

# SID – Wykład 7

## Zbiory rozmyte

Dominik Ślęzak

Wydział Matematyki, Informatyki i Mechaniki UW  
slezak@mimuw.edu.pl



# Wstęp

Language	Ontological Commitment (What exists in the world)	Epistemological Commitment (What an agent believes about facts)
Propositional logic	facts	true/false/unknown
First-order logic	facts, objects, relations	true/false/unknown
Temporal logic	facts, objects, relations, times	true/false/unknown
Probability theory	facts	degree of belief 0..1
Fuzzy logic	degree of truth	degree of belief 0..1



# Wprowadzenie


Metoda reprezentacji wiedzy wyrażonej w języku naturalnym:

Temperatura wynosi  $29^{\circ}\text{C}$   $\longrightarrow$  Jest dość ciepło


informacja liczbowo – naturalna  
dla systemów komputerowych

informacja opisowa –  
naturalna dla człowieka

Zamiast dwóch wartości logicznych (prawda i fałsz), dopuszcza się istnienie nieskończenie wielu wartości (odpowiadających liczbom rzeczywistym od 0 do 1)




# Zbiór rozmyty



- $m_\alpha : X \rightarrow [0, 1]$  – funkcja przynależności zbioru rozmytego  $\alpha$  (uogólnienie funkcji charakterystycznych zbiorów klasycznych)
- dziedzina  $X \subseteq \mathbb{R}$  przyjmuje postać zbioru  $\mathbb{R}$ , przedziału  $[x, y] \subseteq \mathbb{R}$ , bądź  $\{x_1, \dots, x_n\} \subseteq \mathbb{R}$ , w zależności od natury zastosowania
- w tym ostatnim przypadku wygodnie jest reprezentować zbiór rozmyty  $\alpha$  jako tablicę  $\{(x_1, r_1), \dots, (x_n, r_n)\}$ , gdzie  $r_i = m_\alpha(x_i), i = 1, \dots, n$



# Zbiór rozmyty





Pojęcia "ciepło" czy "gorąco" są określone w sposób nieostry: trudno jednoznacznie określić ich granice, ich zakresy mogą się częściowo pokrywać.




# Funkcje przynależności

Funkcje mogą mieć kształt trapezu...




... trójkąta...

... ale też inny (np. sigmoidalny)...



... a zbiór  $X$  nie musi być zbiorem liczb rzeczywistych



# Reguły rozmyte

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

- Jeśli  $x$  jest **małe** i  $y$  jest **średnie**, to uruchom alarm
- Jeśli  $x$  jest **małe** i  $y$  jest **małe**, to ustaw  $z$  na **duże**
- Jeśli  $x$  jest **duże**, to ustaw  $z$  na **małe**

Reguły pochodzące od ekspertów zwykle wyrażone są w języku nieprecyzyjnym

Zbiory rozmyte pozwalają nam przełożyć ten język na konkretne wartości liczbowe



# Przykład

	Sun (%)	Temp. (°C)	Humid. (%)	Wind. (km/h)	Run (km/h)
1	100	31	90	10	6
2	90	22	85	50	8
3	50	25	95	20	12
4	0	15	80	0	13
5	10	4	70	10	15
6	30	7	55	40	7
7	40	8	65	60	15
8	70	14	90	20	10
9	80	1	70	30	14
10	20	13	60	0	14
11	80	11	60	70	14
12	60	17	80	50	13
13	50	26	55	30	16
14	20	12	95	60	9

Zbiory rozmyte pozwalają konstruować reguły typu.

jeśli temperatura jest wysoka i wilgotność jest niska, to sąsiad biega

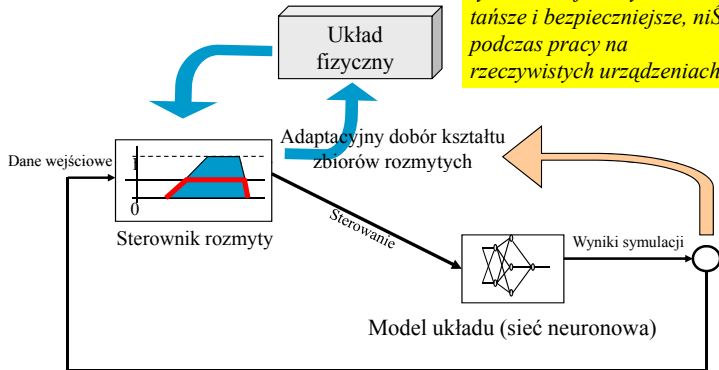
w języku naturalnym, przekładalne jednak na zależności numeryczne.





# Sterowanie

sieć neuronowa jako symulator  
procesu fizycznego



# Logika rozmyta – negacja

Niech  $\alpha$  będzie zbiorem rozmytym określonym na dziedzinie  $X \subseteq \mathbb{R}$

Negację zbioru  $\alpha$  definiujemy jako zbiór  $\neg\alpha$  o funkcji przynależności  $m_{\neg\alpha} : X \rightarrow [0, 1]$  określonej wzorem

$$m_{\neg\alpha}(x) = 1 - m_{\alpha}(x) \quad \forall x \in X$$

Przykładowo, dla zbioru  $\alpha$  określonego przez tablicę  $\{(3, 0.4), (5, 1), (7, 0.5), (9, 0)\}$ ,  
 $\neg\alpha$  to tablica  $\{(3, 0.6), (5, 0), (7, 0.5), (9, 1)\}$



# Logika rozmyta – koniunkcja

Niech  $\alpha, \beta$  będą zbiorami rozmytymi określonymi na dziedzinie  $X \subseteq \mathbb{R}$

Koniunkcję  $\alpha$  i  $\beta$  definiujemy jako zbiór rozmyty  $\alpha \wedge \beta$  o funkcji przynależności  $m_{\alpha \wedge \beta} : X \rightarrow [0, 1]$  określonej wzorem

$$m_{\alpha \wedge \beta}(x) = T(m_\alpha(x), m_\beta(x)) \quad \forall x \in X$$

Funkcja  $T : [0, 1]^2 \rightarrow [0, 1]$  jest T-normą



# Własności T-normy

- Warunki brzegowe:  
 $T(0, x) = 0$  oraz  $T(1, x) = 1$
- Monotoniczność:  
 $x \leq y \implies T(x, z) \leq T(y, z)$
- Symetria:  
 $T(x, y) = T(y, x)$
- Łączność:  
 $T(T(x, y), z) = T(x, T(y, z))$



# Przykładowe T-normy

- T-norma Zadeha:

$$T(r, s) = \min\{r, s\} \quad \forall r, s \in [0, 1]$$

- T-norma Mengera:

$$T(r, s) = r \cdot s \quad \forall r, s \in [0, 1]$$

- T-norma Łukaszczyka:

$$T(r, s) = \max\{0, r + s - 1\} \quad \forall r, s \in [0, 1]$$



# Przykładowe T-normy

Dla  $\alpha$  równego  $\{(3, 0.4), (5, 1), (7, 0.5), (9, 0)\}$   
oraz  $\beta$  równego  $\{(3, 0.6), (5, 0), (7, 0.5), (9, 1)\}$   
koniunkcja  $\alpha \wedge \beta$  odpowiada tablicom:

- Zadeh:  $\{(3, 0.4), (5, 0), (7, 0.5), (9, 0)\}$
- Menger:  $\{(3, 0.24), (5, 0), (7, 0.25), (9, 0)\}$
- Łukasiewicz:  $\{(3, 0), (5, 0), (7, 0), (9, 0)\}$



# Alternatywa jako ko-norma

- Warunki brzegowe:

$$C(0, x) = x \text{ oraz } C(1, x) = 1$$

- Monotoniczność:

$$x \leq y \implies C(x, z) \leq C(y, z)$$

- Symetria:

$$C(x, y) = C(y, x)$$

- Łączność:

$$C(C(x, y), z) = C(x, C(y, z))$$



# Dualność T-norm i ko-norm

- Alternatywa klasyczna:

$$\alpha \vee \beta \equiv \neg(\neg\alpha \wedge \neg\beta)$$

- Alternatywa rozmyta:

$$\begin{aligned} m_{\alpha \vee \beta}(x) &= m_{\neg(\neg\alpha \wedge \neg\beta)}(x) \\ &= 1 - \min\{m_{\neg\alpha}(x), m_{\neg\beta}(x)\} \\ &= 1 - \min\{1 - m_{\alpha}(x), 1 - m_{\beta}(x)\} \\ &= \max\{m_{\alpha}(x), m_{\beta}(x)\} \end{aligned}$$





# Uczenie się reguł rozmytych

Jakość danej reguły wyznaczamy na podstawie analizy wektorów uczących.

Niech  $\alpha, \beta, \gamma$  będą zbiorami rozmytymi o dziedzinach  $X, Y, Z \subseteq \mathbb{R}$

Niech  $(x, y, z) \in X \times Y \times Z$  będzie przykładowym wektorem uczącym.

Niech  $r, s, t \in [0, 1]$  oznaczają stopnie przynależności  $x, y, z$  do zbiorów  $\alpha, \beta, \gamma$ .



# Uczenie się reguł rozmytych

Prawdziwość reguły  $\alpha \wedge \beta \rightarrow \gamma$  dla stopni  $r, s, t \in [0, 1]$  otrzymamy przez ich podstawienie do wzoru na funkcję implikacji

$$F_{\alpha \wedge \beta \rightarrow \gamma} : [0, 1]^3 \rightarrow [0, 1]$$

Wzór ten można wyznaczyć zapisując  $\alpha \wedge \beta \rightarrow \gamma$  jako

$$\neg((\alpha \wedge \beta) \wedge \neg\gamma)$$

Jakość reguły możemy wyrazić jako jej średnią prawdziwość dla dostępnych wektorów uczących  $(x, y, z)$ .



# Stopnie prawdziwości implikacji

- Według T-normy Zadeha:

$$\max\{1 - r, 1 - s, t\} \quad \forall_{r,s,t \in [0,1]}$$

- Według T-normy Mengera:

$$r \cdot s \cdot t + (1 - r \cdot s) \quad \forall_{r,s,t \in [0,1]}$$

- Według T-normy Łukaszcwicza:

$$\min\{1, 2 + t - r - s\} \quad \forall_{r,s,t \in [0,1]}$$



# Wnioskowanie rozmyte

Chcemy wnioskować o stanach z  $Z$  na podstawie obserwacji  $x \in X, y \in Y$

Niech  $\alpha, \beta, \gamma$  będą zbiorami rozmytymi o dziedzinach  $X, Y, Z \subseteq \mathbb{R}$

Zastosowanie reguły rozmytej postaci

*IF  $\alpha$  AND  $\beta$  THEN  $\gamma$*

polega na wyliczeniu, jaki wpływ na  $m_\gamma : Z \rightarrow [0, 1]$  mają stopnie przynależności obserwacji  $x, y$  do zbiorów  $\alpha, \beta$



# Prawa wnioskowania

- Klasyczne prawo odrywania

$$\frac{\alpha \wedge \beta \quad \alpha \wedge \beta \implies \gamma}{\gamma}$$

można przepisać w silniejszej postaci

$$\frac{\alpha \wedge \beta \quad \alpha \wedge \beta \implies \gamma}{\alpha \wedge \beta \wedge \gamma}$$

- Ta druga postać lepiej odzwierciedla ideę wnioskowania rozmytego



# Wnioskowanie rozmyte

Założmy, że mamy do dyspozycji regułę

$$IF \alpha \text{ AND } \beta \text{ THEN } \gamma$$

Niech  $r, s$  oznaczają stopnie przynależności obserwacji  $x, y$  do  $\alpha, \beta$ .

Zgodnie z silniejszą wersją prawa odrywania, funkcja przynależności do  $\gamma$  dla danych  $x, y$  przyjmuje postać

$$m_{\alpha/x \wedge \beta/y \wedge \gamma}(z) = T(r, s, m_{\gamma}(z)) \quad \forall z \in Z$$



# Przykład

$$\alpha: \{(-2, 1), (0, 0.5), (2, 0)\} \quad x = 0$$

$$\beta: \{(-2, 0.3), (0, 1), (2, 0.3)\} \quad y = 2$$


$$\gamma: \{(-2, 0.1), (-1, 0.4), (0, 0.7), (1, 1), (2, 0.5)\}$$

- Z:  $\{(-2, 0.1), (-1, 0.3), (0, 0.3), (1, 0.3), (2, 0.3)\}$
- M:  $\{(-2, 0.015), (-1, 0.06), (0, 0.105), (1, 0.15), (2, 0.075)\}$
- Ł:  $\{(-2, 0), (-1, 0), (0, 0), (1, 0), (2, 0)\}$



# Uściślanie (Defuzyfikacja)

Znając wpływ obserwacji warunkowych na funkcję  $m_\gamma : Z \rightarrow [0, 1]$ , musimy obliczyć wartość  $z \in Z$ , która powinna być podana jako odpowiedź modułu wnioskującego.





# Przykład

$$\alpha: \{(-2, 1), (0, 0.5), (2, 0)\} \quad x = 0$$

$$\beta: \{(-2, 0.3), (0, 1), (2, 0.3)\} \quad y = 2$$

$$\gamma: \{(-2, 0.1), (-1, 0.4), (0, 0.7), (1, 1), (2, 0.5)\}$$

$$Z: \{(-2, 0.1), (-1, 0.3), (0, 0.3), (1, 0.3), (2, 0.3)\}$$

$$z = \frac{-2 \cdot 0.1 - 1 \cdot 0.3 + 0 \cdot 0.3 + 1 \cdot 0.3 + 2 \cdot 0.3}{0.1 + 0.3 + 0.3 + 0.3 + 0.3} = \frac{4}{13}$$



# Dziękuję za uwagę!

