

Modelowanie niepewności

Dr hab. inż. Joanna Józefowska, prof. PP

1/1

Plan wykładu

- Zastosowanie rachunku prawdopodobieństwa do modelowania niepewności
- MYCIN – system ekspercki wnioskujący na podstawie wiedzy niepewnej
- Model współczynnika pewności
- Metoda Dempstera-Shafera
- Zbiory rozmyte
- Zbiory przybliżone

Dr hab. inż. Joanna Józefowska, prof. PP

1/2

Prawdopodobieństwo zdarzenia

- Podejście z dziedziny gier losowych:
prawdopodobieństwo to stosunek liczby wyników spełniających warunki określonego zdarzenia do liczby wszystkich wyników
- Podejście częstotliwościowe:
prawdopodobieństwo jest granicą częstości występowania określonego zdarzenia, po wykonaniu dużej liczby eksperymentów
- Podejście subiektywne:
prawdopodobieństwo jest pewną liczbą charakterystyczną dla danego zdarzenia losowego – miarą przekonania o wystąpieniu zdarzenia, czy też miarą odczuwania niepewności

Dr hab. inż. Joanna Józefowska, prof. PP

1/3

Aksjomaty rachunku prawdopodobieństwa

Aksjomat I Każdemu zdarzeniu A odpowiada określona liczba $P(A)$, zwana prawdopodobieństwem zdarzenia A , spełniająca nierówność: $0 \leq P(A) \leq 1$

Aksjomat II Prawdopodobieństwo zdarzenia pewnego równa się jedności.

Aksjomat III Prawdopodobieństwo sumy zdarzeń parami wyłączających się równa się sumie prawdopodobieństw tych zdarzeń.

Dr hab. inż. Joanna Józefowska, prof. PP

1/4

Prawdopodobieństwo warunkowe

oznaczone symbolem $P(A|B)$ wyraża przekonanie o prawdziwości zdarzenia A przy założeniu, że zdarzenie B zachodzi z całkowitą pewnością

Definicja

Niech prawdopodobieństwo zdarzenia B będzie dodatnie. Prawdopodobieństwo warunkowe zdarzenia A pod warunkiem zdarzenia B wyznaczamy następująco:

$$P(A|B) = \frac{P(A, B)}{P(B)}, \quad \text{gdzie } P(B) > 0$$

Dr hab. inż. Joanna Józefowska, prof. PP

1/5

Twierdzenie o prawdopodobieństwie całkowitym

Jeżeli zdarzenia A_1, A_2, \dots wyłączają się parami i wyczerpują zbiór zdarzeń elementarnych Θ , przy czym $P(A_i) > 0$ dla $i = 1, 2, \dots$ to dla dowolnego zdarzenia B zachodzi równość:

$$P(B) = \sum_i P(B | A_i) P(A_i)$$

Dr hab. inż. Joanna Józefowska, prof. PP

1/6

Twierdzenie Bayesa

Thomas Bayes (1701-1761)

Jeżeli zdarzenia A_1, A_2, \dots spełniają założenia twierdzenia o prawdopodobieństwie całkowitym oraz $P(B) > 0$, to dla $i = 1, 2, \dots$ zachodzi równość:

$$P(A_i | B) = \frac{P(B | A_i)P(A_i)}{\sum_i P(B | A_i)P(A_i)}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/7

Twierdzenie Bayesa

Jeśli uwzględnimy twierdzenie o prawdopodobieństwie całkowitym oraz użyjemy symboli H i E dla zdarzeń oznaczających odpowiednio hipotezę oraz obserwację (przesłankę), to reguła Bayesa przyjmuje postać:

$$P(H | E) = \frac{P(E | H)P(H)}{P(E)}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/8

Wady wnioskowania z zastosowaniem całkowitego rozkładu prawdopodobieństwa

- konieczność zdefiniowania i zapamiętania łącznego rozkładu prawdopodobieństwa
- wysoka złożoność obliczeniowa wyznaczania prawdopodobieństw brzegowych i warunkowych

Dr hab. inż. Joanna Jozefowska, prof. PP

1/9

Wymagania odnośnie do modelu niepewności w systemach regułowych


- W systemach wnioskowania logicznego reguła postaci $A \Rightarrow B$ pozwala wywnioskować B , gdy tylko zachodzi A , niezależnie od innych faktów. W systemach probabilistycznych trzeba wziąć pod uwagę wszystkie dostępne przesłanki.
- Jeżeli przeprowadzimy dowód jakiejś tezy, to tezy tej można użyć w kolejnych dowodach bez potrzeby ponownego jej dowodzenia. W systemach probabilistycznych przesłanki użyte do dowodu mogą ulec zmianie.
- W logice prawdziwość zdań złożonych można wywnioskować na podstawie wartości logicznej termów. Wnioskowanie probabilistyczne zachowuje tej własności, chyba, że nałożymy silne ograniczenia o niezależności.

Dr hab. inż. Joanna Jozefowska, prof. PP

1/10

Współczynnik pewności

- Buchanan, Shortliffe 1975
- Model opracowany dla regułowego systemu MYCIN



Dr hab. inż. Joanna Jozefowska, prof. PP

1/11

Belief

- $MB[H, E]$ – miara zwiększenia przekonania (ang. *belief*) o wystąpieniu hipotezy H , na podstawie obserwacji E .

$$MB[H, E] = \begin{cases} 1 & \text{gdy } P(H) = 1 \\ \frac{\max\{P(H|E), P(H)\} - P(H)}{\max\{1, 0\} - P(H)} & \text{w przeciwnym wypadku} \end{cases}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/12

Disbelief

- MD[H, E] – miara zwiększenia braku przekonania (ang. *disbelief*) o wystąpieniu hipotezy H, na podstawie obserwacji E.

$$MD[H, E] = \begin{cases} 1 & \text{gdy } P(H) = 0 \\ \frac{\min\{P(H|E), P(H)\} - P(H)}{\min\{1, 0\} - P(H)} & \text{w przeciwnym wypadku} \end{cases}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/13

Certainty factor

$$CF(H, E) = MB[H, E] - MD[H, E]$$

$$CF \in [-1, 1]$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/14

Interpretacja współczynnika pewności

Współczynnik pewności jest skojarzony z regułą postaci:

Jeżeli *przesłanka* to *hipoteza*


i oznacza *zmianę* przekonania o prawdziwości hipotezy w wyniku wystąpienia przesłanki (obserwacji).

$$E \xrightarrow{CF(H, E)} H$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/15

Propagacja niepewności



Równoległe połączenie reguł


$$MB(H, E_1 \& E_2) = \begin{cases} 0 & \text{gdy } MD(H, E_1 \& E_2) = 1 \\ MB(H, E_1) + MB(H, E_2) * [1 - MB(H, E_1)] & \text{w przeciwnym razie} \end{cases}$$

$$MD(H, E_1 \& E_2) = \begin{cases} 0 & \text{gdy } MB(H, E_1 \& E_2) = 1 \\ MD(H, E_1) + MD(H, E_2) * [1 - MD(H, E_1)] & \text{w przeciwnym razie} \end{cases}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/16

Propagacja niepewności



Szeregowe połączenie reguł

$$CF(H, E_1) = \begin{cases} CF(E_2, E_1)CF(H, E_2) & \text{gdy } CF(E_2, E_1) \geq 0 \\ CF(E_2, E_1)CF(H, \neg E_2) & \text{w przeciwnym razie} \end{cases}$$

Gdy $CF(H, \neg E_2)$ nie jest zdefiniowane, przyjmuje się że jest ono równe 0.

Dr hab. inż. Joanna Jozefowska, prof. PP

1/17

Współczynnik pewności – definicja probabilistyczna

Heckerman 1986

$$CF(H, E) = \begin{cases} \frac{P(H|E) - P(H)}{P(H|E)(1 - P(H))} & \text{gdy } P(H|E) > P(H) \\ \frac{P(H|E) - P(H)}{P(H)(1 - P(H|E))} & \text{gdy } P(H) > P(H|E) \end{cases}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/18

Wprowadzenie do sztucznej inteligencji

Miara pewności

Grzymała-Busse 1991

$$C'(H) = \begin{cases} C(H) + (1 - C(H))CF'(E \rightarrow H) & \text{gdy } C(H), CF'(E \rightarrow H) \geq 0 \\ C(H) + (1 + C(H))CF'(E \rightarrow H) & \text{gdy } C(H), CF'(E \rightarrow H) \leq 0 \\ \frac{C(H) + CF'(E \rightarrow H)}{1 - \min\{|C(H)|, |CF'(E \rightarrow H)|\}} & \text{gdy } C(H)CF'(E \rightarrow H) \leq 0 \end{cases}$$

$$CF'(E \rightarrow H) = CF(E \rightarrow H) * \max\{0, C(E)\}$$

Dr hab. inż. Joanna Jozefowska, prof. PP 1/19

Wprowadzenie do sztucznej inteligencji

Miara pewności

Jeżeli reguła ma w części warunkowej nie jedną przesłankę ale wyrażenie logiczne, stosowane jest podejście znane z teorii zbiorów rozmytych:

$$C(E_1 \wedge E_2) = \min\{C(E_1), C(E_2)\}$$

$$C(E_1 \vee E_2) = \max\{C(E_1), C(E_2)\}$$

$$C(\neg E_1) = 1 - C(E_1)$$

Dr hab. inż. Joanna Jozefowska, prof. PP 1/20

Wprowadzenie do sztucznej inteligencji

Przykład 1

$$C(s1 \wedge s2) = \min(0,2; -0,1) = -0,1$$

$$CF'(h, s1 \wedge s2) = 0,4 * 0 = 0$$

$$C'(h) = 0,3 + (1 - 0,3) * 0 = 0,3 + 0 = 0,3$$

$$CF'(E \rightarrow H) = CF(E \rightarrow H) * \max\{0, C(E)\}$$

$$C'(H) = \begin{cases} C(H) + (1 - C(H))CF'(E \rightarrow H) & \text{gdy } C(H), CF'(E \rightarrow H) \geq 0 \end{cases}$$

Dr hab. inż. Joanna Jozefowska, prof. PP 1/21

Wprowadzenie do sztucznej inteligencji

Przykład 2

$$C(s1 \wedge s2) = \min(0,2; 0,8) = 0,2$$

$$CF'(h, s1 \wedge s2) = 0,4 * 0,2 = 0,08$$

$$C'(h) = 0,3 + (1 - 0,3) * 0,08 = 0,3 + 0,7 * 0,08 = 0,356$$

Dr hab. inż. Joanna Jozefowska, prof. PP 1/22

Wprowadzenie do sztucznej inteligencji

Teoria Dempstera-Shafera

Wiedza reprezentowana jest w postaci *funkcji przekonania*, stąd też model ten nazywany jest także teorią funkcji przekonania.

Każdemu zdaniu logicznemu przypisuje nie jedną lecz dwie wartości.

Użycie dwóch wartości zamiast jednej umożliwia, oprócz modelowania niepewności, reprezentację *ilości* pozyskanej informacji.

Proste modelowanie wspierania zbioru hipotez przez obserwacje.

Dr hab. inż. Joanna Jozefowska, prof. PP 1/23

Wprowadzenie do sztucznej inteligencji

Funkcja gęstości prawdopodobieństwa

(density probability function)

$$m : 2^\Theta \rightarrow [0,1]$$

$$m[\emptyset] = 0$$

$$\sum_{A \subseteq \Theta} m(A) = 1$$

Dr hab. inż. Joanna Jozefowska, prof. PP 1/24

Przekonanie (belief)

Przekonanie oznaczane w skrócie Bel $\in [0,1]$ mierzy siłę pozyskanych obserwacji wspierających przekonanie o prawdziwości rozważanego zbioru hipotez.

$$\text{Bel}(A) = \sum_{B \subseteq A} m(B)$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/25

Wyobrażalność (plausibility)

Wyobrażalność oznaczana w skrócie Pl $\in [0,1]$ określa na ile przekonanie o prawdziwości **A** jest ograniczone przez dowody wspierające $\neg A$.

$$\text{Pl}(A) = 1 - \text{Bel}(\neg A)$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/26

Łączenie obserwacji pochodzących z różnych źródeł

Założmy, że dane są dwa źródła obserwacji **X** i **Y** reprezentowane odpowiednio przez podzbiory zbioru Θ : X_1, \dots, X_m oraz Y_1, \dots, Y_n . Ponadto na zbiorach **X** i **Y** zdefiniowane są funkcje gęstości prawdopodobieństwa, odpowiednio m_1 i m_2 . Połączenie obserwacji z obu źródeł pozwala obliczyć nową wartość $m_3(Z)$ dla każdego podzbioru zbioru Θ następująco:

$$m_3(Z) = \frac{\sum_{X_i \cap Y_j = Z} m_1(X_i) m_2(Y_j)}{1 - \sum_{X_i \cap Y_j = \emptyset} m_1(X_i) m_2(Y_j)}$$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/27

Przykład

A – allergy
F – flu
C – cold
P – pneumonia

$$\Theta = \{A, F, C, P\} \quad m_1(\Theta) = 1$$

Obserwacja 1 $m_2(\{A, F, C\}) = 0,6$

$$m_2(\Theta) = 0,4$$

	$m_2(\{A, F, C\}) = 0,6$	$m_2(\Theta) = 0,4$
$m_1(\Theta) = 1$	$m_3(\{A, F, C\}) = 0,6$	$m_3(\Theta) = 0,4$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/28

Przykład

$$m_3(\{A, F, C\}) = 0,6 \quad m_3(\Theta) = 0,4$$

Obserwacja 2 $m_4(\{F, C, P\}) = 0,8$

$$m_4(\Theta) = 0,2$$

	$m_4(\{F, C, P\}) = 0,8$	$m_4(\Theta) = 0,2$
$m_3(\{A, F, C\}) = 0,6$	$m_5(\{F, C\}) = 0,48$	$m_5(\{A, F, C\}) = 0,12$
$m_3(\Theta) = 0,4$	$m_5(\{F, C, P\}) = 0,32$	$m_5(\Theta) = 0,08$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/29

Przykład

$m_5(\{F, C\}) = 0,48$	$m_5(\{A, F, C\}) = 0,12$
$m_5(\{F, C, P\}) = 0,32$	$m_5(\Theta) = 0,08$

Obserwacja 3 $m_6(\{A\}) = 0,75$

$$m_6(\Theta) = 0,25$$

$m_7(\{A\}) = 0,15$	$m_6(\{A\}) = 0,75$	$m_6(\Theta) = 0,25$
$m_5(\{F, C\}) = 0,48$	$m_7(\emptyset) = 0,36$	$m_7(\{F, C\}) = 0,12$
$m_5(\{A, F, C\}) = 0,12$	$m_7(\{A\}) = 0,09$	$m_7(\{A, F, C\}) = 0,03$
$m_5(\{F, C, P\}) = 0,32$	$m_7(\emptyset) = 0,24$	$m_7(\{F, C, P\}) = 0,08$
$m_5(\Theta) = 0,08$	$m_7(\{A\}) = 0,06$	$m_7(\Theta) = 0,02$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/30

Przykład

$m_5(\{F,C\}) = 0,48$	$m_5(\{A,F,C\}) = 0,12$
$m_5(\{F,C,P\}) = 0,32$	$m_5(\Theta) = 0,08$

Obserwacja 3

$m_6(\{A\}) = 0,75$

$m_6(\Theta) = 0,25$

$m_7(\emptyset) = 0,6$

$m_5(\{F,C\}) = 0,48$	$m_6(\{A\}) = 0,75$	$m_6(\Theta) = 0,25$
$m_5(\{A,F,C\}) = 0,12$	$m_7(\emptyset) = 0,36$	$m_7(\{F,C\}) = 0,12$
$m_5(\{F,C,P\}) = 0,32$	$m_7(\{A\}) = 0,09$	$m_7(\{A,F,C\}) = 0,03$
$m_5(\Theta) = 0,08$	$m_7(\emptyset) = 0,24$	$m_7(\{F,C,P\}) = 0,08$
	$m_7(\{A\}) = 0,06$	$m_7(\Theta) = 0,02$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/31

Przykład

$m_7(\{A\}) = 0,15$	$m_7(\{A\}) = 0,375$
$m_7(\{F,C\}) = 0,12$	$m_7(\{F,C\}) = 0,3$
$m_7(\{A,F,C\}) = 0,03$	$m_7(\{A,F,C\}) = 0,075$
$m_7(\{F,C,P\}) = 0,08$	$m_7(\{F,C,P\}) = 0,2$
$m_7(\Theta) = 0,02$	$m_7(\Theta) = 0,05$

$\{A\}: [0,375, 0,500]$

$\{F\}: [0, 0,625]$

$\{C\}: [0, 0,625]$

$\{P\}: [0, 0,250]$

$1 - 0,3 - 0,2$

$1 - 0,375$


$1 - 0,375 - 0,3 - 0,075$

Dr hab. inż. Joanna Jozefowska, prof. PP

Teoria zbiorów rozmytych (Zadeh)

Miara przynależności do zbioru jest liczbą z przedziału [0, 1].

Zbyszek jest wysoki.



$T(E_1 \wedge E_2) = \min\{T(E_1), T(E_2)\}$

$T(E_1 \vee E_2) = \max\{T(E_1), T(E_2)\}$

$T(\neg E_1) = 1 - T(E_1)$

$T(A \vee \neg A) \neq 1$

Dr hab. inż. Joanna Jozefowska, prof. PP

1/33


Teoria zbiorów rozmytych

Miara przynależności do zbioru jest liczbą z przedziału [0, 1].

Zbyszek jest wysoki.

oraz

Zbyszek jest towarzyski.



Dr hab. inż. Joanna Jozefowska, prof. PP

1/34

Teoria zbiorów przybliżonych (Pawlak)

Głównym celem zbiorów przybliżonych jest wprowadzenie koncepcji aproksymacji pojęć. Stosowane są głównie w odkrywaniu wiedzy.

System informacyjny (U, A) składa się z niepustego zbioru obiektów U oraz niepustego zbioru atrybutów A , $a: U \rightarrow V_a$, dla każdego $a \in A$ gdzie V_a jest nazywany zbiorem wartości A .

Dr hab. inż. Joanna Jozefowska, prof. PP

1/35

Teoria zbiorów przybliżonych (Pawlak)

Niech $T = (U, A)$, $B \subseteq A$ oraz $X \subseteq U$. Aproksymujemy X używając tylko informacji zawartej w B poprzez skonstruowanie B -dolnej i B -górnej aproksymacji X :



Dr hab. inż. Joanna Jozefowska, prof. PP

1/36

Podsumowanie

- Rachunek prawdopodobieństwa jest daleki od intuicyjnego rozumienia niepewności
- Wnioskowanie z zastosowaniem twierdzenia Bayesa jest bardzo złożone obliczeniowo
- Współczynnik pewności, teoria Dempstera-Shefera teoria zbiorów rozmytych i teoria zbiorów przybliżonych są alternatywnymi narzędziami modelowania wiedzy niepewnej dla celów automatycznego wnioskowania
- Sieci bayesowskie stanowią metodę wnioskowania z zastosowaniem twierdzenia Bayesa redukującą złożoność obliczeń