

**Wiedza z Perspektywy Zbiorów
Przybliżonych**

Zdzisław Pawlak

ICS Research Report 23/92

POLITECHNIKA WARSZAWSKA
INSTYTUT INFORMATYKI
BIBLIOTEKA

Nr IqW.....

Warsaw University of Technology

Warsaw, October 1992

1. Wprowadzenie

Zanim przystąpię do dyskusji zasadniczego problemu tej pracy najpierw chciałbym kilka uwag poświęcić głównym celom jakie sobie stawia sztuczna inteligencja. Istnieją tutaj dwa poglądy (nie wykluczające się). Pierwszy z nich głosi, że celem sztucznej inteligencji jest opracowanie programów mogących symulować inteligentne zachowanie się - drugi zaś przyjmuje, że celem sztucznej inteligencji jest modelowanie pracy mózgu.

Pierwsze rozumienie sztucznej inteligencji wiąże się z psychologią, filozofią i na ten temat pojawia się od dłuższego czasu bardzo duża liczba prac, na pograniczu filozofii, psychologii i informatyki (patrz np. Bachimot, B. (1991), Bersini, H. (1991), Davis, R. i Lenat, D. (1982), Frixione, M. (1991), Hempel, C. G. (1952), Hunt, E. B. (1974) oraz Krish, D. (1991)). Przy bliższym zapoznaniu się z tym kierunkiem okazuje się, iż nie wiadomo dokładnie co to jest inteligencja i trudno w istocie mówić o symulacji tego pojęcia.

W drugim rozumieniu sztucznej inteligencji natrafiamy na podobne kłopoty jak w pierwszym, gdyż mimo olbrzymiej pracy włożonej w badania struktury i funkcji mózgu, do tej pory nie rozumiana jest ani istota tego organu ani nawet pojedynczego neuronu. W tej sytuacji trudno mówić poważnie o modelowaniu mózgu.

Dlatego często przyjmuje się skromniejszy cel. Według tego poglądu głównym celem sztucznej inteligencji jest opracowanie programów, które pozwolą maszynie (robotowi, automatowi) zachować się celowo w otoczeniu, lub mówiąc inaczej - opracowanie programów, pozwalających na rozwiązywanie możliwie szerokiej klasy konkretnych problemów związanych z analizą danych otrzymywanych z otoczenia - i odpowiednie reagowanie na ich podstawie celem rozwiązania określonego zadania. W niniejszym opracowaniu przyjmiemy takie właśnie rozumienie sztucznej inteligencji.

Tak więc "inteligentne" programy (maszyny, roboty, automaty) mają na celu "właściwe" reagowanie na sygnały z otoczenia, przy czym pojęcie sygnału jak i otoczenia ma bardzo ogólne znaczenie. Istnieją tutaj dwa podejścia.

Pierwsze, zwane *behawiorystycznym* (lub *funkcjonalnym*) głosi, że do zrealizowania postawionego powyżej zadania wystarczą algorytmy, które każdej, interesującej nas sytuacji otoczenia, reprezentowanej poprzez odpowiednie sygnały, przypisują jednoznacznie "wyjście" (decyzje, akcje, sterowanie etc.). Typowymi reprezentantami tej klasy są przede wszystkim sieci neuronowe oraz systemy wspomagania decyzji. W obu

wymienionych przypadkach rezultat działania systemu zależy jedynie od wejścia i ewentualnie stanu wewnętrznego systemu. W istocie, od strony teoretycznej, podejście to może być więc uważane za szczególny przypadek teorii automatów skończonych.

Kierunek drugi, zwany *symbolicznym*, zakłada, że do właściwego zachowania się robota (automatu) w otoczeniu konieczne jest aby robot posiadał pewną "wiedzę" o otoczeniu w którym ma działać, lub innymi słowami, aby świat otaczający robota był reprezentowany w jakiś sposób w jego pamięci. A więc nie wystarcza w tym celu jedynie sygnały dochodzące z otoczenia i zapisane na nich z góry reakcje robota, a konieczne jest "rozumienie" przez robota otaczającego go świata. W tym celu musi on o tym świecie posiadać odpowiednią wiedzę, która ta wiedza jest odpowiednio reprezentowana w jego pamięci.

Chociaż na tematy te ukazuje się olbrzymia liczba publikacji (patrz np. Aikins, J. S. (1983), Airenti, G. i Colombetti, M. (1991), Bersini, H. (1991), Bobrow, D. G. (1977), Bobrow, D. G. and Winograd, T. (1977), Brachman, R. J. i Smith, B. C. (1980), Brachman, R. J. i Levesque, H. J. (Ed.) (1986), De Glas, M. (1991), Davis, R. i Lenat, D. (1982), Frixione, M. (1991), Grzymała-Busse, J. (1988), Halpern, J. (1986), Hayes-Roth, B. and McDermott, J. (1978), Holland, J. H., Holyoak, K. J., Nisbett, R. E. i Thagard, P. R. (1986), Hunt, E. B. (1974), Hunt, E. D., Marin, J. i Stone, P. J. (1966), Kerber, M. (1991), Krish, D. (1991), McDermott, D. (1978), Minski, M. (1975), Newell, A. (1982), Orłowska, E. (1989), Orłowska, E. and Pawlak, Z. (1984a), Orłowska, E. i Pawlak, Z. (1984b), Vakarelov, D. (1987), Vakarelov, D. (1989), Wasilewska, A. (1987), Wasilewska, A. (1988), Ziarko, W. (1987)) - to jednakże poglądy na to co to jest wiedza i jak ją należy reprezentować nie jest sprawą zbyt jasną i brak jest jednolitych poglądów na stan, cele i metody tej dziedziny (patrz Brachman (1990)).

Warto dodać, że problematyka wiedzy od dawna zajmowali się również logicy i filozofowie (patrz np. Hempel, C. G. (1952), Hintikka, J. (1962), Popper, K. (1959), Russell, B. (1950)), co dopiero kilka lat temu zostało odkryte przez informatyków.

Od roku 1980 nastąpiło zwrócenie dużej uwagi na możliwości zastosowania logiki do celów reprezentacji wiedzy i dzisiaj logika jest jednym z głównych narzędzi reprezentacji wiedzy (choć nie jedynym), stąd nazwa tego kierunku - symbolizm. Zaletą logiki jest jej ścisłość oraz bogactwo środków formalnych, które mogą być przydatne w problematyce reprezentacji wiedzy. Dokładniej biorąc chodzi tu nie wyłącznie o klasyczny rachunek predykatów, a o całą klasę logik zbudowanych zarówno przez logików dla celów ściśle logicznych (patrz np. Kripke (1971)), jak i logik zaproponowanych przez informatyków specjalnie dla celów sztucznej inteligencji (patrz np. McCarthy (1981), Gabbay, D.M. (1984)).

Metody logiczne reprezentacji wiedzy, mimo swych niewatpliwych zalet, posiadają również poważne wady. Główną z nich to fakt, że logika nie odzwierciedla mechanizmów rozumowania stosowanych we wnioskowaniach potocznych, które są niewatpliwie najciekawsze z punktu widzenia zainteresowań sztucznej inteligencji. Ogranicza to znacznie możliwości systemów budowanych w oparciu o środki logiczne.

Jednym z głównych problemów w rozumowaniach potocznych jest konieczność operowania pojęciami nieściłymi (nieostrymi), wiadomo natomiast, że logika dopuszcza jedynie możliwość posługiwania się pojęciami ściłymi (ostrymi). Klasyczne środki logiczne są w przypadku pojęć nieostrych bezużyteczne. Problem nieostrych pojęć interesował zresztą od dawna również logików i filozofów (patrz np. Black, M. (1937), Black, M. (1963), Fine, K. (1975), Hunt, E. B. (1974), Kohl, M. (1969), Popper, K. (1959), Russell, B. (1923), Russell, B. (1950)) - jednakże rezultaty tych rozwiązań, z uwagi na ich bardzo ogólny charakter, są dla sztucznej inteligencji mało przydatne, chociaż niewatpliwie mają one znaczenie metodologiczne.

Najbardziej znany model matematyczny pojęć nieostrych, zwany teorią zbiorów rozmytych, został zaproponowany przez Zadeha (patrz Zadeh (1965)). Model ten, mimo dużej krytyki (głównie ze strony matematyków) zdobył dużą popularność i znalazł wiele zastosowań. Zaletą tego modelu jest duża jego prostota oraz intuicyjność. Najczęściej krytykowana wada zbiorów rozmytych jest subiektywizm w określeniu tzw. funkcji stopnia przynależności elementu do zbioru. Funkcja ta w wielu przypadkach jest definiowana dość dowolnie, co zdaniem krytyków teorii zbiorów rozmytych nie pozwala na ścisłe operowanie tym pojęciem. Teoria zbiorów rozmytych znalazła również zastosowanie w systemach sztucznej inteligencji, jednakże głównie w podejściu behawiorystycznym, a nie symbolicznym. Wiąże się to z wymienioną wadą tej teorii, a mianowicie brakiem dostatecznej ścisłości matematycznej, co w konsekwencji nie pozwala na zbudowanie (jak dotąd) odpowiedniej logiki rozmytej, chociaż próby w tym kierunku były robione przez wielu autorów.

W niniejszym opracowaniu chciałbym przedstawić inne podejście do wiedzy i jej reprezentacji dla celów sztucznej inteligencji, aniżeli to ma miejsce w podanej poprzednio literaturze. Podejście to jest oparte o tzw. teorię zbiorów przybliżonych (patrz Pawlak (1982)) i zostało szczegółowo omówione w licznych pracach, oraz podsumowane w książce (patrz Pawlak (1991)). Punktem wyjścia proponowanego podejścia jest nowe spojrzenie na nieprecyzyjność pojęć, wiedzy oraz jej reprezentację, chociaż wiele podobnych elementów można znaleźć we wcześniejszych pracach innych autorów (patrz Dubois i Prade (1988)).

Wydaje się, że zaproponowane podejście może stanowić dobrą podstawę teoretyczną do wielu problemów sztucznej inteligencji, a w szczególności teorii wiedzy i jej reprezentacji, chociaż oczywiście nie należy się spodziewać, że rozwiąże ono wszelkie problemy w tej dziedzinie.

Jak wykazały dotychczasowe badania teoria zbiorów przybliżonych pozwala często uzyskać dobre rezultaty praktyczne, w przypadkach gdzie inne metody okazały się nie przydatne (patrz Słowinski (1992)). Wiąże się to z faktem, że proponowane podejście nie wymaga numerycznego charakteryzowania nieprecyzyjności pojęć a używa do tego celu środków teorii-mnogociosowych. W konsekwencji umożliwia to ścisłe sformułowanie rozumowań o charakterze jakościowym, które stanowią podstawę rozumowań potocznych. Warto dodać, że zbliżoną koncepcję podał ostatnio De Glas (patrz De Glas (1991)), jednakże jego podejście jest znacznie mniej zaawansowane. Nadmienmy jeszcze że metodologia zbiorów przybliżonych może być stosowana zarówno do podejścia behawiorystycznego jak i symbolicznego.

W niniejszym opracowaniu rozpatrzmy przykładowo kilka najważniejszych problemów związanych z teorią wiedzy na potrzeby sztucznej inteligencji - w ujęciu zbiorów przybliżonych - a mianowicie: nieostrość pojęć, redukcja wiedzy oraz wyszukiwanie zależności w danych. Wszystkie wyżej wymienione problemy dają się łatwo i precyzyjnie sformułować w języku teorii zbiorów przybliżonych, co więcej ujęcie to prowadzi do nowych faktów na temat rozważanych zagadnień, i ponadto do nowych algorytmów komputerowych związanych z różnymi aspektami sztucznej inteligencji.

W pracy stosujemy standardową notację matematyczną i nie będziemy jej bliżej wyjaśniać zakładając, że jest ona znana czytelnikowi.

2. Wiedza i Klasyfikacja

W pracach z zakresu sztucznej inteligencji dotyczących wiedzy nie ma nigdzie, nawet roboczej, definicji tego pojęcia. Mówi się jedynie o reprezentacji wiedzy. Wydaje się, iż aby coś reprezentować należy najpierw wiedzieć co ma być

reprezentowane. Dlatego też w proponowanym podejściu przyjmuje jako punkt wyjścia definicję pojęcia wiedzy i na tej podstawie zdefiniuje później pojęcie reprezentacji wiedzy.

W dalszym ciągu przez *wiedzę* będę rozumiał *zbiór pojęć*. Takie rozumienie wiedzy, na pierwszy rzut oka wydaje się dalekie od powszechnego rozumienia tego pojęcia, jednakże po bliższym przyjrzeniu się tej definicji okazuje się, że ma ona wiele wspólnego z paradygmatem wiedzy obowiązującym aktualnie w sztucznej inteligencji i w istocie jest ona mu bardzo bliska. Z drugiej strony, formalnie taka definicja wydaje się całkiem naturalna i przypomina ona definicje wielu innych pojęć. Na przykład *teoria* jest definiowana w logice jako zbiór twierdzeń, a *język* w lingwistyce matematycznej - jako zbiór zdań. Z formalnego punktu widzenia więc nic nie przeszkadza aby wiedzę rozumieć jako zbiór pojęć.

Pozostaje jeszcze do wyjaśnienia co rozumiemy przez pojęcie. Jak wiadomo w konwencji teorio-mnogosciowej, *pojęcie* utożsamia się z *podzbiorem* pewnego ustalonego zbioru obiektów, którymi jesteśmy zainteresowani. Np. pojęcie *stary człowiek* utożsamia się w tej konwencji ze *zbiorem wszystkich ludzi starych*, a pojęcie *dobra książka* ze *zbiorem wszystkich dobrych książek*. Widac od razu, że ten sposób formalizacji pojęć jest mało intuicyjny, jednakże jak dotąd lepszemu sposobu nie znaleziono, dlatego w dalszym ciągu będziemy posługiwać się tą konwencją.

Tak więc dla zdefiniowania wiedzy musimy mieć pewien zbiór obiektów, którymi jesteśmy zainteresowani. Czym są obiekty nie gra roli. Mogą to być obiekty fizyczne, abstrakcyjne, momenty czasu etc. Oczywiście przyjmiemy, iż zbiór ten jest skończony i ustalony na czas naszych rozważań. Zbiór taki będziemy nazywać *uniwersum*. Mając więc ustalone uniwersum możemy następnie wybrać odpowiedni zbiór pojęć do wyrażania własności tegoż uniwersum. Oczywiście zależnie od zainteresowań, możemy operować różnym zestawem pojęć odnośnie tego samego uniwersum. Np. jeżeli uniwersum jest zbiorem ludzi, to dla wyrażenia ich stanu zdrowia potrzebny jest inny zestaw pojęć aniżeli dla analizy ich umiejętności zawodowych.

Ponieważ pojęcie jest podzbiorem ustalonego uniwersum, w ten sposób, każde pojęcie wprowadza podział obiektów na dwie klasy: tych obiektów które do rozważanego pojęcia należą i tych - które do niego nie należą. A więc z każdym pojęciem związana jest klasyfikacja binarna. Wygodniej jest przyjąć trochę ogólniejsze założenie, a mianowicie, że klasyfikacja może być podziałem na więcej niż dwie klasy. Dlatego też w dalszym ciągu będziemy przyjmowali, że wiedza związana jest z rodziną podziałów (klasyfikacji) ustalonego uniwersum. Np. jeżeli rozważanym uniwersum jest zbiór ludzi w określonym szpitalu, to wiedza potrzebna do diagnozy ich stanu zdrowia, oraz terapii wiąże się z możliwością klasyfikowania ich odnośnie np. temperatury ciała, ciśnienia krwi, etc. Również automat który miałby autonomicznie zachowywać się właściwie w określonym otoczeniu musi być wyposażony w sensory, które dają mu informacje o otoczeniu oraz jego stanie wewnętrznym, klasyfikując w ten sposób stany otoczenia oraz jego stany wewnętrzne i umożliwiając mu właściwą reakcję na otoczenie. Wiadomo, że umiejętność klasyfikacji jest podstawowym mechanizmem, w który wpożone są wszystkie istoty żyjące - niezbędnym do celowego działania w otoczeniu. Podobnie klasyfikacja na poziomie abstrakcyjnym jest podstawowym mechanizmem nauki. Tak więc wybranie umiejętności klasyfikowania jako podstawowego mechanizmu wiedzy, przynajmniej z punktu widzenia potrzeb sztucznej inteligencji wydaje się całkowicie uzasadnione.

Zwrócmy również uwagę, że przyjęty tu punkt widzenia na wiedzę ma charakter jakościowy a nie ilościowy. Nie mówimy tu o pomiarze temperatury, a klasyfikacji ze względu na temperaturę, co nie musi wiązać się z liczbowym wyrażeniem temperatury. Proponowane podejście wiąże się więc w bardzo naturalny sposób z intensywnie ostatnio uprawianym jakościowym podejściem do wielu rozumowań (np. w fizyce jakościowej) uważanym również za dział sztucznej inteligencji.

W swietle powyzzszych rozwazan naturalna rzecza jest przyjecie definicji wiedzy o okreslonym swiecie (uniwersum) jako zbioru podzialow (klasyfikacji) ze wzgledu na intersujace nas wlasnosci. To znaczy, ze wiedze na okreslony temat (o ustalonym uniwersum) utozsamiamy z umiejetnoscia klasyfikowania intersujacych nas zjawisk, procesow, mysli etc. (obiektow uniwersum). Oczywiscie definicja ta miesci sie w podanej na poczatku ogolniejszej definicji wiedzy, gdyz kazdy podzial wyznacza pewien zbior pojec, ktore sa blokami tego podzialu.

3. Wiedza i Baza Wiedzy

W paragrafie tym podamy scisle, matematyczne sformulowanie poprzednich rozwazan. W tym celu wprowadzimy najpierw pojecie *bazy wiedzy*.

Niech U bedzie skonczonym, niepustym zbiorem, zwanym *uniwersum*. Elementy U bedziemy nazywac *obiektami* i bedziemy oznaczac malymi literami alfabetu x, y, z , ewentualnie ze wskaznikami. Jezeli x jest objektem uniwersum U zapiszemy $x \in U$. Kazdy podzbior $X \subseteq U$ bedziemy nazwyli *pojeciem* w U . Dowolna rodzina podzbiorow (pojec) $P(U)$ bedziemy nazywali wiedza o U , natomiast pare $K = (U, P(U))$ nazwiemy *baza wiedzy* o U .

Baza wiedzy w naszym ujeciu jest wiec para skladajaca sie ze swiata (uniwersum) ktorym jestesmy zainteresowani oraz zbioru pojec, ktorymi chcemy ten swiat opisywac. Ten zbior pojec stanowi wiedze o interesujacym nas swiecie. Definicja ta pozornie odbiega dalece od tego co sie potocznie rozumie w sztucznej inteligencji przez baze wiedzy, ale jak sie przekonamy w dalszym ciagu powyzzsza definicja bardzo dobrze oddaje intuicje bazy wiedzy przyjmowane aktualnie w tej dyscyplinie.

Poniewaz, jak to podalismy poprzednio, jestesmy zainteresowani takimi ukkladami pojec ktore stanovia podzialy, nasza definicje bazy wiedzy mozemy zmodyfikowac w nastepujacy sposob.

Przez baze wiedzy bedziemy rozumieli pare $K = (U, C)$, gdzie $C = \{C_1, C_2, \dots, C_n\}$ jest rodzina podzialow (klasyfikacji) U , to jest kazdy podzial $C \in C$ jest rodzina rozlacznych podzbiorow U taka, ze ich suma jest rowna calemu uniwersum.

Ze wzgledow matematycznych wygodniej jest uzywac zamiast podzialow, relacji rownowaznosci, gdyz oba te pojecia sa rownowazne (tj. kazdy podzial wyznacza pewna relacje rownowaznosci i odwrotnie - kazda relacja rownowaznosci wyznacza pewien podzial) - natomiast relacje rownowaznosci sa latwiejsze w operowaniu. Dlatego tez wyzej podana definicje bazy wiedzy sformulujemy nastepujaco: baza wiedzy bedziemy nazywali system relacyjny $K = (U, R)$, gdzie $R = \{R_1, R_2, \dots, R_n\}$, oraz kazde R_i ($1, 2, \dots, n$) jest relacja rownowaznosci. Oczywiscie kazdy podzial U/R (tj. zbior klas abstrakcji relacji R) jest, zgodnie z przyjeta poprzednio definicja, wiedza o U . Dla uproszczenia rowniez kazda relacje $R \in R$ bedziemy rowniez nazywali wiedza o U .

Wprowadzimy obecnie dwa wazne rodzaje pojec, a mianowicie pojecia podstawowe i pojecia elementarne.

Klasy abstrakcji kazdej relacji $R \in R$ (tj. zbiory $Y \in U/R$) bedziemy nazywali *pojeciami podstawowymi* w bazie wiedzy K . Np. jezeli relacja $R \in R$ reprezentuje podzial obiektow uniwersum ze wzgledu na kolor, to poszczegolne klasy abstrakcji tej relacji sa pojeciami podstawowymi w tej bazie i odpowiadaja pojeciom mozliwych kolorow, np. czerwony, zielony, etc.

Poniewaz iloczyn teorio-mnogosciowy relacji rownowaznosci jest rowniez realcja

rownowaznosci, a wiec kazda rodzina R relacji rownowaznosci wyznacza rowniez relacje rownowaznosci $\cap R$ a tym samym podzial $U/\cap R$, tj. zbior pewnych pojec o U , gdzie $\cap R$ oznacza iloczyn wszystkich relacji nalezacych do R . Klasy abstrakcji relacji $\cap R$ bedziemy nazywali *pojeciami elementarnymi (atomowymi)* w bazie K . Oznacza to, ze jezeli mamy na przyklad w jakiejz bazie wiedzy pojecia elementarne *czerwony* (zbior wszystkich obiektow czerwonych) oraz *kwadratowy* (zbior wszystkich obiektow kwadratowych), to w bazie tej istnieje tez pojecie, ktore jest kombinacja powyzzszych pojec, a mianowicie *czerwony oraz kwadratowy (czerwony kwadrat)*, tj. zbior wszystkich obiektow, ktore sa czerwonymi kwadratami) i pojecie to jest wlasnie pojeciem elementarnym w tej bazie wiedzy. Pojecia elementarne sa jak gdyby najmniejszymi pojeciami ktorych mozemy uzywac do opisu naszego swiata (uniwersum). Rodzina wszystkich pojec elementarnych $U/\cap R$ jest oczywiscie wiedza o U , i bedziemy ja nazywac *wiedza elementarna*. Dla uproszczenia rowniez zbior relacji rownowaznosci R bedziemy nazywac wiedza o U .

Jezeli pojecie X w bazie wiedzy K jest suma teorio-mnogosciowa pojec elementarnych bazy wiedzy K , to pojecie X bedziemy nazywali *pojeciem definiowalnym* w bazie wiedzy K ; w przeciwnym wypadku pojecie X jest *niedefiniowalne* w K . Zauwazmy, ze jezeli X i Y sa pojeciami definiowalnymi w bazie wiedzy K , to ich iloczyn i suma teorio-mnogosciowa, a takze uzupelnienie sa rowniez pojeciami definiowalnymi w tej bazie wiedzy. Pojecia elementarne moga byc wiec przyrownane do cegielek (atomow) z ktorych sklada sie kazde pojecie definiowalne w danej bazie wiedzy. Tak wiec rodzina podzialow, lub rodzina relacji rownowaznosci, wyznacza jednoznacznie zbior pojec elementarnych danej bazy wiedzy, a tym samym zbior wszystkich pojec definiowalnych tej bazy, tj. wszystkiego tego co moze byc w tej bazie wiedzy wyrazone. Zbior pojec elementarnych moze byc wiec uwazany za jednoznaczna charakterystyke kazdej bazy wiedzy.

Wprowadzone pojecia wiedzy i bazy wiedzy pozwalaja na scisle i proste definiowanie wielu waznych aspektow wiedzy, z ktorych kilka przykladowo podajemy ponizej.

Powiemy, ze baza wiedzy $K = (U, Q)$ jest *rownowazna* bazie wiedzy $K' = (U, R)$, jezeli $U/\cap Q = U/\cap R$, tzn. jezeli zbior pojec elementarnych bazy wiedzy K oraz K' sa identyczne. Znaczy to, ze bazy wiedzy K i K' rownowazne, gdy posiadaja one taki sam zbior pojec elementarnych (atomowych), a w konsekwencji - taki sam zbior pojec definiowalnych. Mowiac inaczej, jezeli bazy wiedzy K i K' sa rownowazne to zawieraja one taka sama wiedze o uniwersum U .

Mozemy rowniez latwo zdefiniowac, uzywajac wprowadzonego formalizmu, pojecia wiedzy ogolniejszej i bardziej szczegolowej.

Powiemy, ze wiedza Q jest *ogolniejsza* od wiedzy R (lub, ze wiedza R jest *bardziej szczegolowa* od wiedzy Q) gdy $\cap R \subseteq \cap Q$, tzn. kazda klasa abstrakcji relacji $\cap R$ jest zawarta w jakiejz klasie abstrakcji relacji $\cap Q$; mozemy tez powiedziec, ze wiedza Q jest *uogolnieniem* wiedzy R , a wiedza R jest *uszczegolnieniem* wiedzy Q . Mowiac jeszcze inaczej wiedza Q jest ogolniejsza od wiedzy R , gdy kazde pojecie wiedzy Q jest pewna kombinacja pojec wiedzy R . A wiec wiedza bardziej szczegolowa (ogolniejsza) posiada bardziej szczegolowe (ogolne) pojecia. Np. jezeli w jakiejz bazie wiedzy mamy pojecie koloru czerwonego, zas w innej bazie wiedzy mamy pojecia wielu odcieni czerwieni, to pierwsza wiedza jest ogolniejsza od drugiej, natomiast druga - jest bardziej szczegolowa od pierwszej.

Przyjeta definicja wiedzy oraz bazy wiedzy, jest wiec naturalna i pozwala na latwe definiowanie interesujacych nas wlasnosci wiedzy.

3. Reprezentacja Wiedzy

Ponieważ w proponowanym ujęciu wiedza jest, z formalnego punktu widzenia, systemem relacyjnym, ściślej zbiorem relacji równoważności, powstaje pytanie jak taki zbiór można wygodnie reprezentować w pamięci komputera. Istnieje do tego celu bogaty arsenał środków. Można tu np. zastosować rachunek predykatów, który na pierwszy rzutek wydaje się najbardziej naturalny do tego celu. Tak jednakże nie jest. Zaproponujemy tu formalizm, który jest znacznie wygodniejszy niż rachunek predykatów do reprezentowania relacji równoważności w komputerze - mianowicie zbiór relacji równoważności będziemy przedstawiać w postaci tablicy, której wiersze są indeksowane obiektami, kolumny - *atributami*, zaś elementami tablicy są *wartości atrybutów*. Każdej obiektowi i atrybutowi jest jednoznacznie przyporządkowana w tablicy wartość atrybutu w ten sposób, że wartość ta reprezentuje własność tego obiektu dla danego atrybutu. Np. jeżeli obiektem jest KOWALSKI, atrybutem zaś WIEK, to wartością tego atrybutu dla obiektu KOWALSKI może być np, MŁODY. Tablice takie noszą nazwę systemów informacyjnych, tablic kontyngencji, tablic "atribut-wartość" i inne. My będziemy je nazywać *systemem reprezentacji wiedzy*.

Prosty przykład takiej tablicy podany jest niżej.

<i>U</i>	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>	<i>e</i>
1	1	0	2	2	0
2	0	1	1	1	2
3	2	0	0	1	1
4	1	1	0	2	2
5	1	0	2	0	1
6	2	2	0	1	1
7	2	1	1	1	2
8	0	1	1	0	1

Tablic 1

W tablicy tej, dla uproszczenia obiekty i wartości atrybutów są reprezentowane liczbami, atrybuty zaś - literami *a*, *b*, *c* itp.

Łatwo zauważyć, że każdy atrybut wyznacza pewną relację równoważności określoną na obiektach tablicy. Do jednej klasy abstrakcji danej relacji równoważności należą wszystkie obiekty mające takie same wartości atrybutów. Np. atrybut *a* wyznacza relację równoważności o następujących klasach abstrakcji

{2, 8}, {1, 4, 5}, {3, 6, 7},

zaś atrybut *b* definiuje relację o klasach abstrakcji jak niżej

{1, 3, 5}, {2, 4, 7, 8}, {6}.

Oczywiście każdy podzbiór atrybutów również wyznacza pewną relację równoważności. Np. podzbiór atrybutów {*c*, *d*} wyznacza relację równoważności o następujących klasach abstrakcji

{1}, {3, 6}, {2, 7}, {4}, {5}, {8},

natomiast podzbiór atrybutów $\{a, b, c\}$ wyznacza relacje równoważności o klasach abstrakcji podanych niżej:

{1, 5}, {2, 8}, {3}, {4}, {6}, {7}.

Każda więc taka tablice można uważać za zapis formalny pewnego zbioru relacji równoważności. Atrybuty można wtedy uważać za nazwy relacji równoważności występujących w systemie, zaś wartości atrybutów - za nazwy klas abstrakcji danej relacji.

Odwrotnie, dla każdego systemu relacyjnego (bazy wiedzy, czyli zbioru relacji równoważności) można podać tablice, taka jak to pokazano wyżej, która ten system reprezentuje. Zauważmy, że taka operacja nie jest jednoznaczna. Każdej bazie wiedzy można przyporządkować wiele tablic, różniących się nazwami atrybutów i nazwami wartości atrybutów. Jeżeli te różnice uznamy za nieistotne, to również i ta operacja będzie jednoznaczna. Tak więc zamiast mówić o relacjach równoważności (wiedzy) możemy, przy przyjętym sposobie reprezentacji wiedzy, mówić o danych zawartych w tablicy - co ma bardzo duże praktyczne znaczenie z algorytmicznego punktu widzenia, pozwala bowiem na proste sformułowanie wielu podstawowych algorytmów związanych z analizą wiedzy zawartej w bazie wiedzy. Baza wiedzy można uważać za twór semantyczny, zaś odpowiadający jej system reprezentacji wiedzy za - koncept syntaktyczny. Jeżeli $K = (U, R)$ jest baza wiedzy, to odpowiadający jej system reprezentacji oznaczymy $S_K = (U, A)$, lub krócej $S = (U, A)$, gdy K jest znane i gdzie A jest zbiorem atrybutów reprezentujących relacje ze zbioru R .

Z każdym atrybutem $a \in A$ możemy oprócz relacji równoważności związać również funkcję całkowitą $[a]: U \rightarrow V_a$, gdzie V_a jest zbiorem wartości atrybutu a , i zwany jest dziedziną atrybutu a - taka że $[a](x) \in V_a$ dla każdego $x \in U$ oraz $a \in A$. W dalszym ciągu wszędzie tam gdzie to nie będzie prowadzić do nieporozumień zamiast $[a]$ będziemy pisać a . Funkcja ta jest wygodna do definiowania wielu pojęć dotyczących reprezentacji wiedzy.

Używając wprowadzonego wyżej pojęcia funkcji możemy teraz łatwo podać następującą definicję.

Niech $S = (U, A)$ będzie systemem reprezentacji wiedzy i niech $B \subseteq A$. Relacje równoważności generowana przez zbiór atrybutów $B \subseteq A$ - oznaczymy przez $IND(B)$ i zdefiniujemy następująco:

$$IND(B) = \{(x,y) \in U^2: \text{dla każdego } a \in B, a(x) = a(y)\}$$

oczywiście

$$IND(B) = \bigcap_{a \in B} IND(a),$$

oraz

$$[x]_{IND(B)} = \bigcap_{a \in B} [x]_{IND(a)}$$

gdzie $[x]_\rho$ oznacza klasę abstrakcji relacji ρ zawierająca obiekt x .

Mozemy teraz zamiast używać pojęcia zbioru relacji, posługiwać się pojęciem systemu reprezentacji wiedzy tj. prosto tablicą danych - i wszystkie interesujące nas problemy i własności związane z wiedzą wysyłać dalej w terminach danych zawartych w tablicy.

4. Pojęcia Nieostre, Zbiory Przybliżone

Mając ustalony sposób reprezentacji wiedzy możemy obecnie przystąpić do analizy interesujących nas problemów. Jednym z głównych zagadnień, którymi będziemy się tu zajmować to sprawa nieostrości pojęć a w konsekwencji - niedokładności wiedzy.

Pojęcia mogą być ostre lub nieostre. Na przykład pojęcie *liczby parzystej* jest ostre, gdyż o każdej liczbie naturalnej możemy jednoznacznie powiedzieć czy jest parzysta czy też nie, natomiast pojęcie *pięknej kobiety* jest nieostre, gdyż nie o każdej kobiecie możemy powiedzieć czy jest piękna czy też nie. O niektórych kobietach możemy stwierdzić jednoznacznie, że są piękne - ale mogą istnieć kobiety których nie potrafimy jednoznacznie zakwalifikować jako piękne czy też nie. Niemożliwość rozstrzygnięcia niektórych przypadków nie wynika z naszego braku wiedzy na określony temat, lecz jest związana z istotą nieprecyzyjności pojęć, i zwiększanie wiedzy na ich temat nie zmienia tu sprawy. Jak wspomniano we wstępie problematyka nieostrości pojęć interesowała od dawna filozofów, logików, lingwistów - a ostatnio bardzo intensywnie zajęli się tym zagadnieniem również informatycy, a ściślej badacze zajmujący się sztuczną inteligencją.

Współczesna matematyka (ściślej teoria mnogości) pozwala na operowanie jedynie pojęciami ostrymi, natomiast pojęcia nieostre nie mogą być traktowane metodami teorii mnogości.

Istnieje wiele podejść teoretycznych do tego zagadnienia, których z uwagi na obszerność tego tematu nie będziemy tu referować, a zwrócimy jedynie uwagę na kierunek, który nieostrość pojęć wiąże z istnieniem tzw. obszaru granicznego (*boundary-line region*), tj. przypadków które z racji swej istoty nie mogą być prawidłowo zaklasyfikowane, niezależnie od wiedzy, którą na ich temat posiadamy. Pierwszy, który zwrócił uwagę na nieostrość pojęć był filozof i logik niemiecki, twórca współczesnej logiki, Gotlob Frege (patrz Frege (1904)). Píše on:

The concept must have a sharp boundary. The concept without a sharp boundary there would correspond an area that had not a sharp boundary-line all around.

Teoria zbiorów przybliżonych nawiązuje do tej idei i może być uważana za pewną jej formalizację. Podstawowym pomysłem jest tutaj zastąpienie nieprecyzyjnego pojęcia parą pojęć precyzyjnych, zwanych dolnym i górnym przybliżeniem tego pojęcia. Np. dolnym przybliżeniem pojęcia *piękna kobieta* jest zbiór wszystkich tych kobiet, które bez wątpienia są piękne, natomiast górnym przybliżeniem tego pojęcia będzie zbiór tych wszystkich kobiet, których nie można wykluczyć, że są piękne. Różnica między górnym i dolnym przybliżeniem jest właśnie tym obszarem granicznym, do którego należą wszystkie przypadki, które nie mogą być prawidłowo zaklasyfikowane, na podstawie aktualnej wiedzy. Dolne i górne przybliżenie pojęcia nieostrego są pojęciami dokładnymi, tak że można do nich stosować metody klasycznej teorii mnogości. Im większy obszar graniczny pojęcia tym bardziej jest ono nieostre (nieprecyzyjne, nieokreślone). Oczywiście pojęcia precyzyjne mają obszar graniczny pusty, tzn. każdy przypadek w takim przypadku może być prawidłowo zaklasyfikowany.

Podane wyżej rozważania sformułujemy obecnie we wprowadzonym w poprzedniej sekcji języku. W tym celu wprowadzimy idee przybliżenia jednego pojęcia przez inne pojęcie (tj. przybliżania jednych zbiorów przez inne zbiory). W tym celu wprowadzimy następujące definicje.

Niech $S = (U, A)$ będzie systemem reprezentacji wiedzy, oraz $B \subseteq A$. Przez *dolne B-przybliżenie* X w S będziemy rozumieli zbiór

$$\underline{B}X = U\{Y \in U/IND(B): Y \subseteq X\}$$

zas przez *górne B-przybliżenie* X w S - zbiór

$$\overline{B}X = U\{Y \in U/IND(B): Y \cap X \neq \emptyset\}.$$

Dolne przybliżenie pojęcia jest więc sumą teorio-mnogościową wszystkich tych pojęć elementarnych, które są w nim zawarte, zaś górne przybliżenie - jest sumą tych wszystkich pojęć elementarnych które mają niepuste przecięcie z danym pojęciem.

Różnica między górnym a dolnym przybliżeniem jest brzegiem pojęcia. Prowadzi to do następującej definicji.

B-brzegiem pojęcia X w S , nazwiemy zbiór $BN_B(X) = \overline{B}X - \underline{B}X$.

Bedziemy używać następującej terminologii. Jeżeli $x \in \underline{B}X$ - powiemy, że x jest *pozytywnym przykładem (reprezentantem)* pojęcia X ; jeżeli $x \in U - \overline{B}X = NEG_B(X)$ - powiemy, że x jest *negatywnym przykładem (reprezentantem)* pojęcia X ; jeżeli $x \in BN_B(X)$, to x będziemy nazywać *brzegowym przykładem (reprezentantem)* pojęcia X . Wprowadzimy ponadto następujące terminy: $\underline{B}X = POS_B(X)$ - *obszar pozytywny* X , $NEG_B(X)$ - *obszar negatywny* X , oraz $BN_B(X)$ - *obszar brzegowy* (lub krócej - *brzeg*) X .

Dolne przybliżenie pojęcia jest to więc pojęcie (dokładne) do którego należą wszystkie obiekty co do których nie ma wątpliwości, że są one reprezentantami tego pojęcia w świetle posiadanej wiedzy. Do górnego przybliżenia należą obiekty, których nie można wykluczyć, że są reprezentantami tego pojęcia przy posiadanej wiedzy. Brzegiem zaś pojęcia są wszystkie te obiekty o których nie wiadomo, na podstawie posiadanej wiedzy, czy są one czy też nie reprezentantami danego pojęcia.

Oczywiście pojęcie jest definiowalne w danym systemie reprezentacji wiedzy tylko wtedy gdy jego obszar brzegowy jest pusty, lub innymi słowy, gdy jego dolne i górne przybliżenia są identyczne. Oczywiście im większy jest obszar brzegowy pojęcia tym bardziej jest ono nieostre.

Tak więc pojęcia ostre (dokładne) w danej bazie wiedzy, to tylko te pojęcia, które są sumą teorio-mnogościową pojęć elementarnych (atomowych) w tej bazie wiedzy. Wszystkie inne pojęcia są pojęciami nieostrymi. Pojęcia ostre (w danej bazie wiedzy) są to więc pojęcia, które można wyrazić przy pomocy pojęć elementarnych interesującej nas bazy wiedzy. Oczywiście dane pojęcie może być dokładne w jednej bazie wiedzy a niedokładne w innej.

Dla dokładniejszego scharakteryzowania nieostrości pojęć wprowadzimy dwie metody ścisłego jej określania. Pierwsza będzie miała charakter numeryczny, druga zaś

topologiczny.

Dla numerycznego scharakteryzowania nieostrości pojęć wprowadzimy następującą miarę

$$\alpha_R(X) = \frac{\text{card } \underline{R}X}{\text{card } RX}$$

gdzie $X \neq \emptyset$ oraz $R \in \mathcal{A}$, którą będziemy nazywać *współczynnikiem dokładności* pojęcia X w systemie reprezentacji wiedzy $S = (U, R)$ (lub bazie wiedzy $K = (U, \text{IND}(R))$), lub krótko - *współczynnikiem dokładności* X .

Oczywiście $0 \leq \alpha_R(X) \leq 1$. Jeżeli więc $\alpha_R(X) = 0$, to pojęcie X jest całkowicie nieostre i jego własności nie mogą być wyrażone za pomocą zbioru atrybutów R (wiedzy $\text{IND}(R)$); jeżeli $\alpha_R(X) = 1$, to pojęcie jest ostre i jego własności mogą być w pełni wyrażone za pomocą zbioru atrybutów R , natomiast w przypadku gdy $0 < \alpha_R(X) < 1$ pojęcie jest również nieostre i jego własności mogą być częściowo wyrażone przy pomocy zbioru atrybutów R (wiedzy $\text{IND}(R)$).

Zilustrujemy powyższe rozważania następującym przykładem. Przyjmijmy system reprezentacji wiedzy jak pokazano w Tabelicy 2.

U	a	b	c	d	e
1	1	0	2	2	0
2	0	1	1	1	2
3	2	0	0	1	1
4	1	0	2	2	0
5	0	1	1	1	2
6	2	2	0	1	1
7	0	1	1	1	2
8	1	0	2	2	0

Tabelica 2

W systemie tym mamy następujące pojęcia elementarne:

$$\begin{aligned} E_1 &= \{x_1, x_4, x_8\} \\ E_2 &= \{x_2, x_5, x_7\} \\ E_3 &= \{x_3\} \\ E_4 &= \{x_6\} \end{aligned}$$

Przyjmijmy ponadto następujące pojęcia

$$\begin{aligned} X_1 &= \{x_1, x_4, x_5\} \\ X_2 &= \{x_3, x_5\} \end{aligned}$$

$$X_3 = \{x_3, x_6, x_8\}$$

i sprawdzmy czy pojęcia te są ostre. W tym celu należy policzyć dolne i górne przybliżenia tych pojęć oraz ich współczynniki dokładności. Wyniki tych obliczeń podane są poniżej, gdzie $R = \{a, b, c, d, e\}$.

$$\underline{R}X_1 = \emptyset$$

$$RX_1 = E_1 \cup E_2 = \{x_1, x_2, x_4, x_5, x_7, x_8\}$$

$$BN_R(X_1) = E_1 \cup E_2 = \{x_1, x_2, x_4, x_5, x_7, x_8\}$$

$$NEG_R(X_1) = E_3 \cup E_4 = \{x_3, x_6\}$$

$$\alpha_R(X_1) = 0/6 = 0$$

$$\underline{R}X_2 = E_3 = \{x_3\}$$

$$RX_2 = E_2 \cup E_3 = \{x_2, x_3, x_5, x_7\}$$

$$BN_R(X_2) = E_2 = \{x_2, x_5, x_7\}$$

$$NEG_R(X_2) = E_1 \cup E_4 = \{x_1, x_4, x_6, x_8\}$$

$$\alpha_R(X_2) = 1/4$$

$$\underline{R}X_3 = E_3 \cup E_4 = \{x_3, x_6\}$$

$$RX_3 = E_1 \cup E_3 \cup E_4 = \{x_1, x_3, x_4, x_6, x_8\}$$

$$BN_R(X_3) = E_1 = \{x_1, x_4, x_8\}$$

$$NEG_R(X_3) = E_2 = \{x_2, x_5, x_7\}$$

$$\alpha_R(X_3) = 2/5$$

Dla ilustracji podaliśmy również obszary brzegowe oraz obszary negatywne tych pojęć. A więc żadne z rozpatrywanych pojęć nie jest ostre.

Zwróćmy uwagę, że współczynnik dokładności pojęć nie jest przyjmowany dowolnie, jak to ma miejsce np. w zbiorach rozmytych, a jest obliczany na podstawie danych występujących w systemie reprezentacji wiedzy.

Numeryczna charakterystyka nieostrości pojęć nie daje pełnej informacji o charakterze nieostrości pojęcia dlatego podamy jeszcze jeden sposób charakterystyki nieostrości, który będziemy nazywali topologicznym. Okazuje się mianowicie, że przy przyjętej definicji wiedzy istnieją cztery naturalne rodzaje nieostrzych pojęć, które zdefiniowane są poniżej.

Niech X będzie pojęciem nieostrym w $S = (U, A)$ oraz $R \subseteq A$.

- a) Jeżeli $\underline{RX} \neq \emptyset$ oraz $\overline{RX} \neq U$, to X jest w przybliżeniu R -definiowalne
- b) Jeżeli $\underline{RX} = \emptyset$ oraz $\overline{RX} \neq U$, to X jest wewnątrznie R -niedefiniowalne
- c) Jeżeli $\underline{RX} \neq \emptyset$ oraz $\overline{RX} = U$, to X jest zewnętrznie R -niedefiniowalne
- d) Jeżeli $\underline{RX} = \emptyset$ oraz $\overline{RX} = U$, to X jest całkowicie R -niedefiniowalne.

Znaczenie tych definicji jest następujące.

Jeżeli pojęcie X jest w przybliżeniu R -definiowalne znaczy to, że przy pomocy zbioru atrybutów R (wiedzy $IND(R)$) można określić pozytywne i negatywne przykłady pojęcia X , ale istnieje również pewien obszar brzegowy tego pojęcia.

Jeżeli pojęcie X jest wewnątrznie R -niedefiniowalne nie można przy pomocy zbioru atrybutów R (wiedzy $IND(R)$) zdefiniować pozytywnych przykładów pojęcia X .

Jeżeli pojęcie X jest zewnętrznie R -niedefiniowalne nie można przy pomocy zbioru atrybutów R (wiedzy $IND(R)$) zdefiniować negatywnych przykładów pojęcia X .

Jeżeli pojęcie X jest całkowicie R -niedefiniowalne nie można w oparciu o zbiór atrybutów R (wiedze $IND(R)$) zdefiniować ani przykładów pozytywnych ani negatywnych pojęcia X .

Jest to bardzo ważna klasyfikacja pojęć nieostrych, mówi ona bowiem jak wiąże się wiedza z możliwością określenia pewnych pojęć. Np. gdybyśmy chcieli przy pomocy odpowiednich symptomów określić jakąś chorobę mogłoby się okazać, że jest to niemożliwe. Mogłoby się również zdarzyć np. że dany zestaw symptomów pozwala scharakteryzować osoby które napewno nie są chore na określoną chorobę, natomiast nie pozwalają one dobrze określić ludzi chorych (badz odwrotnie). Intuicyjnie wiąże się to faktem, że pojęć niesotrych nie obowiązuje klasyczna logika a w szczególności klasyczna negacja.

Poniższy przykład obliczeniowy jest dokładniejszą ilustracją powyższych rozważań.

Przyjmijmy system reprezentacji wiedzy jak podano w Tabelicy 3.

U	a	b	c	d
0	1	0	2	0
1	1	0	2	0
2	2	0	0	1
3	0	1	1	1
4	2	1	0	0
5	0	1	1	1
6	2	0	0	1
7	0	0	2	1
8	2	1	0	0
9	2	0	0	1
10	0	0	2	1

Tabelica 3

W systemie tym mamy następujące zbiory elementarne:

$$E_1 = \{x_0, x_1\}$$

$$E_2 = \{x_2, x_6, x_9\}$$

$$E_3 = \{x_3, x_6\}$$

$$E_4 = \{x_4, x_8\}$$

$$E_5 = \{x_7, x_{10}\}.$$

Następujące zbiory

$$X_1 = \{x_0, x_1, x_4, x_8\}$$

$$Y_1 = \{x_3, x_4, x_5, x_8\}$$

$$Z_1 = \{x_2, x_3, x_5, x_6, x_9\}$$

są zbiorami definiowalnymi w tym systemie reprezentacji wiedzy. Natomiast zbiory

$$X_2 = \{x_0, x_3, x_4, x_5, x_8, x_{10}\}$$

$$Y_2 = \{x_1, x_7, x_8, x_{10}\}$$

$$Z_2 = \{x_2, x_3, x_4, x_8\}$$

są zbiorami w przybliżeniu definiowalnymi w tym systemie. Poniżej podano przybliżenia i dokładności dla powyższych zbiorów.

$$\underline{R}X_2 = E_3 \cup E_4 = \{x_3, x_4, x_5, x_8\}$$

$$\underline{R}X_2 = E_1 \cup E_3 \cup E_4 \cup E_5 = \{x_0, x_1, x_3, x_4, x_5, x_7, x_8, x_{10}\}$$

$$BN_R(X_2) = E_1 \cup E_5 = \{x_0, x_1, x_7, x_{10}\}$$

$$\alpha_R(X_2) = 4/8 = 1/2$$

$$\underline{R}Y_2 = E_5 = \{x_7, x_{10}\}$$

$$\underline{R}Y_2 = E_1 \cup E_4 \cup E_5 = \{x_0, x_1, x_4, x_7, x_8, x_{10}\}$$

$$BN_R(Y_2) = E_1 \cup E_4 = \{x_4, x_7, x_8, x_{10}\}$$

$$\alpha_R(Y_2) = 2/6 = 1/3$$

$$\underline{R}Z_2 = E_4 = \{x_4, x_8\}$$

$$\underline{R}Z_2 = E_2 \cup E_3 \cup E_4 = \{x_2, x_3, x_4, x_5, x_6, x_8, x_9\}$$

$$BN_R(Z_2) = E_2 \cup E_3 = \{x_2, x_3, x_5, x_6, x_9\}$$

$$\alpha_R(Z_2) = 2/7$$

Zbiory

$$X_3 = \{x_0, x_1, x_2, x_3, x_4, x_7\}$$

$$Y_3 = \{x_1, x_2, x_3, x_6, x_8, x_9, x_{10}\}$$

$$Z_3 = \{x_0, x_2, x_3, x_4, x_8, x_{10}\}$$

sa przykladami wewnterznie niedefiniowalnych pojec w tym systemie a ich przyblizenia i dokladnosci sa nastepujace:

$$\underline{RX}_3 = E_1 = \{x_0, x_1\}$$

$$\overline{RX}_3 = U$$

$$BN_R(X_3) = E_2 \cup E_3 \cup E_4 \cup E_5 = \{x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}\}$$

$$\alpha_R(X_3) = 2/11$$

$$\underline{RY}_3 = E_2 = \{x_2, x_6, x_4\}$$

$$\overline{RY}_3 = U$$

$$BN_R(Y_3) = E_1 \cup E_3 \cup E_4 \cup E_5 = \{x_0, x_1, x_3, x_4, x_5, x_7, x_8, x_{10}\}$$

$$\alpha_R(Y_3) = 3/11$$

$$\underline{RZ}_3 = E_4 = \{x_4, x_8\}$$

$$\overline{RZ}_3 = U$$

$$BN_N(Z_3) = E_1 \cup E_2 \cup E_3 \cup E_5 = \{x_0, x_2, x_3, x_5, x_6, x_7, x_9, x_{10}\}$$

$$\alpha_R(Z_3) = 2/11$$

Zbiory

$$X_4 = \{x_0, x_2, x_3\}$$

$$X_4 = \{x_1, x_2, x_4, x_7\}$$

$$Z_4 = \{x_2, x_3, x_4\}$$

sa przykladami pojec wewnetrznie niedefiniowalnych w tym systemie a wiec ich dolne

przybliżenia są puste, zaś górne przybliżenia podane są niżej.

$$\bar{R}X_4 = E_1 \cup E_2 \cup E_3 = \{x_0, x_1, x_2, x_3, x_5, x_6, x_9\}$$

$$\bar{R}Y_4 = E_1 \cup E_2 \cup E_4 \cup E_7 = \{x_0, x_1, x_2, x_4, x_6, x_7, x_8, x_9, x_{10}\}$$

$$\bar{R}Z_4 = E_2 \cup E_3 \cup E_4 = \{x_2, x_3, x_4, x_5, x_6, x_8, x_9\}.$$

Powyższe zbiory są przykładami pojęć całkowicie niedefiniowalnych w rozpatrywanym systemie reprezentacji wiedzy.

$$X_5 = \{x_0, x_2, x_3, x_4, x_7\}$$

$$Y_5 = \{x_1, x_5, x_6, x_8, x_{10}\}$$

$$Z_5 = \{x_0, x_2, x_4, x_5, x_7\}$$

Z podanych przykładów widać wyraźnie, jak istotny wpływ na to co chcemy wyrazić ma dobór atrybutów (wiedzy). Jest to sprawa intuicyjnie oczywista, jednakże w zaproponowanym formalizmie można ją wyrazić ściśle, a co ważniejsze można na tej podstawie podać algorytm, które taką ocenę mogą robić automatycznie.

5. Redukcja Wiedzy

Zgodnie z przyjętą definicją wiedza jest zbiorem pojęć. Każda baza wiedzy jest natomiast jednoznacznie określona przez jej zbiór pojęć elementarnych, które są zdefiniowane na podstawie pojęć podstawowych występujących w danej bazie wiedzy. Może się więc okazać, że nie wszystkie pojęcia podstawowe są potrzebne do zdefiniowania wszystkich pojęć elementarnych, określających daną bazę wiedzy. Prowadzi to do pytania jak usunąć z bazy wiedzy te pojęcia, które są zbędne z punktu widzenia ich przydatności do definiowania pojęć elementarnych. Ponieważ pojęcia elementarne wyznaczają co można w danej bazie wiedzy wyrazić, więc usunięcie wszystkich pojęć zbędnych nie uszczupla "mocy ekspresji" bazy wiedzy. Problem ten w naszym ujęciu sprowadza się do eliminacji zbędnych atrybutów w systemie reprezentacji wiedzy. W dalszym ciągu problem ten zdefiniujemy precyzyjniej.

Niech $S = (U, A)$ będzie systemem reprezentacji wiedzy i niech $P \subseteq A$.

Powiemy, że atrybut $a \in P$ jest *zbędny* w P , gdy $IND(P) = IND(P - \{a\})$; w przeciwnym wypadku atrybut a jest *niezbędny* w P .

Zbiór atrybutów P jest *niezależny* (w S), gdy każdy atrybut należący do P jest niezbędny w P .

Podzbiór atrybutów $Q \subseteq P$ jest *reduktem* zbioru atrybutów P gdy

- a) Zbiór atrybutów Q jest niezależny

oraz

- b) $IND(P) = IND(Q)$.

Z definicji wynika, że reduktem danego zbioru atrybutów jest taki jego minimalny podzbiór, który zapewnia taki sam zbiór pojęć elementarnych, a więc taka sama

możliwość wyrażania własności uniwersum, jak oryginalny zbiór atrybutów. Inaczej mówiąc redukt daje dokładnie taką samą możliwość klasyfikacji obiektów uniwersum jak oryginalny zbiór atrybutów.

Wprowadzimy jeszcze jedno ważne pojęcie, w proponowanym podejściu, a mianowicie pojęcie *jadra* zbioru atrybutów P (wiedzy), które będziemy oznaczali przez $CORE(P)$ i zdefiniujemy jako zbiór wszystkich niezbędnych atrybutów w zbiorze P . Istnieje ważne związki między pojęciem jadra a reduktu, który wyraża następujące twierdzenie:

$$CORE(P) = \cap \{RED(P)\},$$

gdzie $RED(P)$ oznacza zbiór wszystkich reduktów zbioru atrybutów P . Jadro zawiera więc wiedzę, która nie może być usunięta w żadnym procesie redukcji wiedzy, jest to więc w jakimś sensie najbardziej istotna część wiedzy. Oczywiście jadro może być zbiorem pustym i wtedy takiej istotnej części wiedzy brak. Następujący przykład służy do zilustrowania powyższych pojęć.

Przyjmijmy następujący system reprezentacji wiedzy.

U	a	b	c	d	e
1	0	1	1	1	1
2	1	1	0	1	0
3	1	0	0	1	1
4	1	0	0	1	0
5	1	0	0	0	0
6	1	1	0	1	1

Tablica 4

Łatwo sprawdzić na podstawie wyżej podanych definicji, że jądrem zbioru atrybutów $\{a, b, c, d, e\}$ jest zbiór $\{b, d, e\}$ oraz, że zbiór ten ma dwa redukty $\{a, b, d, e\}$ oraz $\{b, c, d, e\}$. Znaczący to, że zamiast Tablicy 3 możemy równoważnie używać jedną z poniższych tablic

U	a	b	d	e
1	0	1	1	1
2	1	1	1	0
3	1	0	1	1
4	1	0	1	0
5	1	0	0	0
6	1	1	1	1

Tablica 5

U	b	c	d	e
1	1	1	1	1
2	1	0	1	0
3	0	0	1	1
4	0	0	1	0
5	0	0	0	0
6	1	0	1	1

Tablica 6

Zwróćmy uwagę na różnice między równoważnymi bazami danych a równoważnymi

systemami reprezentacji wiedzy. Tablice 10 oraz 11 reprezentują identyczne bazy wiedzy, tj. bazy wiedzy odpowiadające obu tablicom mają identyczne zbiory pojęć elementarnych. Inaczej mówiąc każda z powyższych tablic wyznacza taki sam podział uniwersum. Natomiast w obu tablicach występują różne nazwy zbiorów elementarnych, gdyż w obu tablicach występują różne zbiory atrybutów, a więc w konsekwencji zbiory elementarne są nazywane różnie. Różnica polega na występowaniu zamiennie w obu tablicach atrybutów a i c . Mamy więc do wyboru jeden z powyższych atrybutów do reprezentowania wiedzy. Ma to duże znaczenie praktyczne, gdyż pozwala używać jednych danych zamiast innych mają gwarancje, iż nie zmienia się przez to wiedzy o uniwersum. Przykładowo, jeżeli naszym uniwersum są pacjenci w szpitalu i można ich opisać kilkoma równoważnymi systemami reprezentacji wiedzy, pozwala to na dobor takich symptomów, które są łatwiej, lub taniej mierzalne czy osiągalne. Można więc w takim przypadku mówić o optymalizacji systemu reprezentacji wiedzy z uwagi na różne kryteria.

6. Zależności w Bazach Wiedzy

Głównym celem autonomicznego inteligentnego systemu jest szukanie związków (zależności) między obserwowanymi danymi. Chodzi tu oczywiście o wykrywanie związków przyczynowo-skutkowych. Problem ten można sformułować w zaproponowanym formalizmie w różny sposób. W terminach pojęć bazy wiedzy możemy mówić np. o zależności jednej wiedzy od innej. Intuicyjnie wiedza Q *zależy* od wiedzy P , gdy każde pojęcie wiedzy Q da się wyrazić w terminach wiedzy P , lub równoważnie - każde pojęcie elementarne wiedzy Q da się wyrazić przy pomocy pojęć elementarnych wiedzy P . "Da się wyrazić" oznacza tu, że jest ono po prostu sumą teorii-mnogociową odpowiednich pojęć. Intuicja ta prowadzi do bardzo prostej definicji formalnej zależności.

Niech $K = (U, R)$, oraz $P, Q \subseteq R$.

Powiemy, że wiedza Q zależy od wiedzy P , symbolicznie $P \Rightarrow Q$ gdy $\cap P \subseteq \cap Q$, to znaczy każda klasa abstrakcji relacji $\cap P$ jest zawarta w jakiejś klasie abstrakcji relacji $\cap Q$.

W terminach systemów reprezentacji wiedzy możemy mówić zamiast o zależności jednej wiedzy od innej, o zależności atrybutów. Powyższa definicja zależności wiedzy przejmie wtedy postać następująca.

Niech $S = (U, A)$, oraz $P, Q \subseteq A$.

Powiemy, że zbiór atrybutów Q zależy od zbioru atrybutów P , symbolicznie $P \Rightarrow Q$, gdy $IND(P) \subseteq IND(Q)$.

Ta ostatnia definicja jest wygodniejsza od pierwszej ze względów algorytmicznych, gdyż pozwala na operowanie atrybutami zamiast relacjami równoważności. Nie będziemy tu podawać szczegółowych algorytmów liczenia zależności, a przytoczymy tylko jedno proste twierdzenie pozwalające na łatwe szukanie wszystkich zależności w danym systemie reprezentacji wiedzy.

Jeżeli P jest reduktom Q , to $P \Rightarrow Q - P$.

Jest to bardzo ważna własność, gdyż mówi ona jak znaleźć wszystkie zależności w systemie reprezentacji wiedzy. Należy po prostu najpierw policzyć wszystkie redukty a następnie na ich podstawie można już otrzymać w prosty sposób wszystkie zależności w systemie. Poniższy przykład zilustruje tę ideę dokładniej.

Rozpatrzmy system reprezentacji wiedzy jak podano w Tablicy 9. Ponieważ w tym systemie mamy dwa redukty $\{a, b, d, e\}$ oraz $\{b, c, d, e\}$ a więc otrzymamy następujące zależności: $\{a, b, d, e\} \Rightarrow \{c\}$ oraz $\{b, c, d, e\} \Rightarrow \{a\}$.

Problematyka zależności jest znacznie bardziej złożona, nie będziemy jej jednakże tutaj bliżej analizować. Chcielibyśmy jedynie pokazać, jak wprowadzony formalizm pozwala na badanie tego problemu.

Literatura

Aikins, J. S. (1983). Prototypic a Knowledge for Expert Systems. *Artificial Intelligence*, 20, pp. 163-210.

Airenti, G. and Colombetti, M. (1991). Artificial Intelligence and the Representation Problem. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France, (Ed. Michel De Glas and Dov Gabbay)*. pp. 17-28.

Bachimot, B. (1991). Artificial Intelligence as the Science of the Intentional: A Proposal. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France, (Ed. Michel De Glas and Dov Gabbay)*. pp. 57-71.

Ballmer, T. and Pinkal, M. (eds.) (1983). Approaching Vagueness. *North-Holland Linguistic Series*. Amsterdam, New York, Oxford.

Bersini, H. (1991). A Plea for a Subjective Animat. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France, (Ed. Michel De Glas and Dov Gabbay)*. pp. 93-105.

Black, M. (1937). Vagueness. *The Philosophy of Sciences*. pp. 427-455.

Black, M. (1963). Reasoning with Loose Concepts. *Dialog*, 2, pp. 1-12.

Bobrow, D. G. (1977). A Panel on Knowledge Representation. *Proc. Fifth International Joint Conference on Artificial Intelligence, Carnegie-Melon University*. Pittsburgh, PA.

Bobrow, D. G, and Winograd, T. (1977). An Overview of KRL: A Knowledge Representation Language. *Journal of Cognitive Sciences*, 1, pp. 3-46.

Brachman, R. J. and Smith, B. C. (1980). Special Issue of Knowledge Representation. *SIGART Newsletter*, 70, pp. 1-138.

Brachman, R.J. and Levesque, H. J. (Ed.) (1986). Readings in Knowledge Representation, *Morgan Kaufmann Publishers, Inc.*

Buchanan, B. and Shortliffe, E. (1984). Rule Based Expert Systems. *Reading, Massachusetts: Addison-Wesley*.

Brachman, R. (1990). The Future of Knowledge Representation Systems. *Proceedings Eight National Conference on Artificial Intelligence, Vol 2* pp. 1082-1092.

De Glas, M. (1991). Intuitionism and Knowledge Representation. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France, (Ed. Michel De Glas and Dov Gabbay)*. pp. 147-156.

- Davis, R. and Lenat, D. (1982). Knowledge-Based Systems in Artificial Intelligence. *McGraw-Hill*.
- Dubois, D. and Prade, H. (1988). Rough Fuzzy Sets and Fuzzy Rough Sets. *Internal Conference on Fuzzy Sets in Informatics, Moscow, September 20-23 and International Journal of General Systems*. (W druku)
- Fine, K. (1975). Vagueness, Truth and Logic. *Synthese*. 30, pp. 265-300.
- Frege, G., (1903). Grundgesetze der Arithmentik, 2, in *Geach and Black (Ed.) Selections from the Philosophical Writings of Gotlob Frege, Blackwell (Oxford) 1970*.
- Frixione, M. (1991). On the Relation between Philosophical Theories of Meaning and Artificial Intelligence. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France, (Ed. Michel De Glas and Dov Gabbay)*. pp. 187-198.
- Grzymała-Busse, J. (1988). Knowledge Acquisition under Uncertainty - a Rough Set Approach. *Journal of Intelligent and Robotics Systems*, 1, pp. 3-16.
- Gabbay, D.M. (1984). Theoretical Foundation for Non-monotonic Reasoning in Expert Systems. *Logic and Models of Concuren Systems*. Springer Verlag, Berlin, pp. 439-459.
- Halpern, J. (ed.) (1986). Theoretical Aspects of Reasoning about Knowledge. *Proceedings of the 1986 Conference*. Morgan Kaufman, Los Altos, California.
- Hayes-Roth, B. and McDermott, J. (1978). An Inference Matching for Inducing Abstraction. *Communication of the ACM*, 21, pp. 401-410.
- Hempel, C. G. (1952). *Fundamental of Concept Formation in Empirical Sciences*. University of Chicago Press. Chicago.
- Hintika, J. (1962). *Knowledge and Belief*. Cornell University Press. Chicago.
- Holland, J. H., Holyoak, K. J., Nisbett, R. E. and Thagard, P. R. (1986). *Induction: Processes of Inference, Learning, and Discovery*. MIT Press.
- Hunt, E. B. (1974). *Concept Formation*. John Wiley and Sons. New York.
- Hunt, E. D., Marin, J. and Stone, P. J. (1966). *Experiments in Inductions*. Academic Press. New York.
- Israeli, D. (1983). The Role of Logic in Knowledge Representation. *IEEE Computer*, October pp. 37-41.
- Kerber, M. (1991). On the Representation of Mathematical Knowledge in Frames and its Consistency. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France, (Ed. Michel De Glas and Dov Gabbay)*. pp. 293-301.
- Kohl, M. (1969). Bertrand Russell on Vagueness. *Australian Journal of Philosophy*. 147, pp. 31-41.
- Kripke, S. (1971). Semantical Considerations on Modal Logic. *Reference and Modality*, (Ed. L.Linsky). Oxford Univ. Press, London, pp. 63-72.

- Krish, D. (1991). (Editor), Special Volume on "Foundations of Artificial Intelligence". *Artificial Intelligence* 47, pp. 1-3.
- McCarthy, J. (1981). Epistemological Problems of Artificial Intelligence. *Readings in Artificial Intelligence*. (Ed. Bonnie Lynn Weber, Nils J. Nilsson), Morgan Kaufman Publishers, Inc, pp. 459-465.
- McCarthy, J. (1986). Applications of Circumscription to Formalizing Common-sense Knowledge. *Artificial Intelligence*, 28, pp. 89-116.
- McDermott, D. (1978). The Last Survey of Representation of Knowledge. *Proc. of the AISB/GI Conference on AI*. Hamburg, pp. 286-221.
- Minski, M. (1975). A Framework for Representation Knowledge. In: Winston, P. (ed.) *The Psychology of Computer Vision*. McGraw-Hill. New York, pp. 211-277.
- Newell, A. (1982). The Knowledge Level. *Artificial Intelligence*, 18, pp. 87-127.
- Orłowska, E. (1989). Logic for Reasoning about Knowledge. *Zeitschr. f. math. Logik und Grundlagen d. Math.*, 35, pp. 559-572.
- Orłowska, E. and Pawlak, Z. (1984a). Expressive Power of Knowledge Representation Systems. *International Journal of Man-Machine Studies*, 20, pp. 485-500.
- Orłowska, E. and Pawlak, Z. (1984b). Logical Foundations of Knowledge Representation. *Institute of Computer Science, Polish Academy of Science, Reports*, 537, pp. 1-106.
- Pawlak, Z. (1982). Rough Sets. *International Journal of Computer and Information Sciences*, 11, pp. 341-356.
- Pawlak, Z. (1991). Rough Sets - Theoretical Aspects of Reasoning about Data. *Kluwer Academic Publishers*.
- Popper, K. (1959). *The Logic of Scientific Discovery*. London: Hutchinson.
- Russel, B. (1923). Vagueness. *Australian Journal of Philosophy*, 1, pp. 84-92.
- Russell, B. (1950). *An Inquiry into Meaning and Truth*. George Allen and Unwin, London.
- Slowinski, R., Ed. (1992). *Intelligent Decision Support - Handbook of Applications and Advances of the Rough sets Theory*. Kluwer Academic Publishers.
- Vakarelov, D. (1987). Abstract Characterization of Some Modal Knowledge Representation Systems and the Logic NIL of Nondeterministic Information. In: Jorraud, Ph. and Squirev, V. (ed.) *Artificial Intelligence II, Methodology, Systems, Applications*. North Holland.
- Vakarelov, D. (1989). Modal Logic of Knowledge Representation Systems. *Lecture Notes on Computer Science*, Springer Verlag, 363, pp. 257-277.
- Vakarelov, D. (1991). Logical Analysis of Positive and Negative Similarity Relations in Property Systems. *Proceedings of the WOCFAI 91, First World Conference on the Fundamentals of Artificial Intelligence, 1-5 July 1991, Paris, France*, (Ed. Michel De Glas and Dov Gabbay). pp. 491-500.
- Wasilewska, A. (1987). Definable Sets in Knowledge Representation Systems. *Bull.*

Polish Acad. Sci. Math., **35**, pp. 629-635.

Wasilewska, A. (1988). Knowledge Representation Systems - Syntactic Methods. *Proc. IPMU-88 Conference, Springer Verlag, Lecture Notes on Computer Science*, **313**, pp. 239-254.

Wille, R. (1982). Restructuring Lattice Theory: An Approach Based on Hierarchies of Concepts. In: I. Rival (Ed.), *Ordered Sets, Reidel*, Dordrecht - Boston, pp. 445-470.

Zadeh, L. A. (1965). Fuzzy Sets. *Information and Control*. **8**, pp. 338-353.

Ziarko, W. (1987). On Reduction of Knowledge Representation. *Proc. 2-nd International Symp. on Methodologies of for Intelligent Systems*. Charlotte, NC. North Holland, pp. 99-113.

**Recently published Research Reports
of the Institute of Computer Science, W.U.T.**

- 11/92 Zdzisław Pawlak,
 Anatomy of Conflicts, May 1992.
- 12/92 Cecylia M. Rauszer,
 Knowledge Representation Systems for Groups of Agents, May 1992.
- 13/92 Zdzisław Pawlak,
 Rough Sets - Basic Concepts, June 1992.
- 14/92 Konstanty J. Kurman, Wiktor B. Daszczuk, Jerzy Mieścicki,
 Projektowanie jednowymiarowych układów automatycznej regulacji przy
 użyciu systemu KURMAN, lipiec 1992.
- 15/92 Zdzisław Pawlak,
 Concurrent Versus Sequential the Rough Sets Perspective, July 1992.
- 16/92 Falk Tannhäuser,
 Generowanie Reduktów, lipiec 1992.
- 17/92 Andrzej Skowron, Jarosław Stepaniuk,
 Intelligent Systems Based on Rough Set Approach, May 1992.
- 18/92 Zdzisław Pawlak,
 Rough Sets and Their Applications, September 1992.
- 19/92 Jerzy Mieścicki,
 Boolean expressions and the families of sets, September 1992.
- 20/92 Jerzy Mieścicki,
 On the behavior of a system of concurrent automata, September 1992.
- 21/92 Piotr K. Sapiecha,
 An Approximation Algorithm for a Certain Class of NP-Hard Problems, May
 1992.
- 22/92 Cecylia M. Rauszer,
 Distributive Knowledge Representation Systems, September 1992.
- 23/92 Zdzisław Pawlak,
 Wiedza z Perspektywy Zbiorów Przybliżonych, October 1992.