

SOUČINOVÉ DISTRIBUČNÍ SMĚSI

II. část: Příklady použití a strukturní model

Jiří Grim

Ústav teorie informace a automatizace AV ČR

Oddělení rozpoznávání obrazů

Květen 2008

Přednáška je volně k dispozici na adrese <http://www.utia.cas.cz/RO>

Outline

- 1 Aplikační oblast: statistické rozpoznávání
 - Obecné řešení statistického problému rozpoznávání
 - Příklad 1: Rozpoznávání obrazců na šachovnici
 - Příklad 2: Rozpoznávání číslic na binárním rastru
- 2 Predikce pomocí součinných distribučních směsí
 - Příklad 3: Modelování textur metodou postupné predikce
 - Příklad 4: Predikce chybějících částí obrázku
- 3 Statistické modelování pomocí součinných směsí
 - Příklad 5: Interaktivní statistický model dat ze sčítání lidu
 - Příklad 6: Vyhledávání poruch a odchylek v textuře
 - Příklad 7: Vyhodnocování mamogramů pomocí směšových modelů
- 4 Shrnutí: Vlastnosti součinných distribučních směsí

Statistické řešení problému rozpoznávání

$\mathbf{x} = (x_1, \dots, x_N) \in \mathcal{X}$: N-rozměrné datové vektory

$\Omega = \{\omega_1, \omega_2, \dots, \omega_J\}$: konečný počet tříd, pravděpodobnosti tříd: $p(\omega)$

$P(\mathbf{x}|\omega)$, $\omega \in \Omega$: odhadnuté podmíněné distribuce

BAYESŮV VZOREC: aposteriorní pravděpodobnosti tříd

$$p(\omega|\mathbf{x}) = \frac{P(\mathbf{x}|\omega)p(\omega)}{P(\mathbf{x})}, \quad P(\mathbf{x}) = \sum_{\omega \in \Omega} P(\mathbf{x}|\omega)p(\omega), \quad \mathbf{x} \in \mathcal{X}$$

BAYESOVA ROZHODOVACÍ FUNKCE: minimalizuje pravděp. chyby

$$d(\mathbf{x}) = \omega_0 = \arg \max_{\omega \in \Omega} \{p(\omega|\mathbf{x})\} = \arg \max_{\omega \in \Omega} \{P(\mathbf{x}|\omega)p(\omega)\}$$

ŘEŠENÍ: odhad neznámých distribucí $P(\mathbf{x}|\omega)$ na základě trénovacích datových souborů $\mathcal{S}_\omega = \{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(K_\omega)}\}, \omega \in \Omega$

POZN. Součinnové komponenty umožňují sekvenční rozhodování (postupné doplňování proměnných) výběr informativních příznaků (globálně i lokálně)

Příklad 1: Rozpoznávání obrazců na šachovnici

Problém:

rozpoznávání dvou tříd obrazců vzniklých na šachovnici náhodnými tahy věže (třída ω_1) resp. jezdce (třída ω_2)

dimenze vektorů: $N = 8 \times 8 = 64$

počet náhodných tahů: do obsazení 20 různých políček

$$\mathbf{x} = (x_1, \dots, x_{64}) \in \{0, 1\}^{64}, \quad x_n \in \{0, 1\}, \quad \sum_{n=1}^{64} x_n = 20, \quad \Omega = \{\omega_1, \omega_2\}$$

Vlastnosti problému:

netriviální statistický charakter problému, neprázdný průnik tříd, neexistují jednoduché příznaky, možnost generování libovolně velkých trénovacích souborů dat

Příklad 1: Rozpoznávání obrazců na šachovnici

Řešení: (Grim et al., 2003)


aproximace podmíněných distribucí $P(\mathbf{x}|\omega)$ pomocí směsí Bernoulliho rozložení s dimenzí $N = 64$

$$P(\mathbf{x}|\omega) = \sum_{m \in \mathcal{M}_\omega} f(m) \prod_{n=1}^{64} \theta_{mn}^{x_n} (1 - \theta_{mn})^{1-x_n}, \quad x_n \in \{0, 1\}, \omega \in \Omega$$

- počet komponent směsi: $|\mathcal{M}_\omega| = 5$; (20; 100;)
- identické počáteční váhy komponent: $f(m) = 1/|\mathcal{M}_\omega|$
- velikost trénovacího souboru: $|\mathcal{S}_\omega| = 2 \times 10^4$; (2×10^5 ; 5×10^6 ;))
- počáteční hodnoty θ_{mn} generovány náhodně z intervalu $\langle 0.1, 0.9 \rangle$
- počet iterací EM algoritmu omezen podmínkou $(L' - L)/L < 5 \times 10^{-3}$


Příklad 1: Rozpoznávání obrazců na šachovnici

Parametry směsi θ_{mn} pro třídu "jezdec"



Příklad 1: Rozpoznávání obrazců na šachovnici

Parametry směsi θ_{mn} pro třídu "věž"



Příklad 1: Rozpoznávání obrazců na šachovnici

PŘESNOST ROZPOZNÁVÁNÍ OBRAZCŮ NA ŠACHOVNICI

	<i>param.</i>	$ \mathcal{S}_\omega = 2 \times 10^4$	$ \mathcal{S}_\omega = 2 \times 10^5$	$ \mathcal{S}_\omega = 5 \times 10^6$
$ \mathcal{M}_\omega = 5$	324	80.19	83.79	83.96
$ \mathcal{M}_\omega = 20$	1299	74.11	91.40	91.83
$ \mathcal{M}_\omega = 100$	6499	54.97	90.36	96.35

- přesnost testována na nezávislém datovém souboru: $|\mathcal{S}_\omega^{test}| = 5 \times 10^5$
- směs 5 komponent je příliš jednoduchá, přesnost rozpoznávání se nezvýší ani po zvětšení trénovacího souboru
- směs 20 komponent dosahuje značnou přesnost již při $|\mathcal{S}_\omega| = 2 \times 10^5$, další zvětšení trénovacího souboru nemá vliv
- směs 100 komponent vyžaduje velký počet dat, ale dosahuje nejpřesnější výsledky rozpoznávání

Příklad 2: Rozpoznávání číslic na binárním rastru

Problém:

rozpoznávání rukou psaných číslic na binárním rastru z databáze Concordia University, Montreal (směrovací čísla z nedoručených dopisů)
4000 trénovacích číslic, tj. 400 pro každou třídu $\omega \in \Omega$
2000 číslic pro nezávislé testování, tj. 200 pro každou třídu

Předzpracování dat:

normalizace číslic na velikost rastru 32×32 (tj. dimenze dat $N = 1024$)
nebyly konstruovány žádné speciální příznaky, databáze byla rozšířena čtyřmi nezávislými posuvy normalizovaných číslic vertikálně i horizontálně ($\pm 1, \pm 2$), tj. pro každou číslici 5×5 nezávislých pozic

popis číslic: $x_n \in \{0, 1\}$, $\mathbf{x} = (x_1, x_2, \dots, x_{1024}) \in \mathcal{X}$, $\mathcal{X} = \{0, 1\}^{1024}$

počet tříd: $|\Omega| = 10$, $\Omega = \{\omega_0, \omega_1, \dots, \omega_9\}$

výsledný soubor: 100000 vzorků číslic ($|\mathcal{S}_\omega| = 5 \times 5 \times 400 = 10000$)

POZN. Pořadí políček rastru ve vektoru \mathbf{x} může být zvoleno libovolně.

Příklad 2: Rozpoznávání číslic na binárním rastru

Řešení: (Grim et al., 2000a, 2000b, 2002)

spočívá v aproximaci podmíněných distribucí $P(\mathbf{x}|\omega)$ v původním 1024-dimensionálním prostoru pomocí strukturní Bernoulliiovské směsi


$$P(\mathbf{x}|\omega) = F(\mathbf{x}|0) \sum_{m \in \mathcal{M}_\omega} f(m) \prod_{n \in \mathcal{N}} \left[\left(\frac{\theta_{mn}}{\theta_{0n}} \right)^{x_n} \left(\frac{1 - \theta_{mn}}{1 - \theta_{0n}} \right)^{1 - x_n} \right]^{\phi_{mn}}, \quad \omega \in \Omega$$

$$F(\mathbf{x}|0) = \prod_{n \in \mathcal{N}} \theta_{0n}^{x_n} (1 - \theta_{0n})^{1 - x_n}, \quad \theta_{0n} = P\{x_n = 1\} = \sum_{\omega \in \Omega} P_n(1|\omega) p(\omega)$$

- $F(\mathbf{x}|0)$: konstantní distribuce pozadí ($\theta_{0n} \approx$ "průměrná" číslice)
- počáteční počet komponent: $|\mathcal{M}_\omega| = 60$ (váhy $f^{(0)}(m) = \frac{1}{60}$)
- počet nenulových parametrů $\phi_{mn} = 1$: $r_\omega = 15000 - 20000$
- náhodné počáteční hodnoty $\theta_{mn} \in \langle 0.1, 0.9 \rangle$ a $\phi_{mn} \in \{0, 1\}$
- počet iterací EM algoritmu: 20 – 40

Příklad 2: Rozpoznávání číslic na binárním rastru

Grafické zobrazení parametrů strukturních směsí



Příklad 2: Rozpoznávání číslic na binárním rastru

PŘESNOST ROZPOZNÁVÁNÍ ČÍSLIC

(8 nezávislých řešení problému - náhodné počáteční parametry směsi)

	M	r	r/M	%(1024)	přesnost
Řešení 1	400	180007	450.0	43.9	0.9330
Řešení 2	370	175000	473.0	46.2	0.9325
Řešení 3	410	200000	487.8	47.6	0.9325
Řešení 4	428	159997	373.8	36.5	0.9315
Řešení 5	381	160000	419.9	41.0	0.9310
Řešení 6	476	240000	504.2	49.2	0.9300
Řešení 7	374	175000	467.9	45.7	0.9295
Řešení 8	420	179994	428.6	41.8	0.9270

r - celkový počet parametrů, M - celkový počet komponent



$$r = \sum_{\omega \in \Omega} \sum_{m \in \mathcal{M}_\omega} \sum_{n \in \mathcal{N}} \phi_{mn}$$

► Publikované výsledky klasifikace

Příklad 3: Modelování textur pomocí normální směsi

černobílé textury: $Y = [y_{ij}]_{i=1}^I \text{ }_{j=1}^J$, $y_{ij} \in \{0, \dots, 255\} \approx$ úrovně šedi

příklady textur: rozměry 512×512 pixelů, tj. $I = J = 512$



Předpoklad statistické "homogenity":

předpokládáme, že texturu lze popsat lokálně na základě statistických vlastností vnitřních pixelů x_1, \dots, x_N nějakého pohyblivého okna

$\mathbf{x} = (x_1, x_2, \dots, x_N) \approx$ vnitřní pixely pohyblivého okna ($N = 400 \div 900$)

$\mathcal{S} = \{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(K)}\} \approx$ data získaná posuvem okna v obrázku textury

POZN. Vektory $\mathbf{x} \in \mathcal{S}$ nejsou nezávislé v důsledku překryvu oken.

Příklad 3: Modelování textur pomocí normální směsi

Princip modelování (Grim et al. 2001, Haindl et al., 2004):

- odhad lokálních statistických vlastností textury uvnitř posuvného okna pomocí normální součinné směsi $P(\mathbf{x})$
- postupná predikce (syntéza) textury (libovolné velikosti) na základě podmíněných distribucí odvozených z $P(\mathbf{x})$
- nahrazení výsledku predikce v každém kroku "nejpodobnější" částí původní reálné textury

$$P(\mathbf{x}) = \sum_{m \in \mathcal{M}} f(m) F(\mathbf{x} | \boldsymbol{\mu}_m, \boldsymbol{\sigma}_m) = \sum_{m \in \mathcal{M}} f(m) \prod_{n \in \mathcal{N}} f_n(x_n | \mu_{mn}, \sigma_{mn})$$

$\mathcal{D} = \{j_1, \dots, j_l\} \subset \mathcal{N} \approx$ definovaná část okna

$\mathcal{C} = \{i_1, \dots, i_k\} = \mathcal{N} \setminus \mathcal{D} \approx$ nedefinovaná část okna

$$\mathbf{x}_D = (x_{j_1}, \dots, x_{j_l}) \in \mathcal{X}_D, \quad F(\mathbf{x}_D | \boldsymbol{\mu}_m, \boldsymbol{\sigma}_m) = \prod_{n \in \mathcal{D}} f_n(x_n | \mu_{mn}, \sigma_{mn})$$

$$\mathbf{x}_C = (x_{i_1}, \dots, x_{i_k}) \in \mathcal{X}_C, \quad F(\mathbf{x}_C | \boldsymbol{\mu}_m, \boldsymbol{\sigma}_m) = \prod_{n \in \mathcal{C}} f_n(x_n | \mu_{mn}, \sigma_{mn})$$

Příklad 3: Modelování textur pomocí normální směsi

podmíněné distribuce:

$$P_{C|D}(\mathbf{x}_C|\mathbf{x}_D) = \frac{P_{CD}(\mathbf{x}_C, \mathbf{x}_D)}{P_D(\mathbf{x}_D)} = \sum_{m \in \mathcal{M}} W_m(\mathbf{x}_D) F(\mathbf{x}_C | \boldsymbol{\mu}_{mC}, \boldsymbol{\sigma}_{mC})$$
$$W_m(\mathbf{x}_D) = \frac{f(m) F(\mathbf{x}_D | \boldsymbol{\mu}_{mD}, \boldsymbol{\sigma}_{mD})}{\sum_{j \in \mathcal{M}} f(j) F(\mathbf{x}_D | \boldsymbol{\mu}_{jD}, \boldsymbol{\sigma}_{jD})}$$

očekávané hodnoty $\bar{\mathbf{x}}_C$ při definované části \mathbf{x}_D :

$$\bar{\mathbf{x}}_C = E_{C|D}\{\mathbf{x}_C|\mathbf{x}_D\} = \int \mathbf{x}_C P_{C|D}(\mathbf{x}_C|\mathbf{x}_D) d\mathbf{x}_C = \sum_{m \in \mathcal{M}} W_m(\mathbf{x}_D) \boldsymbol{\mu}_{mC}$$

nahrazení $\bar{\mathbf{x}}_C$ "nejpodobnější částí" původní reálné textury:


$$\mathbf{x}_C^* = \arg \min_{\mathbf{y}_C \in \mathcal{S}} \{\|\bar{\mathbf{x}}_C - \mathbf{y}_C\|^2\}$$

$\mathbf{y}_C \approx$ části původní textury získané posuvem okna v původním obrázku


Příklad 3: Modelování textur pomocí normální směsi

model textury "ratan":


původní textura



průměry komp. μ_m



syntéza vzorkováním




- velikost obrázku: 512x512 pixels $\Rightarrow |\mathcal{S}| \doteq 233000$
- velikost posuvného okna: 30x30 pixelů
- počet komponent: $|\mathcal{M}| = 80$
- počet iterací EM algoritmu: $t = 15$


Příklad 3: Modelování textur pomocí normální směsi

model textury "ratan":


původní textura



optimální "záplaty"



syntéza vzorkováním





"realistická" syntéza: průměry komponent μ_m nahrazeny podobnými částmi původní textury μ_m^* optimálně vyhledanými podle kriteria:

$$\mu_m^* = \arg \min_{x \in S} \{ \|x - \mu_m\|^2 \}$$

Příklad 3: Modelování textur pomocí normální směsi

model textury "hrubá látka":



- velikost posuvného okna: 30×30 pixelů
- dimenze směsi: $N = 30 \times 30 = 900$, počet komponent: $|\mathcal{M}| = 128$
- počet vzorků textury získaných pohybem okna: $|\mathcal{S}| \doteq 232000$
- míra vzdálenosti komponent směsi: $\bar{q}_{max} = 0.993$
- posuv okna při syntéze: 13 pixelů
- při nahrazování predikované textury reálnou částí obrázku byly použity části původní barevné textury

Příklad 3: Modelování textur pomocí normální směsi

model textury "světlá kůže":






- velikost posuvného okna: 20×20 pixelů
- dimenze směsi: $N = 20 \times 20 = 400$, počet komponent: $|\mathcal{M}| = 50$
- počet vzorků textury získaných posuvem okna: $|\mathcal{S}| \doteq 242000$
- míra vzdálenosti komponent směsi: $\bar{q}_{max} = 0.959$
- posuv okna při syntéze: 12 pixelů

POZN. Paradoxně: nejmenší krok při syntéze není nejlepší, optimální krok odpovídá přibližně polovině strany okna (!?).

Příklad 3: Modelování textur pomocí normální směsi

model textury "koberec":






- dimenze směsi: $N = 30 \times 30 = 900$, počet komponent: $|\mathcal{M}| = 90$
- počet vzorků textury získaných posuvem okna: $|\mathcal{S}| \doteq 232000$
- počet iterací EM algoritmu: $t = 20$
- míra vzdálenosti komponent směsi: $\bar{q}_{max} = 0.997$
- posuv okna při syntéze: 18 pixelů

POZN. Při velikosti okna 30×30 pixelů je dobře popsána jemná struktura, ale selhává popis hrubé struktury koberce.

Příklad 3: Modelování textury pomocí strukturní směsi

strukturní model textury "koberec":



- dimenze směsi: $N = 60 \times 60 = 3600$, počet komponent: $|\mathcal{M}| = 94$
- počet vzorků textury získaných posuvem okna: $|\mathcal{S}| \doteq 205000$
- počet iterací EM algoritmu: $t = 18$
- míra vzdálenosti komponent směsi: $\bar{q}_{\max} = 0.999$
- posuv okna při syntéze: 24 pixelů

POZN. Popis hrubé struktury koberce je zřetelně lepší než při velikosti okna 30×30 pixelů.

Příklad 4: Predikce chybějících částí obrázku

původní poškozený obrázek




Příklad 4: Predikce chybějících částí obrázku

opravený obrázek



Příklad 4: Predikce chybějících částí obrázku

původní poškozený obrázek



Příklad 4: Predikce chybějících částí obrázku

opravený obrázek



Příklad 4: Predikce chybějících částí obrázku

původní poškozený obrázek



Příklad 4: Predikce chybějících částí obrázku

opravený obrázek



Příklad 5: Interaktivní statistický model dat ze sčítání lidu

náklady sčítání lidu: cca 2.5 mld Kč

dostupnost výsledků sčítání lidu je značně omezena nutností ochrany anonymity dat

Současné metody publikace výsledků

- **agregovaná data** (územně, např. na úrovni sčítacích okrsků)
nevýhoda: zcela se znehodnotí informace o subpopulacích
- **publikace tabulek** (tiskem nebo na paměťových médiích)
nevýhody: až do 10 proměnných, nutné ověřování anonymity dat
- **komerční služby statistických úřadů** (písemný dotaz)
nevýhody: těžkopádný a zdlouhavý postup, poplatky
- **anonymizované uživatelské soubory mikrodat** ($|\mathcal{S}| \approx 10^6$)
výhoda: neomezené možnosti formulace otázek
nevýhody: nutné ověřování anonymity dat, omezená distribuce, omezená přesnost údajů (anonymizační procedury, velikost souboru)

Příklad 5: Interaktivní statistický model dat ze sčítání lidu

Interaktivní odvozování statistických vlastností dat pomocí modelu:

Diskrétní součinnová směs může být přímo použita jako báze znalostí pravděpodobnostního expertního systému PES. Umožňuje rychlé odvozování podmíněných histogramů pro libovolně zvolenou subpopulaci interaktivním způsobem při dokonale zabezpečené ochraně dat.

$$\mathbf{x}_C = (x_{i_1}, \dots, x_{i_k}) \in \mathcal{X}_C, \quad C = \{i_1, \dots, i_k\} \subset \mathcal{N}$$

subpopulace: $\mathcal{S}(\mathbf{x}_C) = \{\mathbf{y} \in \mathcal{S} : \mathbf{y}_C = \mathbf{x}_C\} \subset \mathcal{S}$

(Např. dvojicí otázek ($|C| = 2$, $N = 25$) lze určit cca 10^4 subpopulací.)

jednoduchý výpočet podmíněných distribucí $P_{n|C}(x_n|\mathbf{x}_C)$, $n \notin C$:

$$P_{n|C}(x_n|\mathbf{x}_C) = \sum_{m \in \mathcal{M}} W_m(\mathbf{x}_C) f_n(x_n|m), \quad W_m(\mathbf{x}_C) = \frac{w_m F_C(\mathbf{x}_C|m)}{\sum_{j=1}^M w_j F_C(\mathbf{x}_C|j)}$$

Příklad 5: Interaktivní statistický model dat ze sčítání lidu

PRŮMĚRNÁ CHYBA REPRODUKCE RELATIVNÍCH ČETNOSTÍ

(Sčítání lidu 1991 - Pražské domácnosti, 23 otázek, $|S| = 535000$)

Počet komponent	Hodnota kriteria L	Trvání výpočtu	Abs. chyba $\bar{\Delta}$	Rel. chyba $\bar{\delta}$
1	-29,2069	2 s	0,00891	54,4 %
5	-22,8797	25 s	0,00274	22,3 %
10	-20,5518	3 m	0,00211	17,9 %
50	-18,4564	39 m	0,00108	10,8 %
100	-17,7872	2,5 h	0,00083	8,1 %
500	-16,6389	12 h	0,00040	4,2 %
1 000	-16,3837	26 h	0,00035	3,3 %
10 000	-15,8367	72 h	0,00018	1,9 %

ϵ -relevantní subpopulace: $|\mathcal{R}_\epsilon| \doteq 87000$ (kombinace 3 otázek, práh $\epsilon = 0.003$)


$$\bar{\Delta} = \frac{1}{|\mathcal{R}_\epsilon|} \sum_{A \in \mathcal{R}_\epsilon} |P(A) - \hat{P}(A)|,$$

$$\bar{\delta} = \frac{1}{|\mathcal{R}_\epsilon|} \sum_{A \in \mathcal{R}_\epsilon} \frac{|P(A) - \hat{P}(A)|}{\hat{P}(A)}$$

Příklad 5: Interaktivní statistický model dat ze sčítání lidu

ZÁVISLOST ROZLOŽENÍ RELATIVNÍCH CHYB MODELU NA VELIKOSTI SUBPOPULACE

(Sčítání lidu 1991 - Pražské domácnosti, 23 otázek, $|\mathcal{S}| = 535000$, $|\mathcal{M}| = 100$)



osa x: horní meze příslušných intervalů velikosti subpopulace

Příklad 6: Vyhledávání poruch a odchylek v textuře

černobílá textura: $\mathcal{Y} = [y_{ij}]_{i=1}^I \prod_{j=1}^J$, $y_{ij} \approx$ úrovně šedi ($\approx x_n$)

Předpoklad: homogenní textura

lokální statistické závislosti mezi pixely uvnitř zvoleného okna jsou invariantní vůči libovolnému posuvu okna

pixely okna v libovolném pevném pořadí: $\mathbf{x} = (x_1, x_2, \dots, x_N) \in R^N$

Metoda:

aproximace hustoty pravděpodobnosti $P(\mathbf{x})$ pomocí normální směsi součinnových komponent (diagonální kovariační matice)

$$P(\mathbf{x}) = \sum_{m \in \mathcal{M}} w_m F(\mathbf{x} | \mu_m, \sigma_m) = \sum_{m \in \mathcal{M}} w_m \prod_{n \in \mathcal{N}} f_n(x_n | \mu_{mn}, \sigma_{mn})$$

$$f_n(x_n | \mu_{mn}, \sigma_{mn}) = \frac{1}{\sqrt{2\pi}\sigma_{mn}} \exp\left\{-\frac{(x_n - \mu_{mn})^2}{2\sigma_{mn}^2}\right\}$$

Příklad 6: Vyhledávání poruch a odchylek v textuře

Idea:

úspěšná syntéza textury dokazuje, že lokální statistický model ve tvaru distribuční směsi $P(\mathbf{x})$ popisuje původní texturu dostatečně přesně
 \Rightarrow lze jej využít pro analýzu výchozího obrázku textury

LOG-LIKELIHOOD: $\log P(\mathbf{x}) \approx$ míra typičnosti (obvyklosti) \mathbf{x}

POZN.: Hodnota $\log P(\mathbf{x})$ je citlivá vzhledem k odchylkám úrovní šedi.

$$P_0(\mathbf{x}) = \prod_{n \in \mathcal{N}} f_n(x_n | \mu_{0n}, \sigma_{0n}), \quad \mu_{0n} = \frac{1}{|\mathcal{S}|} \sum_{x \in \mathcal{S}} x_n, \quad \sigma_{0n}^2 = \frac{1}{|\mathcal{S}|} \sum_{x \in \mathcal{S}} x_n^2 - \mu_{0n}^2.$$

LOG-LIKELIHOOD RATIO: $\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})} \approx$ míra strukturní typičnosti části textury \mathbf{x} (jmenovatel potlačuje vliv úrovní šedi)

POZN.: Hodnoty průměru a rozptylu μ_{0n}, σ_{0n} jsou téměř identické pro všechna $n \in \mathcal{N} \Rightarrow$ hodnota $\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ méně závisí na změnách úrovní šedi a je více ovlivněna odchylkami struktury.

Příklad 6: Vyhledávání poruch a odchylek v textuře


Lokální analýza textury “obklad”:

hodnoty $\log P(\mathbf{x})$ resp. $\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ jsou zobrazeny jako úrovně šedi centrálního pixelu posuvného okna


původní obrázek



L-věrohodnost



LR-věrohodnost




Remark: Hodnoty $\log P(\mathbf{x})$ jsou velmi citlivé na odchylky úrovní šedi. Tak např. stěží viditelné světlejší pixely v textuře “obklad” (levý obrázek) se projeví jako výrazné tmavé skvrny o velikosti okna (střední obrázek).

Příklad 6: Vyhledávání poruch a odchylek v textuře


Lokální analýza textury "ratan":

hodnoty $\log P(\mathbf{x})$ resp. $\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ jsou zobrazeny jako úrovně šedi centrálního pixelu posuvného okna


původní obrázek



L-věrohodnost



LR-věrohodnost



POZN. Hodnoty $\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ jsou citlivé na strukturální odchylky a méně závisí na úrovních šedi. Nepravdělnosti ve struktuře "ratanu" (levý obrázek) jsou proto zřetelnější na pravém obrázku, který využívá logaritmus věrohodnostního poměru $\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$.

Příklad 6: Vyhledávání poruch a odchylek v textuře

Analýza nepravidelnosti textury “obklad”:


zobrazované vysoké hodnoty $-\log P(\mathbf{x})$ (střední obrázek) resp.

$-\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ (pravý obrázek) jsou zvýrazněny červeným zbarvením centrálního pixelu posuvného okna


původní obrázek



L-nevěrohodnost



LR-nevěrohodnost




Příklad 6: Vyhledávání poruch a odchylek v textuře


Analýza nepravidelnosti textury “ratan”:

vysoké hodnoty $-\log P(\mathbf{x})$ (střední obrázek) resp. $-\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ (pravý obrázek) jsou zvýrazněny červeným zbarvením centrálního pixelu posuvného okna


původní obrázek



L-nevěrohodnost



LR-nevěrohodnost



Příklad 6: Teoretické aspekty lokální analýzy textury

- (!) datové vektory \mathbf{x} generované posuvem okna se překrývají a proto nejsou nezávislé
- datový soubor \mathcal{S} odpovídá pouze "trajektorii" v prostoru \mathcal{X} vzniklé posuvem okna (\Rightarrow není reprezentativní)
- na rozdíl od jiných aplikací (syntéza textury, predikce, rozpoznávání) se odhadnutá směs $P(\mathbf{x})$ aplikuje na původní datový soubor \mathcal{S}
- věrohodnostní kritérium optimálně "přízpůsobuje" odhadovanou směs $P(\mathbf{x})$ na výchozí datový soubor \mathcal{S}
- \Rightarrow aplikace směsi $P(\mathbf{x})$ na původní data $\mathbf{x} \in \mathcal{S}$ je dobře zdůvodněná metodou odhadu
- \Rightarrow hodnota $\log P(\mathbf{x})$ je vhodnou mírou "typičnosti" vektorů $\mathbf{x} \in \mathcal{S}$
- zhoršená reprezentativnost souboru \mathcal{S} není příliš závažná protože směs $P(\mathbf{x})$ se neaplikuje na data mimo soubor \mathcal{S}

Příklad 7: Vyhodnocování screeningových mamogramů

Mamografický screening:

včasná detekce zhoubného nádoru v rámci mamografického screeningu představuje v současnosti jedinou možnost snižování vysoké úmrtnosti

Statistické údaje z mamografického screeningu:

- asi 8 až 10% žen je během života ohroženo rakovinou prsu
- v rámci mamografického screeningu se zhoubný nádor potvrdí jen u 1 až 3 mamogramů z 1000
- 5 až 10% podezřelých nálezů se ověřuje chirurgicky pomocí biopsie (jednoduché vyšetření nicméně fyziky i psychicky traumatizující)
- výsledkem biopsie je v 60 až 80% případů nezhoubný nález
- následné prověřování zhoubných nálezů ukazuje, že výsledky mamografického screeningu jsou v 10 až 20% falešně negativní (tzn. 10 až 20% zhoubných nálezů zůstane nerozpoznáno)
- celkový počet screeningových mamogramů každoročně vyhodnocovaných ve světě se řádově udává v milionech

Příklad 7: Vyhodnocování screeningových mamogramů

Cíl věrohodnostní analýzy:

usnadnit diagnostické vyhodnocování screeningových mamogramů
zvýrazněním atypických resp. podezřelých míst

LOKÁLNÍ ZOBRAZENÍ VĚROHODNOSTI:

$\log P(\mathbf{x}) \approx$ míra typičnosti vnitřku okna \mathbf{x}

Idea: nízké hodnoty $\log P(\mathbf{x})$ zobrazované jako tmavé pixely by měly odpovídat "neobvyklým" resp. "podezřelým" místům mamogramu


LOKÁLNÍ ZOBRAZENÍ VĚROHODNOSTNÍHO POMĚRU:

$\log P(\mathbf{x})/P_0(\mathbf{x}) \approx$ nebylo použito


Pozn. Analýza pomocí věrohodnostního poměru potlačuje vliv úrovní šedi, které mají v případě mamogramu diagnostický význam.

Příklad 7: Vyhodnocování screeningových mamogramů

původní mamogram



věrohodnostní analýza




Příklad 7: Výpočetní aspekty vyhodnocování mamogramů


- zdrojová databáze: 2600 tzv. úplných mammogramů, University of South Florida
<http://marathon.csee.usf.edu/Mammography/Database.html>
- úplný mamogram zahrnuje 4 snímky: dva medio-laterální pohledy a dva cranio-caudální pohledy a je vyhodnocován jako celek
- pravá část mamogramu je před vyhodnocením zrcadlově transformována aby byla využita pravo-levá symetrie snímků
- lokální analýza využívá čtvercové okno o rozměrech 13×13 pixelů s uříznutými rohy, dimenze vnitřku okna x je $N = 145 (= 169 - 4 \times 6)$
- počet komponent odhadované směsi je $M = 36$, parametry jsou inicializovány náhodně
- pro odhad parametrů směsi je k dispozici velký počet dat $|\mathcal{S}| \approx 10^5 - 10^6$ získaných posouváním okna v mamogramu
- lokální statistický model je odhadován individuálně z každého úplného mamogramu, tzn. metoda nevyžaduje trénovací data
- \Rightarrow výsledek věrohodnostní analýzy není ovlivněn vysokou přirozenou variabilitou mamogramů

Příklad 7: Vyhodnocování screeningových mamogramů

ověřený nález




porovnání analýzy a nálezu




Příklad 7: Vyhodnocování screeningových mamogramů

ověřený nález




porovnání analýzy a nálezu



Příklad 7: Věrohodnostní analýza mikrokalcifikací

mikrokalcifikace


zvýrazněné mikrokalcifikace



Remark: Každá pozice okna obsahující izolovaný světlý pixel implikuje sníženou hodnotu $\log P(\mathbf{x})$. \Rightarrow Světlý pixel se zobrazí jako tmavší skvrna o velikosti okna.

Příklad 7: Identifikace "hmot" pomocí "vrstevnic"


část screeningového mamogramu obsahující podezřelé "hmoty"



Remark: "Zhmotnění" může být velmi malé, může mít nezřetelné hranice a různé tvary. Detekce a klasifikace "hmot" se považuje za obtížnější než detekce mikrokalcifikací.

Příklad 7: Identifikace "hmot" pomocí "vrstevnic"


"vrstevnice" zvýrazňující hranice "hmot" a okraje mamogramu



Remark: Jednotlivé věrohodnostní hodnoty $\log P(\mathbf{x})$ jsou typicky určeny jedinou komponentou směsi, která nejlépe odpovídá dané pozici okna. Na okraji různých oblastí mamogramu dochází k záměně komponent, která je spojena s poklesem věrohodnosti $\log P(\mathbf{x})$. Záměna komponent je příčinou vzniku tmavších "vrstevnic" na hranici různých oblastí.

Příklad 7: Identifikace "hmot" pomocí "vrstevnic"

inverzní (negativní) zobrazení "vrstevnic"



Remark: Vrstevnice jsou nejzřetelněji zobrazeny na okraji mamogramu v místě spojitého poklesu úrovní šedi. Vrstevnice mohou usnadnit identifikaci častých kontralaterálních (symetricky lokalizovaných) nálezů a multifokálních nálezů protože oblasti s podobnými vlastnostmi jsou pomocí věrohodnostní analýzy snadno vizuálně identifikovatelné.

Celkové shrnutí

Vlastnosti součinných distribučních směsí:

- efektivní výpočet parametrů směsi pomocí EM algoritmu z velkých datových souborů v mnohorozměrném prostoru (!)
- snadný výpočet marginálních rozložení pravděpodobnosti (!)
- vhodné pro aproximaci obecných rozložení pravděpodobnosti
- při velkém počtu komponent se vlastnosti součinné směsi blíží neparametrickému jádrovému odhadu
- EM algoritmus automaticky řeší problém optimalizace vyhlazení, která je nezbytná v případě neparametrického jádrového odhadu
- existuje strukturní modifikace součinné směsi, která umožňuje rozhodování nezávislé na dimenzi prostoru
- možnost odhadu parametrů směsi z neúplných datových vektorů
- EM algoritmus lze použít na vážená data (možnost zrychlení výpočtu agregací dat a jiné aplikace)
- součinné směsi lze interpretovat jako neuronovou síť (až na úrovni funkčních vlastností neuronů)

Příklad 2: Rozpoznávání číslic na binárním rastru

Publikované výsledky přesnosti klasifikace

Autor	rok	přesnost
Lam & Suen	(1988)	0.9310
Legault & Suen	(1989)	0.9390
Krzyzak et al.	(1990)	0.9485
Mai & Suen	(1990)	0.9295
Nadal & Suen	(1990)	0.8605
Suen et al.	(1990)	0.9305
Kim & Lee	(1994)	0.9585
Lee	(1995)	0.9780
Hwang & Bang	(1996)	0.9785
Cho	(1997)	0.9605

Standardní předzpracování dat:

normalizace velikosti číslic + výpočet speciálních informativních příznaků (např. "Kirsch masks", "peripheral directional contributivity" apod.)

Příklad 5: Interaktivní statistický model dat ze sčítání lidu

Informační analýza dat (datamining) pomocí statistického modelu:

Výběr subpopulací $\mathcal{S}(\mathbf{x}_C) \in \mathcal{R}_\epsilon$ s nejvyšší/nejnižší hodnotou zvoleného informačního kritéria.

$$\mathbf{x}_C = (x_{i_1}, \dots, x_{i_k}) \in \mathcal{X}_C, \quad C = \{i_1, \dots, i_k\} \subset \mathcal{N}$$

subpopulace: $\mathcal{S}(\mathbf{x}_C) = \{\mathbf{y} \in \mathcal{S} : \mathbf{y}_C = \mathbf{x}_C\} \subset \mathcal{S}$

(Např. dvojicí otázek ($|C| = 2$, $N = 25$) lze určit cca 10^4 subpopulací.)

ϵ -relevantní subpopulace (větší než $\epsilon|\mathcal{S}|$):

$$\mathcal{R}_\epsilon = \{\mathcal{S}(\mathbf{x}_C) \subset \mathcal{S} : P_C(\mathbf{x}_C) > \epsilon, \mathbf{x}_C \in \mathcal{X}_C, C \subset \mathcal{N}\}$$

jednoduchý výpočet podmíněných distribucí $P_{n|C}(x_n|\mathbf{x}_C)$, $n \notin C$:

$$P_{n|C}(x_n|\mathbf{x}_C) = \sum_{m \in \mathcal{M}} W_m(\mathbf{x}_C) f_n(x_n|m), \quad W_m(\mathbf{x}_C) = \frac{w_m F_C(\mathbf{x}_C|m)}{\sum_{j=1}^M w_j F_C(\mathbf{x}_C|j)}$$

Příklad 5: Interaktivní statistický model dat ze sčítání lidu

PŘÍKLADY VOLBY INFORMAČNÍHO KRITÉRIA:

nejvyšší podmíněná pravděpodobnost $P_{n|C}(x_n|\mathbf{x}_C)$:
(např. subpopulace s nejvyšší nezaměstnaností)

$$P_{n|C}(x_n|\mathbf{x}_C) = \sum_{m=1}^M W_m(\mathbf{x}_C) f_n(x_n|m), \quad x_n \in \mathcal{X}_n, \quad n \notin C$$

kritérium minimální entropie:

(např. možnost vyhledání typické vlastnosti)

$$H_{x_C}(\mathcal{X}_n) = \sum_{x_n \in \mathcal{X}_n} -P_{n|C}(x_n|\mathbf{x}_C) \log P_{n|C}(x_n|\mathbf{x}_C)$$

maximální množství informace mezi dvěma proměnnými:

(korelační koeficient není definován pro nominální proměnné)

$$I_{x_C}(\mathcal{X}_n, \mathcal{X}_r) = H_{x_C}(\mathcal{X}_n) + H_{x_C}(\mathcal{X}_r) - H_{x_C}(\mathcal{X}_n, \mathcal{X}_r)$$


POZN. Problém přesnosti reprodukce relativních četností v souboru \mathcal{S} pomocí statistického modelu.

Příklad 6: Vyhledávání poruch a odchylek v textuře


Analýza nepravidelnosti textury “látka”:

krajní hodnoty $-\log P(\mathbf{x})$ (střední obrázek) resp. $-\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ (pravý obrázek) jsou zvýrazněny červeným zbarvením centrálního pixelu posuvného okna


původní obrázek



L-nevěrohodnost



LR-nevěrohodnost




Příklad 6: Vyhledávání poruch a odchylek v textuře


Analýza nepravidelnosti textury “květy”:

krajní hodnoty $-\log P(\mathbf{x})$ (střední obrázek) resp. $-\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ (pravý obrázek) jsou zvýrazněny červeným zbarvením centrálního pixelu posuvného okna


původní obrázek



L-nevěrohodnost



LR-nevěrohodnost




Příklad 6: Vyhledávání poruch a odchylek v textuře


Analýza nepravidelnosti textury “koberec”:

krajní hodnoty $-\log P(\mathbf{x})$ (střední obrázek) resp. $-\log \frac{P(\mathbf{x})}{P_0(\mathbf{x})}$ (pravý obrázek) jsou zvýrazněny červeným zbarvením centrálního pixelu posuvného okna


původní obrázek



L-nevěrohodnost



LR-nevěrohodnost



Sekvenční rozhodovací schéma

statistický problém rozpoznávání (diskrétní proměnné):

$$\mathbf{x} = (x_1, \dots, x_N) \in \mathcal{X}, \quad P(\mathbf{x}|\omega)p(\omega), \quad \omega \in \Omega$$

$$P(\mathbf{x}|\omega) = \sum_{m \in \mathcal{M}_\omega} f(m) \prod_{n=1}^N f_n(x_n|m)$$

postupné doplňování příznaků x_n (např. v lékařské diagnostice):

Problém optimálního sekvenčního rozhodování:

volba nejinformativnější proměnné x_n pro danou podmnožinu (subvektor) známých vstupních údajů $\mathbf{x}_D = (x_{j_1}, \dots, x_{j_l}) \in \mathcal{X}_D$ pomocí kritéria maximální podmíněné informace $I_{\mathbf{x}_D}(\mathcal{X}_n, \Omega)$, $n \notin \mathcal{D}$

$$I_{\mathbf{x}_D}(\mathcal{X}_n, \Omega) = H_{\mathbf{x}_D}(\mathcal{X}_n) - H_{\mathbf{x}_D}(\mathcal{X}_n|\Omega), \quad n \notin \mathcal{D}, \quad \mathcal{D} = \{j_1, \dots, j_l\} \subset \mathcal{N}$$

$$H_{\mathbf{x}_D}(\mathcal{X}_n|\Omega) = \sum_{\omega \in \Omega} p(\omega) \sum_{x_n \in \mathcal{X}_n} -P_{n|D\omega}(x_n|\mathbf{x}_D, \omega) \log P_{n|D\omega}(x_n|\mathbf{x}_D, \omega)$$

$$P_{n|D\omega}(x_n|\mathbf{x}_D, \omega) = \frac{P_{nD|\omega}(x_n, \mathbf{x}_D|\omega)}{P_{D|\omega}(\mathbf{x}_D|\omega)} = \sum_{m \in \mathcal{M}_\omega} W_m(\mathbf{x}_D, \omega) f_n(x_n|m)$$

Výběr nejinformativnějšího podprostoru

Motivace:

- výběr nejinformativnější podmnožiny příznaků
- vícestupňové rozpoznávání (urychlení a zpřesnění klasifikace)
- rychlá lokalizace grafických objektů v rovině (čísllice, písmena)

výběr příznaků (proměnných): kritérium maximální informativnosti:

$$\mathcal{D}^* = \arg \max_{\mathcal{D} \subset \mathcal{N}} \{I(\mathcal{X}_{\mathcal{D}}, \Omega)\} = \arg \max_{\mathcal{D} \subset \mathcal{N}} \{H(\mathcal{X}_{\mathcal{D}}) - H(\mathcal{X}_{\mathcal{D}}|\Omega)\}$$

$$P_{\mathcal{D}|\omega}(\mathbf{x}_{\mathcal{D}}|\omega) = \sum_{m \in \mathcal{M}_{\omega}} f(m) \prod_{n \in \mathcal{D}} f_n(x_n|m), \quad \mathcal{D} = \{j_1, \dots, j_k\} \subset \mathcal{N}, \quad |\mathcal{D}| = k$$

$$H(\mathcal{X}_{\mathcal{D}}) = \sum_{\mathbf{x}_{\mathcal{D}} \in \mathcal{X}_{\mathcal{D}}} -P_{\mathcal{D}}(\mathbf{x}_{\mathcal{D}}) \log P_{\mathcal{D}}(\mathbf{x}_{\mathcal{D}})$$

$$H(\mathcal{X}_{\mathcal{D}}|\Omega) = \sum_{\omega \in \Omega} p(\omega) \sum_{\mathbf{x}_{\mathcal{D}} \in \mathcal{X}_{\mathcal{D}}} -P_{\mathcal{D}|\omega}(\mathbf{x}_{\mathcal{D}}|\omega) \log P_{\mathcal{D}|\omega}(\mathbf{x}_{\mathcal{D}}|\omega)$$

optimální podmnožina $\mathcal{D} \subset \mathcal{N}$: úplné prohledání, přibližné metody