studentove rozdelenie sa používa pri testovaní hypotéz s malým počtom vzoriek do 30

Číselné charakteristiky náhodnej premennej

- Charakterizujú vlastnosti náhodnej premennej a umožňujú porovnávať premenné:
- Momenty
- Kvantily
- ...

Momenty

- Všeobecný moment r -tého rádu

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

- Stredná hodnota $E(X)$ ($r=1$) $\mu = \int_{-\infty}^{\infty} x f(x) dx$

- Centrálny moment r -tého rádu

$$\mu'_r = E((X - E(X))^r) = \int_{-\infty}^{\infty} (x - E(X))^r f(x) dx$$


- Rozptyl ($r=2$) $Var(X) = E(X^2) - (E(X))^2$

$$Var(X) = \int_{-\infty}^{\infty} (x - E(X))^2 f(x) dx$$


Šikmost' a špicatosť

- Šikmost'


$$\alpha_3 = \frac{\mu'_3}{\sigma^3}$$



(a) Pozitívne zošikmené rozdelenie.




(b) Symetrické rozdelenie.



(c) Negatívne zošikmené rozdelenie.

- Špicatosť


$$\alpha_4 = \frac{\mu'_4}{\sigma^4}$$



Normálna (0), menšia (< 0) a väčšia (> 0) špicatosť rozdelenia

Kvantily

- Kvantil Q_p je hodnota, pre ktorú platí, že pravdepodobnosť, že náhodná veličina X má hodnotu menšiu ako Q_p , je $100p\%$
- $P(X < Q_p) = p$ $F(Q_p) = p$
- **Medián** – kvantil deliaci súbor na polovice



Kvartil, decil, percentil

• Kvartil


- $Q_{0,25}$ (dolný kvartil), $Q_{0,5}$ a $Q_{0,75}$ (horný kvartil)
- Medzikvartilové rozpätie

• Decil

- $Q_{0,1}, Q_{0,2}, \dots, Q_{0,9}$
- Medzidecilové rozpätie

• Percentil

- $Q_{0,01}, Q_{0,02}, \dots, Q_{0,99}$
- Medzipercentilové rozpätie



Viacrozmerný prípad


- (X, Y) – dvojrozmerná náhodná premenná
- *Združená distribučná funkcia* $F(x, y) = P(X < x, Y < y)$ – pravdepodobnosť, že súčasne nastanú dve udalosti
- *Marginálna DF*
$$F_1(x) = P(X < x) = P(X < x, Y < \infty)$$
$$= F(x, \infty)$$
- *Podmienená DF* $F(x|y) = P(X < x|Y = y)$
- *Nezávislosť premenných* $F(x, y) = F_1(x) \cdot F_2(y)$

Viacrozmerný prípad II

- $f(x, y)$ – združená hustota rozdelenia pravdepodobnosti
- $f(x, y) = f(x|y) \cdot f(y) = f(y|x) \cdot f(x)$

Podmienená marginálna

- Pre nezávislé premenné
 $f(x, y) = f(x) \cdot f(y)$



Charakteristiky

- Vektor stred. hodnôt $E(\mathbf{X}) = (E(X_1), \dots, E(X_N))$
- Vektor rozptylov $Var(\mathbf{X}) = (Var(X_1), \dots, Var(X_N))$
- Obecný združený moment (r_1, \dots, r_N) -tého rádu

$$\mu_{r_1, \dots, r_N} = E(X_1^{r_1} X_2^{r_2} \dots X_N^{r_N}) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} x_1^{r_1} x_2^{r_2} \dots x_N^{r_N} f(x_1, \dots, x_N) dx_1 \dots dx_N$$

- Centrálny združený moment (r_1, \dots, r_N) -tého rádu

$$\mu'_{r_1, \dots, r_N} = E\left(\left(X_1 - E(X_1)\right)^{r_1} \dots \left(X_N - E(X_N)\right)^{r_N}\right) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} (x_1 - E(X_1))^{r_1} \dots (x_N - E(X_N))^{r_N} f(x_1, \dots, x_N) dx_1 \dots dx_N$$

Momenty používané v 2D CV

- Škálovo a translačne invariantné momenty

- $$\eta_{i,j} = \frac{\mu'_{i,j}}{\mu'_{0,0} \left(1 + \frac{i+j}{2}\right)}$$

- Škálovo, translačne aj rotačne invariantné

$$I_1 = \eta_{2,0} + \eta_{0,2}$$

$$I_2 = (\eta_{2,0} - \eta_{0,2})^2 + 4\eta_{1,1}^2$$

Kovariancia

- Stredná hodnota a rozptyl sú užitočné pri skúmaní 1D náhodnej premennej
- Ak má premenná viac rozmerov, mierou na skúmanie ich vzťahu je kovariancia

$$\mathit{Cov}(X_i, X_j) = E((X_i - E(X_i))(X_j - E(X_j)))$$

$$\mathit{Cov}(X_i, X_j) = E(X_i X_j) - E(X_i)E(X_j)$$

$$\mathit{Cov}(X_i, X_i) = E(X_i^2) - (E(X_i))^2 = \mathit{Var}(X_i)$$

$$\mathit{Cov}(X_i, X_j) = \mathit{Cov}(X_j, X_i)$$

Kovariancia II

- To bola kovariancia pre dva rozmery, pre N vypočítame kovariančnú maticu



$$\Sigma = \begin{bmatrix} \text{Var}(X_1) & \text{Cov}(X_1, X_2) & \cdots & \text{Cov}(X_1, X_N) \\ \text{Cov}(X_2, X_1) & \text{Var}(X_2) & \cdots & \text{Cov}(X_2, X_N) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_N, X_1) & \text{Cov}(X_N, X_2) & \cdots & \text{Var}(X_N) \end{bmatrix}$$

- Pri kovariancii nejde o absolútnu hodnotu, ale o znamienko, ak je kladné obe premenné rastú súčasne, ak záporné, tak ak 1. rastie, 2. klesá

Normálne rozdelenie


$$\mathbf{X} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$$

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^N |\boldsymbol{\Sigma}|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$




$$\text{Var}(X) = \text{Var}(Y) = 1, \text{Cov}(X, Y) = 0$$


Normálne rozdelenie II



$$\text{Var}(X) = 2, \text{Var}(Y) = 1, \text{Cov}(X, Y) = 0$$




$$\text{Var}(X) = 1, \text{Var}(Y) = 2, \text{Cov}(X, Y) = 0$$



$$\text{Var}(X) = 2, \text{Var}(Y) = 1, \text{Cov}(X, Y) = -0,5$$

2019-20



$$\text{Var}(X) = 2, \text{Var}(Y) = 1, \text{Cov}(X, Y) = 0,5$$