

www.kwmimkn.polsl.pl

METODY HEURYSTYCZNE

wykład 6

www.kwmimkn.polsl.pl

STANDARDOWE FUNKCJE PRZYNALEŻNOŚCI

www.kwmimkn.polsl.pl

GAUSSOWSKA F. PRZYNALEŻNOŚCI

$$\mu_f(x; x', a) = \exp\left(-\left(\frac{x-x'}{a}\right)^2\right)$$

x' – środek;
 a – określa szerokość krzywej

www.kwmimkn.polsl.pl

F. PRZYNALEŻNOŚCI KLASY S

$$s(x; a, b, c) = \begin{cases} 0 & \text{dla } x \leq a \\ 2\left(\frac{x-a}{c-a}\right)^2 & \text{dla } b \leq x \leq a \\ 1-2\left(\frac{x-c}{c-a}\right)^2 & \text{dla } b \leq x \leq c \\ 1 & \text{dla } x \geq c \end{cases}$$

$$b = \frac{a+c}{2}$$

www.kwmimkn.polsl.pl

F. PRZYNALEŻNOŚCI KLASY π

(zdef. poprzez klasę s)

$$\pi(x; b, c) = \begin{cases} s(x; c-b, c-b/2, c) & \text{dla } x \leq a \\ 1-s(x; c, c+b/2, c+b) & \text{dla } x \geq c \end{cases}$$

www.kwmimkn.polsl.pl

F. PRZYNALEŻNOŚCI KLASY γ

(alternatywa dla s)


$$\gamma(x; a, b) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x-a}{b-a} & \text{dla } a \leq x \leq b \\ 1 & \text{dla } x \geq b \end{cases}$$

F. PRZYNALEŻNOŚCI KLASY L


$$L(x; a, b) = \begin{cases} 1 & \text{dla } x \leq a \\ \frac{b-x}{b-a} & \text{dla } a \leq x \leq b \\ 0 & \text{dla } x \geq b \end{cases}$$

F. PRZYNALEŻNOŚCI KLASY t

(alternatywa dla π)




$$t(x; a, b, c) = \begin{cases} 0 & \text{dla } x \leq a \\ \frac{x-a}{b-a} & \text{dla } a \leq x \leq b \\ \frac{c-x}{c-b} & \text{dla } b \leq x \leq c \\ 1 & \text{dla } x \geq c \end{cases}$$



7

F. PRZYNALEŻNOŚCI KLASY singleton

$$\mu_A(x) = \delta(x - x') = \begin{cases} 1 & \text{jeżeli } x = x' \\ 0 & \text{jeżeli } x \neq x' \end{cases}$$



Singleton charakteryzuje jednoelementowy zbiór rozmyty.


Funkcja ta jest wykorzystywana głównie do operacji rozmywania w systemach wnioskujących.



8

Np.: prędkość samochodu: $X: [0, x_{max}]$


- Mała prędkość samochodu (A) – typ L
- Średnia prędkość samochodu (B) – typ t
- Duża prędkość samochodu (C) – typ γ



$$x=55 \Rightarrow \mu_A(x)=0.25, \mu_B(x)=0.75, \mu_C(x)=0$$



9



Nośnik (baza) zbioru rozmytego A :

zbiór elementów ZR, dla których $\mu(x) > 0$

$$\text{supp } A = \{x \in X; \mu_A(x) > 0\}$$

Jądro zbioru rozmytego A : zb. elementów ZR, dla których $\mu(x)=1$

$$\text{core}(A) = \{x \in X; \mu_A(x) = 1\}$$

α -przekrój zbioru rozmytego A : zbiór nierozmyty taki, że:

$$A_\alpha = \{x \in X; \mu_A(x) \geq \alpha\} \quad \forall (\alpha \in [0, 1])$$



10

Np.:

$$A = \frac{0.1}{2} + \frac{0.3}{4} + \frac{0.7}{5} + \frac{0.6}{8} + \frac{0.3}{10}$$

$$X = \{1, \dots, 10\}$$

α -przekroje:

$$A_0 = X = \{1, \dots, 10\},$$

$$A_{0.1} = \{2, 4, 5, 8, 10\},$$

$$A_{0.3} = \{4, 5, 8, 10\},$$

$$A_{0.6} = \{5, 8\},$$

$$A_{0.7} = \{5\}.$$



11

Wysokość zbioru rozmytego A :

$$h(A) = \sup_{x \in A} \mu_A(x)$$

Zbiór normalny: $h(A) = 1$

Normalizacja zbioru: $\mu_{A_N}(x) = \frac{\mu_A(x)}{h(A)} \quad \wedge_{x \in X}$

Np.:

- przed normalizacją:

$$A = \frac{0.2}{3} + \frac{0.5}{5} + \frac{0.4}{7}$$

- po normalizacji:

$$A_N = \frac{0.4}{3} + \frac{1.0}{5} + \frac{0.8}{7}$$



12

Inkluzja (zawieranie się ZR A w ZR B):

ZR wypukły:

ZR niewypukły:

Równość dwu ZR A i B :

$$\mu_A(x) = \mu_B(x) \quad \forall x \in X$$

13

OPERACJE NA ZBIORACH ROZMYTYCH

14

PRZECIECIE

W literaturze istnieje wiele definicji przecięcia (iloczynu) zbiorów rozmytych pod wspólną nazwą *T-norm*.

$$\mu_{A \cap B}(x) = T(\mu_A(x), \mu_B(x))$$

Najczęściej stosowana definicja przecięcia zbiorów A i B :

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\}$$

lub (iloczyn algebraiczny):

$$\mu_{A \cap B}(x) = \mu_A(x) \cdot \mu_B(x)$$

15

SUMA

Definicje sumy zbiorów rozmytych mają nazwę *S-norm*.

Np.:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\}$$

DOPEŁNIENIE zbioru rozmytego:

$$\mu_{\hat{A}}(x) = 1 - \mu_A(x)$$

Dla ZR **nie są** spełnione prawa dopełnienia:

$$A \cup \hat{A} \neq X \quad A \cap \hat{A} \neq \emptyset$$

16

Przykład:

$$X = \{1, 2, 3, 4, 5, 6, 7\}$$

$$A = \frac{0.8}{3} + \frac{1}{5} + \frac{0.7}{7} \quad B = \frac{0.5}{3} + \frac{0.8}{5} + \frac{1}{6}$$

Przecięcie:

$$A \cap B = \frac{0.5}{3} + \frac{0.8}{5}$$

Suma:

$$A \cup B = \frac{0.8}{3} + \frac{1}{5} + \frac{1}{6} + \frac{0.7}{7}$$

17

Przykład:

$$X = \{2, 3, 4, 5, 6, 7\}$$

$$A = \frac{0.8}{3} + \frac{1}{5} + \frac{0.9}{6} + \frac{0.7}{7}$$

$$\hat{A} = \frac{1}{2} + \frac{0.2}{3} + \frac{1}{4} + \frac{0.1}{6} + \frac{0.3}{7}$$

Przecięcie:

$$A \cap \hat{A} = \frac{0.2}{3} + \frac{0.1}{6} + \frac{0.3}{7} \neq \emptyset$$

Suma:

$$A \cup \hat{A} = \frac{1}{2} + \frac{0.8}{3} + \frac{1}{4} + \frac{1}{5} + \frac{0.9}{6} + \frac{0.7}{7} \neq X$$

18


LICZBY ROZMYTE




Liczby rozmyte to ZR zdefiniowane na osi liczb rzeczywistych.

- Wymagania:**
- zbiór normalny: $h(A)=1$;
 - zbiór wypukły;
 - funkcja przynależności przedziałami ciągła.

np.:



- dodatnie
- ujemne;
- ani dodatnie ani ujemne.



ZASADA ROZSZERZANIA:

Zasada rozszerzania pozwala przenieść (rozszerzyć) różne operacje matematyczne ze zbiorów nierozmytych na zbiory rozmyte (w tym również na liczby rozmyte).

dodawanie	$A_1 \oplus A_2 = B$	$\mu_B(y) = \sup_{x_1+x_2=y} \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2)\}$
odejmowanie	$A_1 \ominus A_2 = B$	$\mu_B(y) = \sup_{x_1-x_2=y} \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2)\}$
mnożenie	$A_1 \odot A_2 = B$	$\mu_B(y) = \sup_{x_1 \cdot x_2=y} \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2)\}$
dzielenie	$A_1 \oslash A_2 = B$	$\mu_B(y) = \sup_{x_1/x_2=y} \min\{\mu_{A_1}(x_1), \mu_{A_2}(x_2)\}$



ZASADA ROZSZERZANIA:

Zasada rozszerzania pozwala przenieść (rozszerzyć) różne operacje matematyczne ze zbiorów nierozmytych na zbiory rozmyte (w tym również na liczby rozmyte).

Nie zawsze wynikiem operacji arytmetycznych na liczbach rozmytych jest liczba rozmyta...


Twierdzenie (Dubois, Prade):

Jeżeli liczby rozmyte A_1 i A_2 mają ciągłe funkcje przynależności, to wynikiem operacji arytmetycznych dodawania, odejmowania, mnożenia i dzielenia są liczby rozmyte.




Dodawanie liczb rozmytych:

$$\mu_{A+B}(x) = \max\{\mu_A(y), \mu_B(z) \mid x = y + z\}$$



Mnożenie liczb rozmytych:


$$\mu_{A \cdot B}(x) = \min\{\mu_A(y), \mu_B(z) \mid x = y \cdot z\}$$



Trójkątne liczby rozmyte:

Opis:

- f. przynależności klasy t ;
- jako: $A = (a_1, a_M, a_2)$



Wyostrenie trójkątnej liczby rozmytej:

$$y^{(1)} = a_M$$


$$y^{(2)} = \frac{a_1 + a_M + a_2}{3}$$

$$y^{(3)} = \frac{a_1 + 2a_M + a_2}{4}$$

$$y^{(4)} = \frac{a_1 + 4a_M + a_2}{6}$$



Płaskie liczby rozmyte:



25

PRZYBLIŻONE WNIOSKOWANIE



26

Logika tradycyjna (dwuwartościowa):

O prawdziwości zdań wnioskuję się na podstawie prawdziwości innych zdań.

Schemat notowania:

- Nad kreską zdania, na podstawie których się wnioskuje;
- Pod kreską otrzymany wniosek.

Jeśli prawdziwe są wszystkie zdania powyżej kreski to prawdziwy jest też wniosek.

Teraz: A, B – zdania.



27

- $A=1$: logiczną wartością zdania A jest prawda;
- $A=0$: logiczną wartością zdania A jest fałsz.

Funktory logiczne:

Operacja logiczna	Funktor	Czyta się:
negacja	\sim lub \neg	nie jest prawdą, że...
koniunkcja	\wedge	i, oraz
alternatywa	\vee	lub
implikacja	\Rightarrow	jeżeli... to ...
równoważność	\Leftrightarrow	wtedy i tylko wtedy, gdy...
tożsamość	\equiv	jest tożsame...
kwantyfikator ogólny	\forall	dla każdego...
kwantyfikator szczególny	\exists	istnieje takie...

28

Implikacja (wynikanie):

Zdanie logiczne o strukturze „jeśli p to q ” ($p \Rightarrow q$)

- p – poprzednik implikacji;
- q – następnik implikacji.

Implikacja jest prawdziwa:

- gdy q jest prawdziwe;
- gdy p i q są fałszywe.



29

REGUŁY WNIOSKOWANIA

MODUS PONENS

Modus ponendo ponens – sposób wnioskowania przez twierdzenie p do twierdzenia q .

Przesłanka:	A
Implikacja:	$A \rightarrow B$
<hr/>	
Wniosek:	B

Z prawdziwości przesłanki i implikacji wynika prawdziwość wniosku.

Np.:

- $A=1$ „Jacek jest kierowcą”
- $B=1$ „Jacek ma prawo jazdy”
- Jeśli $A=1$ to $B=1$



30

MODUS TOLLENS

Modus tollendo tollens – sposób wnioskowania prowadzący przez przeczenie do przeczenia.

Przesłanka:	$\sim B$
Implikacja:	$A \rightarrow B$
<hr/>	
Wniosek:	$\sim A$

Z prawdziwości przesłanki i implikacji również wynika prawdziwość wniosku.

- Np.:**
- $B=0$ ($\sim B=1$) „Jacek nie ma prawa jazdy”
 - $A=0$ ($\sim A=1$) „Jacek nie jest kierowcą”
 - Jeśli $B=0$ to $A=0$



31

REGUŁY WNIOSKOWANIA W LOGICE ROZMYTEJ

Reguły, których przesłanki lub wnioski wyrażone są w języku zbiorów rozmytych.

- Reguły pochodzące od ekspertów zwykle wyrażone są w języku nieprecyzyjnym.
- Zbiory rozmyte pozwalają przełożyć ten język na konkretne wartości liczbowe.

Praca systemu decyzyjnego opartego na logice rozmytej zależy od definicji reguł rozmytych w bazie reguł.



32

Reguły mają postać **IF...AND...THEN**. np.:

IF a is $A1$ **AND** b is $B1$ **THEN** c is $C1$

IF a is $A2$ **AND** b is **NOT** $B2$ **THEN** c is $C2$

gdzie:

a, b, c – zmienne lingwistyczne,
 $A1, \dots, C2$ – zbiory rozmyte.

Zmienne lingwistyczne:

zmienne, które przyjmują jako wartości słowa lub zdania wypowiedziane w języku naturalnym.
(również wartości liczbowe).



33

Różnice w porównaniu z klasycznymi regułami IF-THEN:

- Wykorzystanie zmiennych opisujących zbiory rozmyte;
- Występowanie mechanizmu określającego stopień przynależności elementu do zbioru;
- Wykorzystanie operacji na zbiorach rozmytych.

Np.:

Schemat wnioskowania, w którym przesłanka, implikacja i wniosek są nieprecyzyjne:

Przesłanka:	<i>Prędkość samochodu jest duża</i>
Implikacja:	<i>Jeśli prędkość samochodu jest bardzo duża → poziom hałasu jest wysoki</i>
Wniosek:	<i>Poziom hałasu jest średniowysoki</i>



34

Przesłanka:	<i>Prędkość samochodu jest duża</i>
Implikacja:	<i>Jeśli prędkość samochodu jest bardzo duża → poziom hałasu jest wysoki</i>
Wniosek:	<i>Poziom hałasu jest średniowysoki</i>

Rozmyta reguła wnioskowania modus ponens :

Przesłanka:	x jest A'
Implikacja:	<i>Jeśli x jest $A \rightarrow y$ jest B</i>
Wniosek:	y jest B'



35

Przesłanka:	<i>Prędkość samochodu jest duża</i>
Implikacja:	<i>Jeśli prędkość samochodu jest bardzo duża → poziom hałasu jest wysoki</i>
Wniosek:	<i>Poziom hałasu jest średniowysoki</i>

Zmienne lingwistyczne:

- x – prędkość samochodu
- y – poziom hałasu

Zbiór wartości zmiennych lingwistycznych:

- $x: T1 = \{„mała”, „średnia”, „duża”, „bardzo duża”\}$
- $y: T2 = \{„mały”, „średni”, „średniowysoki”, „wysoki”\}$



36

Do każdego elementu zbiorów T1 i T2 można przyporządkować zbiór rozmyty o założonej przez nas funkcji przynależności.

Tu:

A – „prędkość samochodu jest bardzo duża”;

A' – „prędkość samochodu jest duża”;

B – „poziom hałasu jest wysoki”;

B' – „poziom hałasu jest średniowysoki”.

- Implikacja ma tę samą postać ($A \rightarrow B$) w regule rozmytej jak i w nierozmytej.
- W regule rozmytej jej przesłanka nie dotyczy zb. rozmytego A lecz A' , który może być zbliżony do A , ale niekoniecznie $A=A'$.

37

- Ponieważ $A \neq A'$ - wniosek jest inny niż byłby w przypadku reguły nierozmytej.
- Zbiór rozmyty B' jest określony przez złożenie zbioru rozmytego A' oraz implikacji $A \rightarrow B$:

$$B' = A' \circ (A \rightarrow B)$$

Rozmyta reguła wnioskowania modus tollens :

Przesłanka:	y jest B'
Implikacja:	Jeśli x jest $A \rightarrow y$ jest B
Wniosek:	x jest A'

38

Wyznaczanie funkcji $\mu_{A \rightarrow B}(x, y)$ gdy $\mu_A(x)$ oraz $\mu_B(y)$ są znane:

1. Reguła Mamdaniego:

$$\mu_{A \rightarrow B}(x, y) = \min[\mu_A(x), \mu_B(y)]$$

2. Reguła Larsena:

$$\mu_{A \rightarrow B}(x, y) = \mu_A(x) \cdot \mu_B(y)$$

3. Reguła Łukasiewicza:

$$\mu_{A \rightarrow B}(x, y) = \min[1, 1 - \mu_A(x) + \mu_B(y)]$$

4. Reguła Zadeha:

$$\mu_{A \rightarrow B}(x, y) = \max\{\min[\mu_A(x), \mu_B(y)], 1 - \mu_A(x)\}$$

...

39

STEROWNIKI ROZMYTE

40


Zastosowania praktyczne:

- sprzęt AGD (pralki, lodówki, odkurzacze);
- kamery (autofokus);
- nadzór wentylacji w tunelach;
- sterowanie światłami na wjeździe na autostradę;
- klimatyzacja;
- automatyka przemysłowa;
- sterowanie robotów;
- ...

41

- Nie wymagają tworzenia modelu rozważanego procesu (co często jest trudne);
- Należy jedynie sformułować zasady postępowania w postaci rozmytych reguł (**IF.. THEN**).

Np.: Schemat układu klimatyzacji:




\bar{x}_1, \bar{x}_2 – zmierzone wartości wejściowe;

\bar{y} – sygnał sterujący (intensywność chłodzenia).

42

STEROWNIK ROZMYTY:



Baza reguł (model lingwistyczny):
zbiór rozmytych reguł w postaci:

$$R^{(k)} : \text{IF } (x_1 \text{ is } A_1^k \text{ AND } x_2 \text{ is } A_2^k \dots \text{ AND } x_n \text{ is } A_n^k) \\ \text{THEN } (y_1 \text{ is } B_1^k \text{ AND } y_2 \text{ is } B_2^k \dots \text{ AND } y_m \text{ is } B_m^k)$$

Np. Sterowanie ogrzewaniem:

Cena ogrzewania	Temperatura		
	mróz	zimno	chłodno
tanio	mocno	mocno	średnio
średnio	mocno	średnio	slabo
drogo	średnio	slabo	wcale

$$R^{(1)} : \text{IF } (\text{Temperatura is mróz AND Cena_ogrz is tanio}) \\ \text{THEN } (\text{Grzać is mocno})$$



$$R^{(2)} : \text{IF } (\text{Temperatura is chłodno AND Cena_ogrz is drogo}) \\ \text{THEN } (\text{Grzać is wcale})$$

ROZMYWANIE (fuzyfikacja)

- Przejście od pomiarów (konkretna wartość) do funkcji przynależności przez określenie stopni przynależności zmiennych lingwistycznych do każdego ze zbiorów rozmytych.

Np.: • Temperatura: $T=15^\circ\text{C}$
• Cena ogrz: $p=48\text{zł/MBtu}$

$$R^{(3)} : \text{IF } (\text{Temperatura is chłodno AND Cena_ogrz is tanio}) \\ \text{THEN } (\text{Grzać is średnio})$$



Stopień spełnienia reguły dla wszystkich przesłanek:

$$\mu_{cale}(x) = \min\{\mu_{chłodno}(T), \mu_{tanio}(p)\} \\ = \min\{0.5, 0.3\} = 0.3$$


„poziom zapłonu reguły”

WNIOSKOWANIE

Obliczanie stopnia prawdziwości wniosku:

- Wnioskowanie MIN:


$$\mu_{wniosku} = \min\{\mu_{cale}, \mu_{średnio}\}$$



AGREGACJA

Jeżeli więcej niż jedna reguła ma niezerowy poziom zapłonu, wyniki (zbiory rozmyte) sumuje się.


THEN Grzać is slabo
THEN Grzać is średnio
THEN Grzać is mocno




WYOSTRZANIE (defuzyfikacja)

Jeżeli na wyjściu wymagana jest wartość liczbową, stosuje się jedną z metod wyostrania:


Metoda pierwszego maksimum:




Metoda środka maksimum:



Metoda środka ciężkości (COG):



Tu:



$$h = \frac{\sum \mu_i A_i c_i}{\sum \mu_i A_i}$$

A_i – powierzchnia zbioru i

μ_i – stopień przynależności do zbioru i

c_i – środek ciężkości zbioru i .



STEROWNIKI ROZMYTE TAKAGI-SUGENO



- Baza reguł sterownika ma charakter rozmyty tylko w części **IF**.
- W części **THEN** występują zależności funkcyjne.

Reguły Mamdaniego: wynikiem jest zbiór rozmyty B :

$$\text{IF } x_1=A_1 \text{ AND } x_2=A_2 \dots x_n=A_n \text{ THEN } y=B$$

Reguły Takagi-Sugeno: wynikiem jest funkcja $f(x_i)$:

$$\text{IF } x_1=A_1 \text{ AND } x_2=A_2 \dots x_n=A_n \text{ THEN } y=f(x_1, x_2, \dots, x_n)$$

Zwykle są to funkcje liniowe:


$$f(x_i) = y = a_0 + a_1 x_1 + a_n x_n$$



Np.: $R^{(1)}$: IF prędkość is niska THEN hamowanie = prędkość

$R^{(2)}$: IF prędkość is średnia THEN hamowanie = 4·prędkość

$R^{(3)}$: IF prędkość is wysoka THEN hamowanie = 8·prędkość



$$R^{(1)}: w_1 = 0.3; r_1 = 2$$

$$R^{(2)}: w_2 = 0.8; r_2 = 4 \cdot 2$$

$$R^{(3)}: w_3 = 0.1; r_3 = 8 \cdot 2$$

$$\text{Hamowanie} = \frac{\sum w_i \cdot r_i}{\sum w_i} = 7.12$$

Fuzzy Controller for Front-Load Washing Machine

[HHK-200 Series] [China]

Posted Date: January 31, 2007

Free Member | [Rate this company](#)

[Send Email](#)

[Add to Basket](#)

[Send Fax](#)

[View more pictures](#)

Description

Fuzzy Controller for Front-Load Washing Machine

Features:

- 1) Four Sensors:
 - Laundry Load
 - Cloth Material
 - Water Temperature
 - Dirty Degree of Cloth
- 2) Basic Functions: pre-wash, wash, rinse, spin, water-saving and anti-creases
- 3) Wash Programs: strong, normal, gentle and fast etc
- 4) Automatic Functions: heating, water and electricity saving, and anti clothes-twist
- 5) Variable Spin Speed
- 6) Preset Timer
- 7) LED/LCD/VFD Displays

