

Logika rozmyta

Juliusz Chojenka, Paula Świerska, Wojciech Tejchman

Politechnika Krakowska



20.12.2016 r

Logika rozmyta: binarne członkostwo (należy (1), nie należy (0)) zostało rozszerzone na przedział liczb rzeczywistych $[0,1]$, gdzie punkty końcowe oznaczają pełną należność i nie należność.

Nieskończona ilość wartości między ptk. końcowymi reprezentuje stopień przynależności elementu x w jakimś zbiorze świata X .

Zbiory rozmyte: zbiory z „przestrzeni” X , które mogą określić stopień członkostwa.

Przykład binarny: możemy rozpoznawać temperaturę powyżej 25°C jako gorącą (1), natomiast poniżej jako zimną (0).

Przykład logiki rozmytej:

$T \leq 0^{\circ}\text{C}$ → bardzo zimno

$0^{\circ}\text{C} \leq T \leq 18^{\circ}\text{C}$ → trochę zimno

$18^{\circ}\text{C} \leq T \leq 25^{\circ}\text{C}$ → idealnie

$25^{\circ}\text{C} \leq T \leq 30^{\circ}\text{C}$ → trochę gorąco

$T \geq 30^{\circ}\text{C}$ → Sahara

Zbiór rozmyty \tilde{F} na X wyraża się jako:

$$\mu_{\tilde{F}}(x) : X \rightarrow [0, \alpha]$$

gdzie $\mu_{\tilde{F}}(x)$ jest **funkcją przynależności**.

Przykład: samochód powinien utrzymywać zadaną prędkość d .
Stopień bliskości do zadanej prędkości opisuje funkcja przynależności:

$$\mu_{\tilde{F}}(x) = \exp\left(-\frac{(x-d)^2}{2d}\right)$$

Zbiór rozmyty szybkości:

$$\tilde{S} = \{(x, \mu_{\tilde{S}}(x)) \mid x \in [0, 200]\}$$

Przecięcie zbiorów rozmytych:

$$\begin{aligned}\tilde{C} &= \tilde{A} \cap \tilde{B} \\ \mu_{\tilde{C}}(x) &= \min\{\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x)\}\end{aligned}$$

Suma zbiorów rozmytych:

$$\begin{aligned}\tilde{C} &= \tilde{A} \cup \tilde{B} \\ \mu_{\tilde{C}}(x) &= \max\{\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x)\}\end{aligned}$$

Dopełnienie zbiorów rozmytych:

$$\begin{aligned}\tilde{C} &\not\subseteq \tilde{A} \\ \mu_{\tilde{C}}(x) &= \mu_{\not\subseteq \tilde{A}}(x) = 1 - \mu_{\tilde{A}}(x)\end{aligned}$$

Pojęcia rozmyte

duży, mały, bliski, większy, mniejszy

Założmy, że zysk na pewnym produkcie należy do zbioru wartości od 0% do 100%

Duży: wartość 1 otrzymujemy dla 100%, 0 dla 0%.

$$\mu_{\tilde{L}}(x) = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Mały: wartość 1 otrzymujemy dla 0%, 0 dla 100%.

$$\mu_{\tilde{S}}(x) = \frac{x - x_{max}}{x_{min} - x_{max}}$$

Założmy, że zysk na pewnym produkcie wynosi około $p = 40\%$.

$$\mu_{\tilde{N}}(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(\frac{-(x-p)^2}{2\sigma^2}\right)$$

gdzie $\sigma = 0,1(x_{max} - x_{min})$

Pojęcia rozmyte

duży, mały, bliski, większy, mniejszy

Założmy, że zysk na pewnym produkcie będzie większy niż $p = 40\%$.

$$\mu_{\tilde{G}(x)} = [1 + \exp(\frac{-(x-p)}{2\lambda})]^{-1}$$

gdzie $\lambda = 0,1(x_{max} - x_{min})$

Linguistic hedge: zwiększenie lub zmniejszenie wartości przynależności do zbioru.

Przykład:

Stopień przynależności dla temperatur $T \in [0^\circ C, 40^\circ C]$

$T^\circ C$	0	5	10	15	20	25	30	35	40
$\mu_{\tilde{H}(T)}$	0	0.125	0.25	0.375	0.5	0.625	0.75	0.825	1

Stopień przynależności dla temperatur $T \in [0^\circ C, 40^\circ C]$ dla bardzo gorących

$T^\circ C$	0	5	10	15	20	25	30	35	40
$\mu_{\tilde{H}(T)}$	0	0.016	0.063	0.141	0.25	0.391	0.563	0.681	1

Zastosowanie: przetwarzanie sygnałów, robotyka, inteligentna kontrola procesu technologicznego, systemy ekspertowe, przetwarzanie obrazów, **teoria podejmowania decyzji**, analiza skupień oraz różne metody poznawania takie jak: algorytmy genetyczne i wnioskowanie indukcyjne.

Przykład z teorii podejmowania decyzji: wybór ceny sprzedaży wyrobów ręcznych.