Inteligentne Systemy Obliczeniowe

Wykład 7

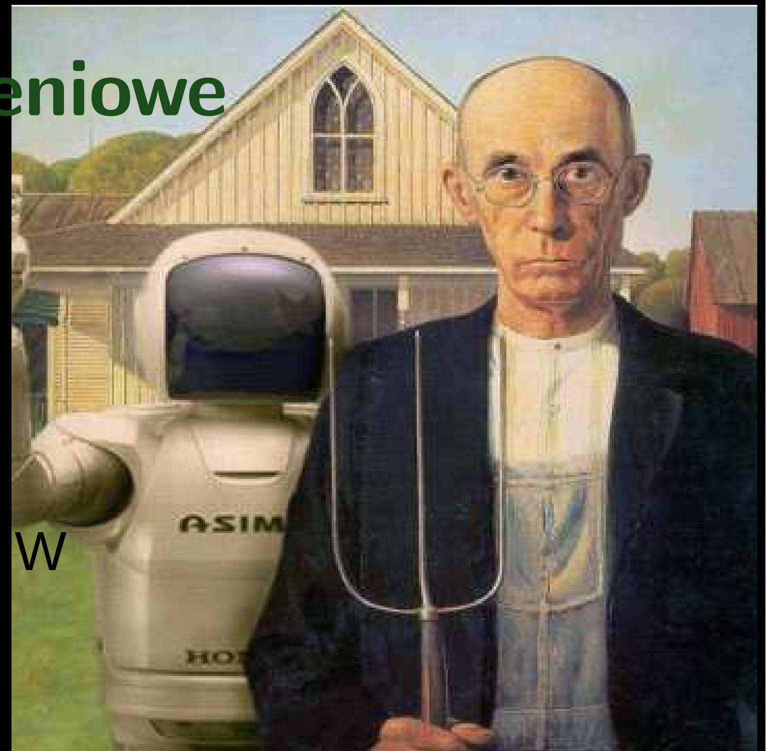

Piotr Wąsiewicz

Zakład Sztucznej Inteligencji - ISE PW

pwasiewi@elka.pw.edu.pl

Generowanie reguł klasyfikujących algorytmem CN2

Indukcja reguł

- Kompleks k składa się z selektorów.
- $k_1 = \{< \text{słoneczna} \vee \text{deszczowa}, \text{zimna} \vee \text{ciepła}, ?, ? >\}$
  $k_2 = \{< \text{słoneczna}, \text{ciepła}, ?, ? >\}$
  $k_2 \prec k_1$
  k_2 jest bardziej szczegółowe od k_1, k_1 jest bardziej ogólne od k_2
- $S \rhd k$ to dokładniej $(\exists k \in S) k \rhd x$ - zbiór wszystkich x pokrywanych przez $k \in S$
- $\{k_1 \rhd x\} = \{1, 2, 5, 6, 9\}$
- $\{k_2 \rhd x\} = \{1, 2\}$
- Kompleks tylko z jednym selektorem nieuniwersalnym zwany jest *kompleksem atomowym* .

Indukcja reguł - sekwencyjne pokrywanie

funkcja *sekwencyjne-pokrywanie*(T)

argumenty wejściowe:

- T - zbiór trenujący dla pojęcia c

zwraca: zbiór reguł reprezentujący hipotezę przybliżającą c

$R := 0; P := T$;

jak długo $P \neq 0$ wykonaj

$k :=$ znajdź-kompleks(T, P);

$d :=$ kategoria(k, T, P);

$R := R \cup \{k \rightarrow d\}$;

$P := P - P_k$;

koniec jak długo

zwróć R

funkcja *znajdź-kompleks-cn2*(T, P)
argumenty wejściowe:

- T - zbiór trenujący dla pojęcia c,
- P - podzbiór zbioru T zawierający przykłady nie pokryte przez wygenerowane wcześniej reguły

zwraca: statystycznie istotny kompleks pokrywający pewną liczbę przykładów z P z dużą dokładnością;

$S := \{<?>\}; k_* := <?>;$
jak długo $S \neq \phi$ wykonaj
$S' := S \cap \mathbb{S};$
$S' := S' - S - \{<\phi>\};$
dla wszystkich kompleksów $k \in S'$ wykonaj
jeśli $\psi_k(P) > \theta \wedge \vartheta_k(P) > \vartheta_{k_*}(P)$ to
$k_* := k$
koniec jeśli
koniec dla
$S :=$ Arg $\max^m_{k \in S'} v_k(P)$
koniec jak długo
zwróć k_*

Entropię zbioru P ze względu na kompleks k określa się następująco:

$$E_k(P) = \sum_{d \in C} -\frac{|P_k^d|}{|P_k|} log \frac{|P_k^d|}{|P_k|}$$

Entropia ma tę cechę, że największą wartość przyjmuje dla zrównoważonych rozkładów częstości kategorii. Funkcja oceniająca kompleksy musi być zanegowaną entropią:

$$\vartheta_k(P) = -E_k(P)$$

Algorytm CN2 - statystyka χ

Niech f_i oznacza *zaobserwowaną częstość* (liczbę wystąpień) i-tej wartości atrybutu y_i dla $i = 1, 2, 3, \dots, v_1$ i odpowiednio f_j dla y_j dla $j = 1, 2, 3, \dots, v_2$, f_{ij} liczbę (częstość) jednoczesnych wystąpień i-tej i j-tej wartości atrybutów y_i i y_j, a e_{ij} to wartość oczekiwana jednoczesnego wystąpienia przy założeniu niezależności y_1 i y_2 i $(v_1 - 1)(v_2 - 1)$ stopniach swobody.

$$\chi^2 = \sum_{i=1}^{v_1} \sum_{j=1}^{v_2} \frac{(f_{ij} - e_{ij})^2}{e_{ij}},$$

gdzie $e_{ij} = \frac{f_i^1 f_j^2}{n}$

Im większa wartość statystyki tym bardziej atrybuty są zależne od siebie.

Algorytm CN2 - statystyka χ

$$\chi_k^2(P) = \sum_{d \in C} \frac{(|P_k^d| - e_k^d(P))^2}{e_k^d(P)},$$

gdzie $e_k^d(P) = |P_k| \frac{|P^d|}{|P|}$

Zbiór testowy T

x	aura	temperatura	wilgotność	wiatr	$c(x)$
1	słoneczna	ciepła	duża	słaby	0
2	słoneczna	ciepła	duża	silny	0
3	pochmurna	ciepła	duża	słaby	1
4	deszczowa	umiarkowana	duża	słaby	1
5	deszczowa	zimna	normalna	słaby	1
6	deszczowa	zimna	normalna	silny	0
7	pochmurna	zimna	normalna	silny	1
8	słoneczna	umiarkowana	duża	słaby	0
9	słoneczna	zimna	normalna	słaby	1
10	deszczowa	umiarkowana	normalna	słaby	1
11	słoneczna	umiarkowana	normalna	silny	1
12	pochmurna	umiarkowana	duża	silny	1
13	pochmurna	ciepła	normalna	słaby	1
14	deszczowa	umiarkowana	duża	silny	0

Zbiór $\mathbb{S}$ kompleksów atomowych

$$\mathbb{S} = \{< \text{deszczowa}, ?, ?, ? >,$$

$$< \text{deszczowa} \vee \text{słoneczna}, ?, ?, ? >,$$

$$< \text{deszczowa} \vee \text{pochmurna}, ?, ?, ? >,$$

$$< \text{pochmurna}, ?, ?, ? >,$$

$$< \text{pochmurna} \vee \text{słoneczna}, ?, ?, ? >,$$

$$< \text{słoneczna}, ?, ?, ? >,$$

$$<?, \text{ciepła}, ?, ? >,$$

$$<?, \text{ciepła} \vee \text{zimna}, ?, ? >,$$

$$<?, \text{ciepła} \vee \text{umiarkowana}, ?, ? >,$$

$$<?, \text{umiarkowana}, ?, ? >,$$

$$<?, \text{umiarkowana} \vee \text{zimna}, ?, ? >,$$

$$<?, \text{zimna}, ?, ? >,$$

$$<?, ?, \text{duża}, ? >, <?, ?, \text{normalna}, ? >, <?, ?, ?, \text{silny} >, <?, ?, ?, \text{słaby} >\}$$

Kolejne kroki algorytmu CN2 1/3

1. Początkowo

   $R = \phi, P = T = \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14\}, \mathbb{S}$

2. Następuje wywołanie *znajdź-kompleks* (T, P).
   - $S = \{<?>\} \neq \phi, k_* =<?>$ i $\vartheta_{k_*}(P) = -E_{k_*}(P) = -0.940$,
   - $S' = \mathbb{S} = S \cap \mathbb{S}$,
   - $k =<$ pochmurna$, ?, ?, ? >$ ma największą wartość $\vartheta_k = 0$ w zbiorze $\mathbb{S}$; $S = \{k\}, k_* = k$,

3. $R = \{<$ pochmurna$, ?, ?, ? > \rightarrow 1\}$, $P = \{1, 2, 4, 5, 6, 8, 9, 10, 11, 14\}$,

4. $P \neq \phi \Rightarrow$*znajdź-kompleks* (T, P),
   - $S = \{<?>\} \neq \phi, k_* =<?>$ i $\vartheta_{k_*}(P) = -1$,
   - $S' = \mathbb{S} = S \cap \mathbb{S}$,
   - $k =<?,$ ciepła$, ?, ? >$ ma największą wartość $\vartheta_k = 0$ w zbiorze $\mathbb{S}$; $S = \{k\} \neq \phi, k_* = k$,

5. $R = \{<$ pochmurna$, ?, ?, ? > \rightarrow 1, <?,$ ciepła$, ?, ? > \rightarrow 0\}$,

   $P = \{4, 5, 6, 8, 9, 10, 11, 14\}$,

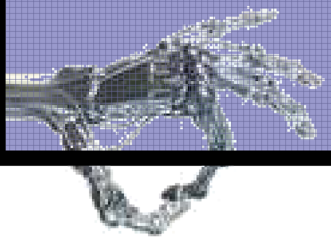

Kolejne kroki algorytmu CN2 2/3

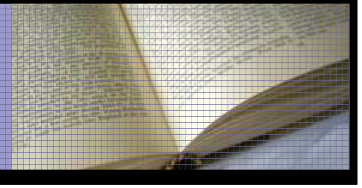

6. $P \neq \phi \Rightarrow$*znajdź-kompleks* (T, P),
   - $S' = \mathbb{S} = S \cap \mathbb{S}$,
   - $k = <?, ?, \text{normalna}, ? >$ zostaje wybrane z najwyższą wartością $\vartheta_k = -0,721$ w zbiorze $\mathbb{S}$; $S = \{k\} \neq \phi, k_* = k$,
   - k_* nie ma wartości 0 (pętla jak długo się nie kończy),
   - w następnym cyklu dla $S' = S \cap \mathbb{S}$ największą wartość $\vartheta_k = 0$ ma kompleks $k = <?, ?, \text{normalna}, \text{słaby} >$, $k_* = k$
7. $R = \{< \text{pochmurna}, ?, ?, ? > \rightarrow 1, <?, \text{ciepła}, ?, ? > \rightarrow 0, < ?, ?, \text{normalna}, \text{słaby} > \rightarrow 1\}$, $P = \{4, 6, 8, 11, 14\}$,
8. po kilku dalszych wywołaniach funkcji *znajdź-kompleks* (T, P) otrzymujemy $R = \{< \text{pochmurna}, ?, ?, ? > \rightarrow 1, <?, \text{ciepła}, ?, ? > \rightarrow 0, < ?, ?, \text{normalna}, \text{słaby} > \rightarrow 1, <?, \text{zimna}, ?, ? > \rightarrow 0, < ?, ?, \text{normalna}, ? > \rightarrow 1, <?, ?, ?, \text{silny} > \rightarrow 0, < \text{słoneczna}, ?, ?, ? > \rightarrow 0\}, P = \{4\}$

Kolejne kroki algorytmu CN2 3/3

9. $P \neq \phi \Rightarrow$*znajdź-kompleks* (T, P),
   - $S = \{<?>\} \neq \phi, k_* = <?>$ i $\vartheta_{k_*}(P) = -E_{k_*}(P) = 0$,
10. Ostatecznie

$$R = \{< \text{pochmurna}, ?, ?, ? > \rightarrow 1,$$

$$<?, \text{ciepła}, ?, ? > \rightarrow 0,$$

$$<?, ?, \text{normalna}, \text{słaby} > \rightarrow 1,$$

$$<?, \text{zimna}, ?, ? > \rightarrow 0,$$

$$<?, ?, \text{normalna}, ? > \rightarrow 1,$$

$$<?, ?, ?, \text{silny} > \rightarrow 0,$$

$$< \text{słoneczna}, ?, ?, ? > \rightarrow 0,$$

$$<? > \rightarrow 1\}$$