

Zbiory rozmyte





logika rozmyta

Logika rozmyta i reguły rozmyte


- Informacja którą przetwarzają ludzie często (zawsze) jest nieprecyzyjna, a mimo to potrafimy poprawnie wnioskować!
- Np. Jeśli przeszkoda jest *blisko* to przyhamuj
- Co to znaczy „blisko”, jaką to ma wartość?
- Co to znaczy „przyhamuj” jak bardzo mam nacisnąć na hamulec?
- „Gdzie kucharek sześć tam nie ma co jeść” - Ilu ekspertów tyle pomysłów na rozwiązanie problemu
- Rozwiązanie „Fuzzy Set Theory” L. Zadeh (1965)

Przykład.

Przy jakiej temperaturze mamy gorączkę?



Reguła rozmyta



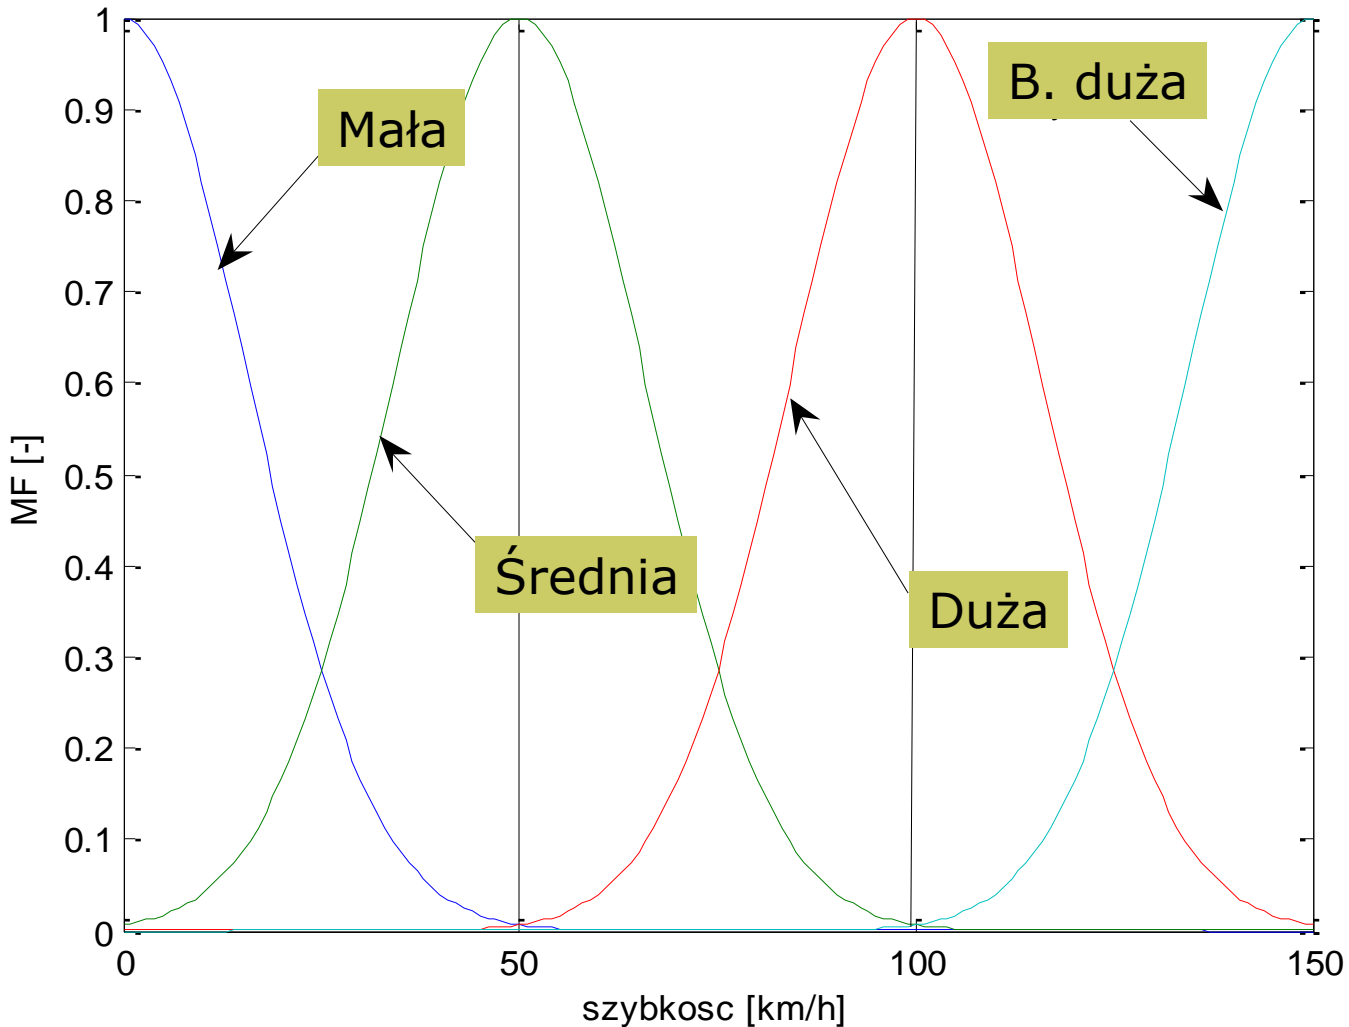
Podstawy + historia

- 1965 rok prof. **Lotofil Zadeh** publikuje „Fuzzy sets”
- Zbiory rozmyte próbują **naśladować sposób rozumienia i postrzegania ludzi** np. jechać szybko, duże drzewo (informacja nieprecyzyjna) – problemy w implementacji w maszynach cyfrowych
- Rozwiązanie - wprowadzenie funkcji opisującej **stopień przynależności elementu do zbioru** (tradycyjny rachunek zbiorów zakłada dwuwartościowy stopień przynależności: 0-nie należy; 1-przynależy do zbioru)
- Główne zastosowanie: sterowanie, wnioskowanie oraz systemy wspomagające podejmowanie decyzji
- Rozwinięcie teorii zbiorów rozmytych -> logika rozmyta – rozwinięcie logiki (L_N) Łukasiewicza

Podstawowe pojęcia

- ❑ **Zmienna lingwistyczna** – wielkość wejściowa, wyjściowa, zmienna stanu. Nazwa zmiennej przyjmująca wartości lingwistyczne. Przykłady: „prędkość”, „ciśnienie”, „wiek”
- ❑ **Wartość lingwistyczna** – jest to słowny opis wartości jakie przyjmuje zmienna lingwistyczna. Przykład: „szybko”, „wolno”, „duże”, „małe”, „stary”, „młody”
- ❑ **Przestrzeń numeryczna zmiennej** – zbiór wartości numerycznych, jaki może przyjąć dana zmienna lingwistyczna
- ❑ **Funkcja przynależności** – funkcja opisująca parametr, stopień w jakim dany punkt należy do danego zbioru

Wartość lingwistyczna, przestrzeń numeryczna zmiennej i funkcja przynależności



Definicje

Zbiór rozmyty – zbiór **A** w niepustej przestrzeni **X** definiowany przez pary:

$$A = \{(x, \mu_A(x)) : x \in X\}$$

Gdzie μ_A – funkcja przynależności definiowana jako: $\mu_A : X \rightarrow [0,1]$

Funkcja przynależności przyporządkowuje każdemu elementowi ze zbioru A wartość z przedziału $[0,1]$, określającą stopień przynależności tego elementu do zbioru A . W odróżnieniu od klasycznego podejścia do teorii zbiorów, gdzie mówiliśmy o funkcji opisującej przyjmującej dwie wartości $\{0,1\}$, w zbiorach rozmytych wyróżniamy trzy przypadki:

$\mu_A(x) = 1$ – pełna przynależność do zbioru rozmytego A ,

$\mu_A(x) = 0$ – brak przynależności elementu x do zbioru rozmytego A ,

$0 < \mu_A(x) < 1$ – częściowa przynależność elementu x do zbioru rozmytego A

Metody zapisu

Zbiór A w przestrzeni X o skończonej liczbie n elementów x przedstawia się następująco:

$$A = \sum_{i=1}^n \frac{\mu_A(x_i)}{x_i}$$

przy czym znak Σ oznacza sumę mnogościową, a operator dzielenia należy traktować jako przyporządkowanie elementowi x_i odpowiadającej mu wartości funkcji przynależności

W przestrzeni o nieskończonej liczbie elementów powyższy zapis przyjmuje postać:


$$A = \int_{\mathbb{X}} \frac{\mu_A}{x}$$

Inną często spotykaną formą zapisu zbioru rozmytego jest zapis skrócony

$$A = \{ \mu_A(x) / x : x \in \mathbb{X} \}$$


Podstawowe zbiory przynależności

- dowolny kształt
- trójkątna funkcja przynależności:



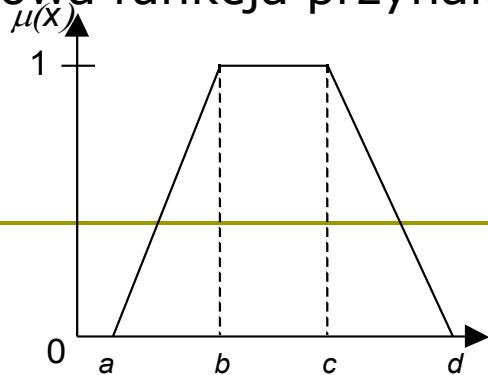
$$\mu_A(x; s, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b < x \leq c \\ 0, & c < x \end{cases}$$

- Gaussowska funkcja przynależności:





$$\mu_A(x; c, a) = \exp\left(-\frac{1}{2}\left(\frac{x-c}{a}\right)^2\right)$$

■ trapezowa funkcja przynależności:




$$\mu_A(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ 1, & b < x \leq c \\ \frac{d-x}{d-c}, & c < x \leq d \\ 0, & d < x \end{cases}$$

■ sigmoidalna funkcja przynależności:




$$\mu_A(x; a, b) = \frac{1}{1 + \exp(-a(x - b))}$$

■ funkcja przynależności klasy S:




$$\mu_A(x; a, b, c) = \begin{cases} 0, & x \geq c \\ 1 - 2\left(\frac{x-c}{c-a}\right)^2, & c > x \geq b \\ 2\left(\frac{x-a}{c-a}\right)^2, & b > x \geq a \\ 1, & x < a \end{cases}; \text{ gdzie } b = \frac{a+c}{2}$$

- funkcja przynależności klasy Z:



$$\mu_A(x; a, b, c) = \begin{cases} 0, & x \geq a \\ 2\left(\frac{x-a}{c-a}\right)^2, & a > x \geq b \\ 1 - 2\left(\frac{x-c}{c-a}\right)^2, & b > x \geq c \\ 1, & x < c \end{cases} ; \text{ gdzie } b = \frac{a+c}{2}$$

- Singleton (wartość ostra):



$$\mu_A(x; x') = \begin{cases} 1, & x = x' \\ 0, & x \neq x' \end{cases}$$

Pojęcia c.d.

▣ **Nośnik zbioru** – jest to zbiór elementów przestrzeni X , dla których funkcja przynależności przyjmuje wartości dodatnie.

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

▣ **Wysokość zbioru** – definiowana jako maksymalna wartość funkcji $\mu_A(x)$

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


Jeśli $h(A)=1$, mówimy wówczas o zbiorze normalnym - w przeciwnym przypadku zbiór rozmyty możemy poddać normalizacji w postaci: $\frac{\mu_A(x)}{h(A)}$

▣ **Zbiór pusty** – to taki zbiór dla którego $\forall_{x \in X} \mu_A(x) = 0$

▣ **Równość zbiorów rozmytych** – Zbiór rozmyty A równy jest zbiorowi rozmytemu B , $A=B$ gdy spełniona jest zależność

$$\forall_{x \in X} \mu_A(x) = \mu_B(x)$$


- **Zawieranie się zbiorów rozmytych** – Zbiór rozmyty A zawiera się w zbiorze rozmytym B , $A \subset B$ gdy



$$\forall_{x \in X} \mu_{A(x)} \leq \mu_B(x)$$

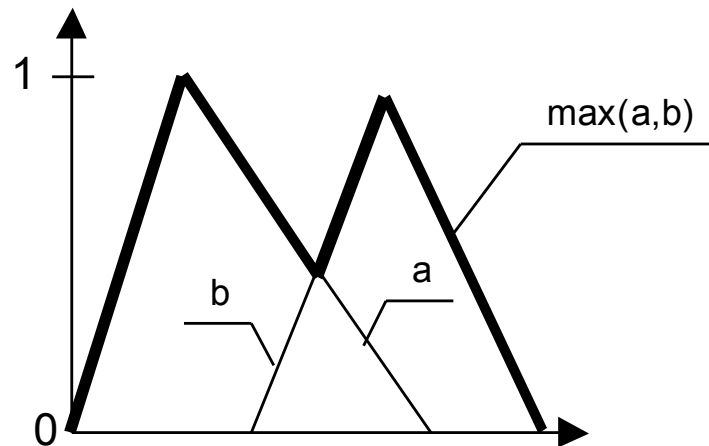
- **Przecięcie zbiorów rozmytych** – W literaturze istnieje wiele definicji przecięcia (iloczynu) zbiorów rozmytych. Noszą one wspólną nazwę T-norm. Iloczyn logiczny zbiorów rozmytych oznacza się $A *_T B$. Najprostszą i najczęściej stosowaną definicją przecięcia zbiorów A i $B \subseteq X$ jest:

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



- **Suma zbiorów rozmytych** – Podobnie jak iloczyn tak i suma zbiorów rozmytych (S-norma) A i $B \subseteq X$ została zdefiniowana na różne sposoby. Sumę zbiorów rozmytych oznaczamy jako $A *_S B$, najprostszym jej przedstawicielem jest operacja maksimum:

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



T – normy

T-norma powinna spełniać warunki:

1. $T(x,1)=x$; $T(x,0)=0$ (Tożsamość jedynek, zerowanie)
2. $T(x,y)=T(y,x)$ (Przemienność)
3. $x \leq u \rightarrow T(x,y) \leq T(u,y)$ (monotoniczność)
 $y \leq r \rightarrow T(x,y) \leq T(x,r)$
4. $T(x,T(y,z))=T(T(x,y),z)$ (Łączność)

Przykłady najczęściej stosowanych T-norm:

Zadeha:

$$\min(x,y)$$

Algebraiczna:

$$x * y$$

Łukasiewicza:

$$\max(x+y-1,0)$$

Fodora:

$$\begin{cases} \min(x, y), & x + y > 1 \\ 0, & x + y \leq 1 \end{cases}$$

Drastyczna:

$$\begin{cases} \min(x, y), & \max(x, y) = 1 \\ 0, & \max(x, y) \neq 1 \end{cases}$$

Einstaina:

$$\frac{x \cdot y}{2 - (x + y - x \cdot y)}$$

S - normy

T-norma powinna spełniać warunki:

1. $S(x,1)=1; S(x,0)=x$
2. $S(x,y)=S(y,x)$
3. $x \leq u \rightarrow S(x,y) \leq S(u,y)$
 $y \leq r \rightarrow S(x,y) \leq S(x,r)$
4. $S(x,S(y,z))=S(S(x,y),z)$

Przykłady najczęściej stosowanych S-norm:

Zadeha: $\max(x,y)$

Algebraiczna: $x+y-x*y$

Łukasiewicza: $\min(x+y,1)$

Fodora:
$$\begin{cases} \max(x, y), & x + y < 1 \\ 1, & x + y \geq 1 \end{cases}$$

Drastyczna:
$$\begin{cases} \max(x, y), & \min(x, y) = 0 \\ 1, & \min(x, y) \neq 0 \end{cases}$$


Einstaina
$$\frac{x+y}{1+x \cdot y}$$

Wnioskowanie i reguły rozmyte




Systemy rozmyte

„Czysty” system rozmyty:



System rozmyty z blokami rozmywania i wyostrzania



Reguła rozmyta


Jeżeli „X jest A” to „Y jest B”

Jeżeli zmienna lingwistyczna X przyjmuje wartość lingwistyczna A to zmienna lingwistyczna Y przyjmuje wartość B

Np. Jeżeli szybkość jest duża to opór jest duży.

Implikacja rozmyta $\rightarrow \min(\mu_A, \mu_B)$

jeżeli x jest



Metody wnioskowania

- Reguła odrywania (modus ponendo ponens)

Modus – sposób

Pono – twierdzenie (wnioskowanie stwierdzające przez stwierdzenie)

Ponens – stwierdzenie

Jeżeli prawdziwe jest zdanie p i implikacja $p \rightarrow q$ to prawdziwe jest zdanie q

$$[p \wedge (p \rightarrow q)] \rightarrow q$$

- Wnioskowanie stwierdzające przez zaprzeczenie (modus tollendo ponens)

Tollendo – usunąć

$$\neg p = \text{nie } p \quad [\neg p \wedge (p \rightarrow q)] \rightarrow q$$

- Wnioskowanie zaprzeczające przez stwierdzenie (modus ponendo tollens)

$$[p \wedge (p \rightarrow \neg q)] \rightarrow \neg q$$

- Modus tollendo tollens

Jeżeli prawdziwe są zdania $\neg q$ i implikacja $p \rightarrow q$ to prawdziwe jest zdanie $\neg p$

$$[\neg q \wedge (p \rightarrow q)] \rightarrow \neg p \quad [\neg q \wedge (q \rightarrow p)] \rightarrow \neg p$$

- Zasada rozkładu

$$\neg p \rightarrow q$$

$$p \rightarrow r$$

$$\frac{\quad}{\neg r \rightarrow q \text{ lub } \neg q \rightarrow r}$$

Implikacje rozmyte

Jeżeli x jest A to y jest B

- Implikacja Mamdaniego:

$$u_{A \rightarrow B} = u_A(x) \wedge u_B(y) = \min(u_A(x), u_B(y))$$

- Implikacja Larsena

$$u_{A \rightarrow B} = u_A(x) u_B(y)$$

- Implikacja Lukasiewicza

$$u_{A \rightarrow B} = \min(1, 1 - u_A(x) + u_B(y))$$

- Implikacja Kleene-Dienesa

$$u_{A \rightarrow B} = \max(1 - u_A(x), u_B(y))$$

- Implikacja Zadeha

$$u_{A \rightarrow B} = \max(\min(u_A(x), u_B(y)), 1 - u_A(x))$$

- Implikacja probabilistyczna

$$u_{A \rightarrow B} = \min(1, 1 - u_A(x) + u_A(x) u_B(y))$$

- Implikacja Goguena

$$u_{A \rightarrow B} = \min(1, u_B(y) / u_A(x))$$

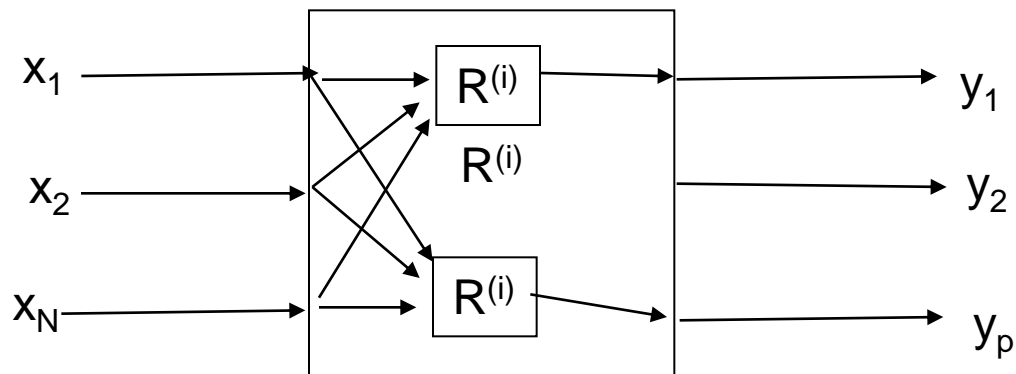
Ogólna postać reguł jeźeli – to dla system MIMO

R^1 : jeźeli (x_1 jest A_1^1) i (x_2 jest A_2^1) i ... i (x_3 jest A_n^1) to

(y_1 jest B_1^1) i (y_2 jest B_2^1) i...i (y_m jest B_p^1)

R^i : jeźeli (x_1 jest A_1^i) i (x_2 jest A_2^i) i ... i (x_3 jest A_n^i) to

(y_1 jest B_1^i) i (y_2 jest B_2^i) i...i (y_m jest B_p^i)



Kanoniczna postać reguł

□ Postać ogólna reguły z MISO

R: jeżeli $((x_1 \text{ jest } A_1^1) \text{ i } (x_2 \text{ jest } A_2^1))$ lub
 $((x_1 \text{ jest } A_1^2) \text{ i } (x_2 \text{ jest } A_2^2))$
to $(y_1 \text{ jest } B_1)$

□ Postać kanoniczna

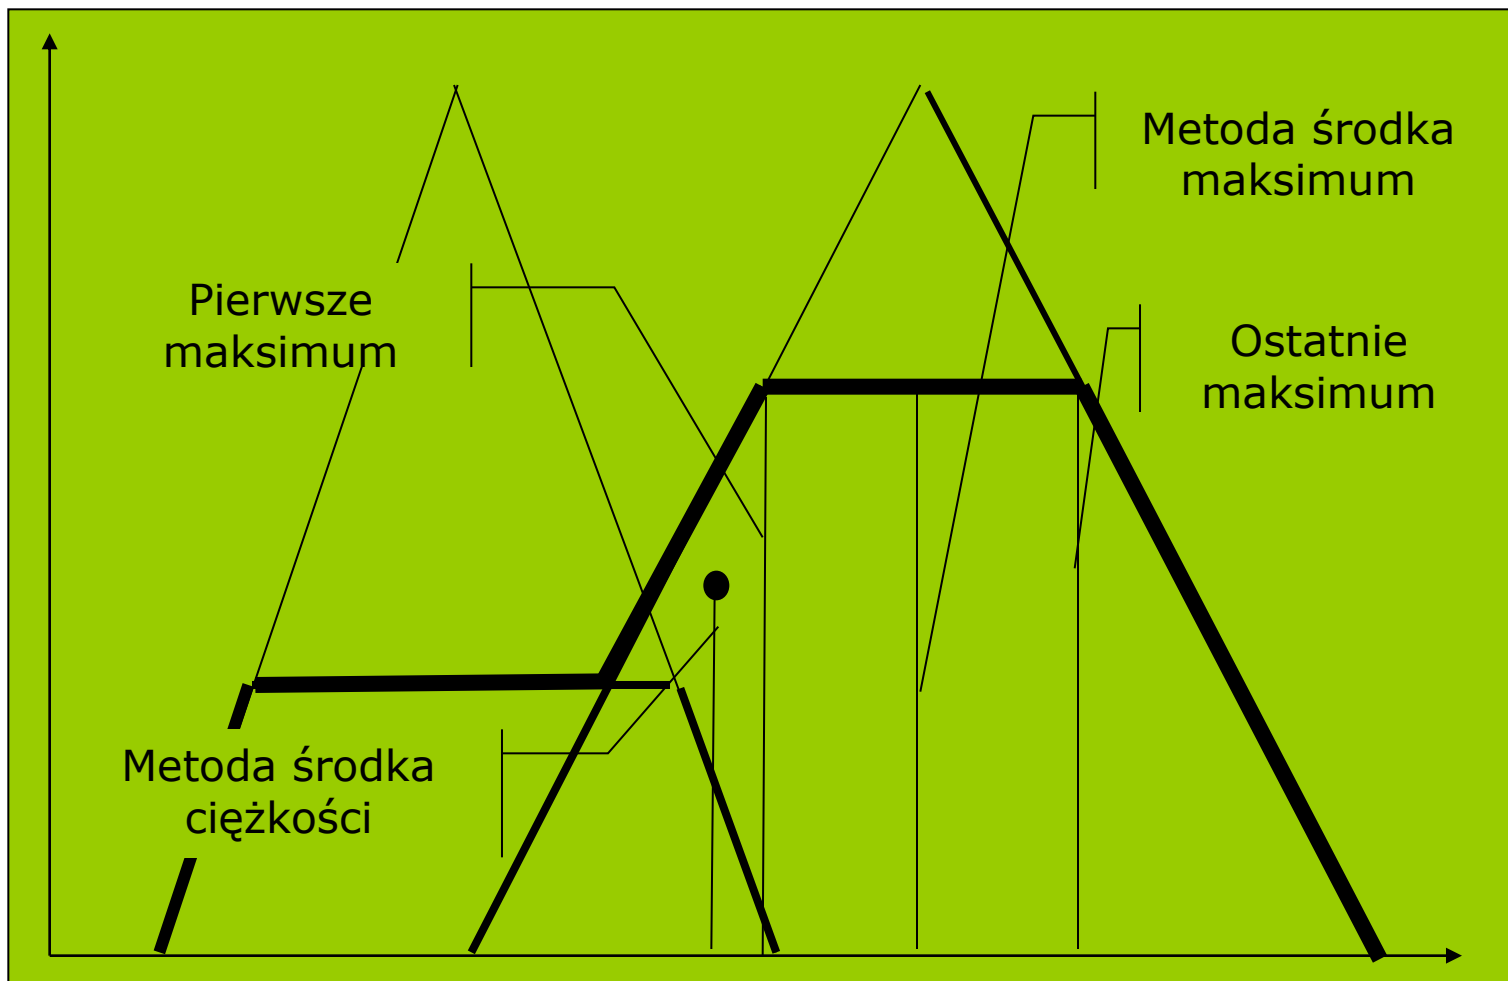
R^1 : jeżeli $(x_1 \text{ jest } A_1^1) \text{ i } (x_2 \text{ jest } A_2^1)$
to $(y_1 \text{ jest } B_1)$

R^2 : jeżeli $(x_1 \text{ jest } A_1^2) \text{ i } (x_2 \text{ jest } A_2^2)$
to $(y_1 \text{ jest } B_1)$

Metody defazyfikacji

- metoda środków maksimum
- metoda pierwszego maksimum
- metoda ostatniego maksimum
- metoda środków ciężkości

$$y_C = \frac{\int y \cdot \mu_{wyn}(y) dy}{\int \mu_{wyn}(y) dy}$$



Modele rozmyte

Rodzaje modeli rozmytych

- Model Mamdaniego

JEŻELI (*x około A*) TO (*y około B*)

- Model Takagi-Sugeno


JEŻELI (*x około A*) TO $y=f(x)$

- Modele relacyjne

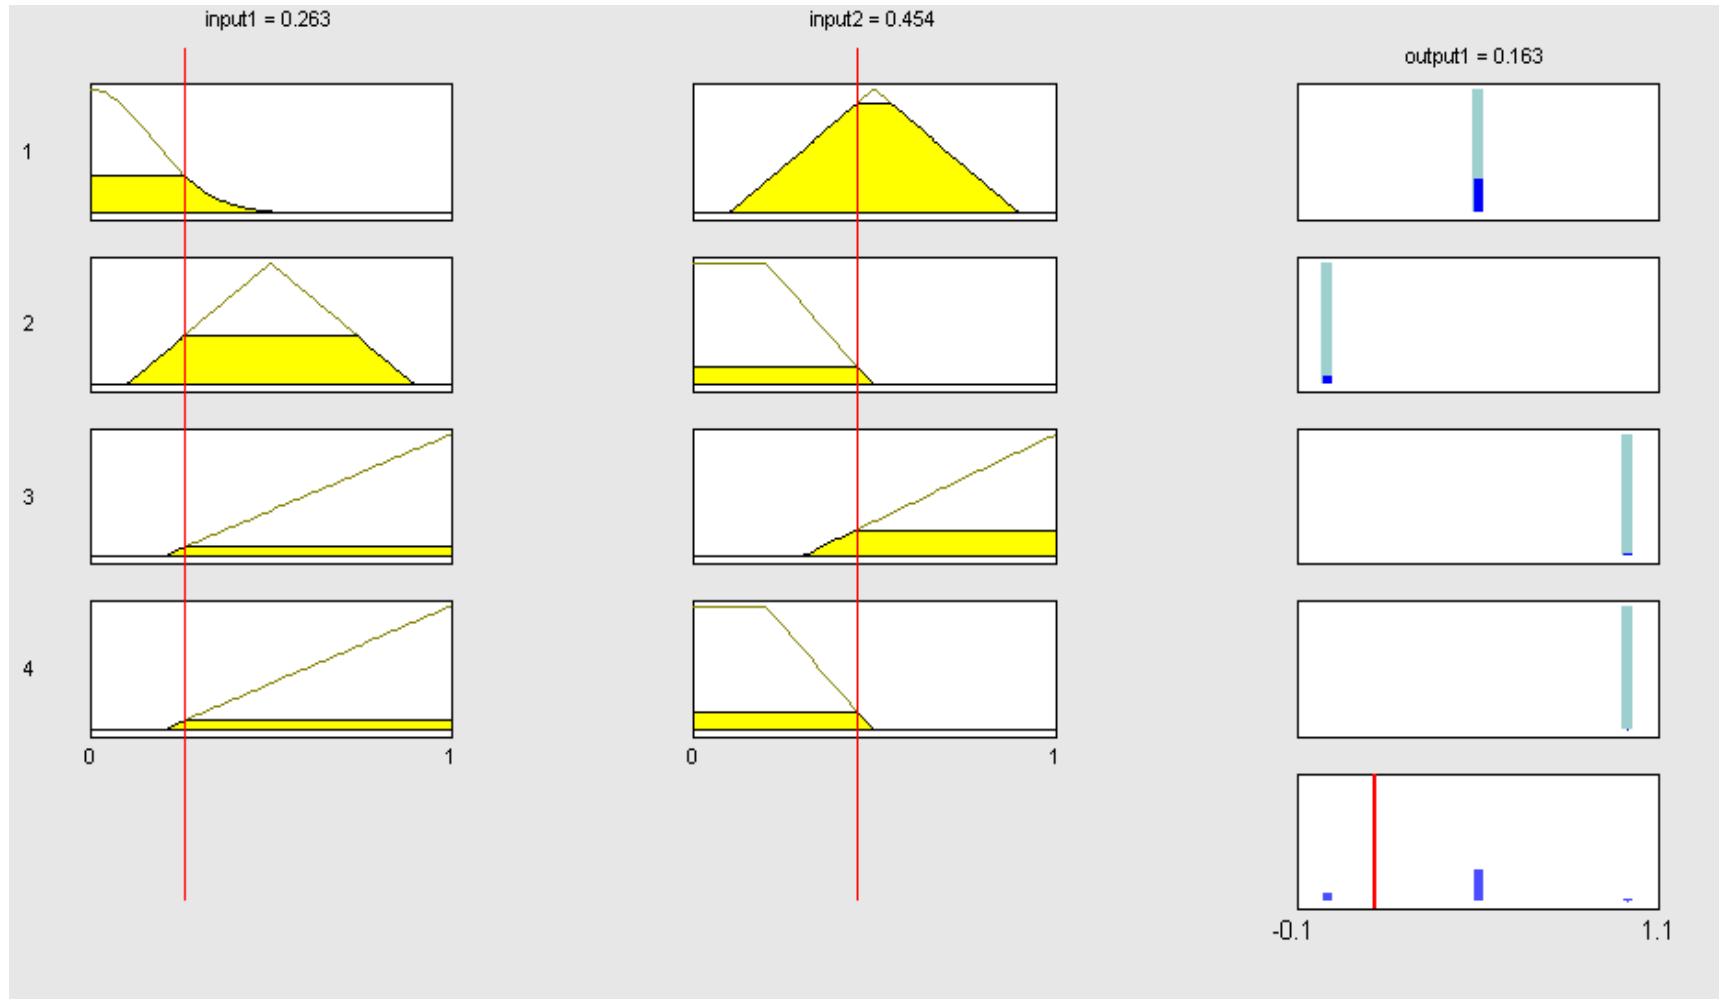
wykorzystują rozmyty rachunek relacji

- inne

Przykład modelu Mamdaniego



Przykład modelu Takagi-Sugeno



Uczenie modeli rozmytych

□ Ręcznie korzystając z wiedzy eksperta

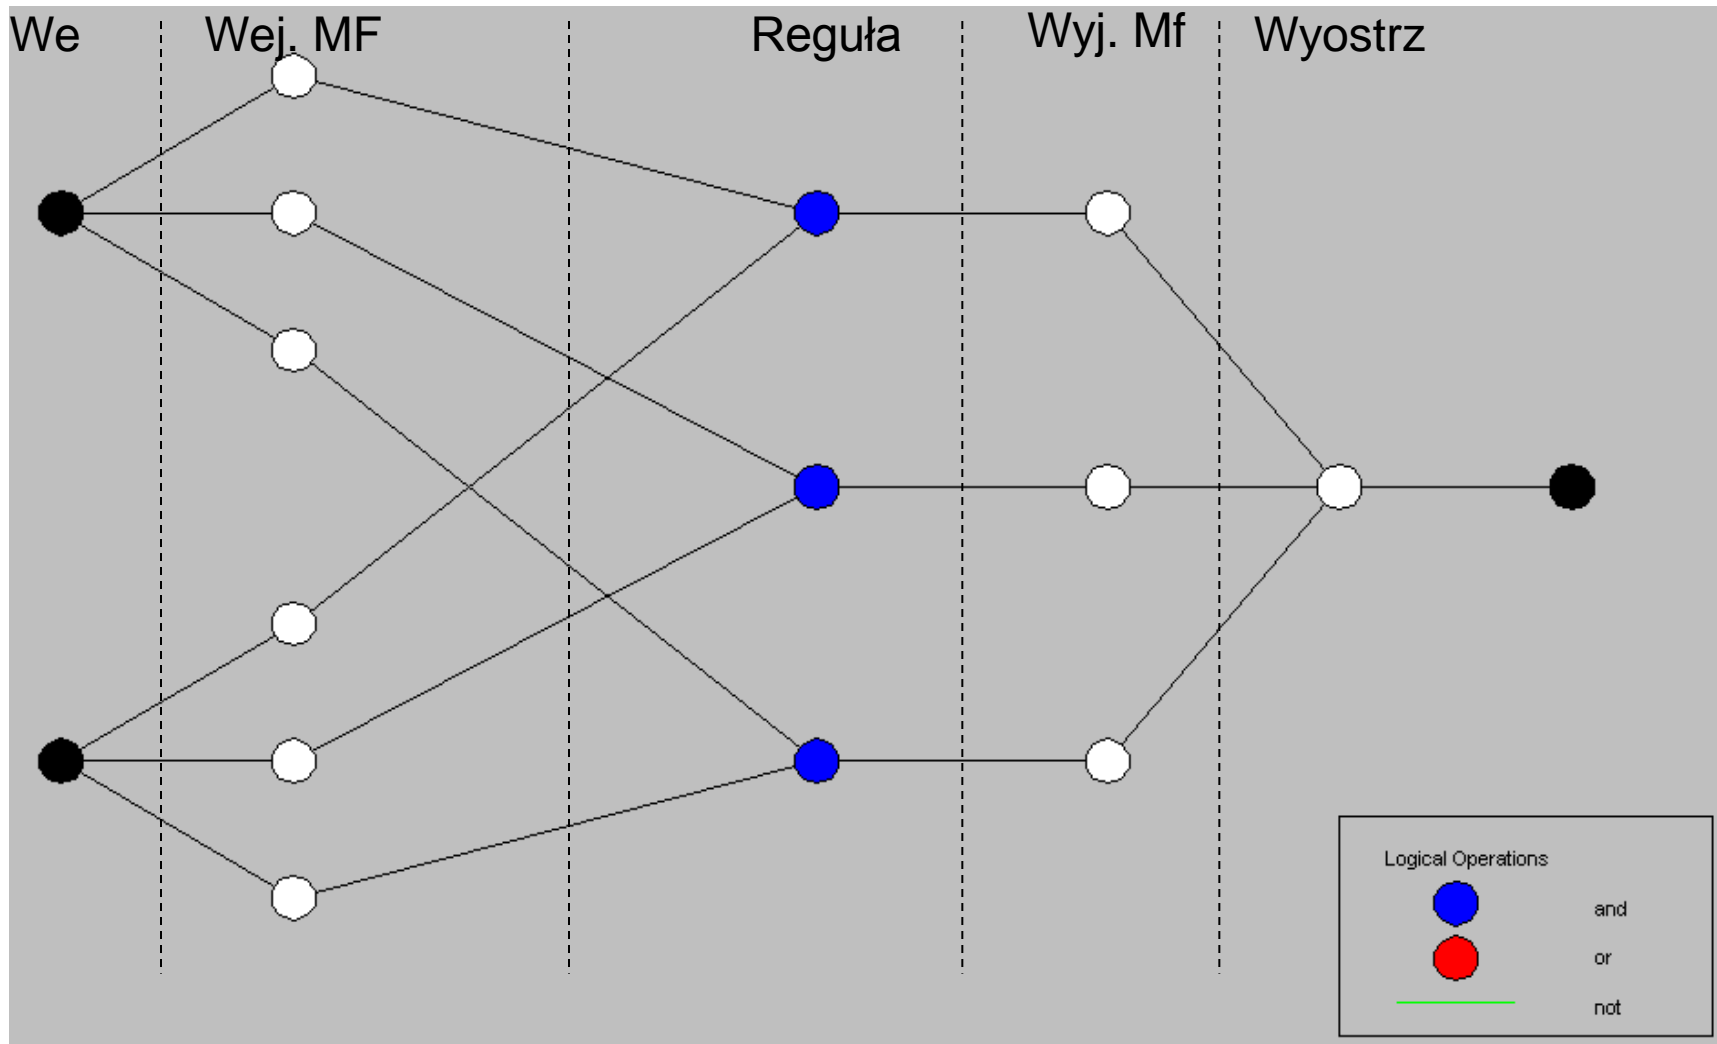
Problem -> Transformacja wiedzy eksperta na odpowiednie funkcje przynależności

□ Uczenie na podstawie danych

□ Systemy neurorozmyte -> transformacja (interpretacja) reguł systemu rozmytego do postaci neuronowej

- Gradientowe metody uczenia (jak RBF)
- Algorytmy genetyczne i ewolucyjne (dobór operatorów)
- Uczenie w oparciu o algorytm samoorganizacji
- Klasteryzację
- Algorytm ARTMAP

Struktura warstwowa systemu neurorozmyte



Klasyfikatory Rozmyte

Brak spójnej interpretacji (L. Kunchewa)

- „A fuzzy classifier is any classifier which uses fuzzy sets either during its training or during its operation”
- „A fuzzy or possibilistic classifier, is any possibilistic classifier for which „


$$\sum_{i=1}^c \mu_i(x) = 1$$

- „A fuzzy classifier is a fuzzy if-then inference system (a fuzzy rules based system) which yields a class label (crisp or soft) for x ”


Po co rozmywać?

- Jedni wolą logikę (nawet rozmytą) inni rozkłady prawdopodobieństwa
- Sterowanie w warunkach niepewnych
- Analiza i przetwarzanie języka naturalnego
- Możliwość budowy reguł w oparciu o lingwistyczną wiedzę eksperta
- Większa elastyczność reguł rozmytych
- Niedokładność danych – zbiory rozmyte drugiego rzędu


Logika rozmyta czy klasyczna?



Logika rozmyta czy klasyczna?




Logika rozmyta czy klasyczna?



If $x_1 < -1$ then B
elseif $x_2 > 1$ then R
elseif $x_1 < 0$ then B
elseif $x_2 > 0$ then R
elseif $x_1 < 1$ then B
elseif $x_2 > -1$ then R
elseif $x_1 < 2$ B
else R

Przykład




if (x_1 około -1)
& (x_2 około -1)
then raczej B

if (x_1 około 1)
& (x_2 około 1)
then raczej R

Zbiory rozmyte II rodzaju

- Rozmywanie zbiorów rozmytych 😊



Prezentacja - Matlab

Literatura

1. Piegat A. Modelowanie i sterowanie rozmyte, AOW Exit, Warszawa 2003
2. Łachwa A. Rozmyty świat zbiorów, liczb, relacji, faktów, reguł i decyzji. AOW Exit, Warszawa 2001
3. Ossowski S. Sieci neuronowe w ujęciu algorytmicznym, WNT Warszawa 1996
4. Kuncheva L. Fuzzy Classifier Design, Studies in Fuzziness and Soft Computing, Physica-Verlag, 2000
5. Nauck D., Klawonn F., Kruse R. Foundations on Neuro-Fuzzy Systems. Wiley, Chichester, 1997.

Pytania?

