

WIDZENIE KOMPUTEROWE

Klasyfikator Bayesowski. Logika rozmyta.

wykład częściowo oparty na materiałach UW

System wnioskowania

System wnioskowania to formalny aparat umożliwiający prowadzenie procesu wnioskowania – wyprowadzania nowych formuł z pewnego początkowego zbioru znanych formuł, nazywanego bazą wiedzy. Systemy wnioskowania dla języka logiki predykatów obejmują dwa składniki:

Aksjomaty: formuły, których prawdziwość przyjmowana jest bez dowodu.

Reguły wnioskowania: wzorce opisujące dozwolone sposoby bezpośredniego wyprowadzania nowych formuł ze znanych formuł.

Aksjomaty

Aksjomaty to formuły, których w systemie wnioskowania używa się wraz z formułami z początkowej bazy wiedzy jako „punktów startowych” wnioskowania, wyprowadzając z nich nowe formuły.

Przykładowe aksjomaty dla logiki predykatów, przy czym w trakcie wnioskowania x , y i z można zastąpić dowolnymi formułami innymi symbolami predykatowymi, zaś symbole zmiennych x i y można zastąpić dowolnymi innymi symbolami zmiennymi.

$$\alpha \vee \neg \alpha$$

$$\alpha \rightarrow (\beta \rightarrow \alpha)$$

$$(\alpha \rightarrow (\beta \rightarrow \gamma)) \rightarrow ((\alpha \rightarrow \beta) \rightarrow (\alpha \rightarrow \gamma))$$

Reguły wnioskowania

Reguła wnioskowania opisuje możliwą realizację pojedynczego kroku wnioskowania. Zwyczajowo regułę wnioskowania zapisuje się w następującej postaci:

$$\frac{\alpha_1, \alpha_2, \dots, \alpha_n}{\beta}$$

gdzie $\alpha_1, \alpha_2, \dots, \alpha_n$ oznaczają wzorce formuł wejściowych reguły, a β oznacza wzorec formuły wynikowej.

Zastosowanie reguły wnioskowania polega na odnalezieniu w bazie wiedzy (połączonej ze zbiorem aksjomatów) formuł pasujących do wzorców formuł wejściowych i wygenerowaniu odpowiedniej formuły wynikowej.

Przykładowe reguły wnioskowania

R1. Reguła *modus ponens*.

$$\frac{\alpha \rightarrow \beta, \alpha}{\beta}$$

R2. Reguła *modus tollens*.

$$\frac{\alpha \rightarrow \beta, \neg \beta}{\neg \alpha}$$

R3. Reguła *modus tollendo ponens*.

$$\frac{\alpha \vee \beta, \neg \beta}{\alpha}$$

R4.

$$\frac{\alpha_1, \alpha_2, \dots, \alpha_n}{\alpha_1 \wedge \alpha_2 \wedge \dots \wedge \alpha_n}$$

R5. Reguła koniunkcji.

$$\frac{\alpha_1 \wedge \alpha_2 \wedge \dots \wedge \alpha_n}{\alpha_1, \alpha_2, \dots, \alpha_n}$$

R6. Reguła specjalizacji.

$$\frac{(\forall x)\alpha}{\alpha[x/t]}$$

Niedoskonała wiedza we wnioskowaniu

Metody wnioskowania w logice predykatów są niezawodne, jeśli chodzi o prawdziwość wyciąganych wniosków. Oparte są one jednak na koniecznym założeniu, że stwierdzenia zawarte w początkowej bazie wiedzy i uznawane za prawdziwe są rzeczywiście prawdziwe. Pod warunkiem ich prawdziwości prawdziwe są także stwierdzenia wyprowadzane w wyniku wnioskowania.

Założenie to może często nie być spełnione w odniesieniu do wiedzy, którą posiada człowiek – wiedza pochodząca od człowieka może być niedoskonała. Stosując do takiej wiedzy metody zakładające doskonałą wiedzę jesteśmy narażeni na uzyskiwanie wniosków, które nie muszą być prawdziwe i o których prawdziwości nie potrafimy nic powiedzieć.

Celowe jest w związku z tym wyposażanie systemów wnioskujących na podstawie niedoskonałej wiedzy w specjalne mechanizmy jej przetwarzania, dzięki którym będzie możliwe charakteryzowanie rodzaju i stopnia niedoskonałości wiedzy pochodzącej od człowieka, a także nowej wiedzy wyprowadzonej na jej podstawie przez system wnioskujący.

Rodzaje niedoskonałości wiedzy

Trzy podstawowe rodzaje:

niepewność: prawdziwość niektórych stwierdzeń nie jest pewna,

niepełność: niektóre prawdziwe stwierdzenia nie są znane, lecz nie można z tego powodu zakładać ich nieprawdziwości,

niedokładność: przynależność do niektórych relacji, odpowiadających predykatom występującym w stwierdzeniach, nie jest znana dokładnie.

W przypadku wiedzy niepewnej mamy do czynienia ze stwierdzeniami, o których w ogólnym przypadku nie można powiedzieć z pewnością, że są prawdziwe albo fałszywe. Potrzebne są w tym celu jakieś metody charakteryzowania stopnia przekonania o prawdziwości stwierdzeń, zarówno tych należących do początkowej bazy wiedzy, jak i uzyskiwanych w wyniku wnioskowania.

Niepełność wiedzy oznacza, że status prawdziwości pewnych stwierdzeń potrzebnych do wnioskowania nie jest znany. Może to wymagać założenia ich prawdziwości w celu przeprowadzenia wnioskowania, lecz z pozostawieniem możliwości rewizji tego wnioskowania, gdyby następnie pojawiła się wiedza zaprzeczająca temu założeniu.

Niedokładność polega na niemożliwości precyzyjnego odróżnienia w dziedzinie na temat której zapisujemy wiedzę, obiektów należących do pewnej relacji od obiektów do niej nie należących.

Metody przetwarzania niedoskonałej wiedzy

Do najbardziej znanych metod należą:

wnioskowanie probabilistyczne: metoda przetwarzania wiedzy niepewnej oparta na bezpośrednim wykorzystaniu rachunku prawdopodobieństwa, w której poszczególnym stwierdzeniom przypisuje się prawdopodobieństwo ich prawdziwości,

stopnie pewności: metoda przetwarzania wiedzy niepewnej, w której poszczególnym stwierdzeniom przypisuje się liczbowe stopnie pewności wyrażające subiektywne przekonanie człowieka o ich prawdziwości,

teoria Dempstera-Schaffera: metoda przetwarzania wiedzy niepewnej, w której prawdopodobieństwa prawdziwości przypisuje się tylko wybranym stwierdzeniom bazowym, a ocenę wiarygodności innych stwierdzeń przeprowadza się na podstawie ich związków ze stwierdzeniami bazowymi,

logika rozmyta: metoda przetwarzania wiedzy niedokładnej, w której rozważa się „częściową” przynależność do relacji,

logiki niemonotoniczne: metody przetwarzania wiedzy niepełnej, w których dopuszcza się, że pojawienie się nowych stwierdzeń może anulować wyprowadzenie wcześniejszych formuł.

Wnioskowanie probabilistyczne (bayesowskie)

Dla dowolnych dwóch zdarzeń A , i B , wzór Bayesa opisuje następującą zależność prawdopodobieństw warunkowych:

$$\Pr(A|B) = \frac{\Pr(A)\Pr(B|A)}{\Pr(B)}$$

Uprawdopodobnianie hipotez przez fakty

Wśród stwierdzeń, jakie są przetwarzane przy wnioskowaniu, wyróżnimy dwie kategorie:

fakty: stwierdzenia dotyczące dziedziny, których prawdziwość jest znana,

hipotezy: stwierdzenia o nieznanym prawdopodobieństwie prawdziwości.

Wnioskowanie o prawdziwości możliwych hipotez przy założeniu prawdziwości pewnego zestawu faktów

Wzór Bayesa ze zmienionymi oznaczeniami:

$$\Pr(h|F) = \frac{\Pr(h)\Pr(F|h)}{\Pr(F)}$$

gdzie h , oznacza pewną hipotezę, a F pewien zbiór faktów. Tak interpretowany wzór Bayesa mówi, w jaki sposób na prawdopodobieństwo rozważanej hipotezy wpływa znajomość faktów.

$\Pr(h)$: prawdopodobieństwo *a priori* hipotezy h , (bez znajomości lub uwzględniania żadnych faktów),

$\Pr(h/F)$: prawdopodobieństwo *a posteriori* hipotezy h , po uwzględnieniu faktów F ,

$\Pr(F)$: prawdopodobieństwo wystąpienia faktów F ,

$\Pr(F/h)$: prawdopodobieństwo, że fakty F należą do hipotezy h .

Wzór Bayesa, podając przepis na wyznaczenie prawdopodobieństwa *a posteriori*, określa wpływ faktów na uprawdopodobnienie hipotezy. Bezpośrednie zastosowanie w przedstawiony sposób wzoru Bayesa można traktować jako elementarny krok wnioskowania bayesowskiego, który jest w pewnym sensie odpowiednikiem zastosowania reguły wnioskowania w logice.

Prawdopodobieństwo występujące w mianowniku ułamka nie zależy od rozważanej hipotezy. Wynika z tego, że gdyby interesowało nas wyłącznie wybranie hipotezy najbardziej prawdopodobnej z pewnego zestawu, wystarczy ograniczyć się do obliczenia licznika ułamka.

Aby poznać dokładne, bezwzględne wartości prawdopodobieństw a posteriori poszczególnych hipotez, należy wziąć pod uwagę sytuację, w której mamy skończoną liczbę możliwych hipotez h_1, h_2, \dots, h_n , wykluczających się parami i wyczerpujących wszystkie możliwości (czyli takich, że dokładnie jedna z nich jest prawdziwa). Wówczas:

$$\Pr(F) = \Pr(h_1)\Pr(F|h_1) + \dots + \Pr(h_n)\Pr(F|h_n)$$

czyli:

$$\Pr(h_i|F) = \frac{\Pr(h_i)\Pr(F|h_i)}{\sum_{j=1}^n \Pr(h_j)\Pr(F|h_j)}$$

Zachodzi:

$$\sum_{i=1}^n \Pr(h_i|F) = 1$$

W szczególności biorąc pod uwagę dwie wykluczające się hipotezy h , i $\neg h$, dostajemy:

$$\Pr(h|F) = \frac{\Pr(h)\Pr(F|h)}{\Pr(h)\Pr(F|h) + \Pr(\neg h)\Pr(F|\neg h)}$$

$$\Pr(\neg h|F) = \frac{\Pr(\neg h)\Pr(F|\neg h)}{\Pr(h)\Pr(F|h) + \Pr(\neg h)\Pr(F|\neg h)}$$

Uwzględnianie pojedynczych faktów

Problematyczne jest określanie prawdopodobieństwa $\Pr(F/h)$, gdyż F , może oznaczać dowolny zbiór znanych faktów. Jeśli mamy ustalony pewien zbiór F' , wszystkich możliwych faktów, które mogą być uwzględniane przy wnioskowaniu, to F , może być jego dowolnym podzbiorem. Bezpośrednie przypisanie każdemu podzbiorniowi prawdopodobieństwa na ogół przekraczałoby możliwości eksperta czy użytkownika systemu wnioskującego.

Przy pewnych założeniach można uniknąć konieczności określania $\Pr(F/h)$ dla dowolnego $F \subseteq F'$, opierając się wyłącznie na prawdopodobieństwach dla pojedynczych faktów $\Pr(f/h)$, gdzie $f \in F'$.

Dla dowolnego faktu f_1 możemy – stosując wzór Bayesa – uzyskać:

$$\Pr(h|f_1) = \frac{\Pr(h)\Pr(f_1|h)}{\Pr(f_1)}$$

Dokładając kolejny znany fakt f_2 , rozważając dwuelementowy zbiór faktów $\{f_1, f_2\}$, otrzymujemy:

$$\Pr(h|f_1 \wedge f_2) =$$

$$\frac{\Pr(h|f_1)\Pr(f_2|f_1 \wedge h)}{\Pr(f_2|f_1)} =$$

$$\frac{\Pr(h)\Pr(f_1|h)\Pr(f_2|f_1 \wedge h)}{\Pr(f_1)\Pr(f_2|f_1)} =$$

$$\frac{\Pr(h)\Pr(f_1|h)\Pr(f_2|f_1 \wedge h)}{\Pr(f_1)\Pr(f_2|f_1)} =$$

$$\frac{\Pr(h)\Pr(f_1|h)\Pr(f_2|f_1 \wedge h)}{\Pr(f_1 \wedge f_2)}$$

Jeśli założymy, że pojedyncze fakty są warunkowo niezależne względem hipotezy, czyli:

$$\Pr(f_2|f_1 \wedge h) = \Pr(f_2|h)$$

$$\Pr(f_1|f_2 \wedge h) = \Pr(f_1|h)$$

to uzyskujemy:

$$\Pr(h|f_1 \wedge f_2) = \frac{\Pr(h)\Pr(f_1|h)\Pr(f_2|h)}{\Pr(f_1 \wedge f_2)}$$

dla dowolnej liczby pojedynczych faktów, co prowadzi do ogólnego wzoru:

$$\Pr(h|f_1 \wedge f_2 \wedge \dots \wedge f_m) = \frac{\Pr(h) \prod_{k=1}^m \Pr(f_k|h)}{\Pr(f_1 \wedge f_2 \wedge \dots \wedge f_m)}$$

Aby posłużyć się nim w celu obliczenia bezwzględnych prawdopodobieństw *a posteriori*, należy tak jak poprzednio wziąć pod uwagę zbiór $\{h_1, h_2, \dots, h_n\}$ hipotez wykluczających się parami i wyczerpujących wszystkie możliwości. Wówczas, przy założeniu warunkowej niezależności faktów względem każdej hipotezy, mianownik powyższego ułamka może być wyznaczony w następujący sposób:

$$\Pr(f_1 \wedge f_2 \wedge \dots \wedge f_m) = \sum_{i=1}^n \Pr(h_i) \prod_{k=1}^m \Pr(f_k|h_i)$$

W szczególności dla zbioru dwóch wykluczających się hipotez $\{h, \neg h\}$, dostajemy w ten sposób:

$$\Pr(f_1 \wedge f_2 \wedge \dots \wedge f_m) = \Pr(h) \prod_{k=1}^m \Pr(f_k|h) + \Pr(\neg h) \prod_{k=1}^m \Pr(f_k|\neg h)$$

Uzyskaliśmy prosty mechanizm wnioskowania bayesowskiego, w którym możemy wyznaczać prawdopodobieństwa *a posteriori* dowolnych hipotez na podstawie znajomości dowolnych zbiorów faktów, pod warunkiem określenia prawdopodobieństw *a priori* każdej hipotezy oraz prawdopodobieństw każdego pojedynczego faktu pod warunkiem prawdziwości każdej hipotezy. Prawdopodobieństwa te stanowią reprezentację niepewnej wiedzy o dziedzinie wnioskowania, która musi być dostarczona systemowi wnioskującemu. Określenie tych prawdopodobieństw w rozsądny sposób jest często możliwe, chociaż oczywiście może niekiedy być trudne.

Przykład: Rozpoznawanie, czy na zdjęciu jest twarz

Rozważmy następującą prostą ilustrację przedstawionego mechanizmu wnioskowania, traktując rozważane w niej przykładowe fakty i hipotezy z należnym dystansem. Weźmiemy pod uwagę sytuację, w której rozpoznając obraz ograniczono zbiór możliwych rozpoznań do następujących dwóch wykluczających się hipotez:

h : na zdjęciu jest twarz,

$\neg h$: na zdjęciu nie ma twarzy.

Niech podstawą do wnioskowania będą następujące pojedyncze fakty:

f_1 : na zdjęciu występują określone kolory (kolory skóry),

f_2 : na zdjęciu jest owal,

f_3 : na zdjęciu występują charakterystyczne gradienty.

Przyjmijmy, że dostarczający wiedzę do systemu rozpoznającego ekspert ustalił następujące wartości prawdopodobieństw:

$$\begin{aligned}\Pr(h) &= 0.1 & \Pr(\neg h) &= 0.9 \\ \Pr(f_1|h) &= 0.5 & \Pr(f_1|\neg h) &= 0.3 \\ \Pr(f_2|h) &= 0.3 & \Pr(f_2|\neg h) &= 0.3 \\ \Pr(f_3|h) &= 0.8 & \Pr(f_3|\neg h) &= 0.4\end{aligned}$$

Na tej podstawie obliczamy prawdopodobieństwa faktów:

$$\Pr(f_1) = \Pr(h)\Pr(f_1|h) + \Pr(\neg h)\Pr(f_1|\neg h) = 0.1 \cdot 0.5 + 0.9 \cdot 0.3 = 0.32$$

$$\Pr(f_2) = \Pr(h)\Pr(f_2|h) + \Pr(\neg h)\Pr(f_2|\neg h) = 0.1 \cdot 0.3 + 0.9 \cdot 0.3 = 0.3$$

$$\Pr(f_3) = \Pr(h)\Pr(f_3|h) + \Pr(\neg h)\Pr(f_3|\neg h) = 0.1 \cdot 0.8 + 0.9 \cdot 0.4 = 0.44$$

Aby wyznaczyć prawdopodobieństwa *a posteriori* rozważanych hipotez na podstawie każdego z pojedynczych objawów należy zastosować bezpośrednio wzór Bayesa:

$$\Pr(h|f_1) = \frac{\Pr(h)\Pr(f_1|h)}{\Pr(f_1)} = \frac{0.1 \cdot 0.5}{0.32} = 0.15625$$

$$\Pr(h|f_2) = \frac{\Pr(h)\Pr(f_2|h)}{\Pr(f_2)} = \frac{0.1 \cdot 0.3}{0.3} = 0.1$$

$$\Pr(h|f_3) = \frac{\Pr(h)\Pr(f_3|h)}{\Pr(f_3)} = \frac{0.1 \cdot 0.8}{0.44} = 0.18182$$

W ten sam sposób można wyliczyć prawdopodobieństwa rozważanych hipotez na podstawie dowolnych dwóch cech oraz wszystkich trzech cech.

Logika rozmyta (fuzzy logic)

Logika rozmyta została wprowadzona jako metoda reprezentacji i przetwarzania wiedzy o charakterze jakościowym. Podstawową zaletą logiki rozmytej jest stworzenie ścisłej interpretacji wiedzy o charakterze zdroworozsądkowym, która bazuje na pojęciach intuicyjnych lub kolokwialnych, takich jak „wysoki wzrost”, „wysokie dochody”, „niska cena”, „duża prędkość” itp. Pojęcia takie mogą być wykorzystane w połączeniu z regułami podobnymi jak w systemach wnioskowania w tradycyjnej logice.

Zbiór rozmyty

Zbiór rozmyty jest uogólnieniem pojęcia zbioru.

Rozważmy zbiór wartości D . Każdy podzbiór $A \in D$ może być opisany za pomocą funkcji charakterystycznej χ_A , zdefiniowanej następująco:

$$\chi_A = \begin{cases} 0 & x \notin A \\ 1 & x \in A \end{cases}$$

Zatem każdy element x z D albo należy do A (wówczas $\chi_A(x) = 1$), albo do niego nie należy (a wtedy $\chi_A(x) = 0$). Z kolei zbiór rozmyty A będący podzbiorem D ma tę cechę, że elementy mogą do niego należeć tylko częściowo. Odpowiednikiem funkcji charakterystycznej χ_A jest funkcja przynależności, przyjmująca wartości $0 \leq \mu_A(x) \leq 1$. Wartość 0 funkcji przynależności oznacza, że element x nie należy do zbioru A , zaś wartość większa od zera oznacza przynależność x do A .

Operacje na zbiorach rozmytych

Dopełnieniem zbioru $A \subset D$ jest zbiór $\bar{A} \subset D$, którego funkcja przynależności jest określona następująco:

$$\forall x \in D \quad \mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

Sumą zbiorów $A \subset D$ i $B \subset D$ jest taki zbiór $C \subset D$, którego funkcja przynależności jest określona następująco:

$$\forall x \in D \quad \mu_C(x) = S(\mu_A(x), \mu_B(x)),$$

gdzie S jest funkcją, nazywaną s-normą, spełniająca następujące warunki:

$$S(m, n) \geq m, \quad S(m, n) \geq n, \quad S(m, n) \leq 1$$

Iloczynem zbiorów $A \subset D$ i $B \subset D$ jest taki zbiór $C \subset D$, którego funkcja przynależności jest określona następująco:

$$\forall x \in D \quad \mu_C(x) = P(\mu_A(x), \mu_B(x)),$$

gdzie P jest funkcją, nazywaną p-normą, spełniająca następujące warunki:

$$P(m, n) \leq m, \quad P(m, n) \leq n, \quad P(m, n) \geq 0$$

Typowo wybiera się jako s-normę i p-normę następujące pary funkcji:

s-norma: $\max(m, n)$; p-norma: $\min(m, n)$ lub s-norma: $\min(m+n, 1)$; p-norma: $m * n$

Logika rozmyta

Założmy, że D jest zbiorem wartości argumentu pewnej funkcji zdaniowej $f(x)$. Posługując się tradycyjną definicją zbioru możemy definiować zbiór A argumentów funkcji zdaniowej $f(x)$, dla których przyjmuje ona wartość „prawda”. Funkcja charakterystyczna χ_A jednoznacznie wyznacza funkcję zdaniową, ponieważ $f(x) = \text{„prawda”}$ wtedy i tylko wtedy gdy $\chi_A = 1$.

Tak więc pojęcia prawdy i fałszu mogą być zdefiniowane za pomocą funkcji charakterystycznej zbioru.

W przypadku zbiorów rozmytych prowadzi to do uogólnienia pojęcia prawdy – pojawia się „prawda częściowa”, której miernikiem jest wartość funkcji przynależności. Funkcje zdaniowe mogą przyjmować wartości z zakresu $[0,1]$.

Korzystając z definicji operacji na zbiorach, można podać definicje negacji, alternatywy i koniunkcji, działające na wartościach z zakresu $[0,1]$.

Negacją rozmytą wartości $x \in [0,1]$ jest wartość

$$y = \neg x = 1 - x$$

Alternatywą rozmytą wartości $x, y \in [0,1]$ jest wartość

$$z = x \vee y = S(x, y)$$

gdzie S oznacza s-normę

Koniunkcją rozmytą wartości $x, y \in [0, 1]$ jest wartość

$$z = x \wedge y = P(x, y)$$

gdzie P oznacza p-normę.

Wnioskowanie rozmyte

Wnioskowanie jest procesem polegającym na sprawdzaniu możliwości wyprowadzenia formuły ze zbioru innych formuł, przy znanych regułach. Wnioskowanie rozmyte przebiega według takiego samego schematu jak wnioskowanie w logice klasycznej, z tym że definicje reguł wnioskowania ulegają modyfikacjom uwzględniającym konieczność posługiwania się wartościami „prawdziwości” z zakresu $[0, 1]$.

Przykład: reguła modus ponens

$$\frac{\alpha \rightarrow \beta, \alpha}{\beta}$$

Zakładamy tutaj, że reguła $\alpha \rightarrow \beta$ jest prawdziwa w stopniu 1, natomiast stopień prawdziwości formuły β jest identyczny stopniowi prawdziwości formuły α .

Prosty regulator rozmyty (FLC)

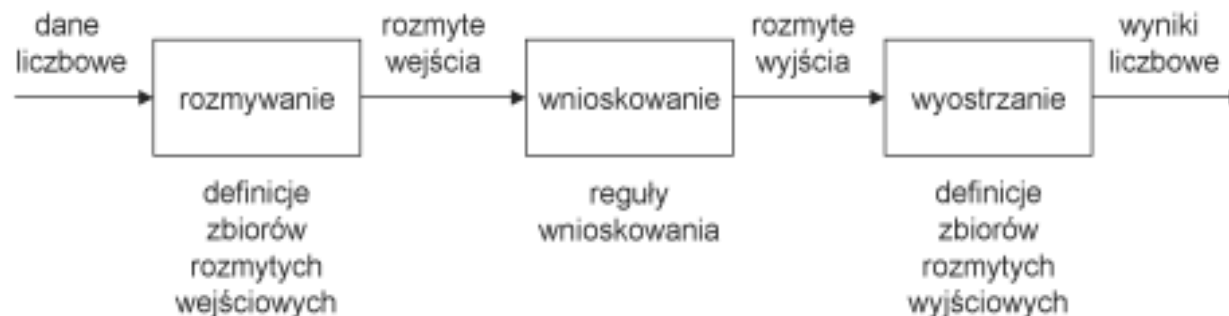
Logika rozmyta jest wykorzystywana na szerszą skalę przede wszystkim w systemach sterowania.

Przykład.

Prosty regulator rozmyty (FLC – fuzzy logic controller), którego zadaniem jest obserwacja wartości wielu sygnałów wejściowych (zakłóceń) i określanie wartości sygnału wyjściowego (sterowania), np. do sterowania siłą ciągu odkurzacza, określenia ustawień czasu naświetlania i przesłony na podstawie pomiaru natężenia oświetlenia, określania nastaw filtrów obrazu itp.

W takich zastosowaniach łatwo jest wyrazić sposób obsługi urządzenia za pomocą prostych reguł typu: „jeśli temperatura pomieszczenia jest niska i wolno spada, to ogrzewanie powinno być silniejsze”. Cechą charakterystyczną tego rodzaju reguł jest określanie wartości wielkości wejściowych i wyjściowych za pomocą wartości nieprecyzyjnych (typu „niskie”, „wysokie”, „szybkie”, „wolne”). W regulatorze FLC takie nieprecyzyjne wartości są reprezentowane jako rozmyte funkcje zdaniowe.

Schemat działania regulatora FLC:



Regulator obserwuje liczbowe wartości wielkości wejściowe. Wartości te są poddawane rozmywaniu: są zamieniane na ich jakościowe odpowiedniki –

wartości lingwistyczne, na przykład „mały”, „średni” i „duży”. Wynikiem rozmywania jest utworzenie wielu stwierdzeń, typu „x jest mały”, których stopień prawdziwości wynika z wartości funkcji zdaniowych dla obserwowanych wartości wejściowych.


Regulator FLC jest wyposażony w zestaw reguł, których części przesłankowe są koniunkcjami stwierdzeń, zaś konkluzjami są stwierdzenia (rozmyte) o wielkości wyjściowej.

W czasie wnioskowania, dla każdej reguły z bazy reguł określa się stopień prawdziwości części przesłankowej (na podstawie stwierdzonego w fazie rozmywania stopnia prawdziwości każdego ze stwierdzeń). W ten sposób, stosując reguły, otrzymuje się wiele stwierdzeń (rozmytych) o wartości wielkości wyjściowej; stwierdzenia te pozostają ze sobą w alternatywie. Otrzymuje się zatem nową funkcję zdaniową $f_y : D_y \rightarrow [0, 1]$ (D_y jest zbiorem wartości wielkości wejściowej), będącą wynikiem etapu wnioskowania.

Ostatnim etapem jest wyostrzenie, w którym wyznacza się wartość liczbową wielkości wyjściowej na podstawie uzyskanej w czasie wnioskowania funkcji zdaniowej – mamy zastąpić funkcję f_y jedną liczbą. Wykonujemy zatem działanie zbliżone do obliczenia wartości oczekiwanej zmiennej losowej na podstawie znajomości jej funkcji gęstości, np. metodą środka ciężkości CoA (ang. Center of Area):

$$y_{CoA} = \frac{\int_D x f_y(x) dx}{\int_D f_y(x) dx}$$


Symulacja FLC



Zadanie polega na podjęciu decyzji o wartości przyspieszenia samochodu w sytuacji dojeżdżania do skrzyżowania, na którym światło zmieniło się z zielonego na żółte.

Wielkościami wpływającymi na decyzję będą: aktualna prędkość samochodu i odległość od skrzyżowania.

Pomierzone wartości tych wielkości są następnie poddawane rozmywaniu: są zamieniane na ich jakościowe odpowiedniki: „mały”, „średni” i „duży”, wg rysunków.



Rozważmy trzy przypadki wielkości wejściowych:

1.

odległość	prędkość
30	50

2.

odległość	prędkość
100	50

3.

odległość	prędkość
30	65

Rozmywanie.

Odczytane z wykresów wartości lingwistyczne są dla poszczególnych przypadków następujące:

1.

	odległość	prędkość
mała	0,6	0,3
średnia	0,4	0,7
duża	0	0

2.

	odległość	prędkość
mała	0	0,3
średnia	1	0,7
duża	0	0

3.

	odległość	prędkość
mała	0,6	0
średnia	0,4	1
duża	0	0

Wnioskowanie.

Niech wnioskowanie odbywa się zgodnie z zestawem reguł:

odległość	prędkość	przyspieszenie
mała	mała	duże-
średnia	mała	małe-
duża	mała	małe-
mała	średnia	duże+
średnia	średnia	małe-
duża	średnia	małe-
mała	duża	małe+
średnia	duża	duże-
duża	duża	małe-

Reguły wnioskowania wraz ze stopniem prawdziwości konkluzji (określonym na podstawie koniunkcji przesłanek) dla rozważanych przypadków (pominięte zostały reguły z nieprawdziwą koniunkcją przesłanek):

1.

odległość	prędkość	przyspieszenie	$\min(\text{odległość}, \text{prędkość})$
mała	mała	duże-	0,3
średnia	mała	małe-	0,3
mała	średnia	duże+	0,6
średnia	średnia	małe-	0,4

2.

odległość	prędkość	przyspieszenie	$\min(\text{odległość}, \text{prędkość})$
mała	średnia	duże+	0,3
średnia	średnia	małe-	0,7

3.

odległość	prędkość	przyspieszenie	$\min(\text{odległość}, \text{prędkość})$
mała	średnia	duże+	0,6
średnia	średnia	małe-	0,4

Wynikiem wnioskowania są następujące wartości lingwistyczne (podane wraz ze stopniem prawdziwości):

1.

przyspieszenie	
duże-	0,3
małe-	0,3
małe+	0
duże+	0,6

2.

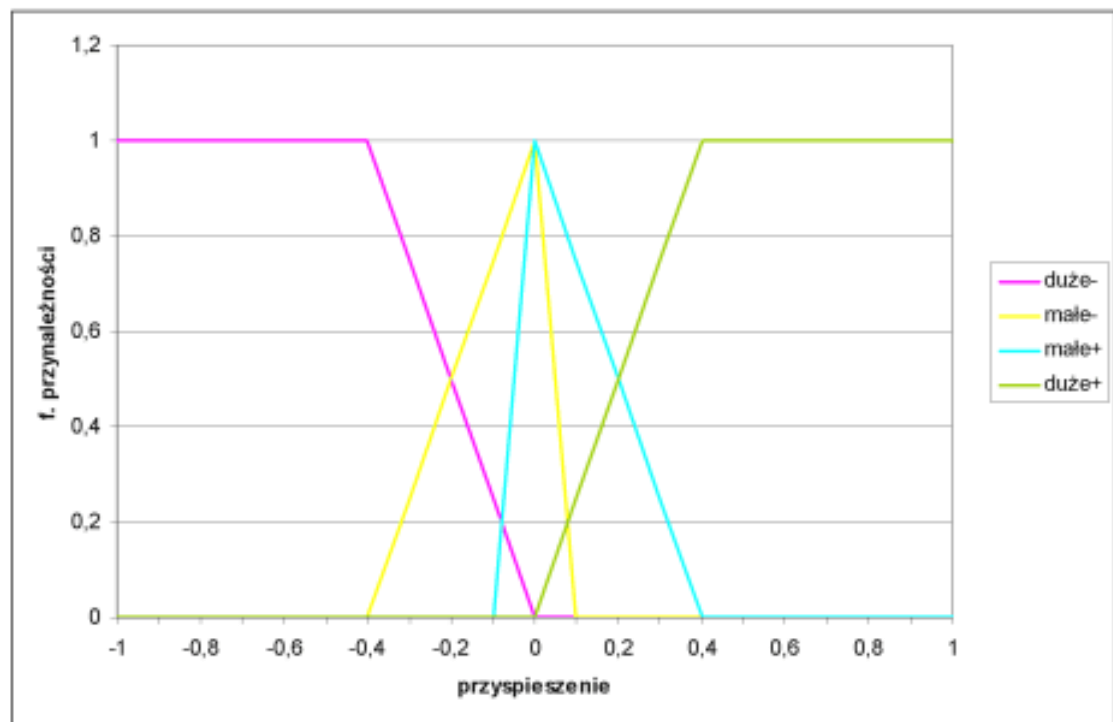
przyspieszenie	
duże-	0
małe-	0,7
małe+	0
duże+	0,3

3.

przyspieszenie	
duże-	0
małe-	0,4
małe+	0
duże+	0,6


Wyostrzanie.

Założmy funkcje przynależności dla zmiennej wyjściowej jak na poniżej:




W wyniku wnioskowania, dla każdego z rozważanych trzech przypadków, otrzymamy inne kształty funkcji przynależności, zobrazowane na rysunkach poniżej. W celu wyznaczenia wartości liczbowej przyspieszenia zastosujemy metodę środka ciężkości (CoA).

Zestaw 1:



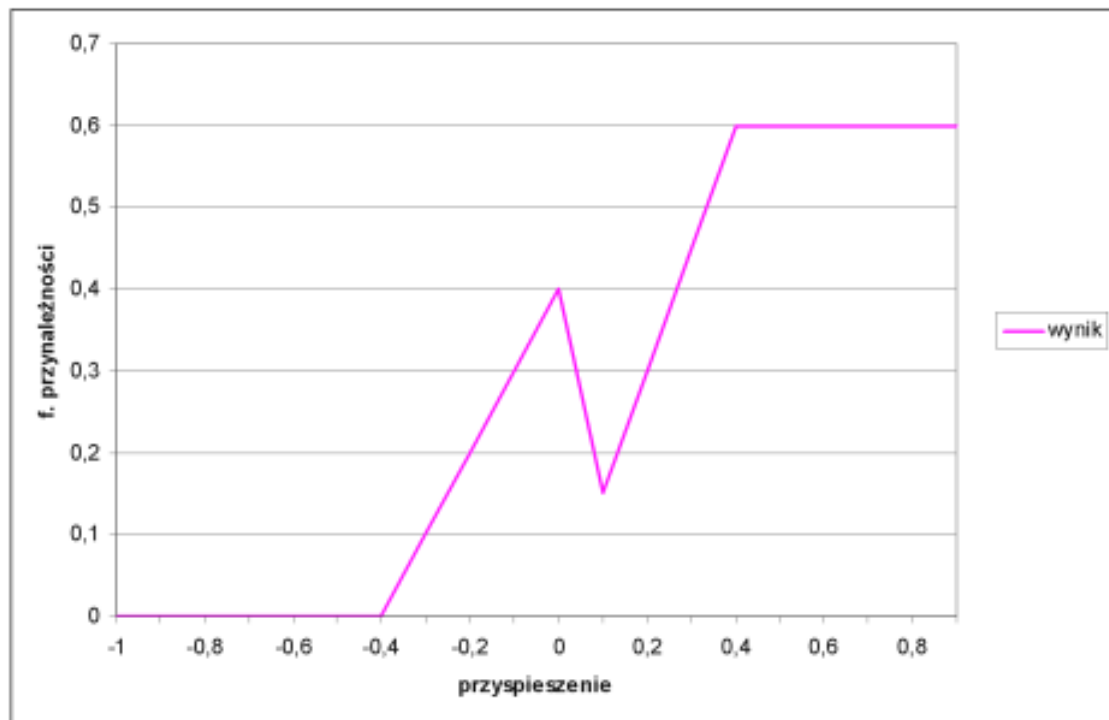
Wynik wyostrzania: 0.150

Zestaw 2:



Wynik wyostrzania: 0.140

Zestaw 3:



Wynik wyostrzania: 0.305