Zbiory rozmyte, liczby rozmyte, logika rozmyta

Modelowanie niepewności

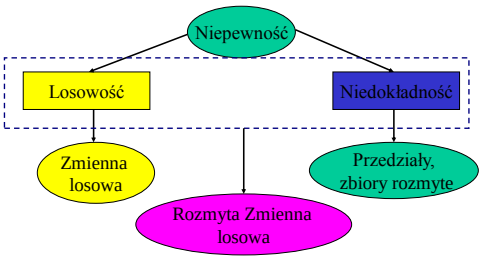

Rodzaje niepewności

- Niepewność stochastyczna:
  Np. rzut kostką, wypadek, ryzyko ubezpieczenia - rachunek prawdop.
- Niepewność pomiarowa
  Około 3 cm; 20 punktów - statystyka.
- Niepewność informacyjna:
  Wiarygodny kredytobiorca, spełniający warunki - data mining.
- Niepewność lingwistyczna
  Np. mały, szybki, niska cena - logika rozmyta

Logika rozmyta i klasyczna

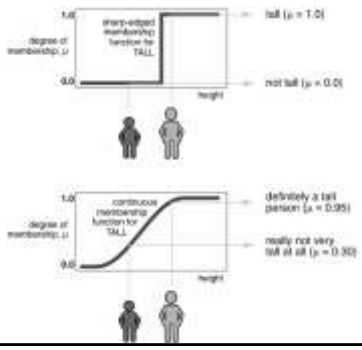

Przykład zbioru klasycznego

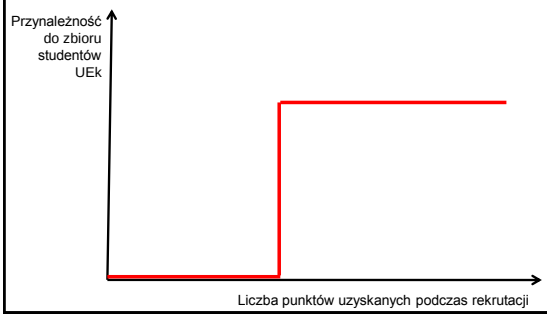

Przykład zbioru rozmytego

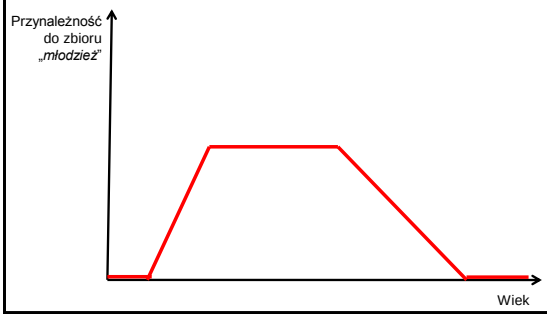

ZBIORY ROZMYTE

Zbiorem rozmytym A, określonym na przestrzeni X jest zbiór uporządkowanych par:

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

gdzie μ_A jest funkcją przynależności (funkcją charakterystyczną) zbioru A.

$$\mu_A \in \langle 0,1 \rangle$$

Zbiory klasyczne

młody = { $x \in M$ | wiek(x) ≤ 20 }

Funkcja charakterystyczna

$$\mu_{\text{młody}}(x) = \begin{cases} 1 : \text{wiek}(x) \le 20 \\ 0 : \text{wiek}(x) > 20 \end{cases}$$

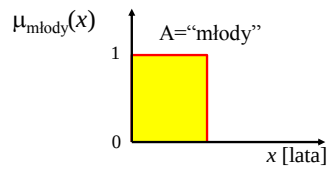

Przykłady

Klasyczne i rozmyte pojęcie „młody człowiek"

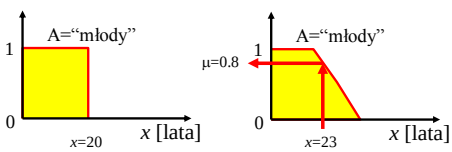

„Temperatura wrzenia" ma wartość około 100 stopni (ciśnienie, skład chemiczny).

$$\mu_w(T) = e^{-2(T-100)^2}$$

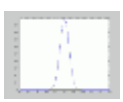

ZBIORY ROZMYTE I FUNKCJA PRZYNALEŻNOŚCI

$\{(x, \mu_A(x)) : x \subset X\}$

Zbiór rozmyty

$\mu_A : X \to \Re$

Funkcja przynależności A

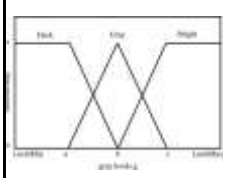

Inny przykład zbiorów rozmytych.

Na rysunku pokazano przykładowy przebieg funkcji przynależności dla trzech zbiorów rozmytych:

- **mała liczba**
- **średnia liczba**
- **duża liczba**

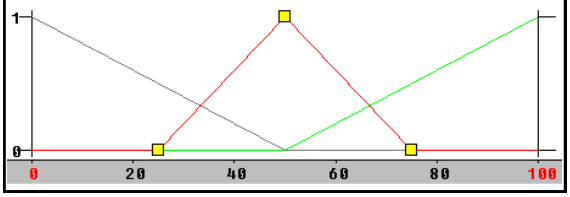

ROZMYWANIE - *FUZZIFICATION*

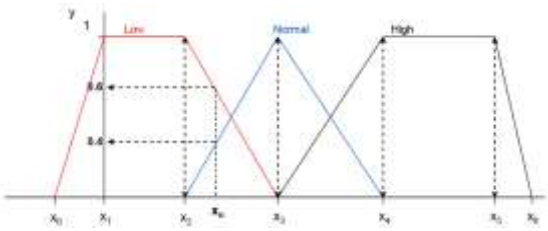

Nośnik zboru rozmytego i jego jądro

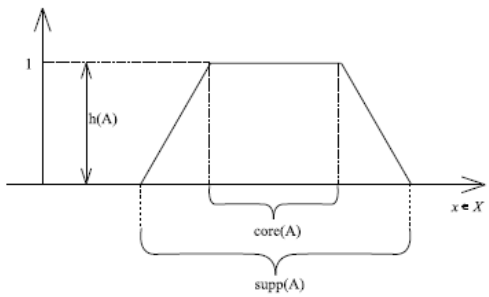

OPERATORY LOGIKI ROZMYTEJ

zbiory rozmyte

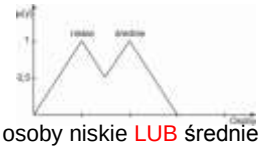

osoby niskie LUB średnie

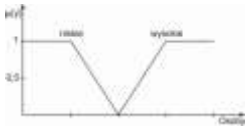

osoby NIE średnie

osoby średnie I wysokie

Rozmyta relacja

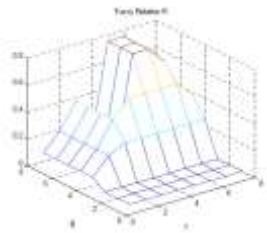

Jeszcze jeden przykład

Liczby rzeczywiste znacznie większe od 10

$$\tilde{A} = \{(x, \mu_{\tilde{A}}(x)), x \in R\}$$

$$\mu_{\tilde{A}}(x) = \begin{cases} 0 \text{ dla } x \le 10 \\ \left(1 + (x-10)^{-2}\right)^{-1} \text{dla } x > 10 \end{cases}$$

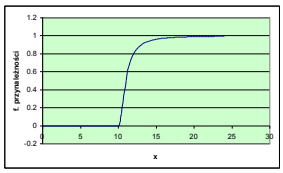

Rozmyta interpretacja określenia „około”

$$x \approx 11$$

$$\tilde{B} = \{(x, \mu_{\tilde{B}}(x)), x \in R\}$$

$$\mu_{\tilde{B}}(x) = (1 + (x-11)^4)^{-1}$$

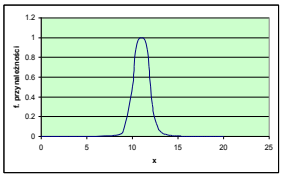

Jednym z często stosowanych narzędzi sztucznej inteligencji jest logika rozmyta

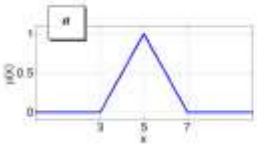

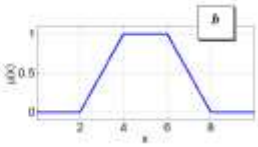

W logice tej przynależność określonego obiektu do określonej kategorii opisywana jest **funkcją przynależności** przyjmującą dowolne wartości z przedziału od **0** do **1**

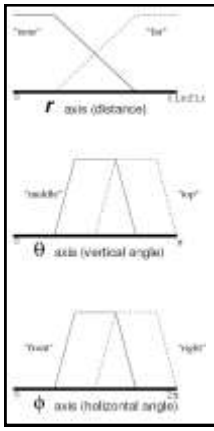

Przykład rozmytego opisu środowiska dla prostego robota

Przykład rozmytej kategoryzacji dla sensorów odległości (dla sterowania robota wymijającego przeszkody)

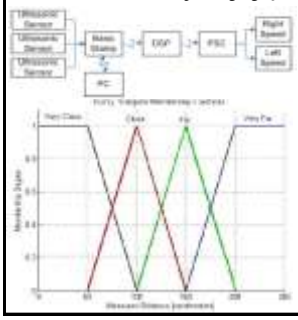

Rule Number	Left Sensor	Central Sensor	Right Sensor	Left Speed	Right Speed
1	Very Far	Very Far	Very Far	1	1
2	Very Far	Very Far	Far	1	1
⋮		⋮			
16	Very Close	Very Far	Far	1	18
51	Very Close	Very Far	Close	1	1
⋮		⋮			
63	Very Close	Very Close	Close	12	1
64	Very Close	Very Close	Very Close	12	1

Proces tworzenia rozmytego lingwistycznego modelu systemu rzeczywistego

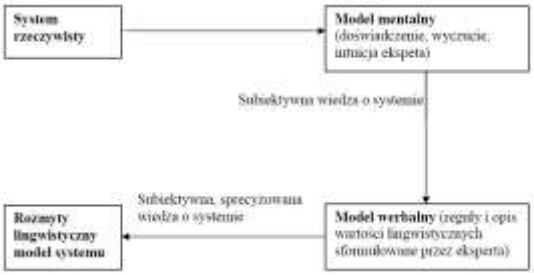

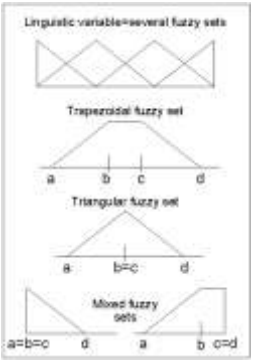

Interpretacja i wyznaczanie funkcji przynależności

Stopień podobieństwa – miara bliskości elementu x do wzorca (rozmyte grupowanie danych, rozmyte sterowanie

Stopień preferencji – A przedstawia zbiór mniej lub bardziej preferowanych obiektów. $\mu_A(x)$ to określenie preferencji dotyczącej obiektu x (rozmyta optymalizacja).

Stopień niepewności - $\mu_A(x)$ to stopień możliwości, że zmiennej X przypisujemy wartość x, gdy jedyną wiedzą, jaką posiadamy jest „X jest A" (teoria możliwości)

Definicje

Support (baza) zbioru rozmytego A:
$\mathrm{supp}(A) = \{ x \in X : \mu_A(x) > 0 \}$

Core (jądro) zbioru rozmytego A:
$\mathrm{core}(A) = \{ x \in X : \mu_A(x) = 1 \}$

α-cut (α-cięcie) zbioru rozmytego A:
$A_\alpha = \{ x \in X : \mu_A(x) > \alpha \}$

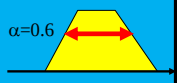

Wysokość = $\max_x \mu_A(x) \le 1$
Zbiór rozmyty normalny: $\sup_{x \in X} \mu_A(x) = 1$

Terminologia

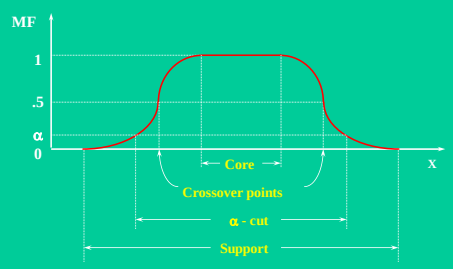

Typy Funkcji Przynależności

Trapezoid: <a,b,c,d>

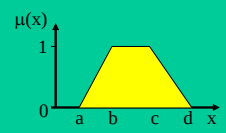

Gaus/Bell: N(m,s)

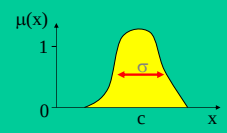

$$Trap(x;a,b,c,d) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{d-x}{d-c}, 1\right), 0\right)$$

$$G(x;a) = e^{-(x-a)^2/2\sigma^2}$$

$$B(x;a,b) = \frac{1}{1+\left|\frac{x-a}{b}\right|^{2b}}$$

Funkcje Przynależności

Trójkątna

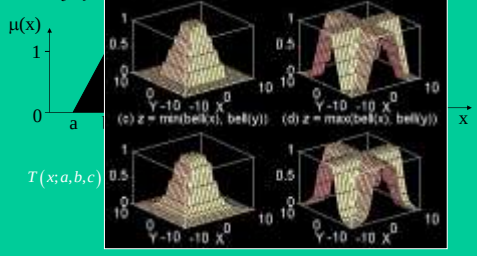

$T(x;a,b,c)$

Zmienne lingwistyczne

Zmienne lingwistyczne są reprezentowane przez czwórkę danych (x, T(x), U, M~), gdzie

x jest nazwą zmiennej,

T(x) to zbiór wartości zmiennej x,

U – uniwersum,

M~ – reguła przyporządkowania zmiennej lingwistycznej do zbiorów rozmytych.

Zmienna lingwistyczna WIEK

x = „wiek”

T(x)= (b. stary, stary, w średnim wieku, młody, ...)

U=[0,130]

$\tilde{M}$(stary)={u,μ_{stary}(u), u $\in$U}

$$\mu_{stary}(u) = \begin{cases} 0 & \text{dla } u \le 50 \\ \left(1+\left(\frac{u-50}{5}\right)^{-2}\right)^{-1} & \text{dla } u > 50 \end{cases}$$

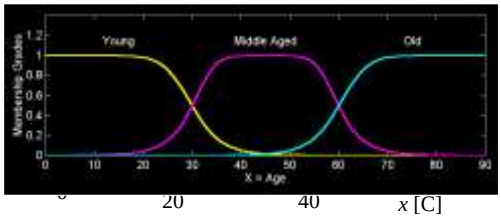

20 40 x [C]

Na zbiorach rozmytych można wykonywać działania

Iloczyn zbiorów rozmytych

Funkcja przynależności zbioru $\tilde{C} = \tilde{A} \cap \tilde{B}$

jest mniejszą z wartości funkcji przynależności zbiorów A i B

$$\mu_c(x) = \min(\mu_A(x), \mu_B(x)) \text{ dla } x \in X$$

Uogólnieniem pojęcia iloczynu zbiorów na zbiory rozmyte są tzw. t - normy

Operator t-normy (T) określa sposób znalezienia części wspólnej zbiorów rozmytych. Charakteryzuje się następującymi cechami:

$T:[0,1] \times [0,1] \rightarrow [0,1]$ przestrzenie odwzorowania

$T(0,0) = 0$ zerowanie

$T(\mu_A(x), 1) = \mu_A(x)$ tożsamość jedynki

$T(\mu_A(x), \mu_B(x)) = T(\mu_B(x), \mu_A(x))$ przemienność

$T(\mu_A(x), T(\mu_B(x), \mu_C(x))) = T(T(\mu_A(x), \mu_B(x)), \mu_C(x))$ łączność

$\mu_A(x) \leq \mu_C(x), \mu_B(x) \leq \mu_D(x) \Rightarrow T(\mu_A(x), \mu_B(x)) \leq T(\mu_C(x), \mu_D(x))$ monotoniczność

t-normy

minimum (MIN)	$\mu_{A\cap B}(x)=MIN(\mu_A(x), (\mu_B(x))$
iloczyn (PROD)	$\mu_{A\cap B}(x)=\mu_A(x)* (\mu_B(x)$
ograniczona różnica	$\mu_{A\cap B}(x)=MAX(0, \mu_A(x)+\mu_B(x)-1)$

Suma zbiorów rozmytych

Funkcja przynależności zbioru $\tilde{C} = \tilde{A} \cup \tilde{B}$

jest większą z wartości funkcji przynależności zbiorów A i B.

$$\mu_c(x) = \max(\mu_A(x), \mu_B(x)) \text{ dla } x \in X$$

s-normy

operatory realizujące sumowanie zbiorów rozmytych

Cechy operatów s-normy:

$T: [0,1] \times [0,1] \rightarrow [0,1]$ przestrzenie odwzorowania

$T(0,0) = 0$ zerowanie

$T(\mu_A(x), 1) = 1$ tożsamość jedynki

$T(\mu_A(x), \mu_B(x)) = T(\mu_B(x), \mu_A(x))$ przemienność

$T(\mu_A(x), T(\mu_B(x), \mu_C(x))) = T(T(\mu_A(x), \mu_B(x)), \mu_C(x))$ łączność

$\mu_A(x) \leq \mu_C(x), \mu_B(x) \leq \mu_D(x) \Rightarrow T(\mu_A(x), \mu_B(x)) \leq T(\mu_C(x), \mu_D(x))$ monotoniczność

Operatory sumy zbiorów

MAX	$\mu_{A\cup B}(x)=MAX(\mu_A(x),\ \mu_B(x))$
suma algebraiczna	$\mu_{A\cup B}(x)=\mu_A(x)+\mu_B(x)-\mu_A(x)\cdot\mu_B(x)$
suma ograniczona	$\mu_{A\cup B}(x)=MIN(1,\ \mu_A(x)+\mu_B(x))$

Przykłady

Suma

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

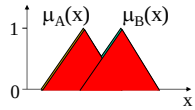

$\mu_{A\vee B}(x)=\min\{1,\mu_A(x)+\mu_B(x)\}$

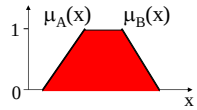

Iloczyn

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

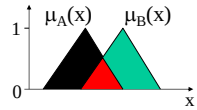

$\mu_{A\wedge B}(x)=\mu_A(x)\bullet\mu_B(x)$

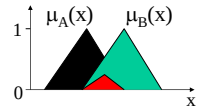

$\mu_C(x) = \mu_{A\vee B}(x)=\max\{\mu_A(x),\mu_B(x)\}$

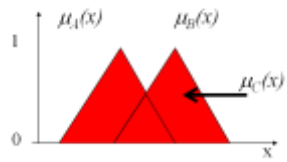

$\mu_{A\wedge B}(x)=min\{\mu_A(x),\mu_B(x)\}$

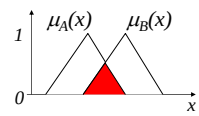

Przykłady

MIN(a,b), a•b

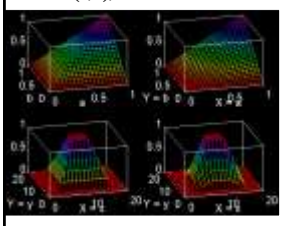

MAX(a,b), a+b

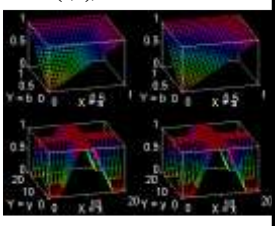

$$\tilde{C}=\tilde{A}\cap\tilde{B}\qquad \mu_{\tilde{C}}(x)=\begin{cases}\min(0,[1+(x-11)^4]^{-1})\ \text{dla x}\le 10\\ \min([1+(x-10)^{-2}]^{-1},[1+(x-11)^4]^{-1})\ \text{dla x}>10\end{cases}$$

$$\tilde{D}=\tilde{A}\cup\tilde{B}\qquad \mu_{\tilde{D}}(x)=\begin{cases}\max(0,[1+(x-11)^4]^{-1})\ \text{dla x}\le 10\\ \max([1+(x-10)^{-2}]^{-1},[1+(x-11)^4]^{-1})\ \text{dla x}>10\end{cases}$$

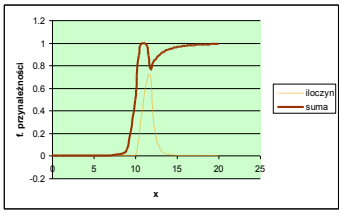

Czasami użyteczne bywa także dopełnienie zbioru rozmytego

$$\tilde{C} = (\tilde{A})'$$

$$\mu_c(x) = 1 - \mu_A(x) \text{ dla } x \in X$$

Wybrane T-normy i S-normy

T-norma $T(\mu_x(x), \mu_y(x))$	S-norma $T(\mu_x(x), \mu_y(x))$
Minimum $\min(\mu_x(x), \mu_y(x))$	**Maximum** $\max(\mu_x(x), \mu_y(x))$
Iloczyn algebraiczny $\mu_x(x)\mu_y(x)$	**Suma algebraiczna** $\mu_x(x) + \mu_y(x) - \mu_x(x)\mu_y(x)$
Iloczyn silny $\min(\mu_x(x), \mu_y(x))$ *gdy* $\max(\mu_x(x), \mu_y(x)) = 1$ 0 *w przeciwnym przypadku*	**Silna suma** $\max(\mu_x(x), \mu_y(x))$ *gdy* $\min(\mu_x(x), \mu_y(x)) = 0$ 1 *w przeciwnym przypadku*
AND Łukasiewicza $\max(0, \mu_x(x) + \mu_y(x) - 1)$	**OR Łukasiewicza** $\min(1, \mu_x(x) + \mu_y(x))$
Iloczyn Einsteina $\frac{\mu_x(x)\mu_y(x)}{2 - (\mu_x(x) + \mu_y(x) - \mu_x(x)\mu_y(x))}$	**Suma Einsteina** $\frac{\mu_x(x) + \mu_y(x)}{(1 + \mu_x(x)\mu_y(x))}$
Iloczyn Hamachera $\frac{\mu_x(x)\mu_y(x)}{\mu_x(x) + \mu_y(x) - \mu_x(x)\mu_y(x)}$	**Suma Hamachera** $\frac{\mu_x(x) + \mu_y(x) - 2\mu_x(x)\mu_y(x)}{1 - \mu_x(x)\mu_y(x)}$
T-Operator Yagera $1 - \min\left\{1, \left[(1-\mu_x(x))^b + (1-\mu_y(x))^b\right]^{\frac{1}{b}}\right\}$	**S-Operator Yagera** $\min\left\{1, \left[(\mu_x(x))^b + \mu_y(x))^b\right]^{\frac{1}{b}}\right\}$

Liczby rozmyte

Zwykle wypukłe, unimodalne (jedno maksimum).

Liczby: jądro = punkt, $\exists_x\ \mu(x)=1$
Monotonicznie maleją po obu stronach jądra.
Typowy wybór: trójkątne funkcje (a,b,c) lub singletony.

$$7_F = \left\{\frac{1/3}{5} + \frac{2/3}{6} + \frac{1}{7} + \frac{2/3}{8} + \frac{1/3}{9}\right\}$$

Dodawanie liczb rozmytych

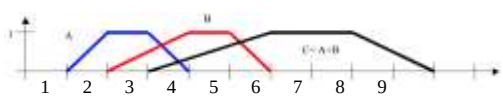

około **trzy** dodać *około* **pięć** to jest *około* ***osiem***

Operacje na liczbach rozmytych

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

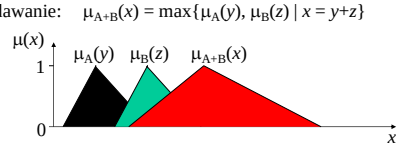

Iloczyn: $\mu_{A\bullet B}(x) = \min\{\mu_A(y), \mu_B(z) \mid x = y\bullet z\}$

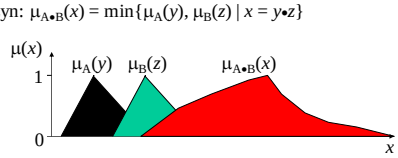

Funkcja

Jeśli $y=f(x)$, i $x=a$ to $y=b$.
Dla punktów - krzywa dla interwałów - pasmo.

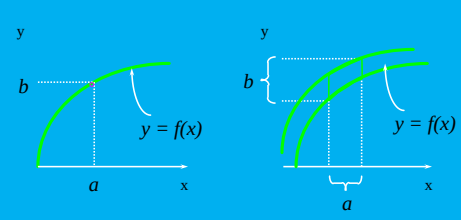

Dla rozmytych zmiennych x ?

Rozmyte funkcje

Mamy zbiór rozmyty A i funkcję f :
Jak wygląda f(A)?

Dla dowolnej funkcji f:

$$\mu_{f(A)}(y) = \max\{\mu_A(x) \mid y=f(x)\}$$

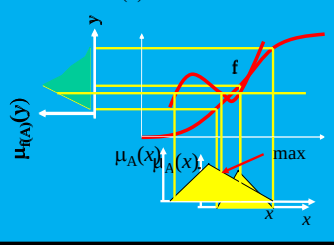

Rozmyte relacje

- Relacje klasyczne

  $R \subset X \times Y$ def: $\mu_R(x,y) = \begin{cases} 1 & \text{iff } (x,y) \in R \\ 0 & \text{iff } (x,y) \notin R \end{cases}$

- Relacje rozmyte

  $R \subset X \times Y$ def: $\mu_R(x,y) \in [0,1]$

$\mu_R(x,y)$ opisuje stopień powiązania x i y

Inna interpretacja: stopień prawdziwości zdania x R y

Przykłady rozmytych relacji

Bliskie: X ≈Y; X zależy od Y; X podobne do Y ...

X = { deszczowo, pochmurnie, słonecznie }

Y = { opalanie, wrotki, kamping, lektura }

X/Y	opalanie	wrotki	kamping	lektura
deszczowo	0.0	0.2	0.0	1.0
pochmurnie	0.0	0.8	0.3	0.3
słonecznie	1.0	0.2	0.7	0.0

Relacje rozmyte związane są z korelacjami.

Reguły rozmyte

Wiedzę potoczną można często zapisać w naturalny sposób za pomocą reguł rozmytych.

Jeśli zm. lingw-1 = term-1 i zm. lingw-2 = term-2
to zm. lingw-3 = term-3

Jeśli Temperatura = zimno i cena ogrzewania = niska
to grzanie = mocno

Co oznacza reguła rozmyta:

Jeśli x jest A to y jest B ?

Korelacja A i B, lub implikacja A =>B

Zastosowania logiki rozmytej

Wszędzie tam, gdzie trudno jest utworzyć matematyczny model ale daje się opisać sytuację w sposób jakościowy, za pomocą reguł rozmytych.

Kontrolery rozmyte:

jeśli się przewraca to popchnąć.

Inteligentne lodówki, pralki, windy, opiekacze do grzanek, aparaty fotograficzne.

Zastosowania medyczne: nieprecyzyjny język daje się przełożyć na reguły rozmyte.

Wiele zastosowań przemysłowych, głównie dotyczących kontroli procesów.

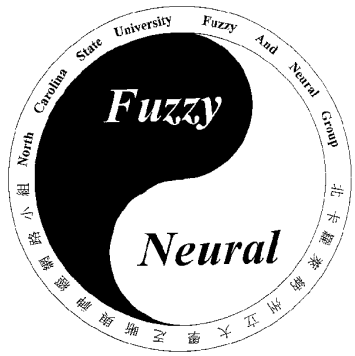

Różne sposoby łączenia zbiorów rozmytych i sieci neuronowych

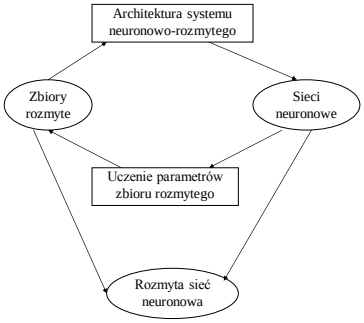

Siła i atrakcyjność logiki rozmytej bierze się stąd, że zostały opracowane i oprogramowane **metody sprawnego wnioskowania** na podstawie rozmytych przesłanek i reguł

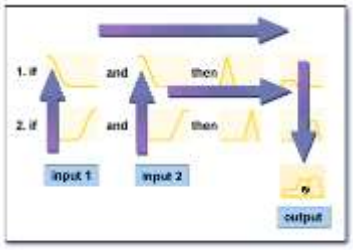

Interpreting the Fuzzy Inference Diagram

Kluczem są tu implikacje rozmyte

$A \rightarrow B$
gdzie A i B to zbiory rozmyte określone przez swoje funkcje przynależności

Implikacja rozmyta $\mu_{A\rightarrow B}(x,y)$
opisana jest funkcją przynależności zdefiniowaną na zbiorze będącym iloczynem kartezjańskim zbiorów przesłanki i konkluzji.

Rozmyta implikacja

Jeśli korelacja to wystarczy T-norma T(*A*,*B*).
A=>B ma wiele realizacji

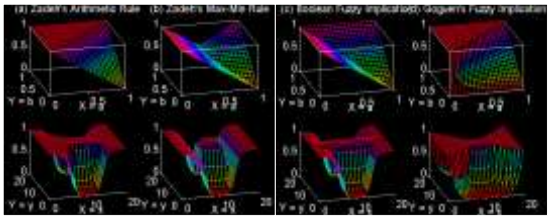

Istnieje wiele reguł obliczania funkcji prawdziwości implikacji rozmytych

1. Reguła typu minimum, tzw. reguła Mamdaniego:

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

2. Reguła typu iloczyn, tzw. reguła Larsena:

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

3. Reguła Łukasiewicza:

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

4. Reguła typu max-min, tzw. reguła Zadeha

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

5. Reguła binarna

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

6. Reguła Goguena

$$\mu_{A\rightarrow B}(x,y) = \mu_R(x,y) = \min\left\{1, \frac{\mu_A(x)}{\mu_B(y)}\right\}$$

7. Reguła Skarpa

$$\mu_{A\rightarrow B}(x,y) = \mu_R(x,y) = \begin{cases} 1 & \text{gdy} \quad \mu_A(x) \le \mu_B(y) \\ 0 & \text{gdy} \quad \mu_A(x) > \mu_B(y) \end{cases}$$

8. Reguła Gödela

$$\mu_{A\to B}(x,y)=\mu_B(x,y)=\begin{cases}1 & \text{gdy} \quad \mu_A(x)\le\mu_B(y)\\ \mu_B(y) & \text{gdy} \quad \mu_A(x)>\mu_B(y)\end{cases}$$

9. Reguła probabilistyczna

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

10. Reguła ograniczonej sumy

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

W rezultacie często systemy, które oryginalnie dostarczają danych pewnych (a nie rozmytych) są przekształcane do rozwiązań opartych na logice rozmytej

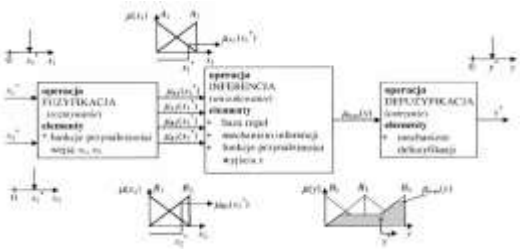

Przykładowe funkcje przynależności różnych kategorii związanych ze sterowaniem bezzałogowego samolotu

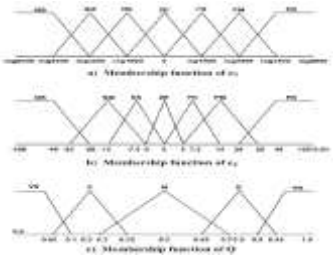

Przykład: www.intelligentsolutionsinc.com

Cel: zbudować rozmyty system ekspertowy wspomagający wnioskowanie o operacjach wydobycia na podstawie:
- cen ropy
- wykazanych rezerw korporacji.

Dane są:
- zbiory rozmyte dla cen ropy
- zbiory rozmyte dla wykazanych rezerw korporacji
- zbiory rozmyte zaangażowania w operację wydobycia (wyjcie).
- reguły postępowania przy zadanych wejściach.

Przykład – rezerwy korporacji

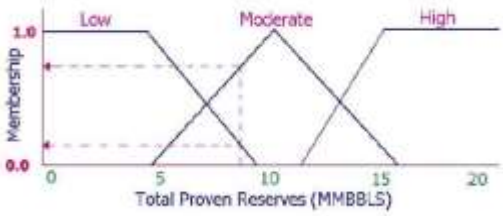

Przykład – cena ropy

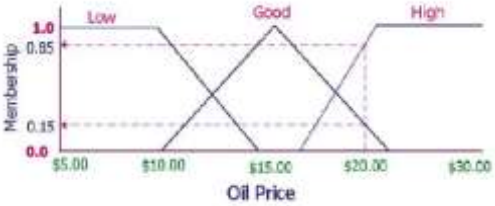

Przykład – zaangażowanie w zwiększenie wydobycia

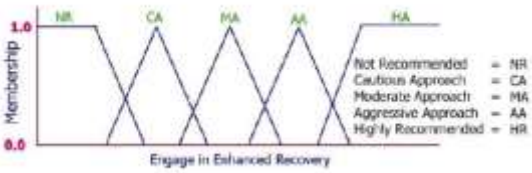

Przykład – reguły rozmyte

Reguła 1:
IF cena ropy jest wysoka
AND wykazane rezerwy są niskie
THEN zwiększenie operacji wydobycia wysoce wskazane.

Przykład - fuzzyfikacja

Cena ropy
MMBBLs (

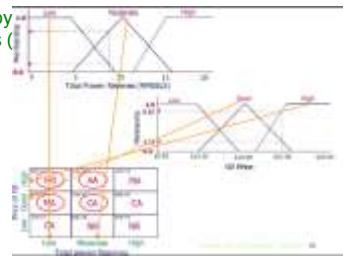

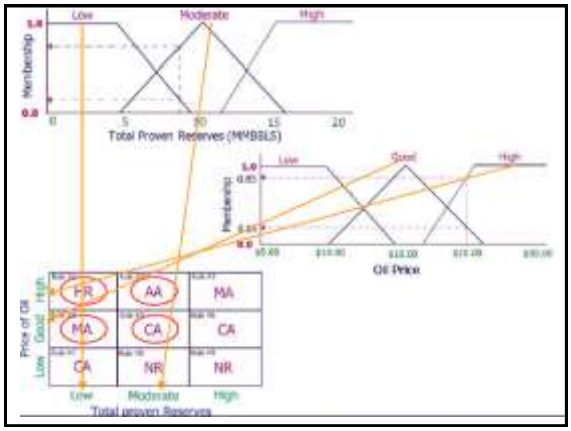

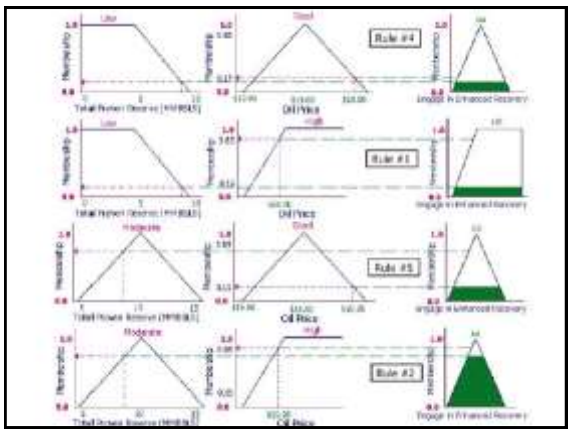

Przykład – rozmyta wartość wynikowa

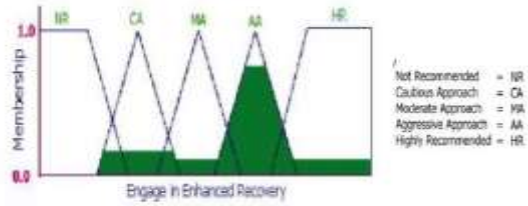

Wyostrzanie wielkości rozmytych

Interpretacja graficzna metody wyostrzania średnią geometryczną

$$y = \frac{(c*d)-(a*b)}{-a-b+c+d}$$

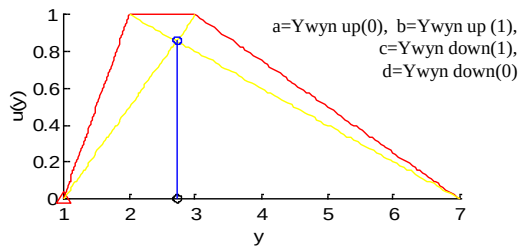

Wyostrzanie metodą średniej parametrycznej przy różnych wartościach parametru *p*

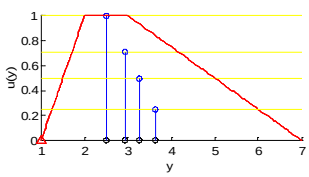

y = mean(Ywyn up(p), Ywyn down(p))

p – parametr mieszczący się przedziale funkcji przynależności *μ [0, 1]* określający poziom, na którym zostają obliczone wartości funkcji *up* i *down* zbioru Y_{wyn}

ROZMYTE SIECI NEURONOWE

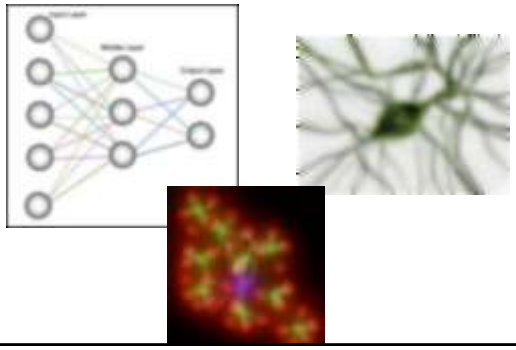

SKŁADNIKI ROZMYTEJ SIECI NEURONOWEJ

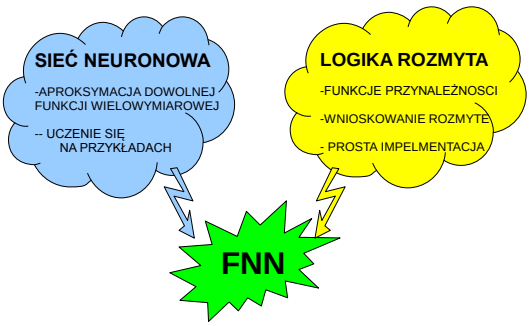

RODZAJE INTEGRACJI NN I FS

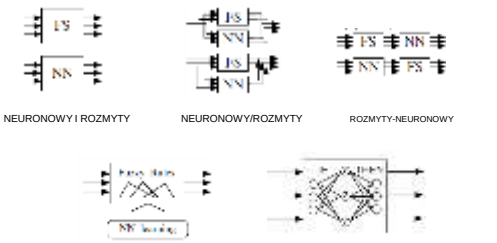

RODZAJE INTEGRACJI NN I FS

NEURONOWY Z ROZMYTYM WEJŚCIEM/WYJŚCIEM

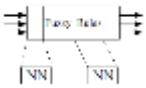

NEURONOWO ROZMYTY

ROZMYTY NEURONOWY

KOOPERACYJNA SIEĆ ROZMYTA

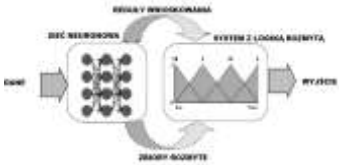

WYKORZYSTANIE SIECI NEURONOWYCH
W CELU TWORZENIA
FUNKCJI PRZYNALEŻNOSCI

KOOPERACYJNA FNN - WYKORZYSTANIE

- FAM – Fuzzy Associative Memory – Rozmyta Pamięć Skojarzeniowa –macierzowy opis funkcji przynależności

FAMM

	Near	Far	Very Far
Small	X1	X2	X3
Medium	X4	X5	X6
Large	X7	X8	X9

WSPÓŁBIEŻNE SIECI FNN

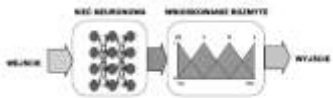

WYKORZYSTANIE SIECI NEURONOWEJ DO
PRZYGOTOWANIE DANYCH WEJSCIOWYCH
DLA CZĘŚCI ROZMYTEJ

NEURON KLASYCZNY I ROZMYTY

Prosta, klasyczny sieć neuronowa:

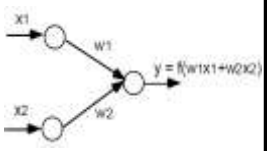

$$p_i = w_i x_i, \quad i = 1, 2$$

$$net = p_1 - p_2 = w_1 x_1 + w_2 x_2$$

$$y = f(net) = f(w_1 x_1 + w_2 x_2)$$

NEURON ROZMYTY

AND

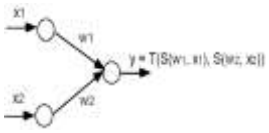

$$p_i = S(w_i, x_i), \quad i = 1, 2$$

$$y = AND(p_1, p_2) = T(p_1, p_2) = T(S(w_1, x_1), S(w_2, x_2))$$

$$y = \min\{w_1 \vee x_1, w_2 \vee x_2\}$$

$$y \in [T(w_1, w_2), 1]$$

OR

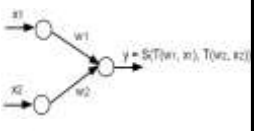

$$p_i = T(w_i, x_i), \quad i = 1, 2$$

$$y = OR(p_1, p_2) = S(p_1, p_2) = S(T(w_1, x_1), T(w_2, x_2))$$

$$y = \max\{w_1 \wedge x_1, w_2 \wedge x_2\}$$

$$y \in [0, S(w_1, w_2)]$$

NURON ROZMYTY *Kwan & Cai*

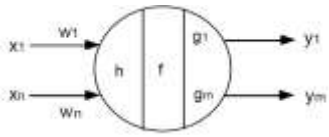

$$p_i = w_i x_i, \ i = 1, \ldots, n$$

$$z = h(w_1 x_1, w_2 x_2, \ldots, w_n x_n)$$

$$s = f[z - \theta]$$

$$y_j = g_j(s), \ j = 1, \ldots, m$$

REGULARNA SIEĆ FNN

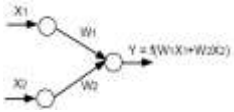

$$P_i = W_i X_i, \ i = 1, 2 \qquad f(x) = (1 + e^{-x})^{-1}$$

$$net = P_1 + P_2 = W_1 X_1 + W_2 X_2$$

$$Y = f(net) = f(W_1 X_1 + W_2 X_2)$$

$$Y(y) = \begin{cases} (W_1 X_1 + W_2 X_2)(f^{-1}(y)) & \text{if } 0 \le y \le 1 \\ 0 & \text{otherwise} \end{cases}$$

HYBRYDOWE SYSTEMU FNN

Przykłady hybrydowych sieci FNN:

- FALCON
- ANFIS
- GARIC
- Takagi Sugeno
- Mamdani
- NEFCLASS (Neuro-Fuzzy Classification)

Fuzzy Adaptive Learning Control Network (FALCON)

- Pierwsza warstwa odpowiada za rozmywanie
- W drugiej warstwie następuje wyliczenie stopnia spełnianie części IF wnioskowania rozmytego
- W czwartej warstwie wyliczamy część THEN wnioskowania rozmytego
- Warstwa trzecia odpowiada zasadom wnioskowania
- Piąta warstwa odpowiada za wyostrzanie
- Nienadzorowane tworzenie prototypów funkcji przynależności
- Wykorzystanie propagacji wstecznej

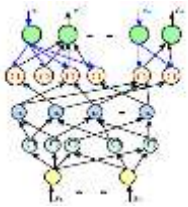

Trening sieci FALCON

- Trening sieci opiera się na poszukiwaniu właściwej postaci trzecie warstwy sieci – zasad wnioskowania
- Przy pomocy dostępnych danych tworzymy pary rozmyte wejście rozmyte wyjście w oparciu o ustalone funkcje przynależności
- Warstwa trzecie będzie tworzona tak, aby z każdego węzła wejściowego i wyjściowego połączyć się do wariantu o najwyższej przynależności
- Waga reguły będzie zależeć od stopnia przynależności węzłów wyjściowych z którymi jest połączona

ANFIS (Adaptive Network Based Fuzzy Inference System)

- jeden z pierwszych hybrydowych FNN (1992)
- ustalona struktura
- adaptacja odbywa się tylko w ramach wartości paramentów
- podczas treningu zostają ustalone funkcje przynależności

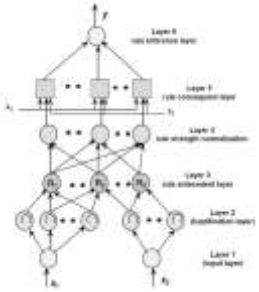

GARIS (Generalized Approximate Reasoning Based Intelligent Control)

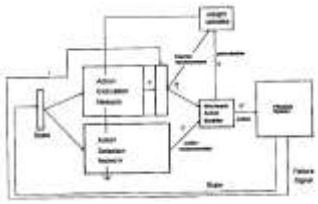

- sieć neuronowa i sieć FNN
- ASN (Action Selection Network)
- AEN (Action State Evaluation)
- SAM (Stochastic Action Modifier)

ASN (Action Selection Network)

- sieć FNN 5-cio warstwowa

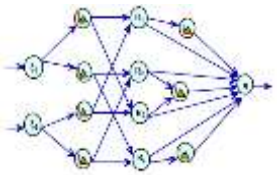

PRASA WALCOWA HITACHI

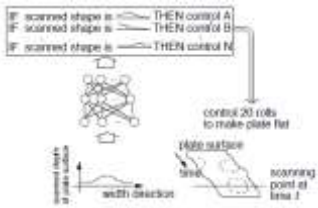

- WCZESNE ZASTOSOWANIE METOD NN+FS (ROK 1992)
- SIEĆ NEURONOWA ODPOWIADA ZA ROZPOZNAWNIE WZORCÓW
-LOGIKA ROZMYTA RALIZUJE REAKCJE NA PODSTAWIE STOPNIE DOPASOWANIA DO

WENTYLATOR AUTOMATYCZNY SANYO

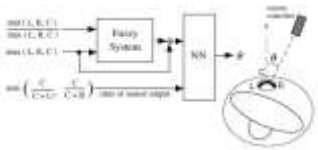

- logika rozmyta szacuje odległość wiatrak – pilot
- sieć neuronowa określa kierunek między osią wiatraka a pilotem
- lepsze możliwości śledzenia pilota od otrzymanych wprost z danych czujników

BIBLIOGRAFIA

- **Robert Full´er, Neural Fuzzy Systems, ˚Abo 1995**
- **Justyna Signerska i Krzysztof Bartoszek, Logika rozmyta**
- **Hideyuki Takagi, Fusion Technology of Neural Networks and Fuzzy Systems: A Chronicled Progression from the Laboratory to Our Daily Lives**
- **Sushmita Mitra, Neuro–Fuzzy Rule Generation: Survey inSoft Computing Framework**
- **Zadeh, Fuzzy Sets, 1965**
- **Ajith Abraham, Neuro Fuzzy Systems: State-of-the-art Modeling Techniques**
- **HR Berenji, P Khedkar, Learning and tuning fuzzy logic controllers through reinforcements**