

## Zastosowania logiki rozmytej

### Wstęp

Do tej pory omawialiśmy, w jaki sposób logika rozmyta może być używana w połączeniu z sieciami neuronowymi: W Części 3 przyjrzelśmy się mechanizmowi rozmycia, który pobiera wyraźne dane wejściowe i tworzy rozmyte dane wyjściowe, które następnie mogą być używane jako dane wejściowe do sieci neuronowej. W Części 9 użyliśmy logiki rozmytej do stworzenia specjalnego typu pamięci skojarzeniowej zwanego FAM (pamięć skojarzona rozmyta). W tym rozdziale skupimy się na samych zastosowaniach logiki rozmytej. Ten rozdział rozpoczyna się od przeglądu różnych typów obszarów zastosowań logiki rozmytej. Następnie przedstawiamy dwie dziedziny zastosowań logiki rozmytej: rozmyte systemy sterowania oraz rozmyte bazy danych i kwantyfikację. W tych sekcjach wprowadzamy również kilka innych pojęć z teorii logiki rozmytej.

### Rozmyty wszechświat aplikacji

Logika rozmyta jest stosowana do wielu różnych problemów. Najbardziej wszechobecnym obszarem wpływu są systemy sterowania, z szybką akceptacją sterowników logiki rozmytej (FLC) do sterowania maszynami i procesami. Istnieje wiele innych obszarów, w których stosowana jest logika rozmyta. Oto krótka lista zaadaptowana przez Yana, z przykładami w każdym obszarze:

- Nauki biologiczne i medyczne Systemy diagnostyczne oparte na logice rozmytej, badania nad rakiem, manipulacje na urządzeniach protetycznych oparte na logice rozmytej, analiza zaburzeń ruchowych oparta na logice rozmytej, itp.
- Zarządzanie i wspomaganie decyzji Wybór lokalizacji fabryki oparty na logice rozmytej, logika rozmyta wspomagana w podejmowaniu decyzji wojskowych (brzmi przerażająco, ale pamiętaj, że rozmyta logika rozmyta dotyczy niedokładności danych, a nie logiki), podejmowanie decyzji w oparciu o logikę rozmytą strategię marketingowe itp.
- Ekonomia i finanse Modelowanie rozmyte złożonych systemów marketingowych, systemy handlowe oparte na logice rozmytej, analiza kosztów i korzyści oparta na logice rozmytej, ocena inwestycji oparta na logice rozmytej itp.
- Nauka o środowisku Prognozowanie pogody oparte na logice rozmytej, kontrola jakości wody oparta na logice rozmytej itp.
- Inżynieria i informatyka Systemy baz danych rozmytych, przewidywanie trzęsień ziemi w oparciu o logikę rozmytą, automatyzację sterowania elektrownią jądrową w oparciu o logikę rozmytą, projektowanie sieci komputerowych w oparciu o logikę rozmytą, ocenę projektu architektonicznego w oparciu o logikę rozmytą, systemy sterowania oparte na logice rozmytej, itp.
- Badania operacyjne Planowanie i modelowanie oparte na logice rozmytej, alokacja zasobów oparta na logice rozmytej itp.
- Rozpoznawanie i klasyfikacja wzorców Rozpoznawanie mowy oparte na logice rozmytej, rozpoznawanie pisma ręcznego oparte na logice rozmytej, analiza charakterystyki twarzy oparta na logice rozmytej, analiza poleceń wojskowych oparta na logice rozmytej, wyszukiwanie obrazów rozmytych itp.
- Psychologia Analiza ludzkiego zachowania oparta na logice rozmytej, dochodzenia kryminalne i prewencja w oparciu o rozumowanie oparte na logice rozmytej itp.

- Niezawodność i kontrola jakości Diagnostyka awarii oparta na logice rozmytej, monitorowanie i kontrola linii produkcyjnej itp.

Przejdziemy teraz do jednej z dwóch domen aplikacji, które szczegółowo omówimy, Fuzzy Databases. W dalszej części rozdziału przyjrzymy się drugiej domenie aplikacji, rozmytym systemom sterowania.

### **Sekcja I: Spojrzenie na rozmyte bazy danych i kwantyfikacja**

W tej sekcji chcemy przyjrzeć się niektórym sposobom zastosowania logiki rozmytej do baz danych i operacji na bazach danych. Standardowe bazy danych zawierają wyraźne zestawy danych i tworzą jednoznaczne relacje na zestawach danych. Tworzą również zapytania, które są konkretne i nie mają żadnych niejednoznaczności. Wprowadzenie niejednoznaczności w co najmniej jednym z tych aspektów standardowych baz danych prowadzi do pomysłów na zastosowanie logiki rozmytej do baz danych. Takie zastosowanie logiki rozmytej może oznaczać, że otrzymujesz bazy danych, które są łatwiejsze do wyszukiwania i łatwiejsze w interfejsie. Wyszukiwanie rozmyte, w którym kryteria wyszukiwania nie są ściśle określone, może być bardziej odpowiednie niż wyszukiwanie precyzyjne. Możesz przywołać dowolną liczbę sytuacji, w których masz tendencję do zadawania niejednoznacznych pytań, ponieważ nie jesteś pewien, czego potrzebujesz. Masz również tendencję do zadawania niejednoznacznych zapytań, gdy wartość „parku piłki” jest wystarczająca do twoich celów. W tej sekcji nauczysz się również kilku pojęć logiki rozmytej. Zobaczysz te pojęcia wprowadzone tam, gdzie pojawiają się w dyskusji na temat pomysłów związanych z rozmytymi bazami danych. Czasami możesz zauważyć pewną dygresję w środku dyskusji o bazie danych rozmytych do tematów logiki rozmytej. Możesz przejść do obszaru, w którym wznawiana jest dyskusja o rozmytej bazie danych i wrócić do pominiętych obszarów, gdy poczujesz potrzebę aby uzyskać wyjaśnienie koncepcji. Zaczniemy od przykładu standardowej bazy danych, relacji i zapytań. Następnie wskazujemy niektóre sposoby, w jakie można wprowadzić rozmycie.

#### **Bazy danych i zapytania**

Wyobraź sobie, że interesuje Cię biznes turystyczny. Być może próbujesz zaprojektować specjalne wycieczki w różnych krajach z własnym zespołem przewodników itp. i chcesz znaleźć odpowiednie osoby na te stanowiska. Na początku, powiedzmy, interesują Cię ich własne doświadczenia w podróżowaniu i posiadana przez nich wiedza z zakresu geografii, zwyczajów, języka, specjalnych okazji itp. Informacje, które chcesz zachować w swojej bazie danych, mogą być podobne do , kim jest dana osoba, obywatelstwo osoby, dokąd podróżowała, kiedy taka podróż miała miejsce, długość pobytu w tym miejscu docelowym, języki osoby, języki, które osoba rozumie, liczba podróży, które osoba

do każdego miejsca podróży itp. Użyjmy kilku skrótów:

cov—kraj odwiedzony

lov — długość wizyty (dni)

nov — liczba wizyt z uwzględnieniem poprzednich wizyt

ctz — obywatelstwo

yov — rok wizyty

lps — język (inny niż ojczysty) ze znajomością mowy

lpu — język mający jedynie biegłość w zrozumieniu

hs — historia była badana (1 — tak, 0 — nie)

Typowe wpisy mogą pojawić się, jak zaznaczono w tabeli 16.1.

Name	age	ctz	cov	lov	nov	yov	lps	lpu	hs
John Smith	35	U.S.	India	4	1	1994		Hindi	1
John Smith	35	U.S.	Italy	7	2	1991	Italian		1
John Smith	35	U.S.	Japan	3	1	1993			0

W przypadku zapytania dotyczącego listy osób, które odwiedziły Indie lub Japonię po 1992 roku przez 3 lub więcej dni, uwzględnione zostaną dwa wpisy Johna Smitha. Warunki podane dla tego zapytania są proste, z  $lov \geq 3$  i  $yov > 1992$  oraz ( $cov = \text{India}$  lub  $cov = \text{Japonia}$ ).

### Relacje w bazach danych

Relacja z tej bazy danych może być zbiorem pięciokrotnych (imię, wiek, cov, lov, yov). Innym może być zestaw trójek (nazwa, ctz, lps). Pięciokrotny (John Smith, 35, India, 4, 1994) należy do poprzedniej relacji, a trójka (John Smith, USA, włoski) należy do tego ostatniego. Możesz także zdefiniować inne relacje.

### Scenariusze rozmyte

Teraz część zapytania może być rozmyta, prosząc o listę młodych osób, które niedawno odwiedziły Japonię lub Indie na kilka dni. Wpisy Johna Smitha mogą, ale nie muszą, zostać uwzględnione tym razem, ponieważ nie jest jasne, czy John Smith jest uważany za młody, czy rok 1993 jest uważany za niedawny, czy też 3 dni kwalifikują się jako kilka dni dla zapytania. Ta modyfikacja zapytania ilustruje jeden z trzech scenariuszy, w których rozmycie może zostać wprowadzone do baz danych i ich wykorzystanie. Tak jest w przypadku, gdy baza danych i relacje są standardowe, ale zapytania mogą być rozmyte. Inne przypadki to: jeden, w którym baza danych jest rozmyta, ale zapytania są standardowe, bez dwuznaczności; i taki, w którym masz zarówno rozmytą bazę danych, jak i kilka rozmytych zapytań.

### Zestawy rozmyte ponownie

Zilustrujemy pojęcie rozmycia w przypadku, gdy baza danych i zapytania mają w sobie rozmycie. Nasza dyskusja jest prowadzona przez odniesienie Terano, Asai i Sugeno. Najpierw przejrzymy i przekształćmy koncepcję zbioru rozmytego w nieco innej notacji.

Jeśli  $a, b, c$  i  $d$  są w zbiorze  $A$  z odpowiednio  $0,9, 0,4, 0,5, 0$  jako stopniami przynależności, a w  $B$  z odpowiednio  $0,9, 0,6, 0,3, 0,8$ , podajemy te zbiory rozmyte  $A$  i  $B$  jako  $A = \{0,9/a, 0,4/b, 0,5/c\}$  i  $B = \{0,9/a, 0,6/b, 0,3/c, 0,8/d\}$ . Teraz  $A[\text{kubek}]B = \{0,9/a, 0,6/b, 0,5/c, 0,8/d\}$ , ponieważ dla każdego pierwiastka bierzesz większy ze stopni przynależności do  $A$  i  $B$ . Ponadto  $A[\text{cap}]B = \{0,9/a, 0,4/b, 0,3/c\}$ , ponieważ teraz przyjmujesz mniejszy ze stopni przynależności do  $A$  i  $B$  dla każdego elementu. Ponieważ  $d$  ma  $0$  jako stopień członkostwa w  $A$  (dlatego nie jest wymieniony w  $A$ ), nie jest wymieniony w  $A[\text{cap}]B$ . Nadajmy wartości rozmyte (FV) każdemu z atrybutów: wiek, lov, nov, yov i hs, definiując zestawy w tabeli.

Fuzzy Value	Set
FV(age)	{ very young, young, somewhat old, old }
FV(nov)	{ never, rarely, quite a few, often, very often }
FV(lov)	{ barely few days, few days, quite a few days, many days }
FV(yov)	{ distant past, recent past, recent }
FV(hs)	{ barely, adequately, quite a bit, extensively }

Atrybuty nazwiska, obywatelstwa, kraju wizyty wyraźnie nie są kandydatami do posiadania rozmytych wartości. Atrybuty lps i lpu, które oznaczają język, w którym istnieje biegłość w mówieniu i język, w którym istnieje zdolność rozumienia, można połączyć z innym atrybutem zwanym flp (biegłość w języku obcym) z wartościami rozmytymi. Mogliśmy wprowadzić do oryginalnej listy atrybut o nazwie lpr (język ze znajomością czytania) wraz z lps i lpu. Jak widać, te trzy elementy można ująć razem w rozmytą wartość atrybutu znajomości języka obcego. Poniżej podajemy rozmyte wartości flp.

FV(flpl) = {not proficient, barely proficient, adequate, proficient, very proficient }

Zauważ, że każda wartość rozmyta każdego atrybutu daje początek zbiorowi rozmytemu, który zależy od elementów, które bierzesz pod uwagę w zestawie i ich stopni przynależności.

Teraz określmy zbiory rozmyte, których elementem jest John Smith, oprócz być może innych. Potrzebujemy wartości stopni przynależności dla Johna Smitha (właściwie jego wartości atrybutów) w różnych zestawach rozmytych. Wybierzmy je w następujący sposób:

```
Age:   mvery young(35) = 0 (degree of membership of 35 in very young is 0.
        We will employ this notation from now on).
        myoung(35) = 0.75
        msomewhat old(35) = 0.3
        mold(35) = 0
```

Założmy, że podobne wartości są przypisane do stopni przynależności wartości atrybutów Johna Smitha do innych zbiorów rozmytych. Tak jak wiek Johna Smitha nie należy do zbiorów rozmytych młody i stary, tak niektóre z jego innych wartości atrybutów nie należą do innych zbiorów rozmytych. Poniżej znajduje się lista zestawów rozmytych, w których pojawia się John Smith:

age\_young = {0.75/35, ...}

age\_somewhat old = {0.3/35, ... }

Podobna próba stwierdzenia liczby wizyt może skłonić Cię do wpisania lis\_rzadko = {0,7/1, 0,2/2}, a lis\_sporo = {0,3/2, 0,6/3, ...}. Ale łatwo zdajesz sobie sprawę, że sama liczba wizyt niewiele znaczy, jeśli nie jest powiązana z krajem wizyty. Jeden kraj może być bardzo często odwiedzany, inny rzadko. Sugeruje to pojęcie relacji rozmytej, która jest również zbiorem rozmytym.

**UWAGA:** Poniżej znajduje się wyjaśnienie relacji i omówienie relacji rozmytych. Jeśli chcesz na razie pominąć tę część, możesz przejść do sekcji „Zapytania rozmyte” kilka stron dalej w tym rozdziale.

### Rozmyte relacje

Standardowa relacja ze zbioru A do zbioru B jest podzbiorem iloczynu kartezjańskiego A i B, zapisanym jako A×B. Elementy A×B są parami uporządkowanymi (a, b), gdzie a jest elementem A, a b jest elementem B. Na przykład para uporządkowana (Joe, Paul) jest elementem iloczynu kartezjańskiego

zbioru ojców, w tym Joe i zbiór synów, w skład którego wchodzi Paul. Albo możesz uznać to za element kartezyjskiego produktu zbioru ludzi z samym sobą. W tym przypadku uporządkowana para (Joe, Paul) znajduje się w podzbiorze, który zawiera (a, b, jeśli a jest ojcem b. Ten podzbiór jest relacją na zbiorze mężczyzn. Relację tę można nazwać „ojciec.”

Relacja rozmyta jest podobna do relacji standardowej, z tym wyjątkiem, że wynikowe zbiory są zbiorami rozmytymi. Przykładem takiej relacji jest „dużo\_więcej\_wykształconych”. Ten rozmyty zestaw może wyglądać mniej więcej tak,

```
much_more_educated = { ..., 0.2/(Jeff, Steve), 0.7/(Jeff, Mike), ... }
```

### Macierzowa reprezentacja relacji rozmytej

Relację rozmytą można podać jako macierz również wtedy, gdy zbiory bazowe, nazwijmy je domenami, są skończone. Na przykład, niech zbiorem ludzi będzie  $S = \{ \text{Jeff, Steve, Mike} \}$  i użyjmy tej samej relacji, dużo\_więcej\_wykształconych. Dla każdego elementu iloczynu kartezyjskiego  $S \times S$  potrzebny jest stopień przynależności do tej relacji. Mamy już dwie takie wartości,  $\text{much\_more\_education}(\text{Jeff, Steve}) = 0,2$  i  $\text{much\_more\_education}(\text{Jeff, Mike}) = 0,7$ . Jaki stopień członkostwa w zestawie powinniśmy przypisać parze (Jeff, Jeff)? Rozsądne wydaje się przypisanie 0. Przypiszemy 0, gdy dwa elementy uporządkowanej pary są takie same. Nasza relacja dużo\_więcej\_wykształconych jest dana przez macierz, która może wyglądać tak:

```
much_more_educated = 

|                   |                   |                   |                  |
|-------------------|-------------------|-------------------|------------------|
|                   | 0/(Jeff, Jeff)    | 0.2/(Jeff, Steve) | 0.7/(Jeff, Mike) |
| 0.4/(Steve, Jeff) | 0/(Steve, Steve)  | 0.3/(Steve, Mike) |                  |
| 0.1/(Mike, Jeff)  | 0.6/(Mike, Steve) | 0/(Mike, Mike)    |                  |


```

**UWAGA:** Zwróć uwagę, że pierwszy wiersz odpowiada uporządkowanym parom, w których pierwszym elementem jest Jeff, druga kolumna odpowiada parom, w których drugim elementem jest Steve, i tak dalej. Główna przekątna ma uporządkowane pary, w których pierwsza i druga składowa są takie same.

### Właściwości relacji rozmytych

Relacja na zbiorze, czyli podzbiór iloczynu kartezyjskiego jakiegoś zbioru ze sobą, może mieć ciekawe własności. To może być odruchowe. W tym celu musisz mieć 1 dla stopnia przynależności każdego głównego wpisu po przekątnej. Nasz przykład tutaj ewidentnie nie jest refleksyjny. Relacja może być symetryczna. W tym celu konieczne jest, aby stopnie przynależności każdej pary wpisów symetrycznie do głównej przekątnej miały tę samą wartość. Na przykład (Jeff, Mike) i (Mike, Jeff) powinni mieć ten sam stopień członkostwa. Tutaj nie, więc nasz przykład a relacja nie jest symetryczna. Relacja może być antysymetryczna. Oznacza to, że jeśli a jest różne od b i stopień przynależności pary uporządkowanej (a, b) nie jest równy 0, to jej lustrzane odbicie, para uporządkowana (b, a), powinna mieć 0 dla stopnia przynależności. W naszym przykładzie zarówno (Steve, Mike), jak i (Mike, Steve) mają dodatnie wartości stopnia członkostwa; dlatego relacja much\_more\_educated nad zbiorem {Jeff, Steve, Mike} również nie jest antysymetryczna. Relacja może być przechodnia. Do przechodniości relacji potrzebny jest następujący warunek, zilustrowany naszym zbiorem {Jeff, Steve, Mike}. Dla zwięzłości użyjmy r zamiast much\_more\_educated, nazwy relacji:

```

min (mx(Jeff, Steve) , mx(Steve, Mike) ) [le] mx(Jeff, Mike)
min (mx(Jeff, Mike) , mx(Mike, Steve) ) [le] mx(Jeff, Steve)
min (mx(Steve, Jeff) , mx(Jeff, Mike) ) [le] mx(Steve, Mike)
min (mx(Steve, Mike) , mx(Mike, Jeff) ) [le] mx(Steve, Jeff)
min (mx(Mike, Jeff) , mx(Jeff, Steve) ) [le] mx(Mike, Steve)
min (mx(Mike, Steve) , mx(Steve, Jeff) ) [le] mx(Mike, Jeff)

```

W powyższych zestawieniach uporządkowane pary po lewej stronie wystąpienia [le] są takie, że drugi element pierwszej uporządkowanej pary pasuje do pierwszego elementu drugiej uporządkowanej pary, a także uporządkowany po prawej stronie para składa się z dwóch niepasujących do siebie elementów w tej samej kolejności. W naszym przykładzie

```

min (mx(Jeff, Steve) , mx(Steve, Mike) ) = min (0.2, 0.3) = 0.2
mx(Jeff, Mike) = 0.7 > 0.2

```

W tym przypadku spełniony jest wymagany warunek. Ale w następujących:

```

min (mx(Jeff, Mike), mx(Mike, Steve) ) = min (0.7, 0.6) = 0.6
mx(Jeff, Steve) = 0.2 < 0.6

```

Wymagany warunek jest naruszony, więc relacja much\_more\_education nie jest przechodnia.

UWAGA: Jeżeli warunek określający właściwość relacji nie jest spełniony nawet w jednym przypadku, relacja nie posiada tej właściwości. Dlatego relacja w naszym przykładzie nie jest zwrotna, symetryczna, nawet antysymetryczna ani przechodnia.

Jeśli się nad tym zastanowić, powinno być jasne, że gdy relacja na zbiorze więcej niż jednego elementu jest symetryczna, to nie może być również antysymetryczna i na odwrót. Ale relacja może być jednocześnie niesymetryczna i niesymetryczna, jak w naszym przykładzie. Przykład związku zwrotnego, symetrycznego i przechodniego podaje następująca macierz:

```

1      0.4  0.8
0.4    1    0.4
0.8    0.4  1

```

## Relacje podobieństwa

Mówi się, że refleksyjna, symetryczna i przechodnia relacja rozmyta jest rozmytą relacją równoważności. Taka relacja nazywana jest również relacją podobieństwa. Kiedy masz relację podobieństwa  $s$ , możesz zdefiniować klasę podobieństwa elementu  $x$  domeny jako zbiór rozmyty, w którym stopień przynależności  $y$  do domeny wynosi  $m_s(x, y)$ . Klasę podobieństwa  $x$  do relacji  $s$  można oznaczyć przez  $[x]_s$ .

## Relacje podobieństwa

Czy uważasz, że podobieństwo i podobieństwo to jedno i to samo? Jeśli  $x$  jest podobne do  $y$ , czy to znaczy, że  $x$  jest podobne do  $y$ ? A może odpowiedź zależy od tego, jakiego sensu używa się, by mówić o podobieństwie lub podobieństwie? W codziennym żargonie Bill może być podobny do George'a w sensie piastowania wysokiego urzędu, ale czy Bill przypomina George'a pod względem finansowym?

Czy to skłania nas do spojrzenia na „relację podobieństwa” i odróżnienia jej od „relacji podobieństwa”? Oczywiście. Przypomnijmy, że relacja rozmyta, która jest zwrotna, symetryczna, a także przechodnia, nazywana jest relacją podobieństwa. Pomaga tworzyć klasy podobieństwa. Jeśli relacji nie ma którejkolwiek z trzech właściwości, nie jest to relacja podobieństwa. Ale jeśli tylko nie jest przechodnia, to znaczy jest zarówno zwrotna, jak i symetryczna, to nadal nie jest relacją podobieństwa, ale relacją podobieństwa. Przykład relacji podobieństwa, nazwijmy ją  $t$ , podaje następująca macierz. Niech domena ma elementy  $a$ ,  $b$  i  $c$ :

$$t = \begin{matrix} & 1 & 0.4 & 0.8 \\ & 0.4 & 1 & 0.5 \\ & 0.8 & 0.5 & 1 \end{matrix}$$

Ta rozmyta relacja jest wyraźnie zwrotna i symetryczna, ale nie jest przechodnia. Na przykład:

$$\min (m_t(a, c) , m_t(c, b) ) = \min (0.8, 0.5) = 0.5 ,$$

ale następująca:

$$m_t(a, b) = 0.4 < 0.5 ,$$

jest naruszeniem warunku przechodniości. Zatem  $t$  nie jest relacją podobieństwa, ale z pewnością jest relacją podobieństwa.

### Rozmyty porządek częściowy

Ostatnia definicja to rozmyty porządek częściowy. Relacja rozmyta, która jest zwrotna, antysymetryczna i przechodnia, jest rozmytym porządkiem częściowym. Różni się od relacji podobieństwa tym, że wymaga antysymetrii zamiast symetrii. W kontekście zbiorów ostrych relacja równoważności, która pomaga generować klasy równoważności, jest również relacją zwrotną, symetryczną i przechodnią. Ale te klasy równoważności są rozłączne, w przeciwieństwie do klas podobieństwa z relacjami rozmytymi. Dzięki zestawom Criss można zdefiniować porządek częściowy, który służy jako podstawa do porównania elementów w domenie ze sobą.

### Zapytania rozmyte

W tym miejscu kończy się nasza dygresja z dyskusji o rozmytych bazach danych. Przypomnijmy teraz, dla natychmiastowego odniesienia, wpisy w definicjach, które wymieniliśmy wcześniej w tabeli:

### Zestaw wartości rozmytych

FV(wiek) { bardzo młody, młody, nieco stary, stary }

FV(nov) { nigdy, rzadko, sporo, często, bardzo często }

FV(lov) {ledwo kilka dni, kilka dni, sporo dni, wiele dni}

FV(yov) {odległa przeszłość, niedawna przeszłość, niedawna }

FV(hs) { ledwo, adekwatnie, całkiem trochę, obszernie}

FV(flپ) {nie biegły, ledwo biegły, adekwatny, biegły, bardzo biegły }

Jeśli odwołasz się do tabel powyżej, zobaczysz, że zapytanie rozmyte definiuje zbiór rozmyty. Załóżmy na przykład, że prosisz o listę młodych ludzi z wystarczającą znajomością Włoch, którzy znają włoski prawie jak rodowity kraj. Chcesz przecięcia zbiorów rozmytych,  $wiek\_młody$ ,  $hs\_adekwatnie$  i  $flp\_bardzo$  biegły. Jak wspomniano wcześniej, John Smith należy do grupy rozmytej  $wiek\_młodość$  z 0,75 stopniem członkostwa. Załóżmy, że jest w  $hs\_odpowiednio$  z 0,2 stopnia członkostwa i na  $flp\_bardzo$  biegły z 0,9 stopnia członkostwa. Następnie umieszczamy go w zestawie rozmytym dla tego zapytania. Stopień przynależności dla Johna Smitha jest najmniejszą wartością spośród 0,75, 0,2 i 0,9, ponieważ bierzemy przecięcie zbiorów rozmytych. Tak więc 0,2/John Smith będzie częścią wyliczenia zbioru rozmytego zapytania. Zwróć uwagę, że możesz użyć nieznanego zamiast wartości atrybutu dla pozycji w bazie danych. Jeśli nie znasz wieku Johna Smitha, możesz wpisać nieznaną w tym polu rekordu Johna Smitha. Możesz powiedzieć, że jego wiek jest nieznaną, chociaż masz z grubsza wyobrażenie, że ma około 35 lat. Mógłbyś wtedy przypisać pewne rozsądne stopnie członkostwa Johna Smitha w rozmytych zestawach, takich jak  $wiek\_młody$  lub  $wiek\_trochę$  stary.

### Rozszerzanie modeli baz danych

Jednym ze sposobów rozszerzenia modelu na model rozmyty, jeśli chodzi o bazy danych, jest wykorzystanie relacji podobieństwa i rozszerzenie na nich operacji, tak jak robią to Buckles i Perry, np. PROJECT. Najpierw są domeny dla bazy danych. W naszym przykładzie dotyczącym przewodników turystycznych i wycieczek, domeny to:

D1 = { Jan Kowalski, ... }, zbiór osób uwzględnionych w bazie danych,

D2 = {Indie, Włochy, Japonia, ... }, zbiór odwiedzanych krajów,

D3 = {Hindi, włoski, japoński, ...}, zbiór języków obcych,

D4 = {USA, ...}, zbiór krajów obywatelstwa,

D5 = zestaw wieków,

D6 = zestaw lat,

D7 = zestaw liczby wizyt,

D8 = zestaw długości wizyt.

Zauważ, że wyliczone zestawy są pokazane z „...” w zestawach, aby wskazać, że może być więcej wpisów na liście, ale nie podajemy pełnej listy. W praktyce dokonasz pełnego wyliczenia, inaczej niż w naszym przykładzie. Dziedziny D5, D6, D7 i D8 można również podać wraz ze wszystkimi ich elementami, ponieważ w praktyce zbiory te są skończone. Jednak koncepcyjnie są to zbiory nieskończone; na przykład D6 jest zbiorem dodatnich liczb całkowitych. Następnie masz zdefiniowane relacje podobieństwa. A potem są operacje.

### Przykład

Rozważ standardową bazę danych podaną poniżej. Można ją również nazwać relacją R1, od zbioru D1 = {Georgette, Darrell, Ernie, Grace} do zbioru D2 = {hiszpański, włoski, francuski, japoński, chiński, rosyjski}, jak pokazano w tabeli 16.4:

D1 : D2

Georgette : hiszpańska

Georgette : włoska



Darrell: francuski

Darrell : hiszpański

Darrell: japoński

Ernie : hiszpański

Ernie : rosyjski

Grace : chiński

Grace : francuska

Założmy, że rozmyta baza danych ma domeny D1 i D2. Założmy, że masz relację podobieństwa S1 w domenie D1 określoną przez macierz:

1	0.4	0.8	0.7
0.4	1	0.5	0.3
0.8	0.5	1	0.4
0.7	0.3	0.4	1

Przypomnijmy, że wpisy w tej macierzy reprezentują stopnie przynależności par uporządkowanych w relacji S1. Na przykład, pierwszy wiersz trzeci element kolumny, który wynosi 0,8, w macierzy odnosi się do stopnia przynależności pary (Georgette, Ernie), ponieważ wiersze i kolumny odnoszą się do Georgette, Darrell, Ernie i Grace w tej kolejności.

Wynik operacji:

PROJECT (R1 over D1) with LEVEL(D1) = 0.6

jest relacją R2 podaną w tabeli.

**Relacja R2, będąca wynikiem działania PROJEKTU**

D1

{Georgette, Ernie}

{Georgette, Grace}

Darrell

Ta operacja projekcji z warunkiem na poziomie działa w następujący sposób. Najpierw należy wybrać kolumnę dla D1 z dwóch kolumn, które pokazuje R1. Powtórzenia są usuwane. Warunek mówi, że jeśli dwa elementy D1 mają podobieństwo 0,6 lub większe, należy je traktować jako takie same. Chociaż poziomy podobieństwa par (Georgette, Ernie) i (Georgette, Grace) są większe niż 0,6, para (Ernie, Grace) ma podobieństwo tylko 0,4, więc nie traktujemy tych trzech jako takich samych. Ten typ tabeli nie jest tworzony w standardowym modelu bazy danych, więc jest to część rozszerzenia standardowego modelu. Założmy, że przekształcasz informacje w relacji R1 i nazywasz je R3, jak pokazano w tabeli

D1D2

Georgette {hiszpańska, włoska}

Darrell {francuski, hiszpański, japoński}

Grace {chiński, francuski}

Ernie {rosyjski, hiszpański}

Tego rodzaju tabela również nie występuje w standardowych bazach danych (gdzie występują grupy zawierające więcej niż jeden element w relacji) i jest przykładem rozszerzonego modelu.

### Dystrybucje możliwości

Jako alternatywę dla stosowania relacji podobieństwa do wprowadzania rozmycia do modelu bazy danych można, za Umano i in., zastosować model dystrybucyjno-relacyjny możliwości. Rozkłady możliwości reprezentują rozmyte wartości atrybutów w danych. Przykładem rozkładu możliwości jest zestaw rozmyty, który widziałeś wcześniej,  $nov\_rarely = \{0.7/1, 0.2/2\}$ , gdzie  $nov\_rarely$  oznacza liczbę odwiedzin uważanych za „rzadkie”.

Przykład

Przykład bazy danych na liniach tego modelu przedstawia tabela:

Przykład relacyjnego modelu rozkładu możliwości

Name	Number of Visits Outside the U.S.	Citizenship	Name of Companion on Latest Visit
Peter	3	U.S.	Barbara
Roberto	$\{10, 11\}_p$	Spain	Anne
Andre	2	unknown	Carol
Raj	14	$\{India, U.S.\}_p$	Uma
Alan	unknown	U.S.	undefined
James	many	U.K.	null

Standardowa baza danych nie może tak wyglądać. Wpisy takie jak wiele i  $\{10, 11\}_p$  wyraźnie sugerują nieostrość. Wpis  $\{10, 11\}_p$  jest rozkładem możliwości, sugerującym, że liczba wizyt poza Stanami Zjednoczonymi dokonanych przez Roberto wynosi 10 lub 11. Podobnie, obywatelstwo Raja to Indie lub Stany Zjednoczone, ale nie podwójne obywatelstwo w obu. Obywatelstwo Andre i liczba wizyt Alana poza Stanami Zjednoczonymi nie są znane i mogą mieć jakiegokolwiek wartości. Możliwości nie można zawęzić, jak w przypadku obywatelstwa Raja i częstotliwości wizyt Roberto poza Stanami Zjednoczonymi. Wpis undefined jest używany w przypadku Alana, ponieważ zawsze podróżował sam, nigdy nie zabierał towarzysza. Liczba wizyt Jamesa jest niewyraźna. Wiele razy podróżował. Rozmyty zestaw dla wielu woli dają możliwość dystrybucji. Można go zdefiniować np. jako:

$many = \{0,2/6, 0,5/7, 0,8/8, 1/9, 1/10, \dots\}$

Nazwisko towarzysza podczas ostatniej wizyty Jamesa poza Stanami Zjednoczonymi jest wpisane jako null, ponieważ z jednej strony nie wiemy, czy nigdy nie zabrał towarzysza, w takim przypadku moglibyśmy użyć undefined jak w przypadku Alana, a z drugiej innych, których wziął za towarzysza, jeśli wziął jednego, w takim przypadku moglibyśmy użyć nieznanego. Mówiąc najprościej, używamy null, gdy nie wiemy wystarczająco dużo, aby użyć nieznanego lub niezdefiniowanego.

### Zapytania

Zwróćmy teraz naszą uwagę na to, w jaki sposób odpowiada się na zapytania za pomocą tego typu modelu bazy danych. Załóżmy, że chcesz mieć w bazie danych listę obywateli USA. Peter i Alan wyraźnie spełniają ten warunek obywatelstwa. Można tylko powiedzieć, że Andre i Raj mogą spełnić ten warunek. Ale Roberto i James wyraźnie nie spełniają podanego warunku. To zapytanie samo w sobie jest ostre i nierozmyte (albo należysz do listy obywateli USA, albo nie). Dlatego odpowiedź powinna być zwięzła, co oznacza, że jeśli stopień członkostwa nie wynosi 1, nie wymienisz żadnego elementu. Dostajesz więc zestaw zawierający tylko Petera i Alana. Drugie zapytanie może dotyczyć osób, które odwiedziły więcej niż kilka osób poza Stanami Zjednoczonymi. Tutaj zapytanie jest niejasne. James z wieloma wizytami poza Stanami Zjednoczonymi wydaje się wyraźnie spełniać ten warunek. Być może rozsądne jest założenie, że każdy element w zbiorze rozmytym dla wielu występuje w zbiorze rozmytym więcej niż kilku o stopniu przynależności 1. 2 Andre może być liczbą, która zasługuje na 0 stopni przynależności w więcej niż kilku. Pozostałe liczby w bazie danych są takie, że prawdopodobnie w różnym stopniu spełniają dany warunek. Widać, że odpowiedzią na to zapytanie rozmyte jest zbiór rozmyty. Teraz trochę zmieniamy biegi, aby porozmawiać o teorii rozmytej. Pomoże to z materiałem do naśladowania.

### **Zdarzenia rozmyte, średnie i wariancje**

Pozwól, że przedstawimy Ci rozmyte zdarzenia, rozmyte średnie i rozmyte wariancje. Te koncepcje są podstawą do badania rozmytych teorii kwantyfikacji. Zobaczysz, jak rozkład prawdopodobieństwa zmiennej i jej zbiór rozmyty są używane razem. Użyjemy przykładu, aby pokazać, jak obliczane są rozmyte średnie i rozmyte wariancje.

### **Przykład: Cena przejęcia firmy XYZ**

Założmy, że jesteś udziałowcem spółki XYZ i czytasz w gazetach, że jej przejęcie jest perspektywą. Obecnie akcje spółki są sprzedawane po 40 dolarów za akcję. Czytasz o wrogim przejęciu przez grupę gotową zapłacić 100 dolarów za udział w XYZ. Inna firma, której działalność jest związana z działalnością XYZ i pozostaje w przyjaznych stosunkach z XYZ, oferuje 85 USD za akcję. Pracownicy XYZ obawiają się o bezpieczeństwo swojego zatrudnienia i zorganizowali się w przygotowaniach do wspólnego zakupu firmy za 60 dolarów za akcję. Cena wykupu akcji spółki jest zmienną z tymi trzema możliwymi wartościami, mianowicie 100, 85 i 60. Zarząd XYZ musi dokonać ostatecznej decyzji o tym, komu sprzedają firmę. Prawdopodobieństwo wynosi odpowiednio 0,3, 0,5 i 0,2, że rada zdecyduje się sprzedać pierwszej grupie po 100 USD, drugiej po 85 USD i pozwolić pracownikom na wykupienie po 60 USD. W ten sposób rozkład prawdopodobieństwa ceny przejęcia będzie następujący:

cena 100 85 60

prawdopodobieństwo 0,3 0,5 0,2

Ze standardowej teorii prawdopodobieństwa rozkład ten daje średnią (lub oczekiwaną cenę) z:

$$100 \times 0,3 + 85 \times 0,5 + 60 \times 0,2 = 84,5$$

oraz wariancja :

$$(100-84,5)^2 \times 0,3 + (85-84,5)^2 \times 0,5 + (60-84,5)^2 \times 0,2 = 124,825$$

Założmy teraz, że analityk bezpieczeństwa specjalizujący się w sytuacjach przejęć czuje, że zarząd nienawidzi wrogiego przejęcia, ale do pewnego stopnia nie może oprzeć się oferowanej cenie. Analityk uważa też, że zarząd lubi zachować pewną kontrolę nad firmą, co jest możliwe, jeśli sprzeda firmę zaprzyjaźnionej firmie stowarzyszonej. Analityk zdaje sobie sprawę, że Zarząd jest wrażliwy na obawy

i obawy swoich lojalnych pracowników, z którymi przez lata zbudował zdrową relację i rozważy ofertę pracowników.

Odczucia analityka znajdują odzwierciedlenie w następującym zbiorze rozmytym:

$$\{0,7/100, 1/85, 0,5/60\}$$

Przypominasz sobie, że ten zapis mówi, że stopień przynależności 100 w tym zbiorze to 0,7, stopień przynależności 85 to 1, a stopień przynależności wynosi 0,5 dla wartości 60. Uzyskany w ten sposób zbiór rozmyty jest również nazywany zdarzeniem rozmytym. Inny analityk może zdefiniować inne rozmyte zdarzenie z wartościami cen przejęcia. Ty, jako udziałowiec, możesz mieć własną intuicję, która sugeruje inne rozmyte wydarzenie. Pozostawmy przy poprzednim zestawie rozmytym, który otrzymaliśmy od analityka bezpieczeństwa i nadajmy mu nazwę A.

### **Prawdopodobieństwo zdarzenia rozmytego**

W tym momencie możemy obliczyć prawdopodobieństwo zdarzenia rozmytego A, używając cen przejęcia jako podstawy odpowiadającej prawdopodobieństwu w rozkładzie prawdopodobieństwa i stopniom przynależności do A. Innymi słowy, stopnie przynależności 0,7, 1, a 0,5 traktuje się jako mające prawdopodobieństwa odpowiednio 0,3, 0,5 i 0,2. Ale chcemy prawdopodobieństwa zdarzenia rozmytego A, które obliczamy jako oczekiwany stopień przynależności przy używanym przez nas rozkładzie prawdopodobieństwa. Nasze obliczenia dają następujące dane:

$$0,7 \times 0,3 + 1 \times 0,5 + 0,5 \times 0,2 = 0,21 + 0,5 + 0,1 = 0,81$$

### **Rozmyta średnia i rozmyta wariancja**

Naszym kolejnym krokiem jest obliczenie średniej rozmytej ceny przejęcia. Nazwijmy to  $A_{\text{fuzzy\_mean}}$ , aby odnieść się do użytego zdarzenia rozmytego. Obliczenia są następujące:

$$A_{\text{średnia\_rozmyta}} = (1/0,81) \times (100 \times 0,7 \times 0,3 + 85 \times 1 \times 0,5 + 60 \times 0,5 \times 0,2) = 85,8$$

Aby uzyskać rozmytą wariancję ceny przejęcia, musisz użyć wartości takich jak  $(100-85,8)^2$ , która jest kwadratem odchylenia ceny przejęcia 100 od średniej rozmytej. Prostszy sposób obliczenia, który jest matematycznie równoważny, jest najpierw wzięcie rozmytej wartości oczekiwanej kwadratu ceny przejęcia, a następnie odjęcie kwadratu średniej rozmytej. Dla ułatwienia użyjmy  $p$  jako zmiennej reprezentującej cenę przejęcia. Obliczenia są jak poniżej:

$$A_{\text{rozmyte\_oczekiwane } p^2} = 1/(0,81) \times (100^2 \times 0,7 \times 0,3 + 85^2 \times 1 \times 0,5 + 60^2 \times 0,5 \times 0,2) = 7496,91$$

$$A_{\text{rozmyta\_wariancja}} = 7496,91 - 85,8^2 = 7496,91 - 7361,64 = 135,27$$

Logika rozmyta zostaje w ten sposób wprowadzona do sfery pojęć prawdopodobieństwa, takich jak zdarzenia, oraz pojęć statystycznych, takich jak średnia i wariancja. Co więcej, możesz mówić o rozmytych oczekiwaniach warunkowych i rozmytych prawdopodobieństwach a posteriori, itp., co pozwala na użycie rozmycia w koncepcjach bayesowskich, analizie regresji i tak dalej. Następnie zagłębisz się w rozmyte teorie kwantyfikacji. W dalszej części kontynuujemy naszą dyskusję z rozmytymi oczekiwaniami warunkowymi.

### **Warunkowe prawdopodobieństwo zdarzenia rozmytego**

Założmy, że jako udziałowiec firmy XYZ w poprzednim przykładzie wymyślisz zestaw rozmyty, nazwiemy zdarzenie rozmyte:

$$B = \{0,8/100, 0,4/85, 0,7/60\}$$

Prawdopodobieństwo wystąpienia zdarzenia rozmytego jest następujące:

$$0,8 \times 0,3 + 0,4 \times 0,5 + 0,7 \times 0,2 = 0,58$$

$B_{\text{fuzzy\_mean}}$  i  $B_{\text{fuzzy\_variance}}$  ceny przejęcia akcji XYZ wyniosły odpowiednio 85,17 i 244,35. Ale chcesz zobaczyć, jak te wartości zmieniają się, jeśli w ogóle, kiedy przyjmiesz A, rozmyte zdarzenie analityka, jako dane. Następnie prosisz o określenie warunkowego prawdopodobieństwa zdarzenia rozmytego, a także warunkowej rozmytej średniej i rozmytej wariancji. Prawdopodobieństwo warunkowe zdarzenia rozmytego oblicza się w następujący sposób:

$$(1/0,81) \times (0,8 \times 0,7 \times 0,3 + 0,4 \times 1 \times 0,5 + 0,7 \times 0,5 \times 0,2) = 0,54$$

Ta wartość jest mniejsza niż prawdopodobieństwo, które uzyskałeś wcześniej, gdy nie przyjąłeś zdarzenia rozmytego analityka jako podanego. Prawdopodobieństwo a priori zdarzenia rozmytego B wynosi 0,58, podczas gdy prawdopodobieństwo a posteriori zdarzenia rozmytego B przy zdarzeniu rozmytym A wynosi 0,54.

### **Warunkowa rozmyta średnia i rozmyta wariancja**

Warunkowa wartość  $B_{\text{fuzzy\_mean}}$  ceny przejęcia przy podanym zdarzeniu rozmytym A wygląda następująco:

$$(1/0,54) \times (100 \times 0,8 \times 0,7 \times 0,3 + 85 \times 0,4 \times 1 \times 0,5 + 60 \times 0,7 \times 0,5 \times 0,2) = 70,37$$

a warunkowa  $B_{\text{fuzzy\_variance}}$  ceny przejęcia ze zdarzeniem rozmytym A, jak podano, wynosi 1301,76, czyli ponad pięć razy więcej niż wtedy, gdy nie przyjęto zdarzenia rozmytego analityka jako podanego.

### **Regresja liniowa a la Możliwości**

Kiedy zobaczysz definicje rozmytych średnich i rozmytych wariancji, możesz pomyśleć, że analizę regresji można również zająć się w sferze logiki rozmytej. W tej części omówimy, jakie podejście jest przyjmowane w tym zakresie. Najpierw przypomnij sobie, co zwykle oznacza analiza regresji. Masz zbiór wartości  $x$  i odpowiadający mu zbiór wartości  $y$ , składający się na pewną liczbę przykładowych obserwacji zmiennych  $X$  i  $Y$ . Określając regresję liniową  $Y$  względem  $X$ , bierzesz  $Y$  jako zmienną zależną, a  $X$  jako zmienną niezależną, a regresja liniowa  $Y$  względem  $X$  jest równaniem liniowym wyrażającym  $Y$  w kategoriach  $X$ . To równanie daje w pewnym sensie linię „najbliższą” punktom próbki (wykres punktowy). Współczynniki w równaniu określa się jako te wartości, które minimalizują sumę kwadratów odchyień rzeczywistych wartości  $y$  od wartości  $y$  od linii. Po określeniu współczynników możesz użyć równania do oszacowania wartości  $Y$  dla dowolnej wartości  $X$ . Ludzie używają równań regresji do prognozowania. Czasami chcesz wziąć pod uwagę więcej niż jedną zmienną niezależną, ponieważ czujesz, że jest ich więcej niż zmienna, która łącznie może wyjaśniać zmiany wartości zmiennej zależnej. To jest twój model regresji wielokrotnej. Wybranie zmiennych niezależnych to miejsce, w którym pokazujesz swoje doświadczenie w modelowaniu, gdy chcesz wyjaśnić, co dzieje się z  $Y$ , ponieważ  $X$  jest różne. W każdym razie zdajesz sobie sprawę, że jest to również problem optymalizacji, ponieważ w grę wchodzi minimalizacja sumy kwadratów odchyień. Rachunek służy do tego dla regresji liniowej. Stosowanie metod rachunku różniczkowego wymaga pewnych własności ciągłości. Gdy takich właściwości nie ma, do optymalizacji należy zastosować inną metodę. Problem można sformułować jako problem programowania liniowego i można zastosować techniki rozwiązywania problemów programowania liniowego. Obróć tę drogę do rozwiązania problemu regresji liniowej z logiką rozmytą. W poprzednim rozdziale poznałeś rozkłady możliwości. Problem

regresji liniowej z logiką rozmytą jest określany jako problem regresji liniowej możliwości. Model, zgodnie z opisem Tarano, Asai i Sugeno, opiera się na funkcji odniesienia L i liczbach rozmytych w postaci par uporządkowanych (a, b). W następnej części przedstawimy liczby rozmyte, a następnie wrócimy do dalszej dyskusji na temat modelu regresji możliwości liniowych.

### Liczby rozmyte

Liczba rozmyta to uporządkowana para liczb (a, b) w odniesieniu do funkcji odniesienia L, która daje funkcję przynależności. Tutaj b musi być liczbą dodatnią. Oto właściwości L, funkcji referencyjnej:

1. Jest funkcją jednej zmiennej i jest symetryczna około 0. To znaczy  $L(x) = L(-x)$ .
2. Ma wartość 1 przy  $x = 0$ . Innymi słowy,  $L(0) = 1$ .
3. Generalnie maleje, gdy x wynosi 0 lub jest liczbą dodatnią, co oznacza, że jego wartość spada wraz ze wzrostem wartości argumentu. Na przykład  $L(2) < L(1)$ .

Zatem  $L(x)$  ma swoje wartości mniejsze niż 1 dla dodatnich wartości x. Nie ma sensu, aby liczby ujemne były wartościami L, więc ignorujesz wartości x, które powodują takie wartości dla L.

4. Maksymalna wartość funkcji wynosi 1, przy  $x = 0$ . Ma ona rodzaj krzywej w kształcie dzwonu.

Jeśli A jest liczbą rozmytą o uporządkowanej parze (a, b) z  $b > 0$ , a funkcją odniesienia jest L, wykonaj następujące czynności:

Piszesz liczbę rozmytą jako  $A = (a, b)L$ . Otrzymasz przynależność do dowolnego elementu x, biorąc ilość  $(x - a) / b$  (która przypomina ci o tym, jak otrzymujesz wynik z) i oszacuj funkcję odniesienia L przy tym argumentcie. To jest:

$$m_A(x) = L((x-a) / b)$$

Przykładami funkcji odniesienia L są:

Przykład 1:  $L(x) = \text{maks. } (0, 1-x^2)$

Otrzymasz następujące elementy pokazane w tabeli.

### Funkcja odniesienia L

x L(x)

-2 0

-1 0

-

0,5 0,75

0 1

0,5 0,75

1 0

2 0

Ta funkcja nie jest jednak ściśle malejąca. Pozostaje stała na poziomie 0 dla  $x > 1$ .

Przykład 2:  $L(x) = 1 / (1 + x^2)$

Otrzymasz wartości pokazane w tabeli.

### Funkcja odniesienia L

x L(x)

-7 0,02

-2 0,2

-1 0,5

-

0,5 0,8

0 1

0,5 0,8

1 0,5

2 0,2

7 0,02


Określmy teraz przynależność 3 do liczby rozmytej  $A = (4, 10)_L$ , gdzie L jest funkcją z drugiego przykładu powyżej, mianowicie,  $1 / (1 + x^2)$ . Najpierw otrzymujesz  $(x-4) / 10 = (3 - 4) / 10 = - 0,1$ . Użyj tego jako argumentu funkcji referencyjnej L.  $1 / (1 + (- 0,1)^2)$  daje 0,99. Wyraża się to w następujący sposób:

$$m_A(3) = L((3-4) / 10) = 1 / (1 + (- 0,1)^2) = 0,99$$

Możesz zweryfikować wartości,  $m_A(0) = 0,862$  i  $m_A(10) = 0,735$ .

### Trójkątna liczba rozmyta

Przy odpowiednim wyborze funkcji referencyjnej można uzyskać symetryczną liczbę rozmytą A, tak że gdy wykreślisz funkcję przynależności w A, otrzymasz trójkąt zawierający pary  $(x, m_A(x))$ , z  $m_A(x) > 0$ . Przykładem jest  $A = (5, 8)_L$ , gdzie  $L = \max(1 - |x|, 0)$ . Liczby x, które mają dodatnie wartości dla  $m_A(x)$  znajdują się w przedziale  $(-3, 13)$ . Również  $m_A(-3) = 0$  i  $m_A(13) = 0$ . Jednak  $m_A(x)$  ma swoją maksymalną wartość przy  $x = 5$ . Teraz, jeśli x jest mniejsze niż -3 lub większe niż 13, wartość L jest zerem i nie bierzesz takiej liczby za członkostwo w A. Zatem wszystkie elementy, dla których członkostwo w A jest niezerowe, są w trójkącie. Ta trójkątna liczba rozmyta jest pokazana na rysunku 16.1. Wysokość trójkąta wynosi 1, a szerokość 16, czyli dwukrotność liczby 8, środek podstawy na 5. Para liczb 5 i 8 to pary określające symetryczną liczbę rozmytą A. Oś pionowa podaje przynależność, więc zakres dla tego wynosi od 0 do 1.



## Model regresji liniowej możliwości

Załóżmy, że masz  $(n + 1)$ -krotki wartości  $x_1, \dots, x_n$  i  $y$ . Oznacza to, że dla każdego  $i$ ,  $i$  w zakresie od 1 do  $k$ , masz  $(x_1, \dots, x_n, y)$ , które są  $k$  obserwacji próbek na  $X_1, \dots, X_n$  i  $Y$ . Model regresji liniowej możliwości jest formułowany w różny sposób w zależności od tego, czy zebrane dane są ostre czy niewyraźne. Podajmy taki model poniżej, dla przypadku z wyraźnymi danymi. Wtedy rozmycie leży we współczynnikach w modelu. Używasz symetrycznych liczb rozmytych,  $A_j = (a_j, b_j)$ . Model regresji możliwości liniowych jest sformułowany jako:

$$Y_j = A_0 + A_1X_{j1} + \dots + A_nX_{jn}$$

Wartość  $Y$  z modelu jest liczbą rozmytą, ponieważ jest funkcją współczynników rozmytych. Współczynniki rozmyte  $A_j$  są wybrane jako te, które minimalizują szerokość (podstawę trójkąta) liczby rozmytej  $Y_j$ . Ale  $A_j$  zależy również od tego, jak duża jest członkostwo obserwowanego  $y_j$ ; ma być w liczbie rozmytej  $Y_j$ . Ta ostatnia obserwacja stanowi ograniczenie dla problemu programowania liniowego, który należy rozwiązać, aby znaleźć regresję możliwości liniowych. Wybierasz wartość  $d$  i prosisz, aby  $m_Y(y)$  [ge]  $d$ . Zamykamy tę sekcję, obserwując, że liniowa regresja możliwości daje trójkątne liczby rozmyte dla  $Y$ , zmiennej zależnej. To jak robienie estymacji interwałowej lub uzyskiwanie pasma regresji. Czytelnicy poważnie zainteresowani tym tematem powinni zapoznać się z Terano.

## Sekcja II: Kontrola rozmyta

W tej sekcji omówiono sterownik logiki rozmytej (FLC), jego zastosowanie i konstrukcję. Sterowanie rozmyte jest obecnie stosowane w różnych maszynach i procesach, z szerokim zastosowaniem, zwłaszcza w Japonii. Kilka z używanych obecnie aplikacji znajduje się na liście w Tabeli 16.10, zaadaptowanej z Yana i innych.

### Zastosowania sterowników logiki rozmytej (FLC) i wykonywane funkcje

Zastosowanie : Funkcje FLC

Kamera wideo: Określ najlepszą ostrość i oświetlenie, gdy na obrazie występuje ruch

Pralka: Dostosuj cykl prania, oceniając stopień zabrudzenia, rozmiar wsadu i rodzaj tkaniny

Telewizja: Dostosuj jasność, kolor i kontrast obrazu, aby zadowolić widzów

Sterowanie silnikiem: popraw dokładność i zakres sterowania ruchem w nieoczekiwanych warunkach

Pociąg metra: Zwiększ stabilność napędu i popraw dokładność zatrzymania, oceniając warunki ruchu pasażerskiego. Zapewnij płynny start i płynne zatrzymanie.

Odkurzacz: Dostosuj moc silnika odkurzacza, oceniając ilość kurzu i brudu oraz charakterystykę podłogi

Podgrzewacz ciepłej wody: dostosuj moc elementu grzejnego w zależności od temperatury i ilości używanej wody


Sterowanie helikopterem: Określ najlepsze działania operacyjne, oceniając instrukcje człowieka i warunki lotu, w tym prędkość i kierunek wiatru

### Projektowanie kontrolera logiki rozmytej

Schemat kontrolera logiki rozmytej został przedstawiony w rozdziale 3. Przerysujmy go teraz i omówmy przykład projektowy. Patrz rysunek 16.2. Dla celów dyskusji załóżmy, że ten FLC steruje podgrzewaczem ciepłej wody. Podgrzewacz ciepłej wody posiada pokrętło HeatKnob (0-10) do sterowania mocą elementu grzejnego, im wyższa wartość, tym jest cieplejsza, a wartość 0 oznacza, że



element grzejny jest wyłączony. W podgrzewaczu wody znajdują się dwa czujniki, jeden informujący o temperaturze wody (TempSense), która waha się od 0 do 125°C, a drugi informujący o poziomie wody w zbiorniku (LevelSense), która waha się od 0 = pusty do 10 = pełny. Załóżmy, że istnieje automatyczna kontrola przepływu, która określa, ile zimnej wody (o temperaturze 10°C) wpływa do zbiornika z głównego źródła wody; ilekroć poziom wody spadnie poniżej 40, kontrola przepływu włącza się i wyłącza, gdy poziom wody wzrośnie powyżej 95.



Cel projektowy można określić jako:

Utrzymuj temperaturę wody jak najbliżej 80°C, pomimo zmian w wodzie wypływającej ze zbiornika i zimnej wody wpływającej do zbiornika.

Krok pierwszy: Definiowanie wejść i wyjść dla FLC

Zakres wartości, jakie mogą przyjmować dane wejściowe i wyjściowe, nazywa się wszechświatem dyskursu. Musimy zdefiniować wszechświat dyskursu dla wszystkich wejść i wyjść FLC, które są wartościami ostrymi. Tabela 16.11 przedstawia zakresy:

Name	Input/Output	Minimum value	Maximum value
LevelSense	I	0	10
HeatKnob	O	0	10
TempSense	I	0	125

Krok drugi: Fuzzuj dane wejściowe


Wejściami do FLC są LevelSense i TempSense. Możemy użyć trójkątnych funkcji przynależności do fuzyfikacji danych wejściowych, tak jak zrobiliśmy to w rozdziale 3, kiedy konstruowaliśmy program fuzzifier. Istnieje kilka ogólnych wskazówek, o których możesz pamiętać podczas określania zakresu zmiennych rozmytych w odniesieniu do danych wejściowych typu Crisp (na podstawie Yan i in.):

1. Rozłóż symetrycznie rozmyte wartości w całym uniwersum dyskursu.
2. Użyj nieparzystej liczby zestawów rozmytych dla każdej zmiennej, aby mieć pewność, że jakiś zestaw będzie pośrodku. Użycie zestawów od 5 do 7 jest dość typowe.
3. Zachodzą na siebie sąsiednie zestawy (zwykle od 15% do 25%). Obie zmienne wejściowe LevelSense i TempSense są ograniczone do wartości dodatnich. Do ich opisu używamy następujących zbiorów rozmytych:


XSmall, mały, średni, duży, XLarge

Poniżej pokazujemy przypisanie zakresów i trójkątnych rozmytych funkcji przynależności do LevelSense. Podobnie przypisujemy zakresy i trójkątne rozmyte funkcje przynależności do TempSense. Optymalizacja tych przypisań jest często wykonywana metodą prób i błędów w celu uzyskania optymalnej wydajności FLC.

<b>Crisp Input Range</b>	<b>Fuzzy Variable</b>
0–2	XSmall
1.5–4	Small
3–7	Medium
6–8.5	Large
7.5–10	XLarge




<b>Crisp Input Range</b>	<b>Fuzzy Variable</b>
0–20	XSmall
10–35	Small
30–75	Medium
60–95	Large
85–125	XLarge



Krok trzeci: skonfiguruj rozmyte funkcje czlonkostwa dla danych wyjsciowych

W naszym przykladzie mamy tylko jedno wyjście, którym jest HeatKnob. Musimy przypisać rozmyte członkostwo do tej zmiennej, tak jak to zrobiliśmy dla danych wejściowych. Używamy różnych nazw zmiennych, aby później przykład był bardziej przejrzysty.

<b>Crisp Input Range</b>	<b>Fuzzy Variable</b>
0–2	VeryLittle
1.5–4	ALittle
3–7	AGoodAmount
6–8.5	ALot
7.5–10	AWholeLot



Krok czwarty: Utwórz bazę reguł rozmytych

Teraz, gdy masz już dane wejściowe i wyjściowe zdefiniowane w postaci zmiennych rozmytych, wystarczy określić, jakie działania należy podjąć w jakich warunkach; oznacza to, że musisz skonstruować zestaw reguł opisujących działanie FLC. Reguły te zwykle przyjmują postać reguł JEŻELI-WTEDY i można je uzyskać od ludzkiego eksperta (heurystyka) lub można je dostarczyć z sieci neuronowej, która wyprowadza reguły z zachowania systemu. Wspomnieliśmy o tym pomysł w Części 3. Zbudujemy bazę reguł dla naszego przykładu projektowego. Dla dwóch wejść definiujemy macierz pokazaną w tabeli poniżej. Nasze wytyczne heurystyczne przy określaniu tej macierzy to: następujące stwierdzenia i ich konwersacje:

1. Gdy temperatura jest niska, pokrętko HeatKnob powinno być ustawione wyżej niż w przypadku wysokiej temperatury.
2. Gdy ilość wody jest mała, pokrętko HeatKnob nie musi być tak wysokie, jak w przypadku dużej ilości wody.

**UWAGA:** W FLC nie musimy określać wszystkich pól w macierzy. To jest w porządku. Brak wpisu oznacza, że nie podjęto żadnych działań, na przykład w kolumnie dla SenseTemp=XL nie jest wymagane żadne działanie, ponieważ temperatura jest już równa lub wyższa od temperatury docelowej.

SenseTemp-> Sense Level	XS	S	M	L	XL
V					
XS	AGoodAmount	ALittle	VeryLittle		
S	ALot	AGoodAmount	VeryLittle	VeryLittle	
M	AWholeLot	ALot	AGoodAmount	VeryLittle	
L	AWholeLot	ALot	ALot	ALittle	
XL	AWholeLot	ALot	ALot	AGoodAmount	

Przyjrzyjmy się kilku typowym wpisom w tabeli: Dla SenseLevel = Medium (M) i SenseTemp = XSmall (XS), dane wyjściowe to HeatKnob = AWholeLot. Teraz przy tej samej temperaturze, wraz ze wzrostem poziomu wody, ustawienie pokrętko HeatKnob również powinno wzrosnąć, aby zrekomensować dodaną objętość wody. Widać, że dla SenseLevel = Large(L) i SenseTemp = XSmall(XS), dane wyjściowe to HeatKnob = AWholeLot. Możesz sprawdzić, czy pozostała część tabeli została utworzona za pomocą podobnego rozumowania.

### Tworzenie reguł IF-THEN

Możemy teraz przetłumaczyć wpisy w tabeli na reguły JEŻELI - TO. Bierzemy je bezpośrednio z tabeli powyższej:

1. IF SenseTemp IS XSmall AND SenseLevel IS XSmall THEN SET HeatKnob TO AGoodAmount

2. IF SenseTemp IS XSmall AND SenseLevel IS Small THEN SET HeatKnob TO ALot
3. IF SenseTemp IS XSmall AND SenseLevel IS Medium THEN SET HeatKnob TO AWholeLot
4. IF SenseTemp IS XSmall AND SenseLevel IS Large THEN SET HeatKnob TO AWholeLot
5. IF SenseTemp IS XSmall AND SenseLevel IS XLarge THEN SET HeatKnob TO AWholeLot
6. IF SenseTemp IS Small AND SenseLevel IS XSmall THEN SET HeatKnob TO ALittle
7. IF SenseTemp IS Small AND SenseLevel IS Small THEN SET HeatKnob TO AGoodAmount
8. IF SenseTemp IS Small AND SenseLevel IS Medium THEN SET HeatKnob TO ALot
9. IF SenseTemp IS Small AND SenseLevel IS Large THEN SET HeatKnob TO ALot
10. IF SenseTemp IS Small AND SenseLevel IS XLarge THEN SET HeatKnob TO ALot
11. IF SenseTemp IS Medium AND SenseLevel IS XSmall THEN SET HeatKnob TO VeryLittle
12. IF SenseTemp IS Medium AND SenseLevel IS Small THEN SET HeatKnob TO VeryLittle
13. IF SenseTemp IS Medium AND SenseLevel IS Medium THEN SET HeatKnob TO AGoodAmount
14. IF SenseTemp IS Medium AND SenseLevel IS Large THEN SET HeatKnob TO ALot
15. IF SenseTemp IS Medium AND SenseLevel IS XLarge THEN SET HeatKnob TO ALot
16. IF SenseTemp IS Large AND SenseLevel IS Small THEN SET HeatKnob TO VeryLittle
17. IF SenseTemp IS Large AND SenseLevel IS Medium THEN SET HeatKnob TO VeryLittle
18. IF SenseTemp IS Large AND SenseLevel IS Large THEN SET HeatKnob TO ALittle
19. IF SenseTemp IS Large AND SenseLevel IS XLarge THEN SET HeatKnob TO AGoodAmount

Pamiętaj, że dane wyjściowe i dane wejściowe do bazy reguł rozmytych są zmiennymi rozmytymi. Dla dowolnej danej ostrej wartości wejściowej może występować rozmyte członkostwo w kilku rozmytych zmiennych wejściowych (określonych przez etap fuzyfikacji). Każda z tych rozmytych aktywacji zmiennych wejściowych spowoduje uruchomienie lub aktywację różnych rozmytych komórek wyjściowych. To prowadzi nas do ostatniego kroku, rozmycia danych wyjściowych do wyraźnej wartości.

Krok piąty: rozmyj wyjścia

Aby sterować pokrętkiem HeatKnob, musimy uzyskać wyraźne ustawienie pokrętła. Jak dotąd mamy kilka reguł JEŻELI-WTEDY z bazy reguł rozmytych uruchamianych jednocześnie, ponieważ dane wejściowe zostały rozmyte. W jaki sposób dochodzimy do pojedynczej wartości wyjściowej Crisp? W rzeczywistości istnieje kilka różnych strategii na to; rozważymy dwie z najczęstszych, metodę środka pola (COA) lub metodę centroidu oraz metodę rozmytego Or. Najłatwiej zrozumieć ten proces na przykładzie. Załóżmy, że w określonym momencie LevelSense = 7,0 i TempSense = 65. Są to ostre dane wejściowe bezpośrednio z czujników. W przypadku fuzyfikacji, załóż, że otrzymujesz następujące rozmyte członkostwa:

crisp input — LevelSense = 7.0

fuzzy outputs with membership values -

Medium: 0.4

Large: 0.6

all others : 0.0

crisp input — TempSense=65

fuzzy outputs with membership values -

Medium: 0.75

Large: 0.25

all others: 0.0

Powoduje to uruchomienie czterech reguł:

1. TempSense = Medium (0.75) AND LevelSense = Medium (0.4)
2. TempSense = Large (0.25) AND LevelSense = Medium (0.4)
3. TempSense = Medium (0.75) AND LevelSense = Large (0.6)
4. TempSense = Large (0.25) AND LevelSense = Large (0.6)

Najpierw musisz określić, jaki powinien być wynik dla każdej klauzuli AND w regułach IF–THEN. Odbywa się to przez spójnik lub operator minimum. Tak więc dla każdej z tych zasad masz następujące siły ognia:

1.  $(0.75) \perp (0.4) = 0.4$
2.  $(0.25) \perp (0.4) = 0.25$
3.  $(0.75) \perp (0.6) = 0.6$
4.  $(0.25) \perp (0.6) = 0.25$

Korzystając z bazy reguł rozmytych i siły przypisanej wcześniej, stwierdzamy, że reguły zalecają następujące wartości wyjściowe (z siłą) dla pokrętła HeatKnob:

1. DobraKwota (0,4)
2. Bardzo mało (0,25)
3. Dużo (0,6)
4. Trochę (0,25)

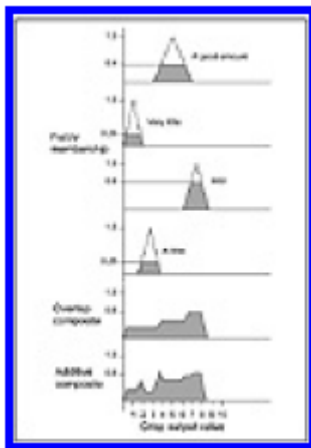
Teraz musimy połączyć zalecenia, aby uzyskać jedną wyraźną wartość. Najpierw użyjemy metody rozmytej Or defuzyfikacji. Tutaj używamy alternatywy lub operatora maksimum, aby połączyć wartości. Otrzymujemy:

$$(0,4) \bullet (0,25) \bullet (0,6) \bullet (0,25) = 0,6$$

Wyraźna wartość wyjściowa dla HeatKnob byłaby wtedy wartością członkostwa pomnożoną przez zakres zmiennej wyjściowej lub  $(0,6) (10-0) = 6,0$ . Innym sposobem łączenia wyjść jest metoda centroid. W przypadku metody centroid istnieją dwie odmiany: metoda nakładania się i metoda składu dodatków. Do przeglądu mamy następujące wartości wyjściowe i mocne strony.

1. Dobra Kwota (0,4)
2. Bardzo mało (0,25)
3. Dużo (0,6)
4. Trochę (0,25)

Używamy wartości siły i wypełniamy konkretną trójkątną funkcję przynależności do tego poziomu siły. Np. dla pierwszej reguły wypełniamy trójkątną funkcję przynależności A Good Amount do poziomu 0,4. Następnie odcinamy wierzchołek trójkąta (powyżej 0,4). Następnie robimy to samo dla pozostałych zasad. Na koniec wyrównujemy obcięte liczby, jak pokazano na rysunku 16.6 i łączymy je zgodnie z metodą składu nakładania lub metodą składu dodatków (Kosko). Możesz zobaczyć różnicę w tych dwóch metodach komponowania na rysunku 16.6. Metoda nakładania po prostu nakłada wszystkie obcięte trójkąty na ten sam obszar. Dzięki tej metodzie możesz stracić informacje. Metoda addytywna dodaje figury geometryczne jedna na drugiej.



Aby uzyskać wyraźną wartość, bierziesz środek ciężkości lub środek ciężkości otrzymanej figury geometrycznej. Zrobmy to dla rysunku metody nakładania. Środek ciężkości to prosta krawędź, którą można przełożyć przez figurę, aby była idealnie wyważona; po obu stronach prostej krawędzi obszar figury jest równy, jak pokazano na rysunku 16.7. Dzieląc geometrię na części i sumując wszystkie udziały powierzchni po obu stronach centroidu, otrzymujemy wartość 5,2 dla tego przykładu. Dotyczy to już wyraźnego zakresu wartości wyjściowych:

HeatKnob = 5.2

To kończy projekt prostego przykładu, który wybraliśmy. Kończymy listą zalet i wad FLC.

#### **Zalety i wady sterowników logiki rozmytej**

Poniższa lista zaadaptowana z McNeilla i Thro pokazuje, że zalety i wady FLC dla systemów sterowania w porównaniu z bardziej tradycyjnymi systemami sterowania.

#### **Zalety:**

- Odnosi wkład do wyników w kategoriach językowych, łatwo zrozumiałych
- Pozwala na szybkie prototypowanie, ponieważ projektant systemu nie musi wiedzieć wszystkiego o systemie przed rozpoczęciem
- Tańsze, ponieważ są łatwiejsze do zaprojektowania

- Zwiększona wytrzymałość
- Uprość pozyskiwanie i reprezentację wiedzy
- Kilka zasad obejmuje dużą złożoność
- Może osiągnąć mniej przeregulowań i oscylacji
- Może osiągnąć stan ustalony w krótszym przedziale czasu

### **Wady**

- Trudno opracować model z systemu rozmytego
- Wymagaj dokładniejszego dostrojenia i symulacji przed uruchomieniem
- Miej piętno związane ze słowem rozmyty (przynajmniej w świecie zachodnim); inżynierowie i większość innych osób są przyzwyczajeni do ostrości i unikania rozmytej kontroli i rozmytego podejmowania decyzji

### **Podsumowanie**

Zastosowania logiki rozmytej są liczne i zróżnicowane. Masz przegląd różnych obszarów zastosowań logiki rozmytej, od sterowania pralkami po analizę kosztów i korzyści opartą na logice rozmytej. Następnie uzyskałeś szczegółowe informacje na temat dwóch domen aplikacji: rozmytych baz danych i rozmytej kontroli. Ta Część dotyczyła rozszerzania modeli baz danych, aby uwzględnić rozmycie wartości atrybutów danych, a także zapytań. Widziałeś rozmyte relacje; w szczególności dokonano przeglądu relacji podobieństwa i podobieństwa oraz klas podobieństwa. Dowiedziałeś się, jak dystrybucje możliwości pomagają definiować rozmyte bazy danych. Dowiedziałeś się również, czym są zdarzenia rozmyte i jak obliczać średnie rozmyte, rozmyte wariancje i rozmyte oczekiwania warunkowe. Przedstawiono koncepcje związane z liniowym modelem regresji możliwości. W rozdziale przedstawiono projekt prostego układu sterowania z logiką rozmytą (FLC) do regulacji temperatury wody w podgrzewaczu wody. Omówiono elementy składowe FLC wraz z procedurami projektowymi. Zaletami projektowania FLC są zdolność szybkiego prototypowania i możliwość rozwiązywania bardzo nieliniowych problemów sterowania bez znajomości szczegółów nieliniowości.