

ESI: Systemy rozmyte

[Matlab_1.0] Matlab2016b i nowsze

10 czerwca 2019

1. **Cel ćwiczeń:** Celem ćwiczeń jest zapoznanie się studentów z zagadnieniami z zakresu logiki rozmytej.
2. **Logika rozmyta:** W logice dwuwartościowej dostępne są dwie opcje 0 lub 1, prawda lub fałsz i wiele wiele innych form na określenie wyniku działania logicznego. W logice rozmytej używa się stanów pomiędzy, przez analogię między kolorem czarnym i białym jest cała gama szarości. Tak też w logice rozmytej opisuje się stany pomiędzy co daje dużo więcej możliwości klasyfikacji wyboru. Dzięki czemu można w wygodny sposób zamodelować zjawiska nieprecyzyjne [4].

Zakłada się, że X jest pewną określoną przestrzenią rozważań. Niech $W \subset X$, zbiorem W identyfikuje się z funkcją przynależności μ [3]. W logice klasycznej jest to funkcja charakterystyczna zbioru W opisywana za pomocą:

$$\chi_W(x) = \begin{cases} 0 & \text{gdy } x \in W \\ 1 & \text{gdy } x \notin W. \end{cases} \quad (1)$$

W przypadku opisywanej logiki rozmytej funkcja ta może przyjąć dowolną formę i przeważnie interpretuje się ją jako poziom przynależności elementu x do zbioru W [2].

Zbiór rozmyty Zbiorem rozmytym A w pewnej niepustej przestrzeni X nazywamy zbiór uporządkowanych par

$$\{(x, \mu_W(x)) : x \in X\}$$

gdzie

$$\mu_W : X \rightarrow \mathfrak{R}$$


jest funkcją przynależności zbioru W .

Przykład Niech W będzie zbiorem niskiej temperatury. $X = [-65^\circ C, 10^\circ C]$ opisuje temperaturę w Rosji. Funkcję, która mogła by opisywać przynależność do zbioru W przedstawiono poniżej:


Gaussowska funkcja przynależności

$$\mu = \exp -\left(\frac{x - c}{d}\right)^2 \quad (2)$$

gdzie c – centrum, d – rozpiętość



Rysunek 1: Przykładowa funkcja przynależności do zbioru W




Rysunek 2: Funkcja Gaussowska

Trójkątna funkcja przynależności


$$\mu = \begin{cases} 0 & \text{gdy } a > x \text{ oraz } x > c \\ \frac{x-a}{b-a} & \text{gdy } a \leq x \leq b \\ \frac{c-x}{b-a} & \text{gdy } b < x \leq c \end{cases} \quad (3)$$

Trapezoidalna funkcja przynależności

$$\mu = \begin{cases} 0 & \text{gdy } a > x \text{ oraz } x > d \\ \frac{x-a}{b-a} & \text{gdy } a \leq x \leq b \\ \frac{d-x}{d-c} & \text{gdy } c < x \leq d \\ 1 & \text{gdy } b < x \leq c \end{cases} \quad (4)$$



Rysunek 3: Funkcja trójkątna



Rysunek 4: Funkcja trapezoidalna

Singleton Często wykorzystywaną funkcją przynależności w systemach rozmytych jest singleton. Niech $W = \{\bar{x}\}$

$$\mu_{\bar{x}}(x) = \begin{cases} 0 & \text{gdym } x \neq \bar{x} \\ 1 & \text{gdym } x = \bar{x} \end{cases} \quad (5)$$


Nośnik zbioru W (support) Nośnikiem zbioru W nazywamy zbiór takich x , które mają znaczenie dla W .

$$\text{supp}(W) = S_W = \{x \in X : \mu_W(x) > 0\} \quad (6)$$

Wysokość zbioru W (height)

$$h(W) = H_W = \sup_{x \in X} \mu_W(x) \quad (7)$$

Zbiór W jest normalny jeżeli $h(W) = 1$. Z punktu widzenia praktyki jest to bardzo istotne. Mianowicie jeżeli W jest normalny to wartość funkcji przynależności można interpretować ja-




Rysunek 5: Wykres funkcji singleton

ko procent na ile dany element x należy do W . W przeciwnym wypadku zawsze można go znormalizować.

Zmienna lingwistyczna W (Linguistic Variable) Zmienna lingwistyczna jest czwórką (N, T, X, M_n) [1], gdzie:

- N nazwa zmiennej np. rozmiar
- T zbiór wartości lingwistycznych np. {mały, średni, duży}
- X przestrzeń rozważań np. $[0, 2.00]$ m
- M_n funkcja semantyczna $M_n : T \rightarrow$ zbiór funkcji przynależności



Rysunek 6: Przykładowe funkcje przynależności ilustrujące M_n

Kompletność (complete) Zmienna lingwistyczna V jest kompletna, jeżeli zachodzi

$$\forall_{x \in X} \exists_{W \in T} \mu_W(x) > 0. \quad (8)$$

Natomiast jeżeli zmienna lingwistyczna nie jest kompletna, to wtedy przestrzeń rozważań X_V

jest nadmiarowa.

Suma do jedności (partition of unity) Mówi się, że zmienna lingwistyczna V sumuje się do jedności jeżeli

$$\forall_{x \in X} \sum_{i=1}^{\bar{T}} \mu_{W^i}(x) = 1. \quad (9)$$

T -norma Funkcja dwóch zmiennych T

$$T : [0, 1] \times [0, 1] \rightarrow [0, 1] \quad (10)$$

nazywa się T -normą, jeżeli

2.1. funkcja T jest nierosnąca względem obu argumentów

$$T(a, c) \leq T(b, d) \quad a \leq b, \quad c \leq d$$

2.2. funkcja T spełnia warunek przemienności

$$T(a, b) = T(b, a)$$

2.3. funkcja T spełnia warunek łączności

$$T(T(a, b), c) = T(a, T(b, c))$$

2.4. funkcja T spełnia warunki brzegowe

$$T(a, 0) = 0, \quad T(a, 1) = a,$$

gdzie $a, b, c, d \in [0, 1]$.

Dla dowolnej T -normy zachodzi:

$$T(a, b) \leq \min(a, b) \quad (11)$$

Przyjmijmy oznaczenie:

$$T(a, b) = a_*^T b$$

Najczęściej spotykane T -normy:

2.1. $T(a, b) = \min(a, b)$

2.2. $T(a, b) = a \cdot b$

S -norma Funkcję dwóch zmiennych S

$$S : [0, 1] \times [0, 1] \rightarrow [0, 1] \quad (12)$$

określa się nazwą S -normy, w przypadku gdy jest nierosnąca względem obu argumentów, spełnia warunek przemienności, łączności oraz zachodzą warunki brzegowe:

$$S(a, 0) = a \quad S(a, 1) = 1$$

Dla dowolnej S -normy zachodzi

$$\max(a, b) \leq S(a, b)$$

Przyjmijmy oznaczenie:

$$S(a, b) = a_*^S b$$

Najczęściej spotykane S -normy:

2.1. $S(a, b) = \max(a, b)$


2.2. $S(a, b) = a + b - ab$

Każdej T -normie odpowiada S -norma, zachodzi między nimi następująca zależność

$$a_*^T b = 1 - [(1 - a)_*^S (1 - b)]$$

Przecięcie zbiorów rozmytych A i B definiuje się jako:

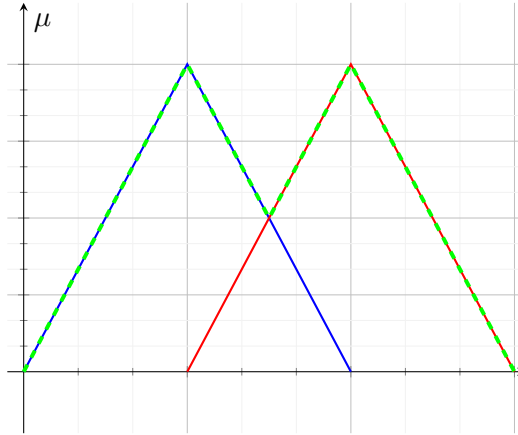
$$\mu_{A \cap B}(x) = T(\mu_A(x), \mu_B(x))$$



Rysunek 7: Przecięcie zbiorów rozmytych (kolor zielony)

Sumę zbiorów rozmytych A i B definiuje się jako:


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



Rysunek 8: Suma zbiorów rozmytych (kolor zielony)

Dopełnieniem zbioru rozmytego $A \subseteq X$ jest zbiór rozmyty \hat{A} o funkcji przynależności:

$$\mu_{\hat{A}}(x) = 1 - \mu_A(x) \quad \text{dla każdego } x \in X$$



Rysunek 9: Dopełnienie zbioru rozmytego

Iloczyn kartezjański zbiorów rozmytych $A_1 \subseteq X_1, A_2 \subseteq X_2, \dots, A_n \subseteq X_n$, oznacza się jako $A_1 \times A_2 \times \dots \times A_n$ i definiuje:


$$\mu_{A_1 \times A_2 \times \dots \times A_n}(x_1, x_2, \dots, x_n) = \min(\mu_{A_1}(x_1), \mu_{A_2}(x_2), \dots, \mu_{A_n}(x_n))$$

Entropią rozmytą nazywa się miarę opisującą rozmycie zbioru:

$$E(A) = \frac{c(A \text{ AND } \text{NOT } A)}{c(A \text{ OR } \text{NOT } A)}$$

gdzie c oznacza sumowanie lub całkowanie po wszystkich wartościach przynależności zbioru A .

Zakładając, że poniżej (rys. 10) przedstawiono zbiór A o nazwie dorosły, gdzie niebieska funkcja przynalżności opisuje przynalżność do niedoroslých natomiast czerwona do grupy dorosłych, to korzystając ze wzoru na entropię otrzymano wynik $\frac{5}{40}$.



Rysunek 10: Przykład do entropii.

3. Relacje rozmyte i reguły wnioskowania:

Relacja rozmyta R zachodząca między dwoma zbiorami (nierozmytymi) X i Y nazywa się zbiór rozmyty określony na iloczynie kartezjańskim $X \times Y$. Relacja rozmyta jest zbiorem par

$$R = \{((x, y), \mu_R(x, y)); x \in X, y \in Y\}$$

gdzie $\mu_R : X \times Y \rightarrow [0, 1]$ jest funkcją przynalżności. Przypisuje ona każdej parze (x, y) stopień przynalżności interpretowany jako siłę powiązania pomiędzy tymi elementami.

Reguła rozmytej implikacji Niech A i B będą zbiorami rozmytymi, $A \subseteq X$ i $B \subseteq Y$. Rozmyta implikacja $A \rightarrow B$ określa relację R w $X \times Y$ i może być definiowana za pomocą jednej z czterech następujących reguł:

- Reguła typu minimum:

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

- Reguła typu iloczyn:

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

- Reguła Sharpa:

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

- Reguła Łukasiewicza:

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

Wniosek reguły rozmytej odnosi się do pewnego zbioru rozmytego B' , który jest określony przez zażenie zbioru rozmytego A' i rozmytej implikacji $A \rightarrow B$, tzn.:

$$B' = A' \circ (A \rightarrow B) \quad (13)$$

W logice rozmytej przesłanki i wniosek są zbiorami rozmytymi.

Przykład :

- Przesłanka: Ludzi na koncercie jest dużo
- Implikacja: Jeżeli ludzi na koncercie jest bardzo dużo, to jest bardzo głośno
- Wniosek: Na koncercie jest średnio głośno

W przedstawionym wnioskowaniu można zauważyć dwie zmienne lingwistyczne i odpowiadające im przestrzenie rozważań, a także zbiory rozmyte:

- Zmienne lingwistyczne: x - ilość ludzi; y - poziom głośności
- Przestrzeń rozważań: $T_x = \{\text{mało, średnio, dużo, bardzo dużo}\}$, $T_y = \{\text{mały, średni, wysoki, bardzo wysoki}\}$
- Zbiory rozmyte: A_x - bardzo duża liczba ludzi, A'_x - duża liczba ludzi B_y - bardzo wysoki poziom głośności, B'_y - wysoki poziom głośności.

Wniosek B'_y z przesłanki wyznacza się znajdując $\mu_{B'_y}(y)$. Niech

$$\mu_{B'_y}(y) = \max_{x \in X} \min[\mu_{A'_x}(x), \mu_{A_x \rightarrow B_y}(x, y)]$$

a także


$$\mu_{A_x \rightarrow B_y}(x, y) = \min[\mu_{A_x}(x), \mu_{B_y}(y)]$$

wtedy

$$\mu_{B'_y}(y) = \max_{x \in X} \min[\mu_{A'_x}(x), \min(\mu_{A_x}(x), \mu_{B_y}(y))] = \min[\max_{x \in X} \min(\mu_{A'_x}(x), \min(\mu_{A_x}(x), \mu_{B_y}(y)))]$$

4. **Systemy rozmyte:** Typowy proces wnioskowania rozmytego składa się z czterech etapów (rys. 11):

- rozmywanie (fuzzification)
- zastosowanie operacji rozmytych
- zastosowanie implikacji rozmytych
- precyzowanie/wyostrzenie (defuzzification) - na przykład metoda wyznaczania "środka ciężkości" (Center of Gravity)




Rysunek 11: Schemat systemu rozmytego

W pierwszej fazie dane wejściowe są "rozmywane", by następnie można było zastosować na nich operacje rozmyte i reguły wnioskowania rozmytego. W kolejnej fazie otrzymane wyniki poddane są "wyostżaniu" i w ten sposób uzyskanie zostaną konkretne dane wyjściowe.

Systemy rozmyte należy traktować jako automaty, które opierają swoje działanie na prawach logiki rozmytej w celu podjęcia decyzji w warunkach niepewnych. System posiada pewną bazę wiedzy oraz reguły wnioskowania. Na podstawie "obserwacji" podejmuje decyzję. Może ona dotyczyć rozległych tematów związanych z wartościami np. prędkości samochodu czy też ciśnienia wody. Baza wiedzy i reguły wnioskowania tworzone są na podstawie wiedzy eksperta. Zatem efektywność takiego systemu opiera się głównie na rzetelności eksperta w danej dziedzinie. Są dwa rodzaje systemów rozmytych, wnioskowanie Mamdaniego oraz Takagi-Sugeno.


5. **Model Mamdaniego:** System, który ma być zamodelowany jest traktowany w modelach Mamdaniego jako czarna skrzynka (black box). Co powoduje, że nie ma informacji o tym jakie zjawiska w nim zachodzą.

Model wnioskowania typu Mamdaniego jest zbiorem reguł opartych o zasadę modus ponens, z których każda definiuje jeden rozmyty punkt w tej przestrzeni. Na podstawie istniejącego zbioru rozmytych punktów można otrzymać wykres rozmyty, w którym interpolacja pomiędzy punktami zależy od użytych elementów aparatu logiki rozmytej. Każda reguła definiuje typowe zachowanie systemu, która geometrycznie odpowiada punktowi w przestrzeni $X \times Y$. Aby dokładniej przybliżyć ideę wnioskowania przybliżonego można porównać mechanizmy wnioskowania tradycyjnego i przybliżonego przyjmując regułę wnioskowania typu modus ponens (rys. 12 i 13).



Rysunek 12: Schemat wnioskowania modus ponens

Należy zwrócić uwagę na różnicę w działaniu zwykłej reguły w porównaniu z regułą rozmytą. Dla



Rysunek 13: Schemat wnioskowania modus ponens z użyciem zbiorów rozmytych

każdego z pokazanych przypadków istnieje implikacja $A \rightarrow B$. Dla reguły nierozmytej wyznaczenie wniosku następuje tylko wtedy gdy zdanie A występujące w przesłance jest również obecne w implikacji $A \rightarrow B$. Natomiast w regule rozmytej przesłanka opisana zbiorem rozmytym A' może być zbliżona do zbioru A z poprzednika implikacji, ale nie musi być koniecznie równa A . Mając dany schemat wnioskowania, aby wyznaczyć zbiór B' opisujący wniosek należy przeprowadzić operację kompozycji o postaci:

$$B' = A' \circ (A \rightarrow B). \quad (14)$$

Wzór na funkcję przynależności zbioru B' zależy od przyjętej T-normy oraz od sposobu realizacji implikacji.

6. **Model Takagi-Sugeno:** W przypadku układów typu Takagi-Sugeno reguły rozmyte zapisujemy w postaci:

$$\text{Jeżeli } x = A \text{ to } y = f(x)$$

Najczęściej przedstawiona reguła przyjmuje postać, w której konkluzja jest kombinacją liniową wejść

$$\text{Jeżeli } x = A \text{ to } y = ax + b$$

W powyższym przypadku procedura wnioskowania rozmytego odbywa się identycznie jak w przypadku rozmytych systemów typu Mamdaniego przy czym następniki reguł rozmytych reprezentowane są przez zbiory rozmyte typu singleton.

7. **Wyostrzanie:** Wyostrzanie to proces wyboru właściwego elementu na podstawie rozmytego zbioru wyjściowego. W praktyce wymagane jest, aby wynikiem działania systemu rozmytego była wartość precyzyjna. Operacja wyostrzania pozwala na przekształcenie zbioru rozmytego w pojedynczą wartość numeryczną.

Metody wyostrzania:

- metoda środka ciężkości, COG (ang. Center Of Gravity)
- metoda pierwszego maksimum, FOM (ang. First Of Maxima)
- metoda średniego maksimum, MOM (ang. Mean Of Maxima)
- metoda środka sum, COS (ang. Center of Sum)
- metoda wysokości, HM (ang. Height Method)

Najczęściej z wymienionych metod wykorzystuje się metodę środka ciężkości (wz. 15) oraz metodę średniego (wz. 16, gdzie G jest zbiorem maksymalnych y_i).

$$y = \frac{\sum_{i=1}^n y_i \mu(y_i)}{\sum_{i=1}^n \mu(y_i)} \quad (15)$$

$$y = \frac{1}{m} \sum_{y_i \in G} y_i \quad (16)$$

8. Zadania:

- 8.1. Zapoznać się z GUI do projektowania systemów rozmytych (komenda *fuzzy*).
- 8.2. Zaprojektować system ogrzewania pomieszczenia zależny od temperatury zewnętrznej ($-20^{\circ}C$, $30^{\circ}C$) oraz wilgotności powietrza (0 – 100%). Wyjściem ma być moc grzałki z zakresu (0 – 1000)W. Zmienne lingwistyczne mają zawierać po 5 wartości. Przygotować system dla modelu Mamdaniego i Takagi- Sugeno. Porównać wyniki.
- 8.3. Sprawdzić dla zadania 2 wpływ zmiany metody wyostrzania oraz zmiany funkcji przynależności.
- 8.4. Zaprojektować samodzielnie system wspomaganie hamowania ABS przy użyciu logiki rozmytej.

Literatura

- [1] George J Klir and Baozung Yuan. *Fuzzy sets and fuzzy logic: theory and applications*, volume 574. Prentice Hall PTR New Jersey, 1995.
- [2] Fuzzy Logic. *Fuzzy logic and neural network handbook*. 1996.
- [3] Timothy J Ross et al. *Fuzzy logic with engineering applications*, volume 2. Wiley Online Library, 2004.
- [4] Lotfi Asker Zadeh. Fuzzy logic. *Computer*, 21(4):83–93, 1988.