

1. Rozpoznávání a klasifikace

Rozpoznávání a klasifikace

Rozpoznávání a klasifikace

- předmětů
- jevů
- situací
- . . .

Obecně hovoříme o rozpoznávání a klasifikaci **objektů** .

Reprezentace objektů



prostřednictvím signálů

- jednorozměrných (zvuky, hudba, řeč, ...)
- dvourozměrných (snímky scén, ...)
- vícerozměrných (obecné)

Reprezentace objektů


- ➡ prostřednictvím signálů
 - jednorozměrných (zvuky, hudba, řeč, ...)
 - dvourozměrných (snímky scén, ...)
 - vícerozměrných (obecné)

Podle charakteru reprezentace objektů signály rozlišujeme objekty (a jejich rozpoznávání)

- vizuální (reálné, upravené, symbolické, stylizované aj.)
- akustické (zvuky, hluky, hudba, řeč, ..., vždy jednorozm.)
- taktilní (obecně reprezentované n -rozměrnými signály)

1. Rozpoznávání a klasifikace

Příklad reprezentace číslice '4' v pravoúhlém rastru:



Reprezentace tzv. jasovou funkcí:

$$f(x, y) = \left\{ \begin{array}{l} 0, \text{ reprezentuje-li obrazový bod bílou barvu podkladu} \\ 1, \text{ reprezentuje-li obrazový bod černou barvu písma} \end{array} \right\}$$

1. Rozpoznávání a klasifikace

Př.: Praktická ukázka:

1	00000000000000000000000000000000	* 0	1	11111111111111111111111111111111	* 35
2	00000000000000000000000000000000	* 0	2	10000000000000000000100011111111111111	* 17
3	00000000000000000000000000000000	* 0	3	1000000000000000000000000000000000011	* 3
4	00000000000000000000000000000000	* 0	4	1000000000000000000000000000000000011	* 3
5	00000000000000000000000000000000	* 0	5	10000000000000000000000000000000000111	* 4
6	00000000000000000000000000000000	* 0	6	00000000000000000000000000000000000011	* 2
7	00000000000000000000000000000000	* 0	7	00000000000000000000111110000000000000111	* 8
8	000000000000000000001111100000000000	* 6	8	10000000000000000000111111110000000000011	* 12
9	00000000000000000000111111111110000000	* 12	9	00000000000000000000111111111000000000011	* 15
10	0000000000000000000011111111111110000000	* 16	10	000000000000000000001111111111100000000111	* 18
11	0000000000000000000011111111111111100000	* 19	11	0000000000000000000011111111111110000000011	* 19
12	000000000000000000001111111111111110000	* 22	12	00000000000000000000111111111110000000011	* 20
13	0000000000000000000000000000000011111110000	* 16	13	00000000000000000000000000000000111111000000111	* 16
14	0000000000000000000000000000000011111111000	* 13	14	0000001111111100000000001111111000000011	* 15
15	00000000000000000000000000000000111111000	* 9	15	0000001111110000000000001111110000000011	* 13
16	00000000000000000000000000000000111111000	* 7	16	0000001111000000000000000011111000000011	* 11
17	00000000000000000000000000000000111111000	* 5	17	0000001111000000000000000011111100000011	* 12
18	00000000000000000000000000000000111111000	* 6	18	0000000000000000000000000011111000000011	* 7
19	000000000000000000000000000000001111110000	* 6	19	0000000000000000000000000011111000000011	* 7
20	000000000000000000000000000000001111110000	* 7	20	0000000000000000000000000011111000000011	* 7
21	000000000000000000000000000000001111110000	* 7	21	00000000000000000000000000111111000000011	* 8
22	0000000000000000000000000000000011111100000	* 6	22	00000000000000000000000000111111000000011	* 8
23	0000000000000000000000000000000011111100000	* 6	23	000000000000000000000000001111110000000011	* 8
24	0000000000000000000000000000000011111100000	* 6	24	0000000000000000000000000011111100000000011	* 8
25	0000000000000000000000000000000011111100000	* 6	25	000000000000000000000000001111100000000011	* 7
26	0000000000000000000000000000000011111100000	* 6	26	000000000000000000000000001111100000000011	* 7
27	0000000000000000000000000000000011111100000	* 6	27	000000000000000000000000001111100000000011	* 8
28	0000000000000000000000000000000011111100000	* 6	28	0000000000000000000000000011111000000000011	* 8
29	0000000000000000000000000000000011111100000	* 6	29	00000000000000000000000000111110000000000011	* 8
30	0000000000000000000000000000000011111100000	* 6	30	000000000000000000000000001111110000000000011	* 9
31	0000000000000000000000000000000011111100000	* 6	31	000000000000000000000000001111110000000000011	* 8
32	000000000000000000000000000000001111100000	* 5	32	000000000000000000000000001111100000000000111	* 10
33	000000000000000000000000000000001111100000	* 5	33	00000000000000000000000000111111000000000000111	* 10
34	000000000000000000000000000000001111100000	* 5	34	000000000000000000000000000000000000000111	* 9
35	0000000000000000000000000000000011111100000	* 6	35	000000000000000000000000000000000000000111	* 16
36	0000000000000000000000000000000011111100000	* 6	36	000000000000000000000000000000000000000111	* 20
37	0000000000000000000000000000000011111100000	* 6	37	000000000000000000000000000000000000000111	* 21
38	0000000000000000000000000000000011111100000	* 7	38	000000000000000000000000000000000000000111	* 21
39	00000000000000000000000000000000111111100000	* 22	39	000000000000000000000000000000000000000111	* 21
40	00000000000000000000000000000000111111110000	* 24	40	000000000000000000000000000000000000000111	* 19
41	000000000000000000000000000000001111111110000	* 24	41	000000000000000000000000000000000000000111	* 12
42	0000000000000000000000000000000011111111110000	* 24	42	000000000000000000000000000000000000000111	* 7
43	00000000000000000000000000000000111111100000	* 7	43	0000000000000000000000000000000000000001111	* 4
44	000	* 0	44	00000000000000000000000000000000000000011111	* 5
45	000	* 0	45	0000000000000000000000000000000000000001111111	* 8
46	000	* 0	46	11	* 35
47	000	* 0	47	11	* 35
48	000	* 0	48	11	* 35
49	000	* 0	49	11	* 35
50	000	* 0	50	11	* 35

Rozpoznávání a klasifikace


Rozpoznávání chápeme jako úlohu, při které objekty zařazujeme do tříd podle jejich společných vlastností tak, že objekty vzájemně si podobné zařazujeme do stejné třídy.

Rozlišujeme:

- **klasifikaci** – zařazujeme do předem známého, pevného počtu tříd (například rozpoznávání znaků)
- **rozpoznávání** – počet tříd není předem znám a třídy identifikujeme až během vlastního rozpoznávání (například rozpoznávání plynulé řeči)

1. Rozpoznávání a klasifikace

Obecná klasifikační úloha



T . . . transformace vstupních charakteristik – vytvoření obrazu

K . . . klasifikátor

\mathbf{v} . . . vektor vstupních charakteristik

\mathbf{x} . . . obraz (symbolický popis) objektu

ω . . . indikátor třídy

Rozhodovací pravidlo

Rozhodovací pravidlo, podle kterého klasifikátor přiřazuje obraz do klasifikační třídy, můžeme obecně definovat jako skalární funkci vektorového argumentu

$$\omega = d(\mathbf{x}) .$$


Přesnější vyjádření rozhodovacího pravidla, které zohledňuje i tzv. nastavení klasifikátoru \mathbf{q} , je

$$\omega = d(\mathbf{x}, \mathbf{q}) .$$

Nastavení klasifikátoru se provádí **trénováním** neboli **učením**. Rozlišujeme **učení s učitelem**, kdy klasifikátoru předkládáme obrazy, u nichž známe jejich příslušnost k třídě, a **učení bez učitele**, kdy správné zařazení do klasifikačních tříd neznáme.

1. Rozpoznávání a klasifikace

Učení (trénování) klasifikátoru



Rozpoznávání a klasifikace objektů

➡ na základě vlastností objektů

Vlastnosti objektů

- měřitelné a kvantifikovatelné
- strukturní

Podle typu vlastností objektů hovoříme o

- vytváření příznakového nebo strukturního popisu objektů
- **příznakových** nebo **strukturních** metodách rozpoznávání

1. Rozpoznávání a klasifikace

Příznakový nebo strukturní popis rozpoznávaných (klasifikovaných) objektů – obecně hovoříme o vytváření symbolických popisů objektů – nazýváme popisem objektů jejich **obrazy**.

Tedy: **Obraz objektu = symbolický popis objektu**

Stejně jako metody rozlišujeme i obrazy (symbolické popisy objektů)

- tvořené příznaky (vektory příznaků)
- strukturní

Obsahují-li obrazy objektů n složek, pak všechny rozpoznávané (klasifikované) obrazy tvoří **obrazový prostor** úlohy.


Jednotlivé klasifikační třídy objektů získáme **rozkladem** obrazového prostoru úlohy na R klasifikačních tříd.

1. Rozpoznávání a klasifikace

Příklady rozkladu obrazového prostoru na třídy

a) třídy disjunktční, s velkou mezi-
třídní vzdáleností – ideální případ


b) třídy disjunktční, kompaktní,
geometricky „blízké“



1. Rozpoznávání a klasifikace


c) třídy disjunktční, kompaktní, s nelineární oddělovací nadplochou

d) třídy disjunktční, nekompaktní, avšak lineárně oddělitelné




1. Rozpoznávání a klasifikace

e) třídy disjunktní, kompaktní, vnořené, komplikovaně oddělitelné (s rozdělovací nadplochou složitého tvaru)




f) nekompaktní, prolínající se třídy s velmi obtížně určitelnou rozdělovací nadplochou



1. Rozpoznávání a klasifikace

Pokud vezmeme v úvahu pravděpodobnostní rozložení obrazů uvnitř jednotlivých tříd:




ideální případ – klasifikační třídy se nepřekrývají – jsou disjunktní – o zařazení obrazu do třídy ω_1 nebo ω_2 lze rozhodnout s jistotou, čili s $P = 1$

reálný případ – klasifikační třídy se překrývají – v oblasti okolo rozdělovací nadplochy lze o zařazení obrazu do příslušné třídy jen s pravděpodobností $P < 1$

1. Rozpoznávání a klasifikace

Příznakové metody rozpoznávání



Obrazy objektů reprezentovány **vektory příznaků** x ,
zařazování obrazů do tříd – klasifikace **deterministickým** nebo
stochastickým rozhodovacím pravidlem ve tvaru

$$\omega = d(x), \text{ resp. } \omega = d(x, q),$$

kde x je klasifikovaný obraz objektu,
 q je vektor nastavení klasifikátoru.

1. Rozpoznávání a klasifikace

Jako obraz (vektor příznaků) lze použít např.:

1. naměřené veličiny přímo,
2. spektrální koeficienty,
3. logaritmus kvadrátu spektra posloupnosti vzorků, např.
 $10 * \log |\mathbf{V}|^2$, kde \mathbf{V} je Four. obraz vektoru \mathbf{v} ,
4. histogram jednoho řádku snímku,
5. úhlové projekce (např. po 45 stupních) průsečíků průvodiče se sejmutým znakem,
6. řetězový kód středové osy podpisu,
7. ortogonální nebo biortogonální transformace signálů aj.

Formalizace úlohy příznakového rozpoznávání

Definice 1.1:

Prostředí (okolí, prostor) úlohy je množina veličin měřitelných fyzikálními principy a přístroji. Úloha rozpoznávání je pak reprezentována množinou funkcí

$$\mathcal{V} = \{ v_i(\mathbf{u}) \mid i = 1, 2, \dots \} ,$$

kde \mathbf{u} je obecný vektor vstupních parametrů; v mnoha případech je však touto nezávisle proměnnou **čas** – pak funkce $v_i(t)$ reprezentují časově proměnné vstupní veličiny.

1. Rozpoznávání a klasifikace

Definice 1.2:

Množinu obrazů dané úlohy (obrazový prostor) označíme \mathcal{X} a budeme předpokládat, že tato zahrnuje pouze obrazy objektů a funkcí, které přísluší ostře (jednoznačně) vymezené aplikační oblasti nebo podmnožině prostředí. Je definována množinou funkcí $f_i(\mathbf{v})$:

$$\mathcal{X} = \{ f_i(\mathbf{v}) \mid i = 1, 2, \dots, n \} .$$

Definice 1.3:

Prvky množiny obrazů dané úlohy $\mathcal{X} = \{ \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n \}$ nazýváme obrazy rozpoznávaných (klasifikovaných) objektů, obraz k-tého objektu je dán :

$$\mathbf{x}_k = f_k(\mathbf{v}) = \begin{pmatrix} f_{k1}(v_1, v_2, \dots, v_m) \\ f_{k2}(v_1, v_2, \dots, v_m) \\ \dots \\ f_{kn}(v_1, v_2, \dots, v_m) \end{pmatrix} .$$

1. Rozpoznávání a klasifikace

Definice 1.4:

Metody rozpoznávání se zabývají matematickými a technickými aspekty automatické klasifikace formálních popisů objektů – obrazů. Rozlišujeme:

- klasifikaci jednoduchých obrazů ,
- analýzu a porozumění komplexním obrazům .

Definice 1.5:

Klasifikací rozumíme jednoznačný přiřazovací předpis, který každému obrazu \mathbf{x}_i z množiny \mathcal{X} přiřadí jednoznačně indikátor třídy ω_r , $r = 1, 2, \dots, R$, R je pevně daný počet klasifikačních tříd. Množinu indikátorů tříd označíme $\Omega = \{ \omega_1, \omega_2, \dots, \omega_R \}$.

Poznámka: V reálných případech obvykle zařadíme do množiny Ω speciální třídu ω_0 ($R + 1.$), do níž zařazujeme nerozpoznané obrazy (obrazy, o jejichž zařazení nelze jednoznačně rozhodnout).

1. Rozpoznávání a klasifikace

Definice 1.6:

Bud' dána daná problémová oblast, její obrazový prostor \mathcal{X} , počet klasifikačních tříd $R \in \mathbb{N}$ a rozklad množiny (prostoru obrazů) \mathcal{X} na podprostory $\mathcal{X}_1, \mathcal{X}_2, \dots, \mathcal{X}_R$ takový, že platí

$$\mathcal{X}_r \neq \emptyset, \quad r = 1, 2, \dots, R,$$

$$\mathcal{X}_r \cap \mathcal{X}_s = \emptyset, \quad r, s = 1, 2, \dots, R, \quad r \neq s,$$

$$\bigcup_{r=1}^R \mathcal{X}_r = \mathcal{X}, \quad \text{popř.} \quad \bigcup_{r=0}^R \mathcal{X}_r = \mathcal{X}.$$

Oblasti \mathcal{X}_r pak nazýváme **klasifikačními třídami**, resp. klasifikačními oblastmi, a klasifikační úlohu **úlohou s oddělitelnými (separovatelnými) třídami**.

Poznámka: Ke zjednodušení klasifikační úlohy dojde tehdy, když klasifikační třídy budou **po dvojicích disjunktní**.

1. Rozpoznávání a klasifikace

Definice 1.7:

Budiž \mathcal{X} obrazový prostor dané úlohy, \mathcal{A} konečná abeceda formálního jazyka a $\mathcal{L}_\omega \subseteq \mathcal{A}^*$ formální jazyk definovaný nad abecedou \mathcal{A} .
Zobrazení

$$J: \left\{ \begin{array}{l} \mathcal{X} \rightarrow \mathcal{L}_\omega \\ f \mapsto b = J(\mathbf{x}) \end{array} \right\}$$

nazveme interpretační funkcí \mathcal{X} jazyka \mathcal{L}_ω . Řetězec (slovo) $b = J(\mathbf{x})$ pak nazveme symbolickým popisem (obrazem) objektu reprezentovaného vektorem $\mathbf{x} \in \mathcal{X}$.

Poznámka: Symbolické popisy objektů příslušejících do jednotlivých klasifikačních tříd jsou slovy jazyka dané třídy a nesouvisejí se symbolickými popisy objektů vytvářenými strukturními metodami rozpoznávání.

1. Rozpoznávání a klasifikace

Definice 1.8:

Určení (výpočet) jednotlivých obrazů objektů (symbolického popisu objektů) se nazývá **analýzou obrazů** (někdy též **vzorů**).

Definice 1.9:

Systemem analýzy obrazů je zpravidla nazýván **algoritmický postup analýzy obrazů** (symbolických popisů objektů).

1. Rozpoznávání a klasifikace

Příznakové metody rozpoznávání dělíme na

1. „klasické“ statistické metody rozpoznávání, založené na použití tzv. diskriminačních funkcí (Fisher) nebo pravděpodobnostech příslušnosti ke klasifikačním třídám (Bayes) ;
2. metody založené na strojovém učení – učení z příkladů; rozlišujeme
 - učení s učitelem (supervised learning) nebo
 - učení bez učitele (unsupervised learning) ;
3. metody založené na použití umělých neuronových sítí, tzv. neuronové klasifikátory .

1. Rozpoznávání a klasifikace

Klasifikátor s diskriminační funkcí

Pro každou třídu definujeme takovou diskriminační funkci, aby pro všechny obrazy patřící do r -té klasifikační třídy platilo

$$g_r(\mathbf{x}) > g_s(\mathbf{x}) \quad | \quad r \in \langle 1, R \rangle, \quad s = 1, \dots, R, \quad r \neq s.$$

Rozhodovací pravidlo pak nabývá tvaru

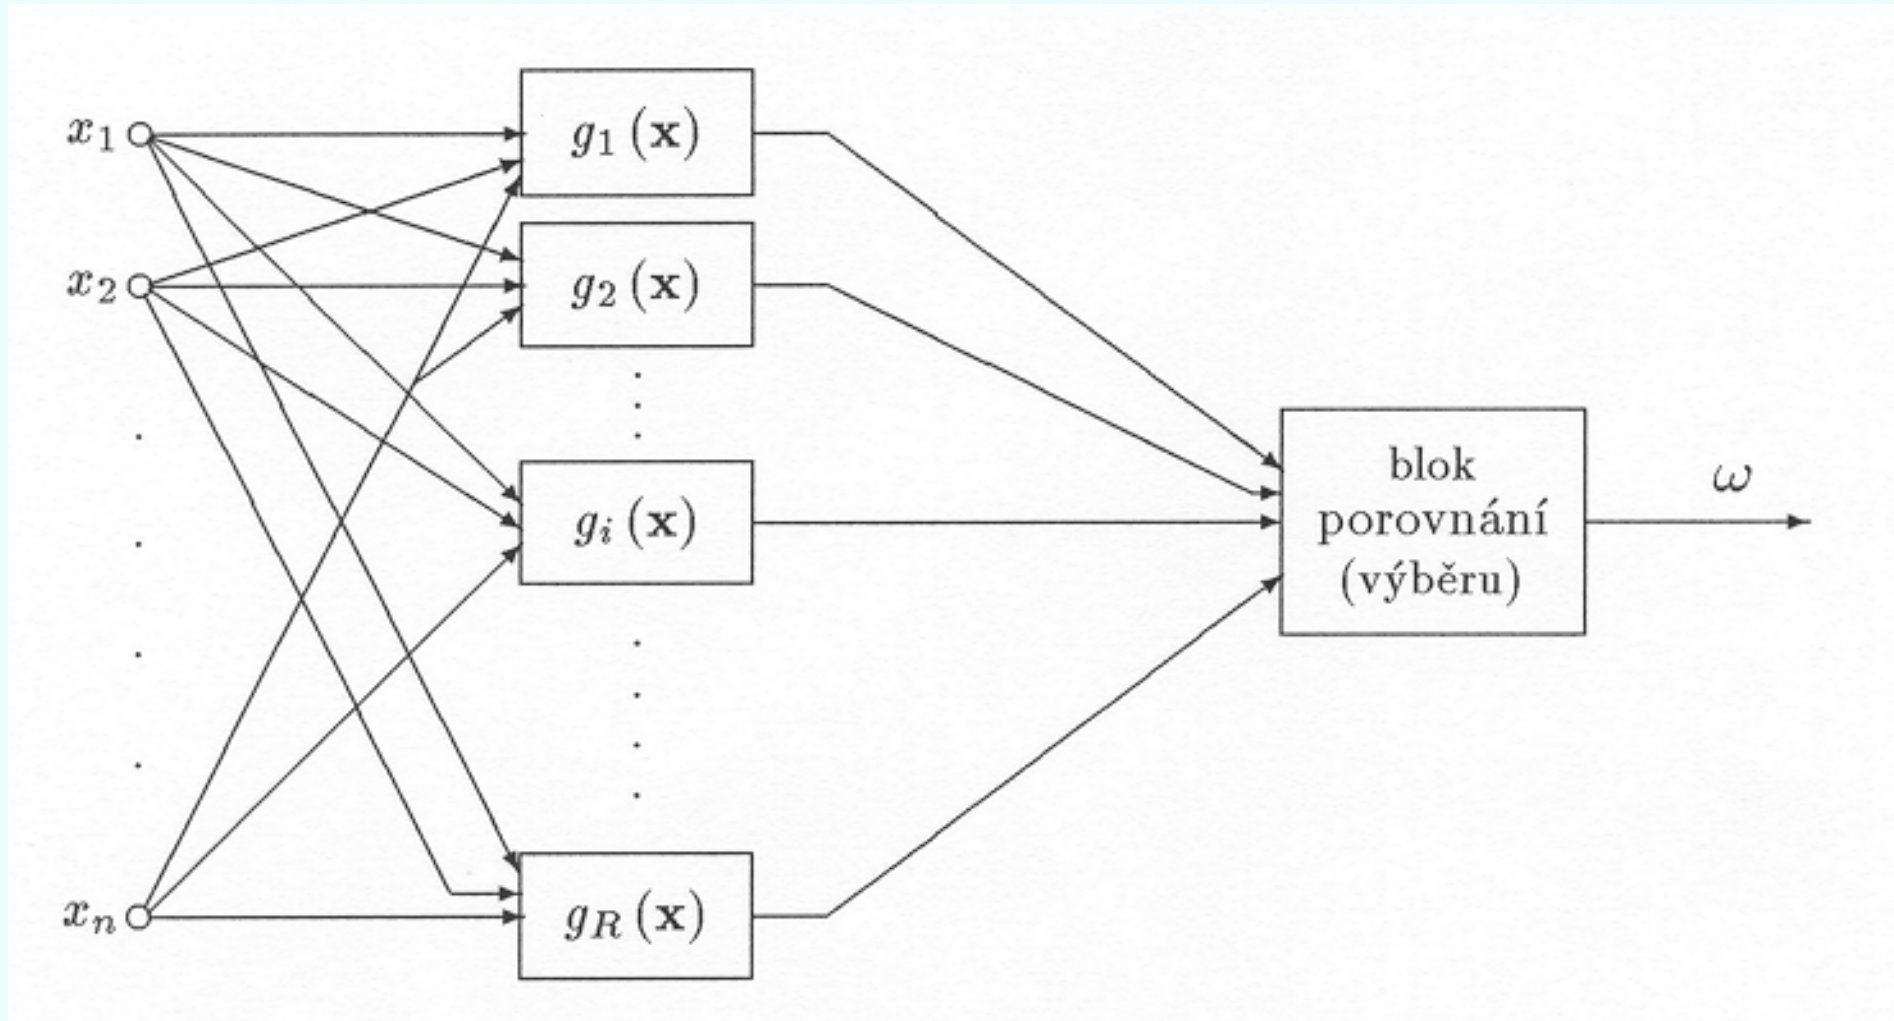
$$\omega_r = \max (g_s(\mathbf{x})), \quad s = 1, \dots, R$$

a rovnice rozdělujících nadploch určíme řešením soustavy rovnic

$$g_r(\mathbf{x}) - g_s(\mathbf{x}) \quad | \quad r, s = 1, \dots, R, \quad r \neq s.$$


1. Rozpoznávání a klasifikace

Struktura klasifikátoru



1. Rozpoznávání a klasifikace

Rozklad obrazového prostoru na podprostory (třídy)




a) s rozdělujícími nadplochami

b) s obalovými třídami

1. Rozpoznávání a klasifikace

Určení rozdělovacích nadploh v obrazovém prostoru



1. Rozpoznávání a klasifikace

Klasifikátor na principu kritéria minimální vzdálenosti
(porovnávání klasifikovaných obrazů se vzorovými obrazy – tzv. etalony)


Lze použít v úlohách s oddělitelnými množinami obrazů (třídami) – ve fázi trénování se vytvoří vzorové obrazy (etalony) jednotlivých tříd – označme je \mathbf{e}_s , $s = 1, \dots, R$.

Neznámé obrazy pak klasifikujeme pravidlem

$$\omega_r = \|\mathbf{e}_r - \mathbf{x}\| = \min \|\mathbf{e}_s - \mathbf{x}\|, \quad s = 1, \dots, R$$

1. Rozpoznávání a klasifikace

Princip:



1. Rozpoznávání a klasifikace

Kritérium minimální chyby (Bayesův klasifikátor)

Pro úlohy s neoddělitelnými (prolínajícími se) třídami obrazů – příslušnost k třídě lze určit jen s určitou pravděpodobností:


Kritérium minimální chyby využívá k popisu úlohy pravděpodobnostního zápisu. Potom hodnotu ω pokládáme za náhodnou proměnnou. Pokud bychom znali pouze hodnoty apriorních pravděpodobností $P(\omega_i)$, zařazovali bychom všechny obrazy do té třídy ω_r , která má nejvyšší apriorní pravděpodobnost $P(\omega_r)$. To by však bylo chybné. Pravděpodobnost této chyby můžeme vyjádřit jako $1 - P(\omega_r)$.

Většinou se nemusíme rozhodovat jen podle apriorních pravděpodobností tříd $P(\omega_i)$, ale máme k dispozici i hodnotu vektoru příznaků \mathbf{x} a všechny podmíněné hustoty rozdělení pravděpodobnosti $p(\mathbf{x} | \omega_r)$.

Tyto podmíněné hustoty pravděpodobnosti vyjadřují rozložení hodnot \mathbf{x} uvnitř jednotlivých tříd; získáme je trénováním klasifikátoru. Histogram četností výskytu jednotlivých obrazů uvnitř jedné třídy je dobrým odhadem hustoty pravděpodobnosti.


1. Rozpoznávání a klasifikace

Příklad – pro jednorozměrný případ (vektor příznaků o jednom prvku):



1. Rozpoznávání a klasifikace

Dvourozměrný případ:



1. Rozpoznávání a klasifikace


Pravděpodobnost (tzv. a posteriori pravděpodobnost), že obraz \mathbf{x} přísluší do třídy s identifikátorem ω_r , je dána vztahem

$$P(\omega_s/x) = \frac{p(x/\omega_s).P(\omega_s)}{p(x)}, \quad p(x) = \sum_{i=1}^R p(x/\omega_i).P(\omega_i).$$

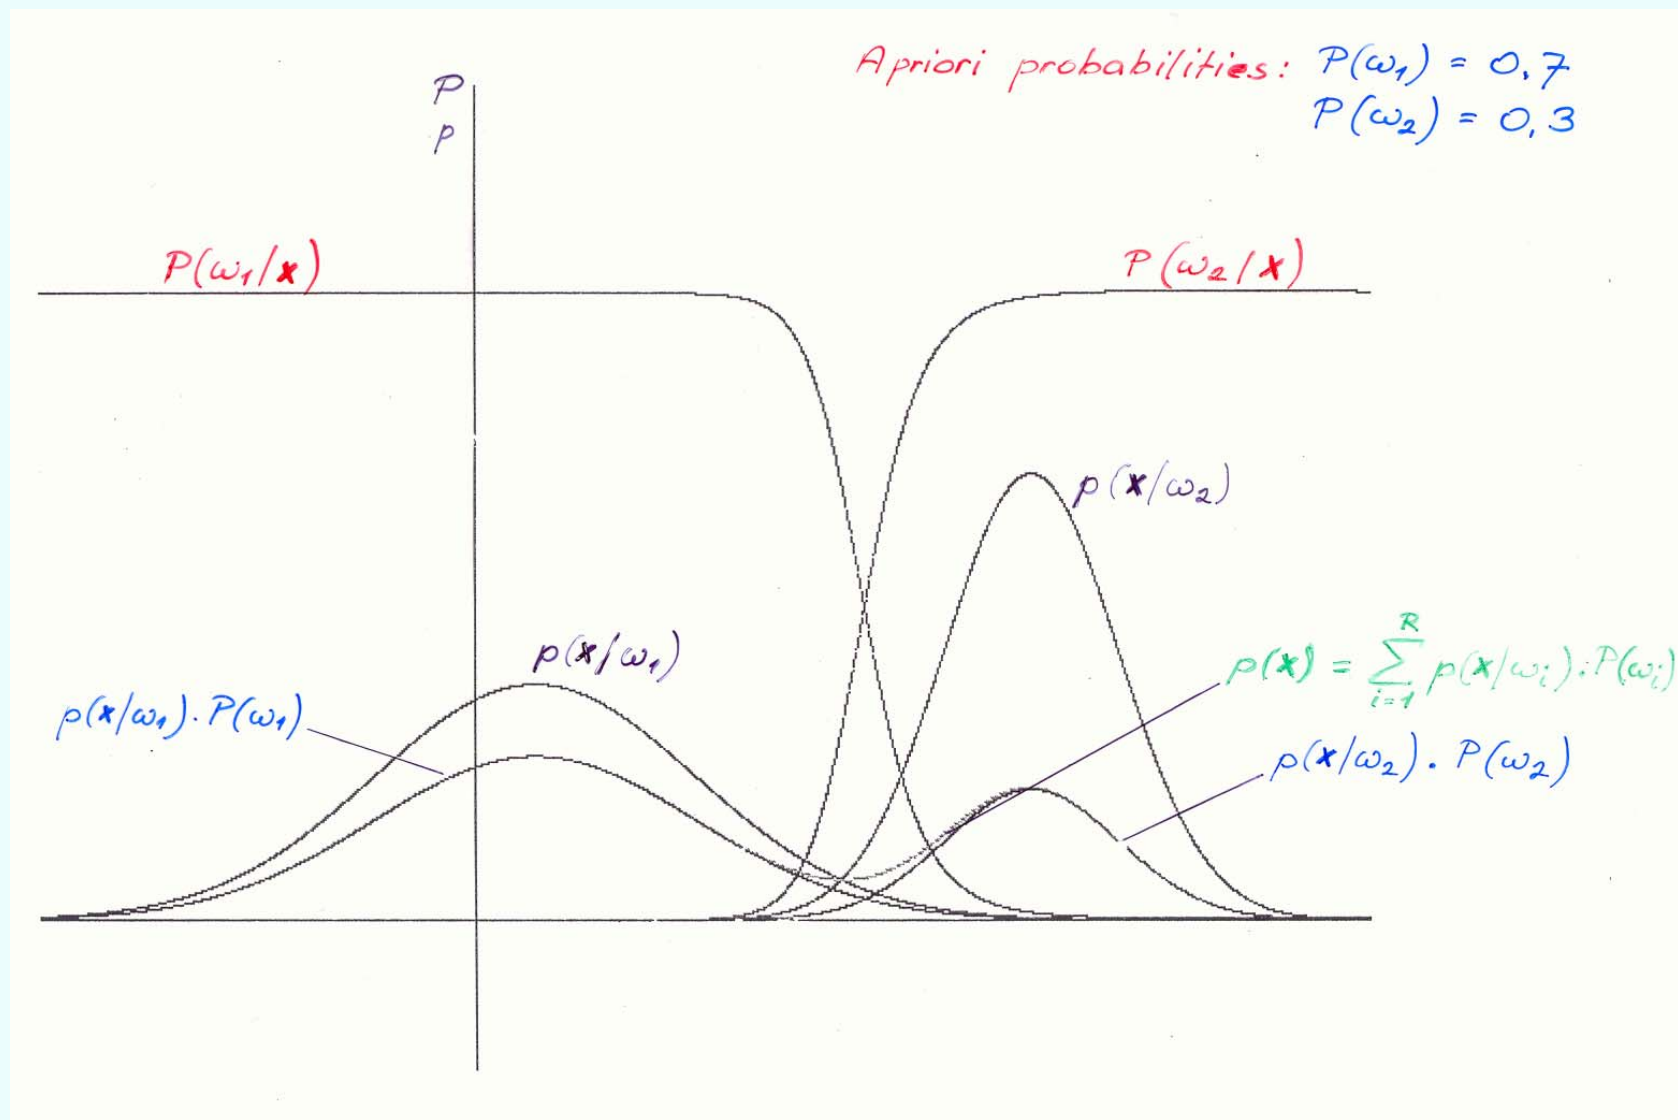
Rozhodovací pravidlo pro zařazení objektu do r -té třídy pak má tvar:

$$\omega_r = \max_{\forall s} (P(\omega_s/x)), \quad s = 1, \dots, R.$$


Ilustrace:




1. Rozpoznávání a klasifikace



1. Rozpoznávání a klasifikace



1. Rozpoznávání a klasifikace



1. Rozpoznávání a klasifikace

Kritérium minimální chyby

The decision rule

$$\omega = d(\mathbf{x}, \mathbf{q}^*)$$

that gives the minimum mean loss $J(\mathbf{q})$ is called the optimum decision rule, and \mathbf{q}^* is called the vector of optimal parameters

$$J(\mathbf{q}^*) = \min_{\mathbf{q}} J(\mathbf{q}), \quad d(\mathbf{x}, \mathbf{q}) \in D$$

The **minimum error criterion** (Bayes criterion, maximum likelihood) uses loss functions of the form $\lambda(\omega_r|\omega_s)$, where $\lambda(\cdot)$ is the number that describes quantitatively the loss incurred if a pattern \mathbf{x} which should be classified into the class ω_s is incorrectly classified into the class ω_r

$$\omega_r = d(\mathbf{x}, \mathbf{q})$$

1. Rozpoznávání a klasifikace

The mean loss is

$$J(\mathbf{q}) = \int_X \sum_{s=1}^R \lambda(d(\mathbf{x}, \mathbf{q})|\omega_s) p(\mathbf{x}|\omega_s) P(\omega_s) d\mathbf{x}$$

where $P(\omega_s)$, $s = 1, \dots, R$ are the a priori probabilities of classes, and $p(\mathbf{x}|\omega_s)$, $s = 1, \dots, R$ are the conditional probability densities of objects \mathbf{x} in the class ω_s .

$$\begin{aligned} \lambda(\omega_r|\omega_s) &= 0 \text{ for } r = s \\ &= 1 \text{ for } r \neq s \end{aligned}$$

and the discrimination functions are

$$g_r(\mathbf{x}) = p(\mathbf{x}|\omega_r)P(\omega_r), \quad r = 1, \dots, R$$

where $g_r(\mathbf{x})$ corresponds (up to a multiplicative constant) to the value of the a posteriori probability $P(\omega_r|\mathbf{x})$.

1. Rozpoznávání a klasifikace

Výpočet aposteriorních pravděpodobností

$$P(\omega_r|\mathbf{x}) = \max_{s=1,\dots,R} P(\omega_s|\mathbf{x})$$

A posteriori probability may be computed from a priori probabilities using the Bayes formula

$$P(\omega_s|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_s)P(\omega_s)}{p(\mathbf{x})}$$

where $p(\mathbf{x})$ is the mixture density.

1. Rozpoznávání a klasifikace

Výsledek
roznování:

```
=====
.....
.....WWW.....: 0
.....WWW.....: 1
-----WWW-----: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....WWWWW.....: 2
.....W.....WW.....: 2
.....WW.....: 1
-----W-----: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
-----W-----: 1
.....W.....: 1
.....W.....: 1
.....W.....: 1
.....WW.....: 1
.....WW.....: 1
.....WWWWWW.....: 1
.....: 0

0023333333333332100

=====
JEDNA SE 0 ZNAK: 5
SPRAVNE ? [Y/N]: Y
POUZITE RADKY: 3 , 14 , 21 ,POUZITE SLOUPCE: 8 ,
```

Strukturní metody rozpoznávání

Strukturní popisy rozpoznávaných objektů

- primitiva
- vlastnosti primitiv
- relace mezi primitivy – prostorové
 - časové
 - funkční

Vytvořený symbolický popis – **obraz** vystihuje (popisuje) **strukturní vlastnosti objektu** .

1. Rozpoznávání a klasifikace

Jako strukturní popisy (obrazy) lze použít:

- řetězec symbolů označujících primitiva
- relační struktura
- graf (obecný, speciální, ...)

Strukturní popisy objektů (= slova) příslušejících do téže třídy tvoří **jazyk** třídy.

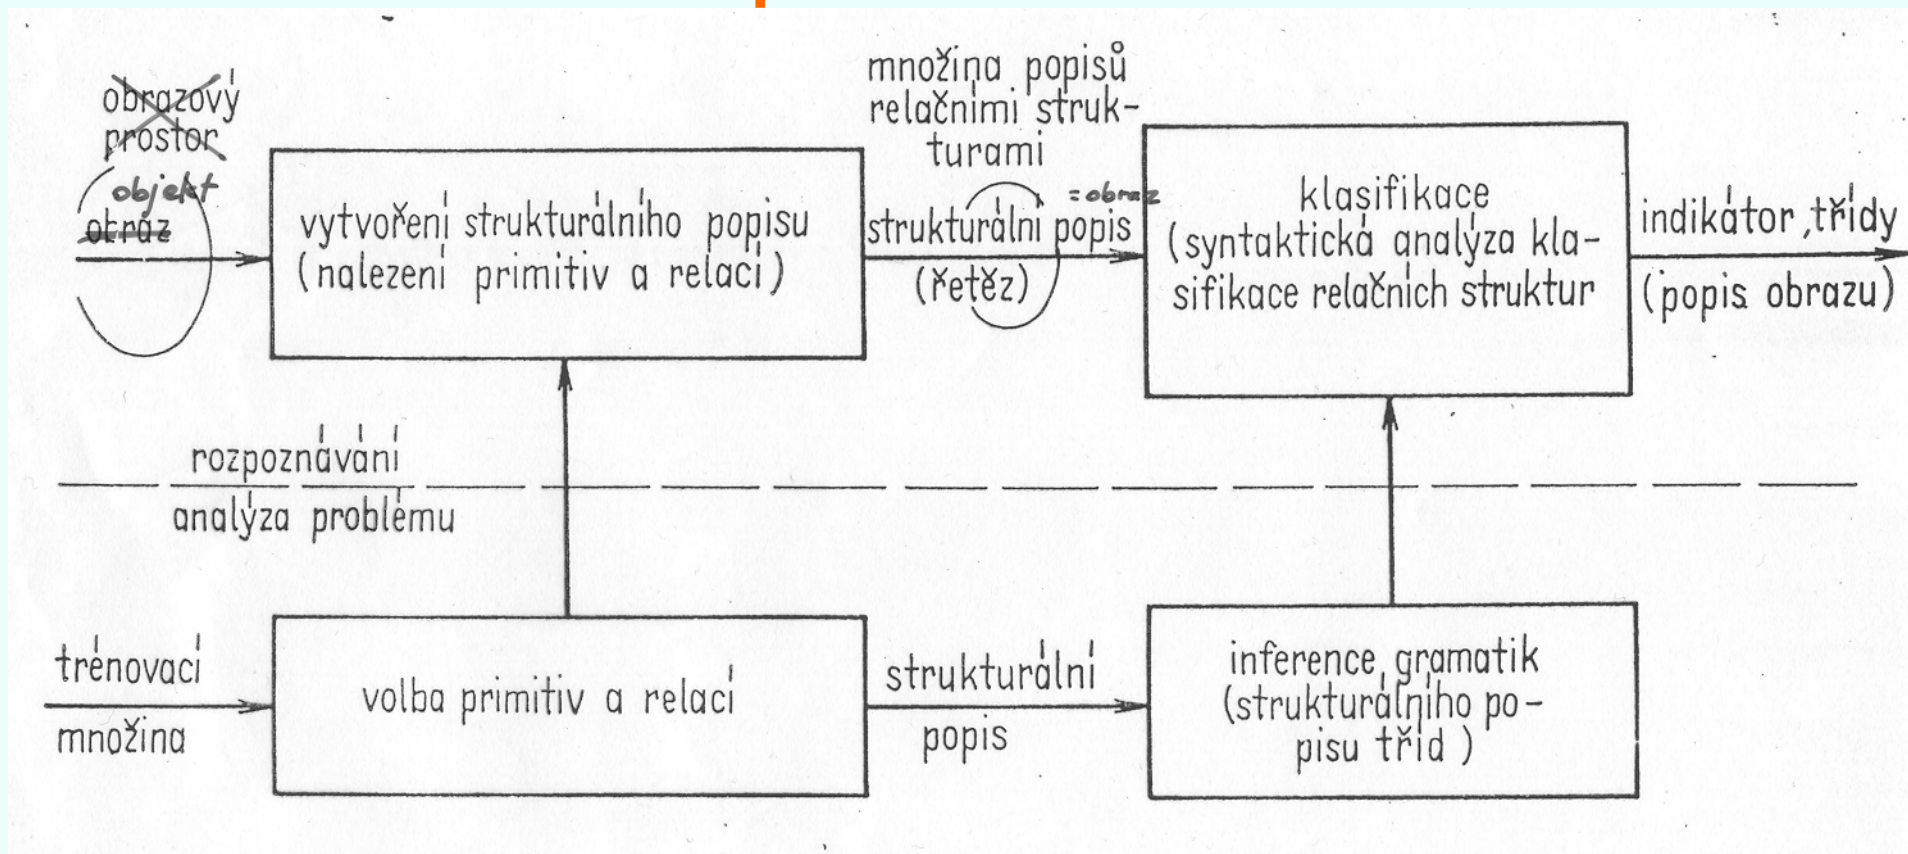
Rozpoznávání strukturně popsaných objektů = rozhodnutí,
zda vytvořený strukturní popis objektu (slovo) **je slovem** (frází)
jazyka příslušné třídy.

Výhody strukturních metod rozpoznávání:

- invariantní na pozici a natočení obrazu,
- méně složité popisy u složitých objektů

1. Rozpoznávání a klasifikace

Úloha strukturního rozpoznávání



1. Rozpoznávání a klasifikace

Slovní formulace:

Algoritmus 7.3 - Syntaktické rozpoznávání

Fáze učení

- (1) Na základě analýzy úlohy definujte primitiva a jejich vzájemné relace.
- (2) Analýzou syntaktických popisů předmětů jednotlivých tříd případně odvozováním (inferencí) (odstavec 7.2.3) sestrojte gramatiku reprezentující každou třídu.

Fáze rozpoznávání

- (3) Při rozpoznávání, do které třídy předmět náleží, extrahujte nejprve jeho primitiva, určete jejich druh a vzájemné relace. Sestrojte slovo reprezentující popisovaný předmět.
- (4) Na základě výsledku syntaktické analýzy zařaďte předmět do té třídy, jejíž gramatika (sestrojená v kroku (2)) dané slovo generuje.

1. Rozpoznávání a klasifikace

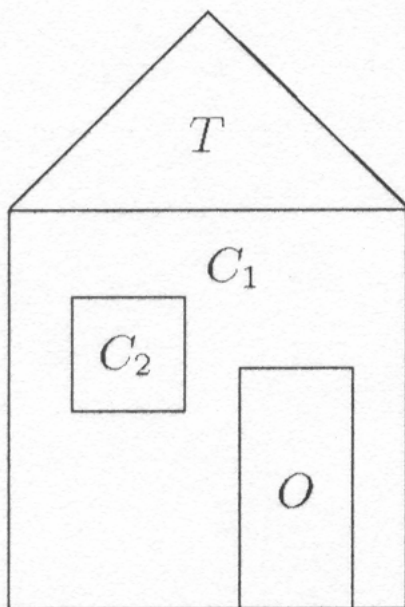
Jak postupovat při vytváření strukturních popisů:

1. nalézt všechna **primitiva** a přiřadit jim prvky nosiče struktury;
2. každému prvku struktury přiřadit **vlastnost** (unární relaci) označenou jménem (symbolem) odpovídajícího primitiva;
3. určit **vztahy mezi primitivy** (binární relace), čímž vytvoříme **relační strukturu**;
4. doplnit případnou informaci číselné povahy (vytvoříme **sémantickou informaci**, popř. sémantický vektor).

1. Rozpoznávání a klasifikace

Vytváření popisné relační struktury (strukturního obrazu)

$\mathcal{M} \equiv \{T, O, C_1, C_2\}$



unární relace:

T ... je trojúhelník


O ... je obdélník

C ... je čtverec

binární relace:

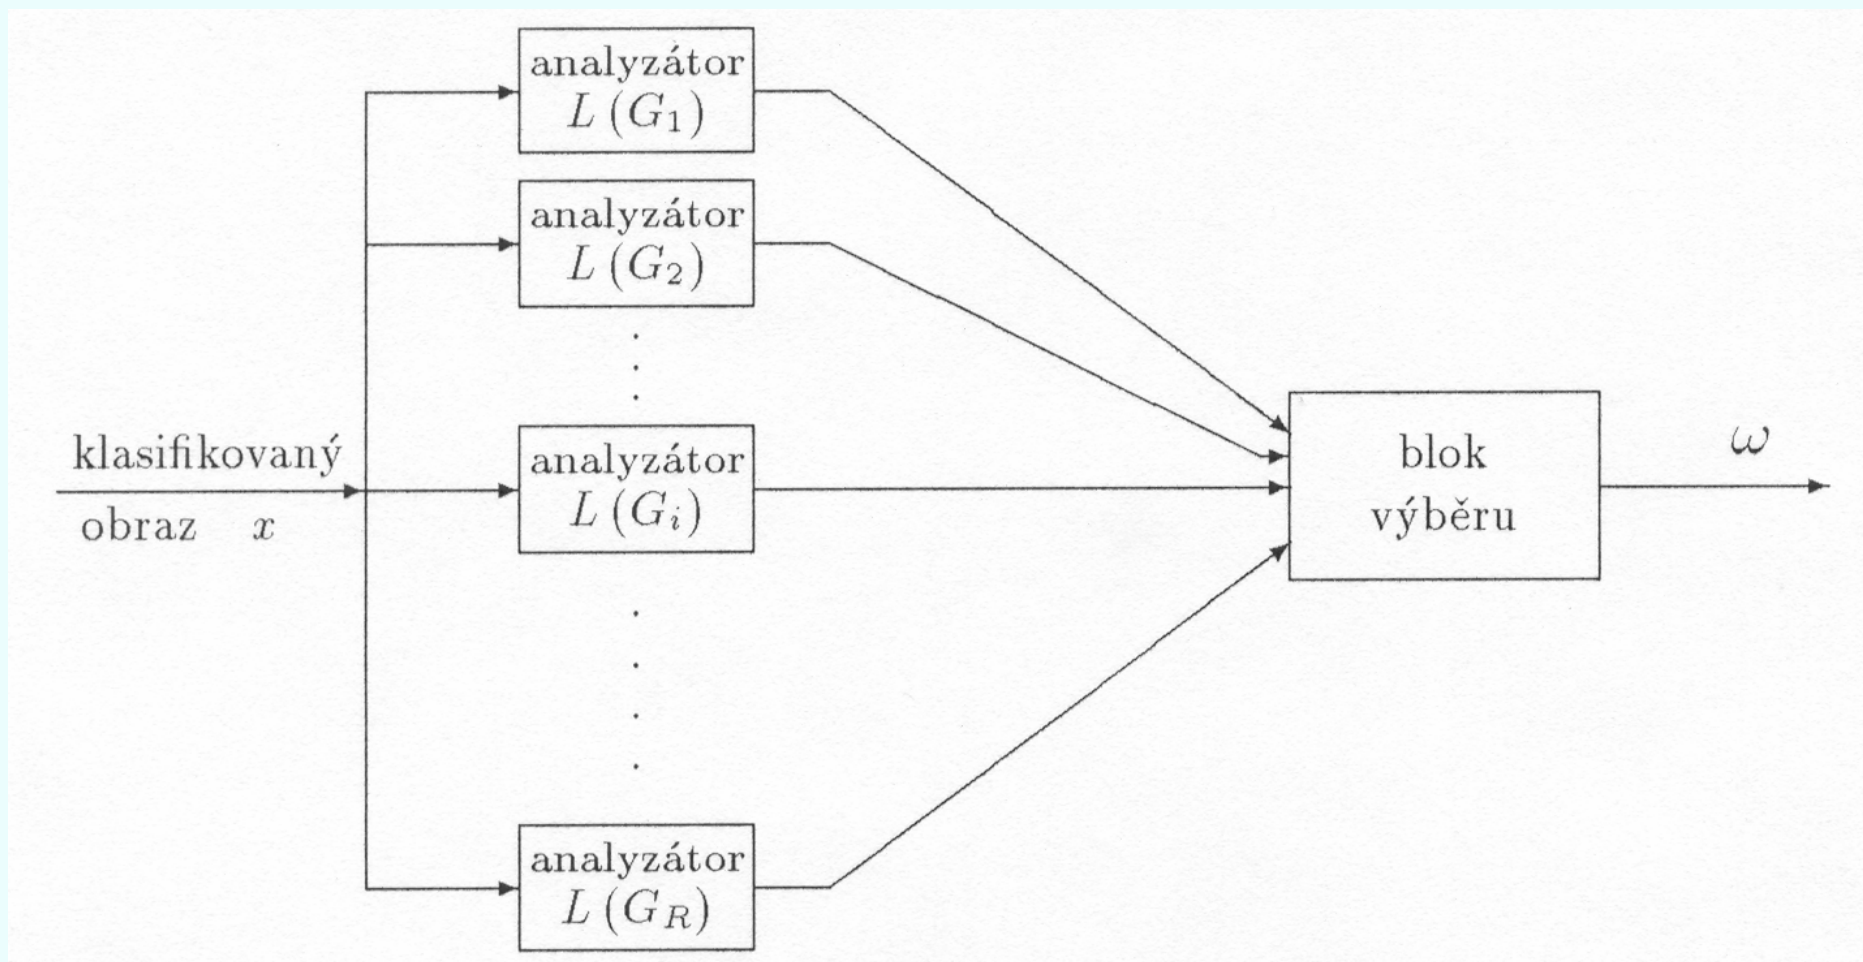
dotýká se ... - - - - -

je uvnitř ... →



1. Rozpoznávání a klasifikace

Struktura klasifikátoru



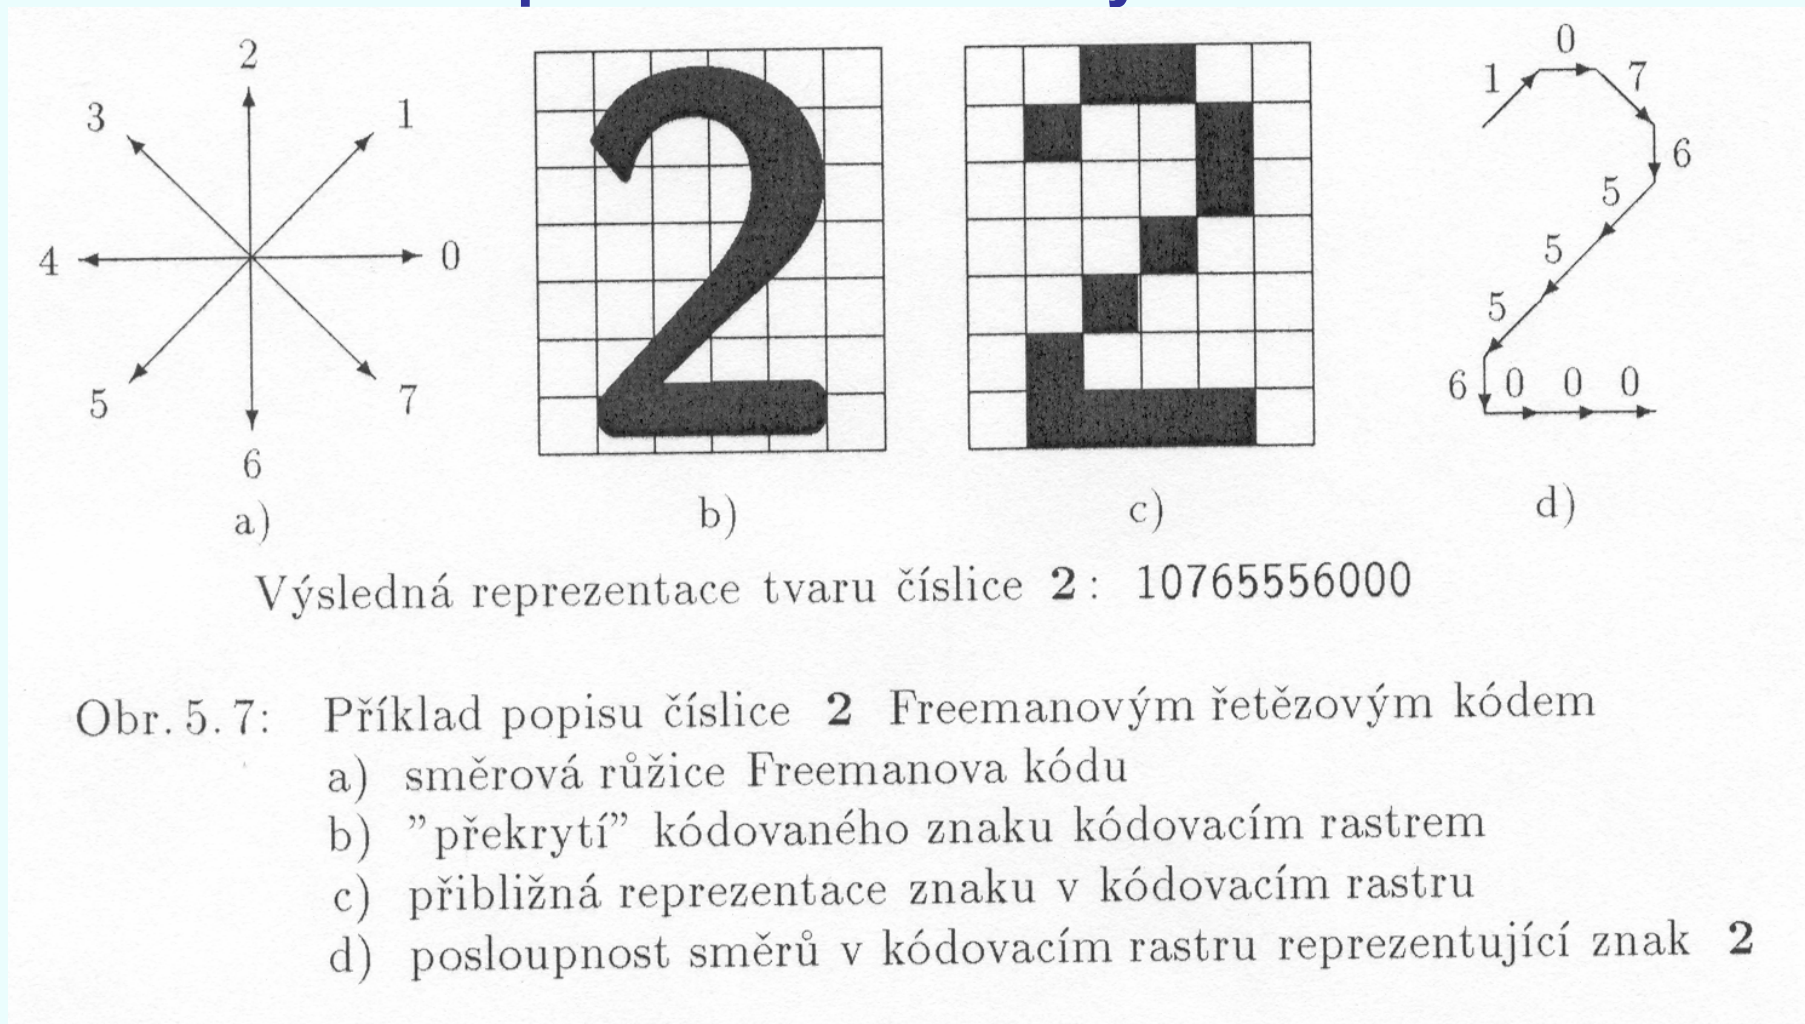
1. Rozpoznávání a klasifikace

Extrakce primitiv, vytváření strukturních obrazů

1. **Počet** typů (druhů) primitiv i relací (vztahů) mezi nimi by měl být **co nejmenší**.
2. **Primitiva** by měla **odpovídat** základním (přirozeným) **strukturním elementům** objektu, jimiž lze objekt vyčerpávajícím způsobem popsat; přitom primitiva musejí být snadno **extrahovatelná** a **klasifikovatelná** (nejčastěji některou příznakovou metodou).
3. **Nalezení** (určení) **primitiv** a **relací** mezi nimi (způsob nalezení, algoritmus, ...) by mělo být **algoritmicky co nejjednodušší**.


1. Rozpoznávání a klasifikace

Příklad extrakce primitiv Freemanovým kódem



1. Rozpoznávání a klasifikace

Vytvoření strukturního popisu



Definujeme primitiva

primitivum	/		—	\	()	⤴	⤵
označení	A	B	C	D	E	F	G	H

Strukturní popisy:

2: GAAC

6: BBHG (BBGH)

Definujeme primitiva

primitivum	/		—	\	⤴	⤵	⤶	⤷
označení	A	B	C	D	E	F	G	H

Strukturní popisy:

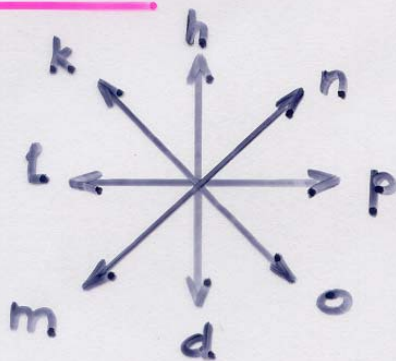
2: EFAAACC

6: BBBGHFE (BBBEFHG)

1. Rozpoznávání a klasifikace

Praktický příklad extrakce primitiv

SMĚROVÁ RŮŽICE:




PRIMITIVA:

oznažení:

A
B
C
D
E
F
G
H

přípustné tvary:



PŘÍKLADY:

př. popisu primitiva E
pomocí směrové růžice:

hhnpnpphh :




1. Rozpoznávání a klasifikace

Strukturní popisy (obrazy) číslic 2 a 6 :

*př. popisu číslice 2
pomocí primitiv :*

EAHFFFAA:





Číslice 6:

DDDHEGF


nebo

DDDAEGBF



1. Rozpoznávání a klasifikace

Strukturní rozpoznávání geometrických objektů



primitivum	—		/	\	()
symb. označení	a	b	c	d	e	f

1. Rozpoznávání a klasifikace

Gramatiky

a

strukturní popisy objektů

$$G_1 = \langle V_{N1}, V_{T1}, S_1, R_1 \rangle \quad G_2 = \langle V_{N2}, V_{T2}, S_2, R_2 \rangle$$
$$V_{N1} \equiv \{S_1, X_1, Y_1\} \quad V_{N2} \equiv \{S_2, X_2, Y_2, Z\}$$
$$V_{T1} \equiv \{e, f\} \quad V_{T2} \equiv \{a, e, f\}$$
$$R_1 \equiv \{S_1 \rightarrow X_1 Y_1, \quad R_2 \equiv \{S_2 \rightarrow X_2 Y_2, X_2 \rightarrow eZ, \\ X_1 \rightarrow e, Y_1 \rightarrow f\} \quad Y_2 \rightarrow fZ, Z \rightarrow aZ|a\}$$

$$G_3 = \langle V_{N3}, V_{T3}, S_3, R_3 \rangle \quad G_4 = \langle V_{N4}, V_{T4}, S_4, R_4 \rangle$$
$$V_{N3} \equiv \{S_3, X_3, Y_3\} \quad V_{N4} \equiv \{S_4, X_4, Y_4\}$$
$$V_{T3} \equiv \{a, b\} \quad V_{T4} \equiv \{a, b\}$$
$$R_3 \equiv \{S_3 \rightarrow (X_3 Y_3)^2, \quad R_4 \equiv \{S_4 \rightarrow (X_4 Y_4)^2, \\ X_3 \rightarrow b, Y_3 \rightarrow a\} \quad X_4 \rightarrow b, Y_4 \rightarrow aY_4|a\}$$

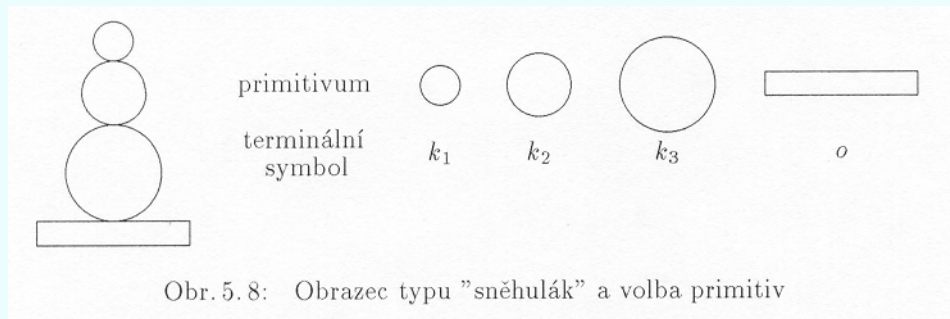
$$G_5 = \langle V_{N5}, V_{T5}, S_5, R_5 \rangle \quad G_6 = \langle V_{N6}, V_{T6}, S_6, R_6 \rangle$$
$$V_{N5} \equiv \{S_5, X_5, Y_5\} \quad V_{N6} \equiv \{S_6, X_6\}$$
$$V_{T5} \equiv \{a, b\} \quad V_{T6} \equiv \{a, c, d\}$$
$$R_5 \equiv \{S_5 \rightarrow (X_5 Y_5)^2, \quad R_6 \equiv \{S_6 \rightarrow cX_6 d, \\ X_5 \rightarrow bX_4|b, Y_5 \rightarrow a\} \quad X_6 \rightarrow a\}$$

$$G_7 = \langle V_{N7}, V_{T7}, S_7, R_7 \rangle$$
$$V_{N7} \equiv \{S_7, X_7, Y_7\}$$
$$V_{T7} \equiv \{a, b, c, d\}$$
$$R_7 \equiv \{S_7 \rightarrow cX_1 d, \\ X_7 \rightarrow Y_7 a Y_7, Y_7 \rightarrow b Y_7 | b\}$$

- (1) ef
- (2) eafa, resp. eafaa ... e(a)ⁿf(a)ⁿ
- (3) baba
- (4) baabaa, resp. baaabaaa ... b(a)ⁿb(a)ⁿ
- (5) bbabba, resp. bbbabbbba ... (b)ⁿa(b)ⁿa
- (6) cad
- (7) cbabd, resp. cbbabbd ... c(b)ⁿa(b)ⁿd

1. Rozpoznávání a klasifikace

Strukturní rozpoznávání s využitím sémantické informace



Obr. 5. 8: Obrazec typu "sněhulák" a volba primitiv

Strukturní popis:

$$k_1 k_2 k_3 o$$

„klasická“ regulární gramatika:

$$G_{sněh} = \langle V_{N\ sněh}, V_{T\ sněh}, S, R_{sněh} \rangle ,$$

kde

$$V_{N\ sněh} \equiv \{ S, A, B, C \} ,$$

$$V_{T\ sněh} \equiv \{ k_1, k_2, k_3, o \} ,$$

$$R_{sněh} \equiv \{ S \rightarrow k_1 A, A \rightarrow k_2 B, B \rightarrow k_3 C, C \rightarrow o \} .$$

Využijeme-li atributovou regulární gramatiku, dostaneme:

$$k_{(6)} k_{(8)} k_{(10)} o .$$

Třídu "sněhuláků" lze pak reprezentovat atributovou regulární gramatikou

$$G_{a_sněh} = \langle V_{N\ a_sněh}, V_{T\ a_sněh}, S, R_{a_sněh}, C_{a_sněh}, P_{a_sněh}, \mathbf{v} \rangle ,$$


kde $V_{N\ a_sněh} \equiv \{ S, A \}$, $V_{T\ a_sněh} \equiv \{ k, o \}$,

vektor \mathbf{v} obsahuje jediný parametr v_1 označující poloměr koule a množina přepisovacích pravidel bude ve tvaru

$R_{a_sněh} :$	r_i	$C_{a_sněh}$	$P_{a_sněh}$
	$S \rightarrow k A$		$v_1 = 0$
	$A \rightarrow k A$	$par \geq v_1$	$v_1 = par$
	$A \rightarrow o$		

1. Rozpoznávání a klasifikace

Příklad klasifikace znaků umělými neuronovými sítěmi



1. Rozpoznávání a klasifikace

Klasifikace znaku M:

