

Pravděpodobnost a statistika; Opakování pro rozpoznávání

Václav Hlaváč

České vysoké učení technické v Praze

Český institut informatiky, robotiky a kybernetiky

160 00 Praha 6, Jugoslávských partyzánů 1580/3

<http://people.ciirc.cvut.cz/hlavac>, vaclav.hlavac@cvut.cz

také z Centra strojového vnímání, <http://cmp.felk.cvut.cz>

Poděkování: T. Brox, V. Franc, R. Gutierrez-Osuna, M. Navara, M. Urban.

Osnova přednášky:

- ◆ Pravděpodobnost × statistika.
- ◆ Náhodné jevy.
- ◆ Sdružená, podmíněná pravděpodobnost.
- ◆ Bayesova věta.
- ◆ Distribuční funkce, hustota.
- ◆ Charakteristiky náhodných veličin.

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, 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?

Statistika, motivační příklad

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.

Pravděpodobnost, statistika

- ◆ **Pravděpodobnost: Pravděpodobnostní popis \implies budoucí chování systému.**
 - je teorie (nástroj) pro účelné rozhodování v situacích, kdy výsledek náhodných jevů závisí na okolnostech, které známe jen částečně.
 - Poskytuje model takových systémů a slouží jako nástroj pro kvantifikaci výsledků.
- ◆ **Statistika: Chování systému \implies pravděpodobnostní popis.**
 - je nástroj pro hledání a ověřování pravděpodobnostního popisu reálných systémů na základě jejich pozorování.
 - Poskytuje daleko víc: Nástroj pro zkoumání světa, pro hledání a ověřování závislostí, které nejsou zjevné.
 - Dva typy: Popisná nebo inferenční statistika.
 - Sběr, organizace a analýza dat.
 - Zobecňuje z omezených / konečných vzorků.
 - Odhad parametrů, testování hypotéz, atd.

Náhodné jevy, pojmy

Náhodný pokus

Prostor elementárních jevů je neprázdná množina Ω 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 Ω .

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.

Pravděpodobnost, zavedení


- ◆ **Klasická** (P.S. Laplace, 1812. 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)



histogram × spojitá hustota
pravděpodobnosti

Axiomatická definice pravděpodobnosti

- ◆ Ω - prostor elementárních jevů
- ◆ \mathcal{A} - jevové pole

1. $P(A) \geq 0, \quad A \in \mathcal{A}.$
2. $P(\Omega) = 1.$

Neformálně: Pokaždé, když se uskuteční experiment, poskytne nějaký výsledek.

3. Jestliže $A \cap B = \emptyset$, pak $P(A \cup B) = P(A) + P(B), \quad A \in \mathcal{A}, B \in \mathcal{B}.$

Fine, T. (2014). Theories of Probability: An Examination of Foundations. Academic Press.

Tři Kolmogorovovy axiomy nám neříkají (neposkytují): (a) Kde a kdy se mají použít; (b) Návody nebo postupy pro výpočet pravděpodobností; (c) Vhled to podstaty náhodných procesů.

Pravděpodobnost

je funkce P , která jevům přiřazuje čísla z intervalu $[0, 1]$ a splňuje podmínky

$$(P1) \quad P(\text{true}) = 1,$$

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

Z těchto podmínek vyplývá:

- ◆ $P(\text{false}) = 0$
- ◆ $P(\neg A) = 1 - P(A)$,
- ◆ jestliže $A \subseteq B$, pak $P(A) \leq P(B)$.

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

Odvozené vztahy

◆ Jestliže $A \subset B$, pak $P(B \setminus A) = P(B) - P(A)$.
Symbol \setminus označuje množinový rozdíl.

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

◆ Statistická nezávislost: $P(A \cap B) = P(A) P(B)$

Slovy: Jevy A a B jsou nezávislé, když znalost o výskytu jevu A nám neříká nic o výskytu jevu B .

Sdružená pravděpodobnost, marginalizace


- ◆ **Sdružená pravděpodobnost** $P(A, B)$, také někdy označovaná $P(A \cap B)$, je pravděpodobnost, že jevy A, B nastanou současně.
- ◆ Sdružená pravděpodobnost je symetrická: $P(A, B) = P(B, A)$.
- ◆ **Marginalizace** (neformálně sčítací pravidlo, ignoruje se proměnná(é)):
$$P(A) = \sum_B P(A, B)$$
 umožňuje vypočítat pravděpodobnost jevu A ze sdružené pravděpodobnosti $P(A, B)$ jako $P(A, B)$ přes všechny možné jevy B . Pravděpodobnosti $P(A)$ se říká marginální pravděpodobnost.

Kontingenční tabulka, marginalizace


Příklad – závod v orientačním běhu

Orienteering competition example, participants									
Age	<= 15	16-25	26-35	36-45	46-55	56-65	66-75	>= 76	Sum
Men	22	36	45	33	29	21	12	2	200
Women	19	32	37	30	23	14	5	0	160
Sum	41	68	82	63	52	35	17	2	360

Orienteering competition example, frequency									
Age	<= 15	16-25	26-35	36-45	46-55	56-65	66-75	>= 76	Sum
Men	0,061	0,100	0,125	0,092	0,081	0,058	0,033	0,006	0,556
Women	0,053	0,089	0,103	0,083	0,064	0,039	0,014	0,000	0,444
Sum	0,114	0,189	0,228	0,175	0,144	0,097	0,047	0,006	1



Marginal probability $P(\text{sex})$



Marginal probability $P(\text{Age_group})$

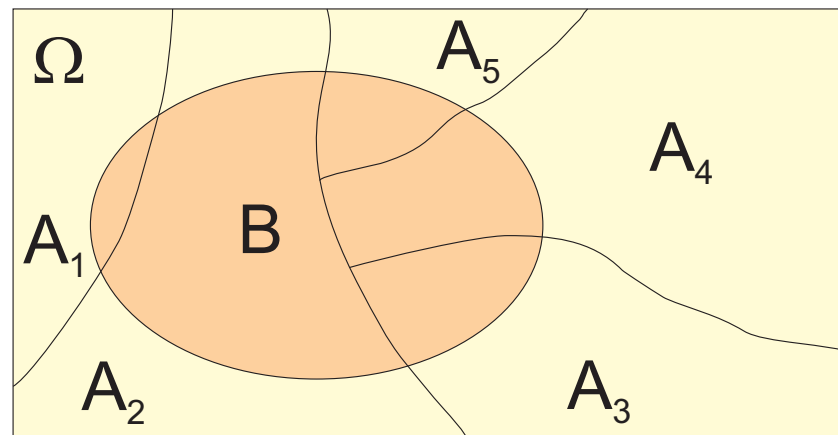
Použití rozdělení množiny na části

Když se jevy A_i vzájemně vylučují a rozdělují zcela prostor jevů Ω , tj.

$$A_i \cap A_j = \emptyset, \text{ for } \forall i, j, \quad \bigcup_{i=1, \dots, n} A_i = \Omega,$$

potom


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



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 pravděpodobnosti

- ◆ $P(\text{true}|B) = 1, P(\text{false}|B) = 0.$
 - ◆ 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
$$\bigvee_{i \in I} B_i = \text{true}.$$
 - ◆ Úplný systém jevů má tu vlastnost, že nastane právě jeden z nich.

Příklad: podmíněná pravděpodobnost

Jeden hod kostkou. 

Jaká je pravděpodobnost, že padne číslo > 3 (jev A) za podmínky, že padlo liché číslo (jev B).





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

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

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

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

Sdružená a podmíněná pravděpodobnost, příklad



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

(Thomas Bayes *1702 - †1761)

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

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

kde $P(B_i|A)$ je **aposteriorní** pravděpodobnost; $P(B_i)$ je **apriorní** pravděpodobnost a $P(A|B_i)$ jsou známé **podmíněné pravděpodobnosti** jevu A , když známe pozorování B_i .

Důkaz (s využitím věty o úplné pravděpodobnosti):

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

Význam Bayesovy věty

- ◆ Bayesova věta je základním nástrojem strojového učení (rozpoznávání).
Známe (pozorujeme) jevy B_i , kde $i \in I$ představuje rozdělení prostoru jevů na části. Předpokládejme, že nastane jev A . Bayesova věta dovoluje optimálně odhadnout, který z jevů B_i nastal.
 - ◆ Podmíněné pravděpodobnosti $P(A|B_i)$ (někdy se jim říká věrohodnosti) se odhadují pomocí experimentů nebo ze statistického modelu.
 - ◆ Když známe podmíněné $P(A|B_i)$, můžeme určit aposteriorní pravděpodobnosti $P(B_i|A)$, které slouží k optimálnímu odhadu, který jev z B_i nastal.
 - ◆ K výpočtu aposteriorní pravděpodobnosti $P(B_i|A)$ musíme znát *apriorní* pravděpodobnosti $P(B_i)$.
 - ◆ Neformálně: *aposteriorní* \propto (*apriorní* \times *podmíněné pravděpodobnosti*) jevu při známých pozorováních.
-
- ◆ Podobně definujeme podmíněné rozdělení náhodné veličiny, podmíněnou hustotu spojité náhodné veličiny apod.

ML and MAP

Opišme Bayesovu větu z průsvitky 19

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

- ◆ Apriorní pravděpodobnosti je pravděpodobnost $P(B_i)$, která nevyužívá znalost z pozorování (experimentů).
- ◆ Věrohodnost (podmíněná pravděpodobnost jevu A za podmínky B_i) ohodnocuje kandidáta na výstup měření. Postupu hledání takového ohodnocení výstupu, které maximalizuje věrohodnost, se říká **postup maximální věrohodnosti**, zkráceně **ML postup**.
- ◆ Aposteriorní pravděpodobnost je pravděpodobnost jevu B_i , když se vezme v úvahu pozorování (měření). Postupu, který maximalizuje aposteriorní pravděpodobnost, se říká **postup maximální aposteriorní pravděpodobnosti**, zkráceně **MAP postup**.

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.

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.

Náhodná veličina

- ◆ **Náhodná veličina** je libovolná funkce $X : \Omega \rightarrow \mathbb{R}$, kde Ω je prostor elementárních jevů.
- ◆ **Proč byl zaveden pojem náhodné veličiny?** Dovoluje pracovat s pojmy jako distribuční funkce, hustota pravděpodobnosti, matematické očekávání (střední hodnota), atd..
- ◆ Existují **dva základní typy** náhodných veličin:
 - **Diskrétní** – mají spočítatelně hodnot. *Příklady: vrhací kostka, počet aut, které ulicí projela za hodinu.*
 Diskrétní pravděpodobnost je dána $P(X = a_i) = p(a_i)$, $i = 1, \dots$,
 $\sum_i p(a_i) = 1$.
 - **Spojitě** – hodnoty jsou z intervalu, tedy z nekonečného množství hodnot. *Example: výška člověka.*
 Spojitá pravděpodobnost je dána distribuční funkcí nebo hustotou pravděpodobnosti.

Distribuční funkce náhodné veličiny

Distribuční funkce náhodné veličiny X je funkce $F: X \rightarrow [0, 1]$ 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.


Spojité distribuční funkce a hustota

- ◆ 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 pravděpodobnosti 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 pravděpodobnosti

Příklad: rozdíl mezi pravděpodobností a hustotou pravděpodobnosti



- ◆ Otázka 1: Jaká je pravděpodobnost, že změřená teplota je přesně 31.5°C ?
 - ◆ Odpověď 1: Tato pravděpodobnost je nula v limitě.
-
- ◆ Otázka 2: Jaká je pravděpodobnost, že měřená teplota je v intervalu mezi 30°C and 31°C ?
 - ◆ Odpověď 2: Tato pravděpodobnost je dána plochou pod hustotou pravděpodobnosti (také funkce hustoty pravděpodobnosti), což je zhruba 0,09 podle odhadu z obrázku výše.

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.

Matematické očekávání, též střední hodnota

- ◆ (Matematické) očekávání = průměrná hodnota pravděpodobnostního rozdělení.
- ◆ Spojitá definice: $E(x) = \mu = \int_{-\infty}^{\infty} x f(x) dx$.
- ◆ Diskrétní definice: $E(x) = \mu = \sum_x x P(x)$.
- ◆ Očekávání lze odhadnout z řady vzorků pomocí $E(x) \approx \frac{1}{N} \sum_i x_i$. Odhad se stane přesným, když $N \rightarrow \infty$.
- ◆ Očekávání přes více proměnných: $E_x(x, y) = \int_{-\infty}^{\infty} (x, y) f(x) dx$
- ◆ Podmíněné očekávání: $E(x|y) = \int_{-\infty}^{\infty} x f(x|y) dx$.

Základní charakteristiky náhodné veličiny

Spojité rozdělení

Diskrétní rozdělení

Matematické očekávání

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

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

k -tý obecný moment

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

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

k -tý centrální moment

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

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

Rozptyl, disperze, 2. centrální moment

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

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

Standardní odchylka $\sigma(x) = \sqrt{D(x)}$


Centrální limitní věta (1)

Centrální limitní věta poskytuje pravděpodobnostní popis výběrových průměrů, které byly vytvořena z průměrů nekonečného počtu náhodně vybraných vzorků o velikosti N z rodičovské populace. Centrální limitní věta dovoluje předpovědět pravděpodobnostní charakteristiky nezávisle na rozdělení rodičovské populace.

1. Střední hodnota populace výběrových průměrů (tj. která vznikne z výběrových průměrů o N vzorcích náhodně vybíraných z rodičovské populace), se rovná střední hodnotě rodičovské populace.
2. Standardní odchylka populace výběrových průměrů se rovná standardní odchylce rodičovské populace dělené druhou odmocninou velikosti vzorků N .
3. Pravděpodobnostní rozdělení výběrových průměrů se bude blížit normálnímu (gausovskému) rozdělení s rostoucí velikostí N vybíraných vzorků.

Centrální limitní věta (2)

- ◆ Důsledkem Centrální limitní věty je skutečnost, že po průměrování měření určité veličiny se pravděpodobnostní rozložení těchto průměru bude blížit normálnímu (gaussovskému) rozdělení.
- ◆ Uvažujme měřenou veličinu složenou z několika dalších nekorelovaných veličin, které jsou zatíženy šumem různých rozdělení. Pravděpodobnostní rozdělení složené veličiny se bude blížit k normálnímu rozdělení, když bude narůstat počet veličin tvořících složeninu.
- ◆ Důsledkem Centrální limitní věty je tudíž i častý výskyt normálního rozložení týkajících se měření.



Centrální limitní věta (3), aplikační pohled

- ◆ Pro aplikace je podstatné, že není potřebné generovat velké množství náhodných výběrů. Stačí pořídit jediný dosti velký náhodný výběr a díky centrální limitní větě víme, jaké je rozdělení výběrových průměrů, aniž je musíme generovat.
- ◆ Co lze považovat za dostatečně velký výber? Záleží na aplikaci. Ve statistice bývá považováno za dolní hranici 30-50 pozorování. Vzpomeňte na vzorky kolem 1000 respondentů v odhadech volebních výsledku.
- ◆ Míra nejistoty hodnoty parametru populace (zde jsme mluvili jen o průměru) se vyjadřuje intervalem spolehlivosti. Viz učebnice statistiky.

Statistický princip filtrace šumu

Uvažujme skoro nejjednodušší statistický model šumu v obraze.

Nechť je každý pixel obrazu zatížen náhodným aditivním šumem:

- ◆ statisticky nezávislým,
- ◆ s nulovou střední hodnotou μ ,
- ◆ směrodatnou odchylkou σ .

Mějme i realizací, $i = 1, \dots, n$. Odhad správné hodnoty je

$$\frac{g_1 + \dots + g_n}{n} + \frac{\nu_1 + \dots + \nu_n}{n}.$$

Výsledkem je náhodná veličina s $\mu' = 0$ a $\sigma' = \sigma/\sqrt{n}$.

Předchozí úvaha má oporu v teorii pravděpodobnosti, a to ve velmi silné a obecné Centrální limitní větě.

Náhodné vektory

- ◆ Pojem “náhodný vektor” rozšiřuje pojem “náhodné číslo”. Náhodný vektor X je (sloupcový) vektor, který přiřazuje náhodné veličiny x_1, \dots, x_n výsledkům pokusu, tj. elementárním jevům $\omega \in \Omega$.
- ◆ Uvažujme **náhodný vektor** $X = (x_1, x_2, \dots, x_n)^\top$. Distribuční funkce a hustota pravděpodobnosti se rozšíří takto
 - **sdružená distribuční funkce**

$$F_X(x) = P_X((X_1 \leq x_1) \cap (X_2 \leq x_2) \cap \dots \cap (X_n \leq x_n))$$

- **sdružená hustota pravděpodobnosti**

$$f_X(x) = \frac{\partial^n F_X(x)}{\partial x_1 \partial x_2 \dots \partial x_n}$$

Jednodušší charakteristiky náhodných vektorů, střední vektor, kovarianční matice



- ◆ Mějme na paměti, že náhodný vektor plně charakterizuje jeho sdružená distribuční funkce nebo sdružená hustota pravděpodobnosti.
- ◆ Podobně jako u náhodných proměnných je praktické používat jednodušší popisné charakteristiky náhodných vektorů jako
 - Vektor střední hodnoty (matematického očekávání)

$$E(\mathbf{X}) = (E(x_1), E(x_2), \dots, E(x_n))^T = \mu = (\mu_1, \mu_2, \dots, \mu_n)^T$$

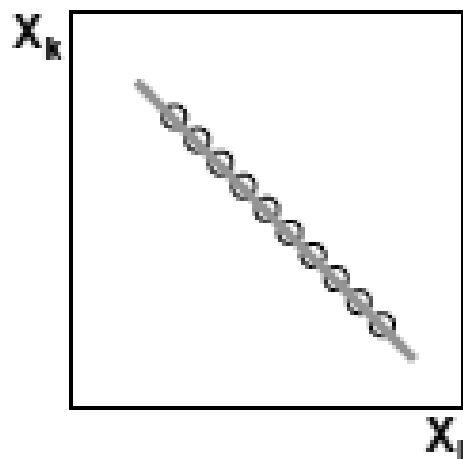
- Kovarianční matice (*Zobecňuje pojem rozptylu do více dimenzí.*)

$$\Sigma_{\mathbf{X}}(i, k) = \text{cov}(\mathbf{X}) = E((\mathbf{X} - \mu)(\mathbf{X} - \mu)^T) = \begin{bmatrix} \sigma_1^2 & \dots & c_{1n} \\ \dots & \ddots & \dots \\ c_{n1} & \dots & \sigma_n^2 \end{bmatrix}$$

Kovarianční matice, vlastnosti

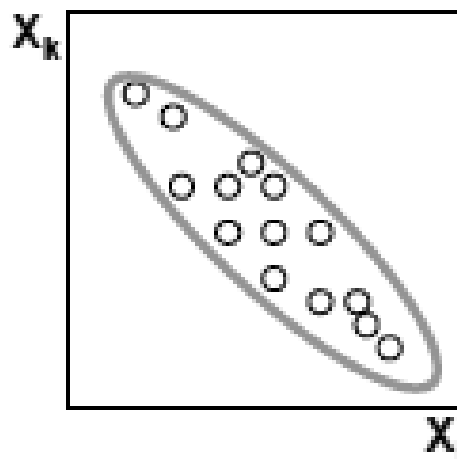
- ◆ Kovarianční matice naznačuje podobnost, jakou se mění každá možná dvojice prvků náhodného vektoru (jinak, jak se společně mění; angl. co-vary).
- ◆ Kovarianční matice má několik důležitých vlastností
 - Kovarianční matice je symetrická (tj. $\Sigma = \Sigma^T$) a je pozitivně semidefinitní, což znamená, že $x^* M x \geq 0$ pro všechna $x \in \mathbb{C}$. Značení x^* znamená komplexně sdružené číslo k číslu x .
 - Když se x_i a x_k obě zvětšují, potom $c_{ik} > 0$.
 - Když x_i klesá a současně x_k roste, potom $c_{ik} < 0$.
 - Když jsou x_i a x_k nekorelované, potom $c_{ik} = 0$.
 - $|c_{ik}| \leq \sigma_i^2$, kde σ_i je standardní odchylka x_i .
 - $c_{ii} = \sigma_i^2 = D(x_i)$.
- ◆ Prvky kovarianční matice se mohou vyjádřit jako $c_{ii} = \sigma_i^2$ and $c_{ik} = \rho_{ik} \sigma_i \sigma_k$. Veličině ρ_{ik} se říká korelační koeficient.

Prvky kovarianční matice, grafická ilustrace



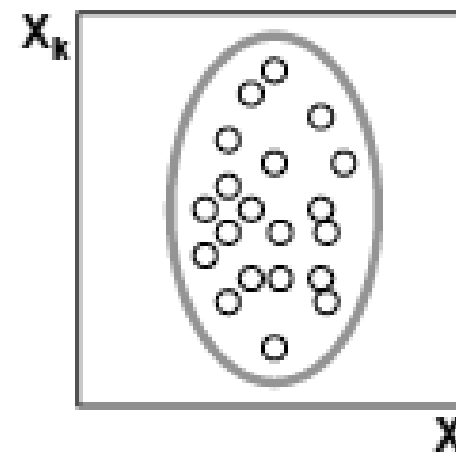
$$C_{IK} = -\sigma_I \sigma_K$$

$$\rho_{IK} = -1$$




$$C_{IK} = -\frac{1}{2} \sigma_I \sigma_K$$

$$\rho_{IK} = -\frac{1}{2}$$




$$C_{IK} = 0$$

$$\rho_{IK} = 0$$



$$C_{IK} = +\frac{1}{2} \sigma_I \sigma_K$$

$$\rho_{IK} = +\frac{1}{2}$$



$$C_{IK} = \sigma_I \sigma_K$$

$$\rho_{IK} = +1$$

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.