




Grey Scale #13



DANES-PICTA.COM

A 1 2 3 4 5 6 M 8 9 10 11 12 13 14 15 B 17 18 19



AKADEMIA OBRONY NARODOWEJ

WYDZIAŁ WOJSK LOTNICZYCH I OP

Mjr dr inż. Adam HALAMA

EKSPERTOWY MODEL OCENY DZIAŁANIA ŚRODKÓW NAPADU POWIETRZNEGO

I etap badań

ZASTOSOWANIE SZTUCZNEJ INTELIGENCJI W PROCESACH OCENY PRZECIWNIKA POWIETRZNEGO

3.4.1.0

Biblioteka Główna Akademii Obrony Narodowej

S/3520



05-003520-001-0

WARSZAWA

1997

63990





**AKADEMIA OBRONY NARODOWEJ**

**WYDZIAŁ WOJSK LOTNICZYCH I OP**

**Mjr dr inż. Adam HALAMA**

**EKSPERTOWY MODEL OCENY DZIAŁANIA  
ŚRODKÓW NAPADU POWIETRZNEGO**

**I etap badań**

**ZASTOSOWANIE SZTUCZNEJ INTELIGENCJI  
W PROCESACH OCENY PRZECIWNIKA POWIETRZNEGO**

**3.4.1.0**

Biblioteka Główna  
Akademii Obrony Narodowej

**S/3520**



05-003520-001-0

**WARSZAWA**



**63990**

**AKADEMIA OBRONY NARODOWEJ**  
**WYDZIAŁ WOJSK LOTNICZYCH I OP**




**mjr dr inż. Adam HALAMA**

**EKSPERTOWY MODEL**  
**OCENY DZIAŁANIA**  
**ŚRODKÓW NAPADU POWIETRZNEGO**  
**I Etap badań**

**ZASTOSOWANIE SZTUCZNEJ INTELIGENCJI**  
**W PROCESACH OCENY**  
**PRZECIWNIKA POWIETRZNEGO**

**3.4.1.0.**



---

**W A R S Z A W A**

**1 9 9 7**

LEWIS & CLARK

EXPLORATION



1804

## Spis treści

<b>WSTĘP</b> .....	<b>3</b>
<b>1. PODSTAWY SYSTEMÓW EKSPERTOWYCH</b> .....	<b>8</b>
1.1. Inteligencja i sztuczna inteligencja.....	8
1.2. Systemy ekspertowe .....	15
1.3. Struktura systemów ekspertowych.....	18
1.4. Rodzaje systemów ekspertowych.....	19
<b>2. PODSTAWOWE METODY STOSOWANE W SYSTEMACH EKSPERTOWYCH</b> .....	<b>22</b>
2.1. Metody reprezentowania wiedzy .....	22
2.1.1. Wiedza oraz sposoby jej reprezentacji .....	22
2.1.2. Rachunek zdań .....	23
2.1.3. Stwierdzenia .....	24
2.1.4. Regułowa reprezentacja wiedzy.....	26
2.1.5. Wektory wiedzy.....	28
2.1.6. Rachunek predykatów.....	29
2.1.7. Sieci semantyczne.....	30
2.1.8. Reprezentacja wiedzy za pomocą ram.....	31
2.1.9. Modele obliczeniowe.....	32
2.1.10. Sieci neuronowe .....	32
2.2. Metody wnioskowania.....	40
2.2.1. Wnioskowanie w przód .....	40
2.2.3. Wnioskowanie wstecz.....	41
2.2.4. Wnioskowanie mieszane.....	42
2.2.5. Wnioskowanie rozmyte .....	43
<b>ZAKOŃCZENIE</b> .....	<b>51</b>
<b>LITERATURA</b> .....	<b>53</b>

## Wstęp

Intensywność prowadzonych działań na współczesnym polu walki stwarza konieczności ciągłej oceny działania przeciwnika. Zjawisko to szczególnie widoczne jest w obronie powietrznej i obronie przeciwlotniczej. Ocenę tę należy prowadzić już podczas zbierania informacji o sytuacji na polu walki celem przewidywania jej rozwoju, utrzymania lub odtwarzania gotowości bojowej oraz przygotowania się do przyjęcia zadania bojowego. Następnie podczas analizy zadania, określenia koncepcji działań oraz opracowania szczegółowego planu działań wojsk obrony przeciwlotniczej. Ciągła ocena przeciwnika powietrznego prowadzona jest też na potrzeby kierowania ogniem. Proces oceny przeciwnika powietrznego na potrzeby kierowania ogniem został zautomatyzowany między innymi w systemie zautomatyzowanego dowodzenia wojskami obrony przeciwlotniczej ZENIT. Podprogram REKOMENDACJE umożliwia nie tylko ocenę bieżącej sytuacji powietrznej, na podstawie danych z posterunków radiolokacyjnych, ale również jej przyszły rozwój, co ostatecznie pozwala zaproponować dowódcy sposób odparcia uderzenia środków napadu powietrznego poprzez przydział zadań ogniowych podległym oddziałom i pododdziałom. Proces oceny przeciwnika powietrznego w trakcie nalotu, który potrafi wykonać maszyna elektroniczna, jest tylko jednym z etapów oceny przeciwnika powietrznego. Można więc zadać sobie pytanie czy pozostałe etapy oceny może wykonać maszyna, czy zadanie to mogą wykonać systemy eksperckie.

Według J. Strelau'a<sup>1</sup> **system ekspercki** inaczej zwany systemem doradczym to komercyjny program komputerowy, składający się z trzech niezależnych fizycznie, współpracujących ze sobą części: bazy wiedzy, kontrolera wyводу oraz interfejsu. Program ekspercki ma na celu zastąpienie pracy eksperta w danej dziedzinie. Rozwijając dalej powyższą definicję za J. Strelau'em należy zdefiniować części składowe systemu eksperckiego.

---

<sup>1</sup> Strelau J.: O inteligencji człowieka. Wiedza powszechna. Warszawa 1987

**Baza wiedzy** (Knowledge Base) to część systemu, zawierająca wiedzę o dziedzinie i o podejmowaniu decyzji przez eksperta. Wiedza ta może być przechowywana w różnej postaci, ważne jest to, że na jej podstawie dokonuje się wnioskowanie w systemie. Niemożliwe jest istnienie systemu eksperckiego bez wiedzy.

**Kontroler wyvodu** (Inference Engine) to część systemu kierująca rozwiązaniem problemu. Ta część odpowiedzialna jest za poprawne zastosowanie wiedzy, obsługę ewentualnych sytuacji wyjątkowych, sposób wnioskowania. System ekspercki pozbawiony kontrolera wyvodu nie jest w stanie zastosować posiadanej wiedzy, po prostu nie działa. Każdy działający system musi mieć kontroler wyvodu, choć zdarzają się przypadki, gdy jest on zredukowany do minimum (na przykład do postaci: „Wybierz pierwszą możliwą do zastosowania regułę i zastosuj ją”).

**Interfejs** to część systemu zajmująca się komunikacją ze światem zewnętrznym komputera, odpowiedzialna zarówno za wprowadzanie danych do systemu, jak i za wyprowadzanie na zewnątrz wniosków systemu. Program, który nie komunikuje się ze światem zewnętrznym, nie jest w stanie wyprowadzić żadnego wyniku, więc jest bezużyteczny.

Obecny stan wiedzy o ocenie przeciwnika powietrznego pozwala na zbudowanie wszystkich trzech modułów systemu eksperckiego. Wiedzy o środkach napadu powietrznego ich potencjale, taktyce i technice wykonywania zadań umożliwia budowę bazy wiedzy. Znajomość metod oceny przeciwnika powietrznego pozwala zbudować kontroler wyvodu. Budowa prostego w obsłudze a jednocześnie posiadającego duże możliwości interfejsu przy obecnym rozpowszechnieniu mikrokomputerów nie przedstawia większych trudności. Z powyższego wynika, że istnieją realne przesłanki do opracowania

## **EKSPERCKIEGO SYSTEMU OCENY PRZECIWNIKA POWIETRZNEGO.**

Literaturę analizowaną w etapie badań wstępnych i w pierwszym etapie badań podzieliłem na trzy podstawowe grupy:

- literatura o przeciwniku powietrznym
- literaturę o metodach oceny przeciwnika powietrznego
- literatura sztucznej inteligencji i systemach eksperckich

Do pierwszej grupy zaliczyłem wszystkie podręczniki, opisy, skrypty itp. opisujące zarówno taktykę i technikę wykonywania zadań jak i potencjał środków napadu powietrznego w poszczególnych krajach. Pomimo dość luźnego powiązania wymienionych zagadnień z tematem badań literatura ta jest niezbędna w przyszłości do stworzenia części bazy danych dotyczącej możliwości środków napadu powietrznego.

Druga grupa literatury obejmuje swoim zakresem metody oceny przeciwnika powietrznego do reprezentatywnych prac należy tutaj zaliczyć: Metodykę oceny przeciwnika powietrznego na szczeblu taktycznym i operacyjno-taktycznym wojsk systemu OP RP pana płk. Zbigniewa Groszka<sup>2</sup>; Prognozowanie uderzeń ŚNP przeciwnika na obiekty obrony korpusu OPK metodą symulacji grafo-dynamicznej pana Jagielskiego<sup>3</sup> oraz Metodyka oceny zagrożenia wojsk lądowych uderzeniami środków napadu powietrznego<sup>4</sup> panów płk. Bogdana Zdrodowskiego i płk Zbigniewa Groszka. Opisane w literaturze metody stwarzają przesłanki do budowy eksperckiego systemu oceny przeciwnika powietrznego. Z poszczególnych książkach opisane są zarówno metody jak i szczegółowe procedury pozwalające dokonać oceny działania środków napadu powietrznego.

Trzecia grupa literatury dotycząca sztucznej inteligencji i systemów eksperckich reprezentowana jest bardzo szeroko ze względu na popularność tych zagadnień w związku z ciągłym rozwojem techniki mikrokomputerowej. Z pośród bardzo wielu wydawnictw na szczególną uwagę zasługuje praca pana profesora Jana Mulawki Systemy ekspertowe<sup>5</sup>. Warta przypomnienia jest

---

<sup>2</sup> Groszek Zb.: Metodyka oceny przeciwnika powietrznego na szczeblu taktycznym i operacyjno-taktycznym wojsk systemu OP RP, AON 1993

<sup>3</sup> Jagielski J.: Prognozowanie uderzeń ŚNP przeciwnika na obiekty obrony korpusu OPK metodą symulacji grafo-dynamicznej, ASG WP, 1984

<sup>4</sup> Groszek Zb., Zdrodowski B.: Metodyka oceny zagrożenia wojsk lądowych uderzeniami środków napadu powietrznego. AON Warszawa 1994

<sup>5</sup> Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

również praca pana ppłk Zbigniewa Świątnickiego: *Wojskowe systemy eksperckie*<sup>6</sup>.

Analiza literatury potwierdziła istnienie realnych przesłanek do skonstruowania programu eksperckiego. Wynikiem tego było przystąpienie do prac badawczych w ramach tematu **Ekspertowy model oceny działania środków napadu powietrznego.**

Głównym celem badań jest **skonstruowanie modelu umożliwiającego dokonanie oceny środków napadu powietrznego w czasie prowadzenia działań na współczesnym polu walki.**

**Etap I** W ramach pracy realizowane mają być cztery podtematy w 1997 roku praca pod tytułem **zastosowanie sztucznej inteligencji w procesach oceny przeciwnika powietrznego.** Głównym celem badań w ramach podtematu jest **usystematyzowanie wiedzy o systemach eksperckich i sztucznej inteligencji w aspekcie oceny przeciwnika powietrznego.**

**Etap II** W 1998 praca tytułem **Metody oceny przeciwnika powietrznego,** celem dokonania **identyfikacji metod oceny przeciwnika powietrznego oraz wyboru metod spełniających wymagania programów ekspertowych.**

**Etap III** W 1999 prowadzone będą badania nad **modelem ekspertowego programu oceny przeciwnika powietrznego** w celu **wypracowania założeń, wytycznych eksploatacyjnych, opracowania funkcji programu ekspertowego oceny przeciwnika powietrznego.**

**Etap IV** Na zakończenie w 2000 roku ma powstać **Ekspertowy model oceny przeciwnika powietrznego.**

---

<sup>6</sup> Świątnicki Zb.: *Wojskowe systemy eksperckie.* Bellona Warszawa 1995

Obecnie został zakończony pierwszy etap badań, a wnioski z niego zawarte są w kolejnych rozdziałach niniejszego opracowania.

W ramach pierwszego etapu prac badania były prowadzone nad  
**zastosowaniem sztucznej inteligencji w procesach oceny przeciwnika powietrznego.**

Głównym celem badań pierwszego etapu badań było:

*usystematyzowanie wiedzy o systemach eksperckich i sztucznej inteligencji w aspekcie oceny przeciwnika powietrznego.*

Osiągnięcie celu głównego było możliwe dzięki rozwiązaniu następujących problemów cząstkowych :

- Co to jest sztuczna inteligencja oraz system ekspertowy i czy mogą mieć zastosowanie w ocenie przeciwnika powietrznego?
- Jakie podstawowe metody reprezentacji wiedzy oraz wnioskowania stosowane są w systemach ekspertowych i czy można je stosować w systemie ekspertowym oceny działania przeciwnika powietrznego?

Przypuszczam, że można zastosować system ekspertowy do oceny działania przeciwnika powietrznego?

Najprawdopodobniej nie wszystkie metody reprezentacji wiedzy i metody wnioskowania będą miały swoje zastosowania w przyszłym programie komputerowym. Mało prawdopodobne będzie operowanie na zbiorach rozmytych i sieciach neuronowych.

W procesie badawczym podstawową metodą badawczą, była analiza literatury, która umożliwiła mi usystematyzowanie wiedzy o systemach eksperckich i sztucznej inteligencji w aspekcie oceny przeciwnika powietrznego.

# 1. Podstawy systemów ekspertowych

## 1.1. Inteligencja i sztuczna inteligencja

*Pojęcie inteligencji* Pojęcie inteligencji najprawdopodobniej wprowadził już w starożytności Cynceron<sup>7</sup>. W jego interpretacji termin ten miał oznaczać zdolności umysłowe człowieka. Późniejsi badacze nadali temu terminowi bardziej rozwiniętą interpretację. Najogólniej mówiąc, termin inteligencja oznacza *zdolność rozumienia otaczających sytuacji i znajdowania na nie właściwych reakcji*. W płaszczyźnie filozoficznej inteligencję określa się jako zdolność umysłu do efektywnego ujmowania - dzięki posługiwaniu się pamięcią, wyobraźnią i myśleniem pojęciowym - zagadnień zarówno praktycznych, jak i teoretycznych, przed którymi staje. Wyjaśnienia te sygnalizuje powiązanie inteligencji człowieka z takimi jej cechami jak: świadomość, podświadomość, intuicja, operowanie pojęciami, myślenie treściowe, rozumienie, przeżywanie stanów emocjonalnych<sup>8</sup>.

Inteligencja jest więc właściwością psychiczną, która przejawia się we względnie stałej, charakterystycznej dla jednostki, efektywności wykonywania zadań. Bardzo często można spotkać się ze stwierdzeniem, że inteligencja to zdolność uczenia się oraz rozwiązywania zadań, a jej miarą jest stopień trudności przyswajanego materiału. Inteligencję można więc interpretować jako zdolności rozpoznawania obserwowanego wycinka rzeczywistości, jego rozumienia, określania właściwych celów oraz poszukiwania sposobów osiągnięcia tych celów. Oznacza to umiejętność rozwiązywania świadomie określonych zadań. „Rozumienie otaczającej rzeczywistości” można przy tym interpretować jako wynik procesu percepcji tej rzeczywistości i zbierania o niej informacji z otoczenia i ich klasyfikowania.

---

<sup>7</sup> Strelau J.: O inteligencji człowieka. Wiedza powszechna. Warszawa 1987

<sup>8</sup> Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

Pojęcie sztucznej inteligencji      Jeżeli zdefiniowana została inteligencja, należy zadać sobie pytanie czym wobec tego jest sztuczna inteligencja. (Artificial Intelligence). Podanie precyzyjnej definicji nie jest możliwe chociażby ze względu na sprzeczność między znaczeniem słów „sztuczna” a „inteligencja”. Spotykane w literaturze definicje uwypuklają różne aspekty badań w zakresie tej dziedziny:

Według Joanny Chromiec i Edyty Strzemiecznej<sup>9</sup> sztuczną inteligencję można definiować na trzy sposoby

**Definicja 1.**

Sztuczna inteligencja to nauka mająca za zadanie nauczyć maszyny zachowania podobnego do ludzkiego.

**Definicja 2.**

Sztuczna inteligencja to nauka o tym, jak spowodować aby komputery robiły rzeczy, które aktualnie ludzie robią lepiej.

**Definicja 3.**

Sztuczna inteligencja to nauka o obliczeniach, które umożliwiają rozumienie, rozumowanie, działanie.

Inne definicje przytacza profesor Jan Mulawka w „Systemach ekspertowych”<sup>10</sup>

**Definicja 4.**

Sztuczna inteligencja jest nauką o maszynach realizujących zadania, które wymagają inteligencji wówczas, gdy są wykonywane przez człowieka.<sup>11</sup>

**Definicja 5.**

Sztuczna inteligencja stanowi dziedzinę informatyki dotyczącą metod i technik wnioskowania symbolicznego przez komputer oraz symbolicznej reprezentacji wiedzy stosowanej podczas takiego wnioskowania.

---

<sup>9</sup> Chromiec J., Strzemieczna E.: Sztuczna inteligencja. Akademicka Oficyna Wydawnicza PLJ. Warszawa 1994

<sup>10</sup> Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

<sup>11</sup> Minsky M.: Steps Toward artificial intelligence. W: Computers and Thought. Mc Graw-Hill New York 1975

Definicja 1 koncentruje się głównie na podejściu psychologicznym, i rzeczywiście prawdą jest, że sztuczna inteligencja zajmuje się badaniem zachowań ludzkich w różnych dziedzinach i próbuje zachowania te przenieść na maszyny. Jednak wiadomo, że ludzie są omylni i na przykład często popełniają błędy w obliczeniach, implementacja takich zachowań nie jest celem sztucznej inteligencji.

Definicja 2 sugeruje, że dzięki sztucznej inteligencji wykonanie zadań przez maszyny ma być lepsze niż ludzkie. Z kolei definicja ta odwołuje się do obecnego poziomu wiedzy człowieka i możliwości maszyn, nie ma jednak gwarancji na to, jak sytuacja zmieni się w przyszłości. Być może w niektórych dziedzinach wykonanie zadań przez człowieka poprawi się w przyszłości, lub poprawi się szybciej niż możliwości maszyn i po jakimś czasie okaże się, że mimo postępu w ramach sztucznej inteligencji znowu ludzie będą robili zadania lepiej.

Definicja 3 najlepiej dostosowana jest do współczesnego stanu sztucznej inteligencji, ale chyba zbyt mało sugeruje związek z ludzkimi zachowaniami.

Wady tej pozbawiona jest już definicja 4 lecz jej struktura oparta jest na pojęciu inteligencji czyli czymś trudno definiowalnym, a więc i ta definicja nie jest ścisła.

Ostatnia, 5 definicja ogranicza się do sprowadzenia sztucznej inteligencji do części składowej informatyki.

Konkluzją tych rozważań powinno być stwierdzenie, że podobnie jak przy pojęciu inteligencji, łatwiej chyba zrozumieć intuicyjnie czym jest sztuczna inteligencja, niż ją faktycznie zdefiniować.

*Rys historyczny* Jedną z pierwszych prac naukowych poświęconych sztucznej inteligencji była *Computing Machinery and Intelligence* wydana w 1950 roku przez Alana Turina (1912-1954), który zaproponował w niej tzw. test na inteligencję (zwany testem Turina). W podejściu Turina maszynę można nazwać inteligentną, jeśli przy tych samych przesłankach,

rozumowanie ludzkie i maszynowe są nie do odróżnienia. Testowi poddawany był jeden człowiek i jedna maszyna. Osoba przeprowadzająca test miała być odizolowana zarówno od człowieka jak i komputera poddawanych testowi, więc kontaktować się z nimi mogła wyłącznie przez terminal, zadając jednak dowolne pytania. Zadaniem osoby przeprowadzającej test było odróżnienie rozmówców: który jest człowiekiem, który komputerem. Oczywiście żaden komputer nie przeszedł tego testu pomyślnie. Wynik testu wykazywały wyższość człowieka nad maszyną. Jednak do czasu. W 1997 roku szachowy mistrz świata A. Kasparow przegrał pojedynek szachowy z komputerem.

W latach pięćdziesiątych problemy zaliczane obecnie do sztucznej inteligencji próbowano rozwiązywać za pomocą modeli ludzkiego mózgu<sup>12</sup> i poddawanie ich odpowiedniemu treningowi. Zarówno fizjologia mózgu nie jest tak dobrze znana, jak i sprzęt komputerowy tego okresu nie był w stanie podołać takiemu zadaniu, więc pierwsze próby przyniosły raczej rozczarowanie. Warto jednak wspomnieć o powstałym w owym okresie systemie PERCEPTRON Franka Rosenblatta. Był to prosty model siatkówki oka kręgowców, składającej się z 400 punktów o wartościach: 1=oświetlony, 0=ciemny. Urządzenie to było w stanie rozpoznawać pewną klasę obrazów. Wiele idei tego rozwiązania jest wykorzystywanych po dzień dzisiejszy, choć w zmodyfikowanej formie w sieciach neuronowych.

Następnym krokiem w rozwoju sztucznej inteligencji było zaproponowane przez Allana Newella i Herberta Simona przedstawienie kojarzenia i rozumowania, jako poszukiwania rozwiązania w przestrzeni stanów. Zaproponowane przez nich metody heurystyczne są wykorzystywane do dzisiaj, ale złożoność problemów właściwych sztucznej inteligencji pozwala na wykorzystanie tych metod tylko do ograniczonych klas problemów.

Dopiero lata osiemdziesiąte i badania nad systemami eksperckimi przyniosły efekty w pracach związanych ze sztuczną inteligencją. Znalaziono wówczas realne rozwiązania dla wąskich klas problemów, ale po raz pierwszy

---

<sup>12</sup> Pierwsza sieć neuronowa

miały one możliwość szerszego zastosowania. Niektóre z powstałych wówczas systemów stanowią do dzisiaj rozwiązania modelowe (np. MYCIN<sup>13</sup>).

Dzięki rozwojowi techniki audiowizualnej, zainteresowania sztucznej inteligencji w latach osiemdziesiątych skupiły się na rozpoznawaniu mowy i obrazu oraz komputerowym uczeniu się (machine learning). Warto przy tej okazji wspomnieć system EURISKO Douga Lenata, który potrafił definiować nowe pojęcia i nowe zasady heurystyczne dodając je do już posiadanych. Zastosowany przy projektowaniu układów scalonych wynalazł bramkę logiczną and/or.

Aktualnie badania nad sztuczną inteligencją ponownie skupiają się na rozwiązaniach związanych z sieciami neuronowymi, jednak już przynoszą lepsze efekty niż w latach pięćdziesiątych, dzięki wyższemu rozwojowi techniki komputerowej i stosowaniu sieci wielopoziomowych.

W metodach sztucznej inteligencji następuje przejście od przetwarzania danych do przetwarzania wiedzy. Systemy te określa się jako systemy oparte na wiedzy (knowledge - based systems). Metody algorytmiczne charakterystyczne dla przetwarzania proceduralnego w sztucznej inteligencji zostają zastąpione przeszukiwaniem inteligentnym (intelligent search).

Reasumując historyczny aspekt sztucznej inteligencji prof. Jan Mulawka w procesie rozwoju metod sztucznej inteligencji wyróżnia trzy ważne etapy. W początkowym okresie do ok. 1970 r. poszukiwano ogólnych metod rozwiązywania problemów i ich zastosowania do stworzenia programu ogólnego przeznaczenia. Próby te zakończyły się jednak niepowodzeniem. W 1971 r. ukazał się raport Lighthilla, który zahamował na pewien czas postęp w

---

<sup>13</sup> MYCIN - najpopularniejszy systemem doradczy. Jest to system diagnozującym choroby krwi i proponujący sposób ich leczenia. Stawiana diagnoza wynika z wiedzy systemu łączącej rodzaj infekcji z objawami i wynikami testów pacjenta. Wiadomości wstępne o pacjencie system gromadzi w czasie „wstępnej konwersacji”. System pyta pacjenta o jego imię, nazwisko, płeć, wiek, czyli nie będące ogólną charakterystyką chorego, a także o początki choroby i jej aktualne objawy, wyniki wstępnych badań. System wnioskuje na podstawie zawartych w nim reguł i stawia przybliżoną diagnozę. Po skonsultowaniu diagnozy z użytkownikiem, zaleca sposób leczenia, pobierając, jeśli jest to konieczne, dodatkowe dane o pacjencie. W przypadku niepewnej diagnozy system może podać wszystkie prawdopodobne diagnozy i stopnie pewności, jakie im w trakcie wnioskowania przypisał. Lekarz ma za zadanie wybrać właściwą jego zdaniem diagnozę, MYCIN podaje wtedy, jaki sposób leczenia należy zastosować i w razie potrzeby przelicza np. dawki leków dla wagi pacjenta.

tej dziedzinie. Rozpoczęte prace były jednak dalej prowadzone i w 1974 r. powstał program o nazwie MYCIN, który stanowi ważne osiągnięcie w rozwoju systemów ekspertowych. W następnych latach do ok. 1980 r. poszukiwano ogólnych metod poprawy reprezentacji i przeszukiwania oraz zastosowanie ich do tworzenia specjalistycznych programów. W trzecim etapie od ok. 1980 r. rozwijano metody, które polegały na zastosowaniu dużej ilości wąsko specjalizowanej wiedzy o wybranej wąskiej dziedzinie w celu stworzenia bardzo specjalizowanych programów. Szeroko były prowadzone badania między innymi nad wykorzystaniem systemów eksperckich w wojsku. Programy wojskowe można podzielić na dwie zasadnicze grupy. Pierwszą wspomagającą dowodzenie, w tym podejmowanie decyzji, i drugą wspomagającą eksploatację sprzętu.

W pierwszej grupie należało by wyróżnić TWIRL<sup>14</sup> (*Tactical Warfare In the Poss Language*), Tepler<sup>15</sup> oraz polski program REKOMENDACJE<sup>16</sup> który jest elementem zautomatyzowanego systemu dowodzenia wojsk obrony przeciwlotniczej ZENIT. O wiele więcej przykładów można przedstawić w drugiej grupie są to między innymi systemy : ALV (*Automobiles Lend Vehicle*)<sup>17</sup>, PA (*Pilot Associate*)<sup>18</sup> oraz systemy typu CITS (*Central Integrated Test System*)<sup>19</sup>. Większa liczba wysoko specjalistycznych systemów przystosowanych do danego typu uzbrojenia uwarunkowana jest łatwiejszym opisem matematycznym zjawisk technicznych niż zjawisk współczesnego pola walki. Wieloznaczność zjawisk na współczesnym polu walki wymagała od konstruktorów i sprzętu wykonującego obliczenia

---

<sup>14</sup> Program ten służy do weryfikacji różnych wariantów działania wojsk lądowych w obronie i natarciu. Źródło Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995

<sup>15</sup> System wspomagający planowanie zadań dla 1000 samolotów. Źródło Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995

<sup>16</sup> Program REKOMENDACJE dokonuje podziału celów do zwalczania przez poszczególne oddziały i pododdziały przeciwlotnicze oraz lotnictwo myśliwskie.

<sup>17</sup> System umożliwiający poruszanie się pojazdu samochodowego w terenie bez kierowcy. Źródło Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995

<sup>18</sup> Wielo elementowy, zbudowany na systemach ekspertowych program konstrukcji robota lotniczego. Źródło Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995

<sup>19</sup> Systemy tego typu służą do diagnostyki remontowej sprzętu i uzbrojenia. Obecnie działają już systemy do diagnostyki samolotów B-1B, F15, F-16. Źródło Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995

rozpatrywanie bardzo wielu teoretycznie nie mających ze sobą wiele wspólnego zagadnień i wyciąganie wspólnych wniosków. Zadania takiego nie były w stanie wykonać komputery lat osiemdziesiątych. Obecny rozwój techniki mikrokomputerowej pozwala na rozwiązywanie tych zadań na powszechnie dostępnym sprzęcie.

Badania te przyniosły liczne praktyczne zastosowania systemów ekspertowych, zarówno w sferze poza militarnej jak i ściśle wojskowej, najważniejsze przedstawiłem w tabelicy 1.

*Tabela 1. Zestawienie najważniejszych osiągnięć w okresie rozwoju metod sztucznej inteligencji*

Etap	Okres	Kluczowe osiągnięcia
0	Lata przed II wojną światową	logika formalna, psychologia poznawcza
1	Lata powojenne 1945-1954	powstanie komputerów, rozwój cybernetyki
	Rozpoczęcie badań w dziedzinie sztucznej inteligencji 1955-1960	rozwój komputerów, Lisp, sformułowanie programu rozwiązywania problemów
2	Badania w dziedzinie rozwiązywania problemów 1961-1970	heurystyki, robotyka, programy do gry w szachy
	Systemy oparte na bazach wiedzy 1971-1980	MYCIN
3	Po 1981 r. liczne zastosowania praktyczne	TWIRL, Tepler, ALV, PA, CITS

Obecnie w etapie burzliwego rozwoju komputerów i oprogramowania, badania prowadzone w zakresie sztucznej inteligencji można podzielić na szereg poddziedzin<sup>20</sup> :

<sup>20</sup> Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

- rozwiązywanie problemów i strategie przeszukiwań,
- teoria gier,
- automatyczne dowodzenie twierdzeń,
- przetwarzanie języka naturalnego (włączając przetwarzanie mowy),
- systemy ekspertowe,
- robotyka,
- procesy percepcji (wizja, słuch, dotyk),
- uczenie się maszyn,
- wyszukiwanie informacji (inteligentne bazy danych),
- programowanie automatyczne.

Z wymienionych poddziedzin ocena przeciwnika powietrznego mieści się w :

- systemach ekspertowych,
- wyszukiwaniu informacji (inteligentne bazy danych).

## **1.2. Systemy ekspertowe**

System ekspertowy jest programem komputerowym, który wykonuje złożone zadania o dużych wymaganiach intelektualnych i robi to tak dobrze jak człowiek, będący ekspertem w tej dziedzinie. Określenie „system ekspertowy” może być zastosowane do dowolnego programu komputerowego, który na podstawie szczegółowej wiedzy może wyciągać wnioski i podejmować decyzje, działając w sposób zbliżony do procesu rozumowania człowieka. W ten sposób określamy system, który niekoniecznie zastępuje eksperta - człowieka<sup>21</sup>. W wielu bowiem sytuacjach, np. podczas podejmowania decyzji w na współczesnym polu walki, podczas sterowania lub diagnozy skomplikowanych urządzeń technicznych jak samolot najnowszej generacji lub na pokładzie statków kosmicznych itd., człowiek nie mógłby

---

<sup>21</sup> Baborski A.: Efektywne zarządzanie a sztuczna inteligencja Wyd. Akademii Ekonomicznej im Oskara Langego. Wrocław 1994

swymi zmysłami ogarnąć całej sytuacji. Są więc potrzebne systemy, które pracują w czasie rzeczywistym i wykonują swoje funkcje lepiej niż człowiek. Z tego względu przez system ekspertowy należy rozumieć program komputerowy przeznaczony do rozwiązywania specjalistycznych problemów, które wymagają profesjonalnej ekspertyzy.

Systemy ekspertowe można podzielić na trzy ogólne kategorie:

- doradcze (*advisory*);
- podejmujące decyzje bez kontroli człowieka (*dictatorial*);
- krytykujące (*criticizing*).

**Systemy doradcze** prezentują rozwiązania dla użytkownika, który jest w stanie ocenić ich jakość. Użytkownik może odrzucić rozwiązanie oferowane przez system i zażądać innego rozwiązania. Takie rozwiązanie zastosowane jest między innymi w zautomatyzowanym systemie dowodzenia wojskami obrony przeciwlotniczej ZENIT, podczas rekomendacji przydziałów celów do zniszczenia.

**Systemy podejmujące decyzje bez kontroli człowieka** są same dla siebie końcowym autorytetem. Są używane np. do sterowania różnymi obiektami, gdzie udział człowieka jest utrudniony lub wręcz niemożliwy. Systemów tej kategorii nie można zastosować do oceny przeciwnika działania powietrznego przy obecnym stanie wiedzy. Perspektywicznie realne jest zbudowanie urządzenia sterującego systemem zwalczania obiektów powietrznych bez ingerowania człowieka.

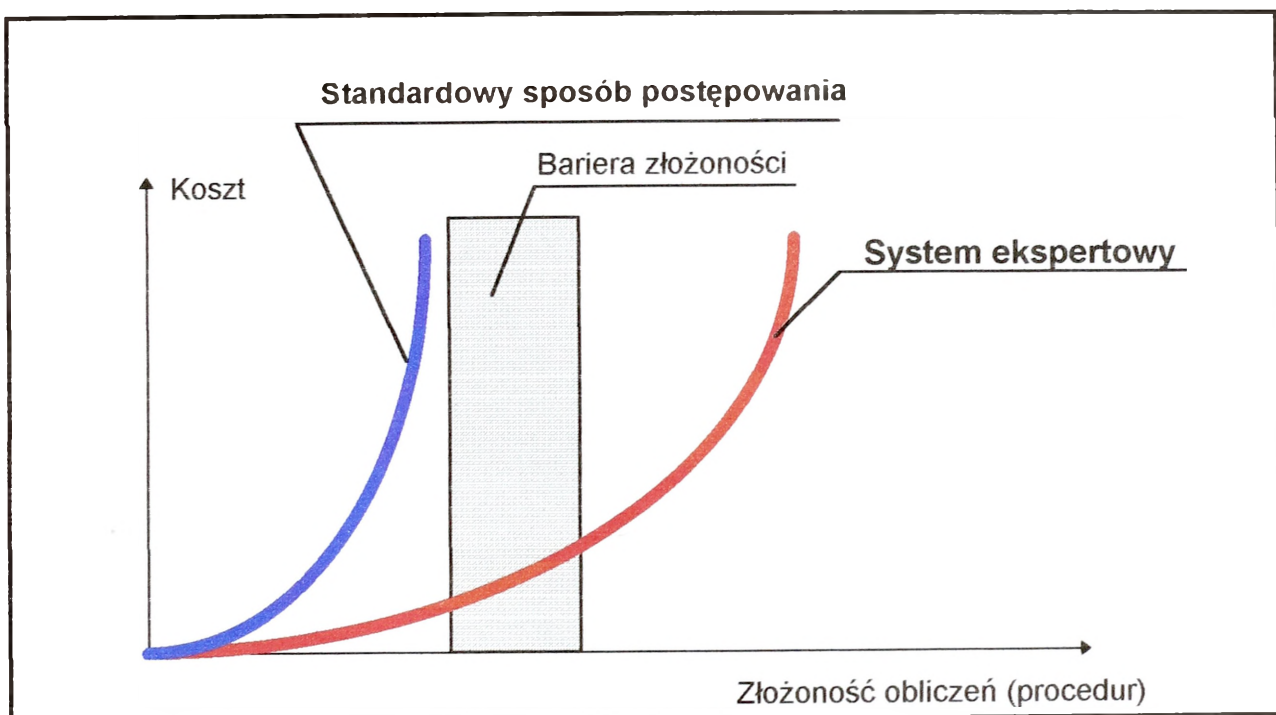
Z kolei dla **systemów krytykujących** jest przedstawiany problem jak też jego rozwiązanie. System dokonuje w tym przypadku analizy i komentuje uzyskane rozwiązanie. Systemy tej kategorii mogły by być bardzo pomocne do weryfikacji przyjętych rozwiązań taktycznych w procesie dydaktycznym, były by one bardzo dobrym narzędziem do kształcenia specjalistów w zakresie oceny przeciwnika powietrznego.

Systemy ekspertowe stosuje się przede wszystkim w wielu dziedzinach gdzie:

- informacja o danej dziedzinie jest niepewna;

- nie istnieje model matematyczny;
- rozwiązywanie problemów jest bardzo skomplikowane.

Szerszego wyjaśnienia wymaga trzecia kategoria dziedzin w których rozwiązywanie problemów jest bardzo skomplikowane. Dla problemów rozpatrywanych w ramach tych dziedzin mogą być opracowane teorie, lecz jest niemożliwością ogarnąć za pomocą algorytmów wszystkich teoretycznie możliwych przypadków w rozsądnym czasie. Powstaje często w praktyce bariera złożoności obliczeniowej, przedstawiona na rysunku 1. Bariere tę można pokonać stosując systemy eksperckie.



Rysunek 1. Zależność złożoność obliczeń - koszt w standardowym sposobie postępowania oraz przy zastosowaniu systemów eksperckich na tle bariery złożoności

Zagadnienie to jest również uwzględniane w obronie powietrznej, przypomnę tutaj, ściśle związany z oceną działania przeciwnika powietrznego, problem czasu potrzebnego i dysponowanego na postawienie oddziałom i pododdziałom zadań osiągnięcia gotowości do działania.

System ekspercki, dysponując zapisaną wiedzą eksperta np. z zakresu oceny przeciwnika powietrznego, może jej używać wielokrotnie w sposób ekonomicznie efektywny, gdyż nie jest przy tym wymagana obecność eksperta. Umożliwia to ekspertowi jednoczesne uwolnienie się od powtarzania analogicznych czynności i zajęcie się bardziej twórczymi zadaniami. Szczególną zaletą takich systemów jest możliwość rozwiązywania problemów

bez bezpośredniego udziału eksperta, jak również możliwość agregacji wiedzy w jednym systemie wielu ekspertów. Przykładowo specjalista znający teoretyczne możliwości bojowe śmigłowców przeciwpancernych aby odpowiedzieć na pytanie jakie są te możliwości w konkretnej sytuacji, z uwzględnieniem bardzo wielu czynników typu, dzień walki, procent ukompletowania, warunki klimatyczne, wyszkolenie obsługi itp. , musi każdorazowo wykonać czasochłonne obliczenia. Maszyna - system ekspercki - wykona te obliczenia o wiele szybciej jednocześnie dane wejściowe i wnioski z obliczeń będą automatycznie wykorzystywane do dalszej analizy dla innych specjalistów.

### **1.3. Struktura systemów ekspertowych**

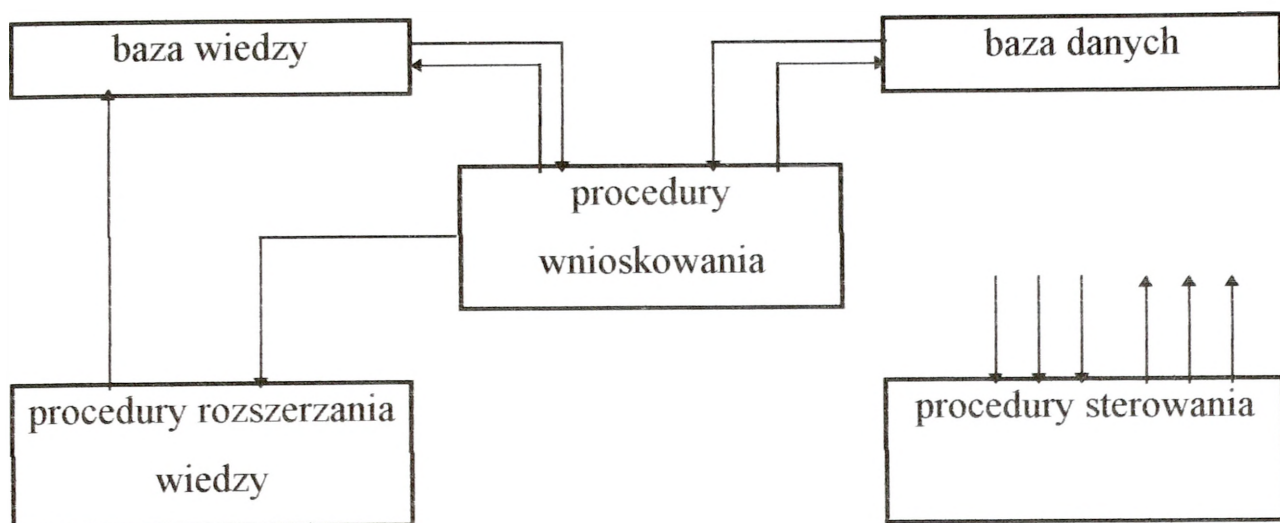
Rozważając szczegółowo strukturę systemów ekspertowych można w niej wyróżnić następujące podstawowe elementy<sup>22</sup>:

- baza wiedzy (np. zbiór reguł obowiązujących w danej dziedzinie);
- baza danych (np. dane o obiekcie);
- procedury wnioskowania - realizujące zasadnicze zadanie systemu;
- procedury sterowania dialogiem - procedury wejścia i wyjścia umożliwiają formułowanie zadań przez użytkownika i przekazywanie rozwiązania przez program;
- procedury umożliwiające rozszerzanie oraz modyfikacje wiedzy - może to być także wiedza zdobyta przez sam system ekspertowy.

Uwzględniając te elementy strukturę systemu ekspertowego można przedstawić w postaci schematu - rysunek 2.

---

<sup>22</sup> Muławka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996



Rysunek 2 Struktura systemu ekspertowego

#### 1.4. Rodzaje systemów ekspertowych

Oceniając system ekspertowy, często najpierw należy sprawdzić co otrzymujemy na jego wyjściu. Wynikiem może być: diagnoza, prognoza lub plan.

**Diagnoza** jest to ocena stanu istniejącego na podstawie posiadanych danych. Do tej grupy zaliczamy programy: MYCIN<sup>23</sup>, CASNET<sup>24</sup>, CITS<sup>25</sup> W sferze wojskowej programy tego typu diagnozują stan techniczny uzbrojenia np. CITS dokonuje diagnozy samolotu B-1B.

**Prognoza** jest to przewidywanie stanu przyszłego na podstawie istniejących danych. Niektóre programy medyczne, np. CASNET, stawiają prognozę stanu zdrowia pacjenta na podstawie własnej diagnozy.

**Plan** wreszcie jest rozumiany jako opis pewnego stanu, do którego należy dążyć.

Łączenie ze sobą tych trzech typów pracy systemu ekspertowego jest oczywiście możliwe. Dzięki połączeniu rozpoznawania wzorca, diagnozy i planowania uzyskujemy systemy sterujące, np. system sterowania statkiem powietrznym - automatyczny pilot . Inną grupę stanowią systemy diagnozowania i planowania na przykład systemów uczących. Pod kątem tak

<sup>23</sup> Patrz przypis 13

<sup>24</sup> Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995

<sup>25</sup> Tamże

określonych zadań należy zatem porównywać i oceniać różne systemy ekspertowe. W tabelicy 2 przedstawiłem różne rodzaje systemów ekspertowych w zależności od realizowanych przez te systemy zadań.

*Tabela 2 Rodzaje systemów ekspertowych<sup>26</sup>*

Kategoria	Zadania realizowane przez systemy ekspertowe
Interpretacyjne	dedukują opisy sytuacji z obserwacji lub stanu czujników, np. rozpoznawanie mowy, obrazów, struktur danych
Predykcyjne	wnioskują o przyszłości na podstawie danej sytuacji, np. prognoza rozwoju działań na polu walki
Diagnostyczne	określają wady systemu na podstawie obserwacji, np. medycyna, elektronika, mechanika
Kompletowania	konfigurują obiekty w warunkach ograniczeń, np. konfigurowanie systemu komputerowego
Planowania	podejmują działania, aby osiągnąć cel, np. ruchy robota
Monitorowania	porównują obserwacje z ograniczeniami, np. w elektrowniach atomowych, medycynie, w ruchu ulicznym
Sterowania	kierują zachowaniem systemu; obejmują interpretowanie, predykcję, naprawę i monitorowanie zachowania się obiektu
Poprawiania	podają sposób postępowania w przypadku złego funkcjonowania obiektu, którego te systemy dotyczą
Naprawy	harmonogramują czynności przy dokonywaniu napraw uszkodzonych obiektów
Instruowania	systemy doskonalenia zawodowego dla studentów

W zależności od kryterium podziału wyróżnić można bardzo wiele grup systemów ekspertowych.

<sup>26</sup> Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

Przy podziale względu na metodę prowadzenia procesu wnioskowania systemy ekspertowe można podzielić na:

- z logiką dwuwartościową (Boole'a),
- z logiką wielowartościową,
- z logiką rozmytą.

Ze względu na rodzaj przetwarzanej informacji systemy ekspertowe dzielą się na:

- systemy z wiedzą pewną, czyli zdeterminowaną;
- systemy z wiedzą niepewną, w przetwarzaniu której wykorzystuje się przede wszystkim aparat probabilistyczny.

Charakterystyczną cechą większości znanych systemów ekspertowych jest przedstawienie informacji w postaci symbolicznej. Umożliwia to wykorzystanie w systemie wszelkich istniejących układów przetwarzania symboli. Możemy przyjąć, że właśnie posługiwanie się symbolami wyróżnia klasyczne systemy ekspertowe spośród innych programów. Istnieją jednak systemy ekspertowe oparte na niesymbolicznych metodach przetwarzania informacji, np. sieci neuronowe. Wśród technik opartych na symbolicznym przetwarzaniu informacji kryterium podziału systemów ekspertowych jest dokonywane ze względu na rodzaj reprezentacji wiedzy. Możemy tu wyróżnić takie metody reprezentacji wiedzy jak:

- reguły,
- ramy,
- sieci semantyczne,
- predykaty

## 2. Podstawowe metody stosowane w systemach eksperckich

### 2.1. Metody reprezentowania wiedzy

#### 2.1.1. Wiedza oraz sposoby jej reprezentacji

Reprezentacja wiedzy w dziedzinie sztucznej inteligencji stanowi jeden z podstawowych problemów, który nie został jeszcze w pełni rozwiązany. Na wstępie należałoby wyjaśnić, czym jest wiedza w danej dziedzinie. Najczęściej pojęcie to oznacza zbiór wiadomości z określonej dziedziny, wszelkie zobiektywizowane i utrwalone formy kultury umysłowej i świadomości społecznej powstałe w wyniku kumulowania doświadczeń i uczenia się. Można także powiedzieć, że wiedza jest symbolicznym opisem otaczającego nas świata rzeczywistego charakteryzującym aksjomatyczne i empiryczne relacje, zawierającym procedury, które manipulują tymi relacjami. Wiedza zatem składa się z następujących elementów: opisów lub inaczej faktów, relacji, procedur.

Metody reprezentacji wiedzy zajmują się modelowaniem świata rzeczywistego z wykorzystaniem komputerów. Do najczęściej stosowanych metod reprezentowania wiedzy czyli technik organizowania baz wiedzy należy zaliczyć<sup>27</sup>:

- metody bazujące na bezpośrednim zastosowaniu logiki: rachunek zdań, rachunek predykatów;
- metody wykorzystujące zapis stwierdzeń;
- metody wykorzystujące systemy regułowe (wektory wiedzy);
- metody z wykorzystaniem sieci semantycznych;
- metody oparte na ramach;
- metody używające modeli obliczeniowych.

Wymienione metody opisałem w kolejnych podrozdziałach.

Oprócz wyżej wymienionych i dobrze poznanych symbolicznych metod reprezentacji wiedzy bardzo modny jest obecnie inny nurt badań w tej



dziedzinie - reprezentacje niesymboliczne. Metody te odwołują się do obserwacji i doświadczeń zebranych na podstawie otaczającego nas świata żywych istot. Tzw. sztuczne sieci neuronowe symulują właściwości reprezentacji wiedzy i jej przetwarzania, podobnie jak komórki nerwowe zwierząt i ludzi.

### 2.1.2. Rachunek zdań<sup>28</sup>

Podstawowe koncepcje mechanizmów wnioskowania większości znanych systemów ekspertowych wywodzą się z logiki dwuwartościowej. Opis cech otaczającego nas świata formułujemy w postaci zdań. O zdaniu prawdziwym mówimy, że ma wartość logiczną 1, o zdaniu fałszywym, że ma wartość logiczną 0. Zdania oznaczamy symbolami, np. A, B, C, D ... Mogą one być łączone za pomocą funktorów zdaniotwórczych (spójników logicznych):

- $\neg$  negacja,
- $\wedge$  koniunkcja,
- $\vee$  alternatywa,
- $\Rightarrow$  implikacja,
- $\Leftrightarrow$  równowość.

Łącząc zdania funktorami można tworzyć wyrażenia logiczne, tzw. formuły. Formuły zawsze dają zdanie prawdziwe niezależnie od wartości logicznych zmiennych zdaniowych, nazywamy prawami rachunku zdań (tautologiami). Są dwie metody sprawdzania, czy dana formuła jest tautologią:

- a) metoda zerojedynkowa,
- b) metoda dedukcji (wnioskowania).

W pierwszej metodzie wartość logiczna formuły złożonej jest wyznaczana przez wartości logiczne jej składników. Aby rozstrzygnąć, czy formuła jest tautologią, należy rozważyć wszystkie możliwe kombinacje

---

<sup>27</sup> Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

<sup>28</sup> Metody reprezentowania wiedzy opisałem na podstawie : Mulawka J. Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996

wartości logicznych zmiennych w niej występujących. Jeżeli w każdym przypadku wartość formuły wynosi 1, to ta formuła jest tautologią.

Z kolei w drugiej z wymienionych metod wnioskowanie odbywa się przy pomocy reguł wnioskowania, które umożliwiają, na podstawie prawdziwości pewnych zdań zwanych przesłankami, wnioskowanie o prawdziwości innego zdania zwanego wnioskiem. Zagadnieniom wnioskowania poświęcamy więcej uwagi w dalszych punktach niniejszej pracy.

Głównym zadaniem logiki rachunku zdań jest upraszczanie wyrażeń logicznych dla ich lepszego zrozumienia. Wykorzystuje się tu równoważność wyrażeń. Oprócz zdań często używamy funkcji zdaniowych, które stają się zdaniami po ustaleniu wartości zmiennych.

Bazy wiedzy oparte na logice, mimo swej modularności, deklaratywności i nieproceduralności, są trudne do przetwarzania. Bardzo szybko następuje w nich eksplozja kombinatoryczna, czyli lawinowy i niekontrolowany rozrost bazy wiedzy o fakty będące powieleniem istniejących już informacji lub powstawaniem niepożądanych struktur, np.:

jeżeli  $A \vee B$  jest prawdą w bazie wiedzy,

to prawdą jest  $A \vee B \vee B$

również prawda jest  $A \vee B \vee B \vee B \vee B$

Systemy ekspertowe oparte na klasycznej logice wykazują tendencje do wytwarzania tego typu nadmiarowych tautologii.

### 2.1.3. Stwierdzenia

Stwierdzenia są jednym z głównych elementów baz wiedzy. Dotyczą one takich zagadnień jak zdarzenia, zjawiska, objawy, czynności. Stwierdzenia najczęściej są zapisywane w postaci uporządkowanej trójki

( $\langle$  OBIEKT  $\rangle$ ,  $\langle$  ATRYBUT  $\rangle$ ,  $\langle$  WARTOŚĆ  $\rangle$ )

Przykładowo stwierdzenie, że na lotnisku LUBLIN jest 20 samolotów typu MiG-21 można zapisać trójką:

( $\langle$ MIG-21 $\rangle$ ,  $\langle$ LUBLIN $\rangle$ ,  $\langle$ 20 $\rangle$ )

lub

(<LUBLIN>, <MiG-21>, <20>)

w zależności czy obiektem są samoloty czy lotniska.

Dla uproszczenia stwierdzeń stosuje się słowniki nazw obiektów i atrybutów oraz ich wartości. Umożliwia to identyfikowanie zapisów za pomocą etykiet - bez wielokrotnego powtarzania nazw. Dzięki temu uzyskuje się oszczędniejszy zapis, który zajmuje mniej miejsca w pamięci komputera. Na ogół stosuje się słowniki otwarte. W niektórych systemach stwierdzenia są zapisywane w postaci uporządkowanej czwórki

( ( < OBIEKT > , < ATRYBUT > , < WARTOŚĆ > , < CF > ) )

przy czym CF jest stopniem pewności (Certainty Factor), prowadząc do tzw. stwierdzeń przybliżonych. Każdemu stwierdzeniu jest wówczas przypisany pewien współczynnik określający stopień pewności stwierdzenia. Na ogół jest to liczba z przedziału  $\{-1,1\}$ . Jeżeli współczynnik ten jest definiowany trójargumentowo, to  $CF=1$  oznacza, że stwierdzenie jest w pełni prawdziwe. Z kolei dla  $CF= -1$  wiemy, że stwierdzenie jest fałszywe. Natomiast  $CF=0$  oznacza stwierdzenie, o którym nie wiadomo, czy jest prawdziwe, czy fałszywe.

Stopnie pewności wyznacza się subiektywnie. W niektórych systemach stopnie pewności przypisuje się nie stwierdzeniom lecz wartościom atrybutów, co może prowadzić do szeregu paradoksów.

Dla przedstawionego powyżej przykładu stwierdzenie, że na lotnisku LUBLIN najprawdopodobniej jest 20 samolotów typu MiG-21 można zapisać trójką:

(<MIG-21>, <LUBLIN>, <20> , <1>)

gdy wiadomość jest pewna

(<MIG-21>, <LUBLIN>, <20> , <-1>)

gdy wiadomo, że samolotów tych tam nie ma

(<MIG-21>, <LUBLIN>, <20> , <0>)

gdy wiadomość nie jest pewna.

w zależności czy obiektem są samoloty czy lotniska.

#### 2.1.4. Regułowa reprezentacja wiedzy

Wśród różnych metod reprezentacji wiedzy ważną rolę odgrywają metody oparte na regułach. Jeżeli zbiór stwierdzeń nie jest wystarczający do opisanego jakiejś dziedziny wiedzy. Są jeszcze potrzebne reguły, których ogólna postać może być wyrażona jako:

JEŚLI przesłanka, TO konkluzja

oraz

JEŚLI przesłanka, TO działanie (produkcja)

Przykładowo

JEŚLI (leci samolot rozpoznawczy), TO (nasze stanowiska są rozpoznane)

oraz

JEŚLI(leci samolot rozpoznawczy), TO (zmień stanowiska)

Przesłanka może zawierać pewną liczbę stwierdzeń połączonych funktorami logicznymi. Należy zwrócić uwagę, że w systemach opartych na regułach nie występuje niekontrolowany rozrost bazy wiedzy o nadmiarowe tautologie. Baza wiedzy zawiera w tym przypadku zbiór reguł oraz zbiór faktów. Możliwość reprezentowania świata ogranicza się do powyższych struktur zdaniowych. Wydawałoby się, że jest to dość prymitywna metoda. Okazuje się jednak, że jest przeciwnie. Zdecydowana większość powstałych do tej pory systemów ekspertowych jest oparta na regułach. Podejście to umożliwia uzyskanie dużej modularności bazy wiedzy.

Reprezentacja regułowa często jest wykorzystywana w systemach dedukcyjnych, gdzie zbiór faktów początkowych jest przekształcany w pewien zbiór faktów końcowych. W zależności od przeznaczenia system może spełniać różne funkcje, np. klasyfikowanie, diagnozowanie, ustalanie przyczyn, najlepszy dobór, planowanie, prognozowanie, monitorowanie itp.

Praktycznie działające systemy ekspertowe oparte na regułach mogą zawierać reguły charakteryzowane stopniami pewności. Podobnie jak przy reprezentowaniu stwierdzeń są to liczby zazwyczaj z przedziału  $(-1,1)$  albo

(0,1). Dzięki temu można za pomocą tych liczb dać znać systemowi, jaki jest stosunek użytkownika lub twórcy systemu do pewności konkluzji występującej w danej regule.

Zbiór reguł można rozpatrywać jako szczególny sposób zapisu pewnej sieci stwierdzeń, ponieważ z prawdziwości jednego stwierdzenia mogą wynikać inne. W niektórych systemach jest dopuszczalna rozwinięta (tzw. pełna) postać reguł, która zawiera dodatkowe stwierdzenie uznawane za prawdziwe w razie niespełnienia przesłanki. Ogólna postać reguły rozwiniętej jest następująca:

JEŚLI przesłanka, TO konkluzja1 INACZEJ konkluzja2

Przykładowo

JEŚLI (leci samolot rozpoznawczy)

TO (nasze stanowiska są rozpoznane)

INACZEJ (nasze stanowiska nie są rozpoznane przez ten samolot)

Przy czym konkluzja 2 jest tym dodatkowym stwierdzeniem. Taka postać reguł może jednak czasami prowadzić do uznania nieoczekiwanych konkluzji. Ze względu na założoną nieraz kompletność bazy wiedzy, brak przesłanki jest utożsamiany z uznaniem tej przesłanki za przesłankę fałszywą. W związku z tym wskazane jest stosowanie reguł w postaci podstawowej (JEŚLI ... TO ...) Postępowanie takie upraszcza działanie maszyny wnioskującej.

Jeżeli warunki w złożonej przesłance są połączone funktorami koniunkcji, to proces analizowania takiej przesłanki jest przerywany (z wynikiem negatywnym) po napotkaniu pierwszego nie spełnionego warunku. W niektórych systemach w regułach może występować funktor alternatywy, np.

JEŚLI (leci samolot rozpoznawczy)

LUB (leci bezpilotowy środek rozpoznawczy)

TO (nasze stanowiska są rozpoznane)

Regułę taką możemy zamienić na zestaw dwóch równoważnych reguł nie zawierających funktora alternatywy:

JEŚLI (leci samolot rozpoznawczy)

TO (nasze stanowiska są rozpoznane)

lub

JEŚLI (leci bezpilotowy środek rozpoznawczy)

TO (nasze stanowiska są rozpoznane)

Stosowanie spójnika LUB jest dopuszczalne, lecz nie zalecane ze względu na większe skomplikowanie modułu wnioskującego.

Ze względu na sposób uzyskiwania ostatecznych konkluzji w procesie wnioskowania rozróżniamy dwa rodzaje reguł:

- reguły proste - takie, które mają postać wniosków pośrednich;
- reguły złożone - takie, które umożliwiają bezpośrednie wyznaczenie wniosków przez system

#### 2.1.5. Wektory wiedzy

Wektory wiedzy są pewnego rodzaju uogólnieniem reguł, w wyniku którego otrzymujemy zapis w postaci wektorowej. Aby zilustrować ten sposób reprezentacji wiedzy, przyjmujemy, że w wektorach występują trzy symbole:

\*, T, N. Znaczenie poszczególnych symboli jest następujące:

\* - dany warunek/wniosek w regule nie występuje,

T - dany warunek/wniosek jest prawdziwy (tak),

N - dany warunek/wniosek jest fałszywy (nie).

W podejściu tym najpierw dana bazę reguł w tradycyjny sposób, przy czym poszczególne reguły powinny zawierać jednakową liczbę warunków i wniosków. Następnie dokonujemy kodowania poszczególnych członów reguł z wykorzystaniem trzech wprowadzonych symboli. W rezultacie zamiast pisać pełną reprezentację poszczególnych reguł, otrzymujemy bardzo zwarty opis w postaci wektorów, zawierających trzy wymienione symbole.

### 2.1.6. Rachunek predykatów

Ważnym narzędziem w metodach reprezentacji wiedzy jest rachunek predykatów, stanowiący podstawę programowania w logice<sup>29</sup>.

Rachunek predykatów jest rozszerzeniem rachunku zdań przez wprowadzenie kwantyfikatorów: „dla każdego”  $\forall$  oraz „istnieje takie że”  $\exists$ . Wyrażenie  $W(x)$ , w którym występuje zmienna  $x$  i które staje się zdaniem prawdziwym lub fałszywym, gdy w miejsce  $x$  podstawimy wartość zmiennej  $x$ , nazywamy funkcją zdaniową albo predykatem.

Predykat składa się z nazwy i dowolnej liczby argumentów, które są nazywane termami. Termami mogą być stałe alfanumeryczne, jak też numeryczne i zmienne oraz wyrażenia. W wyniku podstawienia stałych za zmienne otrzymujemy zdania prawdziwe lub fałszywe. Przyporządkowanie termom symboli, a nazwie relacji między obiektami definiuje semantykę języka predykatów. Zaletą predykatów są proste i zrozumiałe interpretacje wyrażania zdań.

Należy zauważyć, że nie wszystkie pojęcia o otaczającej nas rzeczywistości dają się reprezentować w logice. Obecnie trudno byłoby jednak wskazać metodę opisu, która sprostałaby wszystkim wymaganiom. Na podkreślenie zasługuje fakt, że rachunek predykatów nadaje się dobrze do opisu podstaw matematyki, która z kolei wystarcza do opisu formalizmów większości współczesnych dyscyplin naukowych. Dużą zaletą teorii logicznych jest ich formalność, czyli możliwość ścisłego i jednoznacznego opisu ich konstrukcji i mechanizmów, co przy reprezentowaniu wielu problemów odgrywa istotną rolę.

---

<sup>29</sup> Szerzej metoda reprezentacji wiedzy opisana jest w Mulawka J. Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996.

### 2.1.7. Sieci semantyczne<sup>30</sup>

Kolejnym modelem wykorzystywanym przy reprezentowaniu wiedzy są sieci semantyczne (semantic nets). Zostały one opracowane przez Quilliana. Początkowym założeniem Quilliana była chęć stworzenia modelu pamięci ludzkiej. Dopiero później okazało się, że model w postaci sieci semantycznej pasuje także do reprezentacji wiedzy.

Zakładając, że baza wiedzy stanowi zbiór stwierdzeń i relacji między nimi. Posługując się tymi pojęciami, możemy utworzyć tzw. sieć stwierdzeń - jako pewien graf, którego węzłami są stwierdzenia, a gałęziami relacje. Węzłom (podobnie jak gałęziom) mogą być przypisane wagi określające np. stopnie przekonania o słuszności tych stwierdzeń. Uogólnieniem koncepcji sieci stwierdzeń są sieci semantyczne lub asocjacyjne. Uogólnienie polega na przyjęciu założenia, że węzły odpowiadają kompletnym opisom pojęć lub obiektów i nie są wyłącznie stwierdzeniami.

Quillian wyszedł z założenia, że pamięć ludzką najlepiej opisuje model asocjacyjny. Oznacza to, że jedne terminy są wyjaśniane przez inne terminy. Każdy element jest zdefiniowany przez inny element. Powstaje w tym momencie pewna struktura powiązań. Struktura ta może być zamknięta, a grafy mogą być skierowane. Niestety, model ten nie ma ściśle zdefiniowanej syntaktyki, ponieważ Quillian ograniczył się tylko do podania koncepcji. Syntaktyka w tym przypadku zależy od konkretnej implementacji.

Sieć semantyczna jest pewnego rodzaju logiką, gdzie relacje między obiektami są przedstawione w postaci rysunku. Jest tu więc jak gdyby wyrysowany mechanizm dedukcji. Wnioskowanie podpowiada „poruszaniu się” po grafie.

Model reprezentacji wiedzy za pomocą sieci semantycznych ma również swoje wady. Problemem jest tutaj na przykład określenie, czy węzły sieci oznaczają jeden obiekt czy klasę obiektów. Dlatego też sieci semantyczne wiąże się zazwyczaj z ramami lub z regułami. Ramy w takim podejściu odpowiadają obiektom i opisują ich strukturę wewnętrzną, sieć semantyczna

---

<sup>30</sup> Metoda ta znana jest również pod nazwą grafów.

natomiast odpowiada relacjom między ramami.

#### 2.1.8. Reprezentacja wiedzy za pomocą ram

Ramy umożliwiają deklaracyjną i proceduralną reprezentację wiedzy. Stwarzają one możliwość organizacji bazy wiedzy w taki sposób, że reguły będące reprezentacją wiedzy danej dziedziny są wyraźnie oddzielone od reguł niezbędnych do poprawnego działania systemu ekspertowego. Inną ich zaletą jest możliwość grupowania informacji dotyczących wybranego fragmentu wiedzy w postaci jednej ramy, co upraszcza późniejszą weryfikację i ewentualne modyfikacje bazy wiedzy.

Za twórcę ram uważa się Minsky'ego, który użył tej metody reprezentowania wiedzy do rozpoznawania obrazów. Nazwał on ramą strukturę danych opisującą pewien obiekt, w którym mieszczą się wszystkie typowe i oczekiwane informacje, a także przypuszczenia o tym obiekcie.

Minsky oparł swój pomysł na analizie sposobu zachowania się człowieka znajdującego się w nowej dla niego sytuacji i w nowym otoczeniu, ale mającego o tej dziedzinie już pewne wcześniejsze wyobrażenia. Człowiek wydobywa wówczas z pamięci określoną strukturę, czyli ramę, i konfrontuje tę sytuację z wiedzą zawartą w ramie. Z kolei, gdy człowiek zetknie się z całkowicie nowym obiektem, wówczas jego pierwszą reakcją będzie próba zapamiętania go i wprowadzenia jego nazwy. Jest to równoważne wykreowaniu nowej ramy.

Rama jest zbiorem klatek. Całość informacji o obiekcie, zawarta w ramie, jest dzielona na części będące wartościami klatek ramy.

Każda klatka odpowiada pewnej właściwości danego obiektu i jest określonego rodzaju, tzn. ma zdefiniowaną dziedzinę wartości, które mogą być w niej umieszczone.

W zależności od dziedziny wartości zawartych w klatce istnieją różne rodzaje klatek. Klatka jest jednoznacznie zdefiniowana przez podanie jej rodzaju, jak również do jakiej ramy należy.

Wartości klatki mogą być różne. W szczególności wartością klatki może być

odwołanie do innej ramy albo dowolna procedura lub funkcja.

Klatki są dodatkowo dzielone na fasety, zawierające wybrane wartości klatki.

Ramy, klatki i fasety są identyfikowane za pomocą nazw.

#### 2.1.9. Modele obliczeniowe

Modele obliczeniowe służą do do rozwiązywania prostych problemów z dziedzin elementarnych, np. matematyki, fizyki. Są one szczególnie przydatne w pakietach programów do wspomaganie projektowania, gdzie wykonuje się dużo prostych zadań obliczeniowych na mało skomplikowanych modelach. Znajdują one również zastosowanie w programach służących do nauczania matematyki i fizyki na poziomie szkoły podstawowej i średniej jako moduł weryfikujący wyniki nauczania. Modele te można zastosować do wykonywania wszelkich prostych, nie warunkowych, kalkulacji.

#### 2.1.10. Sieci neuronowe<sup>31</sup>

Mniej więcej na początku lat 90-tych zapanowała na całym świecie zadziwiająca moda na sieci neuronowe. Moda ta przejawia się w ogromnej liczbie publikacji naukowych, jakie ukazują się na ten temat na świecie, niezliczonych konferencjach, na których prezentowane są wyniki prac naukowych i prób zastosowania. Liczba ta ostatnio lawinowo wzrasta. Chwilami odnosi się wrażenie, że badanie i stosowanie sieci neuronowych stało się tak dalece „w dobrym tonie”, że nie posiadanie dorobku i przemyśleń w tym zakresie jest wręcz nietaktem towarzyskim. Jeśli coś jest modne, to czasem warto się do tej mody przyłączyć. Dlatego modne tematy warto i należy poznać. Można także ignorować modę i trzymać się na uboczu, ale wtedy także warto wiedzieć z czego się rezygnuje. Niezależnie więc od tego czy pragnie się włączyć sieci neuronowe do swoich prac, czy nie powinno się ich poznać - takim wstępem na początku 1997 roku rozpoczął swój artykułów „Sieci neuronowe nowa metoda rozwiązywania zadań” Ryszard Tadiusiewicz

---

<sup>31</sup> Tadiusiewicz R. Sieci neuronowe. Akademicka Oficyna Wydawnicza Warszawa 1993

Co to są „Sieci neuronowe”? Sieci neuronowe są nowym i pod wieloma względami atrakcyjnym narzędziem informatycznym, zasadniczo odmiennym w swoich założeniach od tych komputerów, którymi posługujemy się na co dzień, a jednocześnie wybitnie wygodnym i zdatnym. Dlatego właśnie interesują się nimi zarówno badacze, jak i praktycy. Zalety sieci neuronowych polega na dwóch podstawowych atutach:

- stanowią one dogodną i tanią propozycję wieloprocessorowego systemu o bardzo wielu elementach przetwarzających równolegle dostarczane informacje;
- nie wymaga programowania, tylko wykorzystuje proces uczenia.

Pierwszy atut sieci, polegający na możliwości realizacji w nich postulatu „masowego równoległego przetwarzania” (massive parallel processing) wynika z faktu, że sieć neuronowa zbudowana jest z bardzo wielu (od kilkuset do kilkudziesięciu tysięcy) równocześnie pracujących i wspólnie przetwarzających informacje elementów zwanych neuronami. Ich pierwowzorem są komórki nerwowe budujące mózg człowieka, ale w istocie elementy używane w technicznych sieciach neuronowych są skrajnie uproszczone i zawierają tylko podstawowe (nie do końca wiadomo, czy najważniejsze) właściwości swoich biologicznych pierwowzorów. Neurony są bardzo proste w swojej budowie i działaniu, w związku z czym łatwo jest je symulować za pomocą komputera. Możliwa jest także budowa specjalistycznych układów scalonych (są już takie) mogą one zawierać setki takich elementów w jednym „chipie”.

Z takich neuronów (czyli procesorów zawierających zarówno elementy pamięci, jak i pewne możliwości przetwarzania informacji) buduje się sieć, relacje ze sobą według pewnych prostych reguł. Przy doborze sposobu połączeń i struktury sieci ponownie spotykamy maksymalne uproszczenia, gdyż generalnie w sieciach neuronowych wierność biologicznemu oryginałowi poświęca się na rzecz prostoty. Używane sieci najczęściej buduje się jako struktury złożone z pewnej liczby warstw neuronów, połączonych między sobą w sąsiednich warstwach na zasadzie „każdy z każdym”. Jest to

biologicznie nie uzasadnione i bardzo daleko idące uproszczenie. Struktura warstwowa ustępuje wprawdzie w pewnych rejonach mózgu (np. w korze wzrokowej), jednak z pewnością nie jest tak prosta i regularna, jak struktura budowanych sztucznie sieci – nie mówiąc już o tym, że inne fragmenty mózgu mają zupełnie inną budowę, na przykład bardziej zbliżoną (lokalnie) do topologii gwiazdy. Ponieważ jednak przyjęcie struktury warstwowej ułatwia techniczne operowanie siecią i zapewnia możliwość jej zdefiniowania przy minimalnym wkładzie pracy zarówno w rozwiązaniach symulacyjnych (wystarczy kilka prostych pętli w programie by „obsłużyć” całą sieć), wszyscy tak postępują nie martwiąc się ani przesłankami biologicznymi, ani dowodami wskazującymi, że architektura sieci bardziej zmyślnie dostosowanej do charakteru zadania może znacznie lepiej realizować stawiane zadania. Z kolei pomysł jednorodnego „pełnego” schematu połączeń między elementami poszczególnych warstw zapewnia minimalizację wysiłku związanego z odwzorowaniem sieci, chociaż odbywa się to kosztem dużego nakładu (np. pamięci w modelu symulacyjnego potencjalne połączenia w strukturze chipu), niezbędnego dla zapewnienia możliwości odwzorowania w sieci wszystkich niezbędnych przy takim założeniu połączeń.

Warto zauważyć, że bez przyjęcia (arbitralnie!) jednorodności struktury sieci samo tylko opisanie topologii jej połączeń wymaga podania setek tysięcy parametrów, co skutecznie udaremnia wszelkie próby stosowania takich struktur o nadmiernie wymyślnych architekturach połączeń. Natomiast decyzja o przyjęciu połączeń typu „każdy z każdym” stanowi elementarny i nie wymagający żadnego głębszego zastanowienia akt woli konstruktora sieci. Tak jest łatwiej i dlatego (prawie) wszyscy tak robią. Możliwość wygodnego (czytaj: bezmyślnego) stosowania tego typu uproszczenia wynika z faktu, że w trakcie procesu uczenia sieć „sama” wybierze z dostępnych jej początkowo wszystkich połączeń te, które są naprawdę potrzebne, odrzucając pozostałe. Podsumowując tę część rozważań możemy stwierdzić, że sieć składa się z bardzo wielu prostych elementów zdolnych do równoczesnego przetwarzania informacji, których wspólne i równoczesne działanie tworzy efekt w postaci

przetwarzania informacji wejściowej, podawane do pierwszej warstwy neuronów (dane) na sygnały pojawiające się na wyjściach wszystkich neuronów sieci, z których niektóre, tworzące ostatnią warstwę sieci, dostarczają rozwiązania postawionego zadania (wyniki). Dzięki równoczesnej pracy wszystkich neuronów sieć może dostarczać rozwiązań o wiele szybciej niż jakikolwiek inny system komputerowy. Ponieważ wiele osób mogłoby się zawiść należy przedstawić oczywisty fakt, że chętnie stosowane symulowanie sieci na zwykłych komputerach nie zwiększa ich szybkości - chociaż może przyczynić się do efektywniejszego rozwiązania problemów dzięki zastąpieniu skomplikowanego algorytmu numerycznego prostszą obliczeniowo „siecią”.

Drugim atutem sieci jest ich zdolność do uczenia się. Jest to bardzo silny argument zdecydowanie przemawiający za szerokim stosowaniem sieci wszędzie tam, gdzie algorytm działania nie jest do końca znany lub musi być często i szybko modyfikowany (na przykład w zadaniach prognozowania rzeczywistości). Warto uwypuklić kilka ogólnych zagadnień wiążących się z zagadnieniem „uczenia się sieci”

Po pierwsze, możliwość uczenia sieci usuwa w ich przypadku jeden z najtrudniejszych problemów wiążących się z technikami systemów wieloprocessorowych. Ogólnie wiadomo, że sensowne zaprogramowanie systemu złożonego z kilku jednostek mających równocześnie przetwarzać informację (np. systemu wielotransputerowego) wymaga o wiele większego wysiłku, niż napisanie programu dla konwencjonalnej maszyny jednoprocessorowej. Gdyby trzeba było „ręcznie” programować sieć złożoną z kilkudziesięciu tysięcy równocześnie pracujących procesorów (neuronów), byłby to prawdziwy horror. Tymczasem twórca sieci nie musi nawet palcem kiwnąć - sieć sama się zaprogramuje w wyniku procesu uczenia.

Po drugie, użytkownik może na własną rękę sieć dowolnie „douceć” adaptując jej zachowanie do swoich szczególnych wymagań, przy czym wysiłek, jaki człowiek w ten „trening” wkłada może być naprawdę minimalny (w skrajnych przypadkach sieć doucza się całkiem sama, obserwując wyniki

swojego działania i korygując ewentualne błędy). Żeby było jeszcze atrakcyjnej twórca sieci może nie mieć pojęcia, jak należy rozwiązać postawione zadanie, a sieć potrafi sama znaleźć to rozwiązanie i zapamiętać „odkrytą, przez siebie metodę! Na tej właśnie zasadzie działają między innymi systemy wykorzystujące sieci neuronowe do prognoz giełdowych - my nie wiemy, od czego naprawdę zależy wyżka lub niżka cen określonych akcji, ale możemy zmusić sieć, by próbowała te zmiany przewidywać na podstawie analizy wcześniejszych zmian notowań traktowanych jako materiał do uczenia sieci. Najzabawniejsze jest, że sieć naprawdę potrafi to zrobić! Znane są przykłady znakomitego prognozowania za pomocą sieci notowań giełdowych, kursów walut, zapotrzebowania na energię elektryczną i wielu innych na pozór przypadkowych przebiegów przy czym twórcy sieci nawet po ich wytrenowaniu nie potrafili dojść do tego „jak ona to robi”.

Wreszcie po trzecie, sieć potrafi (w ograniczonym zakresie) uogólnić wiedzę zdobytą w toku procesu uczenia. Po nauczeniu sieci reagowania w określony sposób na określone zbiory danych (z rozwiązania pewnej klasy problemów) można kazać jej rozwiązać zadanie podobne do tych, które podawano w trakcie uczenia, ale w pewnym stopniu odmienne. Sieć jest w stanie uogólnić posiadane wiadomości na przypadki, których nigdy nie widziała, może więc „wymyślić” sposób rozwiązania nieznanego zadania, czego zwykły komputer normalnie zaprogramowany nigdy nie robi. Przykładem zadań, w których te własności sieci znajdują zastosowania, są pamięci asocjacyjne można sieć nauczyć kilku obrazów, a potem pokazać drobny fragment jednego z nich, być może nawet zakłócony i zniekształcony. Sieć na podstawie tej niepełnej i niedokładnej informacji potrafi odnaleźć i otworzyć pełny obraz w jego idealnej postaci. Sieć ma więc pewne cechy upodabniacie je do naszego mózgu, w którym też możliwe jest uogólnianie zdobytej wiedzy na nowe (choć podobne) przypadki, a pamięć funkcjonuje na zasadzie asocjacji, a nie na zasadzie adresów czy słów kluczowych. Jest to fascynujące spostrzeżenie, samo w sobie wystarczające do tego, by uznać sieć za interesujący obiekt badań. Takich zaskakujących analogii z ludzkim

umysłem jest w dziedzinie sieci neuronowych więcej. Sieć nie daje się na przykład „wyprowadzić w pole” i jeśli uczący ją nauczyciel popełnia błędy lub jest niekonsekwentny - sieć uzyskuje możliwość realizacji stawianego zadania lepiej, niż nauczyciel, który ją naucza. Obserwacje, za pomocą których sieć „trenujemy” mogą być także obarczone błędami, a także decyzje nauczyciela, na których sieć ma się wzorować bywają błędne zdarza się to zwłaszcza w zadaniach rozpoznawania obrazów. Okazuje się, że sieć potrafi te losowe zjawiska „uśrednić”, uzyskując zwykle bardziej klarowny obraz rozpoznawanego wzorca, niż by wynikało z podawanych w trakcie uczenia przykładów. Sieć wykazuje też zwiększoną odporność na uszkodzenia - potrafi zwykle działać poprawnie nawet w przypadku, kiedy część jej elementów jest uszkodzona, połączenia są zerwane, a informacje zawarte w strukturze sieci (to one zawierają właśnie zgromadzoną w toku uczenia „wiedzę” sieci) są bezpowrotnie stracone. Takich właściwości nie ma żaden z komputerów, natomiast są one dobrze znane neurologom, gdyż mózg człowieka wykazuje właśnie zdumiewające zdolności poprawnego działania mimo bardzo obszernych niekiedy uszkodzeń.

Podsumowując tę część rozważań należy stwierdzić, że sieci neuronowe są zdolne do samo programowania się w wyniku procesu uczenia, a takie wykazują pewne cechy podobne do cech rzeczywistego mózgu, a wyraźnie odmienne od cech klasycznych komputerów.

Wszystkie te możliwości słusznie uznawane są za wielce przydatne atuty, dlatego liczba zastosowań sieci neuronowych jest już bardzo długa i zapewne będzie w najbliższym czasie dalej wydłużana. Czy z tego wynika, że powinniśmy zarzucić dobrze znane, „klasyczne” komputery i wszystkie zadania obliczeniowe rozwiązać wyłącznie z pomocą sieci neuronowych. Zdecydowanie nie. Sieci są narzędziem modnym i wygodnym, mającym jednak szereg bardzo istotnych ograniczeń. Można podać kilka charakterystycznych cech zadań, których rozwiązanie z wykorzystaniem sieci jest praktycznie nie niemożliwe. Pierwsza klasa zadań, przy rozwiązaniu których trzeba całkowicie zrezygnować z sieci, związana jest z manipulacjami na symbolach. Wszelkie

formy przetwarzania informacji w postaci symbolicznej są niesłychanie trudne do przeprowadzenia przy użyciu sieci neuronowych, dlatego występowanie elementu polegającego na przetwarzaniu symboli powinno być sygnałem, że z użycia sieci trzeba będzie zrezygnować. Sprowadzając rzecz do krańcowego przykładu można powiedzieć, że nie ma elementarnego sensu budowanie edytora tekstu działającego w oparciu o koncepcję sieci neuronowej lub procesora wyrażeń algebraicznych wykorzystującego tę samą koncepcję. Drugim „klasycznym” obszarem, w którym z użycia sieci neuronowych trzeba zrezygnować, jest problematyka obliczeń przy których wymagana jest wysoka dokładność wyniku numerycznego. Sieć pracuje zawsze w sposób „jakościowy”, to znaczy dostarczane przez nią rozwiązania mają zawsze charakter przybliżony. Dokładność tego przybliżenia jest zadowalająca w wielu zastosowaniach: przy przetwarzaniu sygnałów, analizie sygnałów, rozpoznawaniu mowy, prognozowaniu wartości notowań giełdowych, sterowaniu robotów, aproksymowaniu wartości złożonej funkcji itp. Absolutnie nie do przyjęcia jest jednak przybliżone wykonywanie obliczeń charakterystyczne dla sieci neuronowej w przypadku obsługi kont bankowych lub realizacji precyzyjnych obliczeń inżynierskich. Trzeci wreszcie obszar, w którym trudno oczekiwać dobrych wyników przy stosowaniu sieci neuronowych związany jest z zadaniami wymagającymi wieloetapowego rozumowania - na przykład wieloetapowego rozstrzygnięcia o prawdziwości lub fałszywości pewnych sekwencji stwierdzeń logicznych. Sieć na ogół usiłuje rozwiązać postawiony problem jednokroково - jeśli się jej to uda, wynik jest dostępny natychmiast i jest to duży praktyczny sukces. Jeśli jednak trzeba przeprowadzić pewien ciąg rozumowania, a zwłaszcza jeśli trzeba poddać dokumentację tego ciągu częściowych uzasadnień końcowego wniosku (na przykład w systemach ekspertowych) - sieć okazuje się tworem zupełnie nieprzydatnym i wszelkie próby jej zastosowania prowadzić muszą do frustrujących niepowodzeń.

Efekt końcowy obliczeń wykonanych przy pomocy sieci neuronowych jest jednokrokowym obliczeniem. Wynika z tego, że wynik nie może być

wariantowany, inaczej mówiąc maszyna wykorzystująca sieci neuronowe daje jednoznaczną odpowiedź i "uważa", że odpowiedź ta jest jedyna i najlepsza. Takie przedstawienie wyników jest niedopuszczalne przy ocenie działania przeciwnika powietrznego. Skutki pomyłki lub złej interpretacji wyników mogły by być jeszcze do przyjęcia podczas ćwiczeń ale podczas prowadzenia działań wojennych były by nie do naprawienia.

Z powyższego wynika, że nie należy wyciągać pochopnych wniosków: sieć nie może sama wykonywać obliczeń symbolicznych ale może wspomagać systemy operujące na symbolach w zakresie czynności, z którymi one sobie nie radzą; przykładem mogą być sieci Teuvo Kohonena lub klasyczna sieć NetTalk Terence Sejnowskiego używane do zamiany tekstu ortograficznego na ciąg symboli fonetycznych służących do sterowania synteizatorem mowy. Podobnie ze stwierdzenia, że sieci nie nadają się do obsługi pracy terminala w okienku bankowym nie wynika ich bezużyteczność w zastosowaniach bankowych - przeciwnie, okazały się wyjątkowo użyteczne w badaniach wiarygodności kredytobiorców lub przy ustalaniu warunków negocjowanego kontraktu. Podobne zastrzeżenia można mnożyć bez końca. Ważny jest jednak konkretny końcowy wniosek.

Sieć neuronowa nadaje się do wielu zastosowań, nie jest jednak tak uniwersalna jak klasyczny komputer. Dlatego entuzjastom łatwo jest wskazać zadania, których rozwiązania za pomocą sieci okazały się znacząco lepsze, niż rozwiązania uzyskane przez klasyczne komputery, zaś malkontenci bez trudu wskażą zadania, dla których rozwiązania wykorzystujące sieci okażą się groteskowo niepoprawne.

## 2.2. Metody wnioskowania

Jak już wcześniej pisałem, w systemach ekspertowych rozumowanie jest oparte na logice matematycznej. Tradycyjne systemy działają na podstawie klasycznej logiki dwuwartościowej, korzystając z tzw. reguły modus ponens, zwanej również regułą odrywania, którą zapisuje się następująco:

$$\frac{(A \Rightarrow B), A}{B}$$

Reguła ta oznacza, że jeżeli z przesłanki A wynika B oraz A jest prawdziwe, to przyjmujemy, że fakt B jest również prawdziwy. Dla uproszczenia często przyjmujemy, że wystąpienie pewnego faktu w bazie wiedzy (odpowiednia lista) świadczy o jego prawdziwości, co znacznie przyspiesza proces wnioskowania.

Wyróżniamy trzy podstawowe typy wnioskowania: w przód (progresywne), wstecz (regresywne) i mieszane. Osobną grupę stanowią techniki wnioskowania wykorzystujące wiedzę niepewną, wśród których szczególną rolę odgrywa wnioskowanie rozmyte. W następnych podrozdziałach opisałem sposoby wnioskowania, najczęściej stosowane w znanych systemach ekspertowych.

### 2.2.1. Wnioskowanie w przód

Idea wnioskowania w przód jest niezwykle prosta. Na podstawie dostępnych reguł i faktów należy generować nowe fakty tak długo, aż wśród wygenerowanych faktów znajdzie się postawiony cel (hipoteza).

Podstawową cechą tego sposobu wnioskowania, która w pewnych sytuacjach może być jego wadą, jest możliwość zwiększania się bazy faktów. Postępowanie takie umożliwia, szczególnie w przypadku baz wiedzy o niewielkiej liczbie faktów, zwiększenie ich liczby, a co za tym idzie, przyspieszenie procesu sprawdzania postawionej hipotezy. Jednocześnie, z innego punktu widzenia, tworzenie nowych faktów, w pewnych szczególnych

sytuacjach może być zjawiskiem niepożądanym, gdyż zajmują one niepotrzebnie pamięć operacyjną komputera, co może doprowadzić do jej całkowitego zapelnienia.

Algorytm wnioskowania w przód można wyrazić w następujący sposób:

BAZA\_WIEDZY = Wiedza początkowa/Fakty

DOPUKI osiągnięto cel lub nie można zastosować więcej reguł

WYKONAJ

Określ zbiór C reguł w bazie wiedzy BAZA\_WIEDZY, dla których są spełnione przesłanki.

Ze zbioru C wybierz regułę R na podstawie strategii sterowania wnioskowaniem.

BW: = Wynik uaktywnienia reguły R działający na BW plus BW.

Wnioskowanie takie może być wykorzystywane do wyboru prawdopodobnej grupy uderzeniowej lotnictwa przeciwnika przy znanym obiekcie ataku. Wnioskowanie wykonane przez maszynę powoduje kierowanie się w typ przypadku ścisłą logiką a nie intuicją doświadczeniem eksperta.

### 2.2.3. Wnioskowanie wstecz

Wnioskowanie wstecz przebiega w odwrotną stronę niż wnioskowanie w przód. Ogólnie polega ono na wykazaniu prawdziwości hipotezy głównej na podstawie prawdziwości przesłanek. Jeśli nie wiemy, czy jakaś przesłanka jest prawdziwa, to traktujemy tę przesłankę jako nową hipotezę i próbujemy ją wykazać. Jeżeli w wyniku takiego postępowania zostanie wreszcie znaleziona reguła, której wszystkie przesłanki są prawdziwe, to konkluzja tej reguły jest prawdziwa. Na podstawie tej konkluzji dowodzi się następną regułę, której przesłanka nie była poprzednio znana itd. Postawiona hipoteza jest prawdziwa, jeśli wszystkie rozważane przesłanki dadzą się wykazać.

Algorytm wnioskowania regresywnego można przedstawić następująco:

BW: = Wiedza początkowa/Fakty

DOPUKI hipoteza zostanie wykazana lub gdy nie można zastosować więcej reguł

#### WYKONAJ

Określ zbiór C reguł w bazie wiedzy, których konkluzje dadzą się zunifikować z hipotezą.

Ze zbioru C wybierz regułę R na podstawie strategii sterowania wnioskowaniem.

Jeśli przesłanka reguły R nie znajduje się w bazie wiedzy BW, dokonaj wnioskowania regresywnego dla przesłanki reguły R (aby ją udowodnić).

Wnioskowanie takie może być wykorzystywane do określenia prawdopodobnej grupy uderzeniowej lotnictwa przeciwnika przy znanych rezultatach działań przeciwnika. Wnioskowanie wykonane przez maszynę powoduje ponownie kierowanie się ścisłą logiką a nie intuicją doświadczeniem eksperta.

#### 2.2.4. Wnioskowanie mieszane

Wnioskowanie mieszane stanowi kompromis między wnioskowaniem w przód i wstecz<sup>32</sup>, dzięki czemu jest pozbawione niektórych wad wspomnianych metod. Strategia wnioskowania mieszanego opiera się na wykorzystaniu ogólnych reguł, tzw. metareguł stanowiących metawiedzę, na podstawie której program zarządzający dokonuje odpowiedniego przełączania między poszczególnymi rodzajami wnioskowania. W metaregułach są zawarte wskazania dotyczące priorytetów wyboru rodzaju wnioskowania. W zależności od sytuacji system może automatycznie dobierać najbardziej odpowiednie sposoby wnioskowania. W przypadku przechodzenia z jednego rodzaju wnioskowania na drugi za hipotezę główną zawsze przyjmuje się tę, którą postawił użytkownik. Dzięki temu na każdym etapie wnioskowania istnieje możliwość udzielenia odpowiedzi na postawioną hipotezę.

We wnioskowaniu mieszanym poza wczytaniem przez system bazy

---

<sup>32</sup> Wójcik M.: Metody automatycznego wnioskowania, PWN Warszawa 1991

wiedzy należy wczytać także zbiór zawierający metareguly. System działa tak, jakby można było w nim wyróżnić dwie maszyny wnioskujące (progresywną i regresywną). Wiedza zapisana w metaregulach może preferować jeden z rodzajów wnioskowania. Na przykład baza wiedzy jest dzielona na dwie części: reguły związane z wnioskowaniem wstecz oraz reguły związane z wnioskowaniem w przód. Załóżmy, że wyższy priorytet dajemy wnioskowaniu wstecz. Wówczas jest ono zalecane dopóty, dopóki da się zastosować jakąś regułę. Po każdym cyklu wnioskowania są sprawdzane warunki zapisane w metaregulach. Jeżeli nie daje się dalej stosować wnioskowania wstecz, to system zostaje przełączony w tryb wnioskowania w przód. Przy wyprowadzaniu kolejnych faktów jest sprawdzany warunek, czy system uzyskał już odpowiedź na postawioną hipotezę; jeżeli tak, to wynik jest przekazywany jako rozwiązanie. W przeciwnym przypadku proces jest kontynuowany; w zależności od okoliczności może być uruchamiany drugi rodzaj wnioskowania. Cykl ten powtarza się tak długo, aż zostanie osiągnięty cel główny lub zostaną wyczerpane wszystkie możliwości jego wykazania na podstawie posiadanej bazy wiedzy lub też odpowiedzi udzielonych przez użytkownika w trakcie dialogu.

#### 2.2.5. Wnioskowanie rozmyte

Zrozumienie filozofii wnioskowania rozmytego wymaga chociaż krótkiego wyjaśnienia pojęcia zbiorów i liczb rozmytych. Każda właściwość obiektów określa pewien zbiór, do którego należą te obiekty spełniające daną właściwość. Dla właściwości dobrze określonej zbiór ten ma jednoznaczne granice oddzielające elementy należące od nie należących do niego. Przyjmijmy, że  $U$  jest przestrzenią rozważanych obiektów. Zbiór taki scharakteryzujemy przez funkcję  $\mu$  ustalającą przynależność obiektów do zbioru  $\mu_w : U \Rightarrow \{0,1\}$ , przy czym indeks  $w$  oznacza zbiór obiektów. Oznaczmy przez  $A$  zbiór odpowiadający pewnej właściwości.

Dla wielu tych właściwości trudno jest określić granicę rozdzielającą elementy spełniające ją od nie spełniających. Z tego względu naturalne wydaje się rozszerzenie pojęcia zbiorów przez rozszerzenie wartości funkcji  $\mu$ . Funkcję  $\mu$  będziemy nazywać funkcją przynależności (membership function), przekształcającą elementy przestrzeni  $U$  w odcinek  $(0,1)$ . Zbiór taki jest nazywany rozmytym (fuzzy). Tak więc jest on pewnym podzbiorem zbioru  $U$  o rozmytych granicach. Zakładamy, że dla pustego zbioru  $\mu_o(u)=0$ .

Wszelkie pojęcia właściwości związane ze zbiorami rozmytymi można określić za pomocą funkcji przynależności.

Na tej podstawie można sądzić, że podejście to jest odpowiednie do reprezentowania różnych nieprecyzyjności spotykanych podczas komunikowania się ludzi w życiu codziennym.

Co to są w takim razie liczby rozmyte. Często w mowie potocznej spotykamy się z nieprecyzyjnymi określeniami typu „około 2”, „więcej niż” itp. Okazuje się, że liczby rzeczywiste można uogólnić na tego typu nieprecyzyjne określenia. Wprowadza się wówczas uogólnione operatory arytmetyczne jedno- i dwuargumentowe. Uzasadnionym uogólnieniem tych operatorów jest rozszerzenie ich do klasycznych operatorów arytmetycznych.

Liczbą rozmytą typu  $L$  nazwiemy wypukły i znormalizowany zbiór rozmyty z przestrzeni  $\mathfrak{R}$  taki, że istnieje dokładnie jedno  $x_o \in \mathfrak{R}$ , dla którego  $\mu_L(x_o) = 1$ ;  $x_o$  jest nazywane średnią wartością  $L$  (są również rozważane przypadki, dla których  $x_o$  jest przedziałem).


Przykładowymi liczbami rozmytymi są:

$$\text{„około 2”} = L_1 \quad \mu_{L_1}(x) = \frac{1}{1 + 2|2 - x|}$$

$$\text{„około 5”} = L_2 \quad \mu_{L_2}(x) = \frac{1}{1 + (5 - x)^2}$$

przy czym w wyrażeniu opisującym funkcje przynależności pierwszej liczby rozmytej użyto wartości bezwzględnej, a dla drugiej liczby wykorzystano w mianowniku podnoszenie do kwadratu.

Oczywiście liczby rozmyte mogą być reprezentowane na wiele sposobów. Często są wprowadzane liczby rozmyte o z góry określonych funkcjach przynależności. Przykładem mogą być liczby L-R lub liczby  $\alpha - \beta$ .

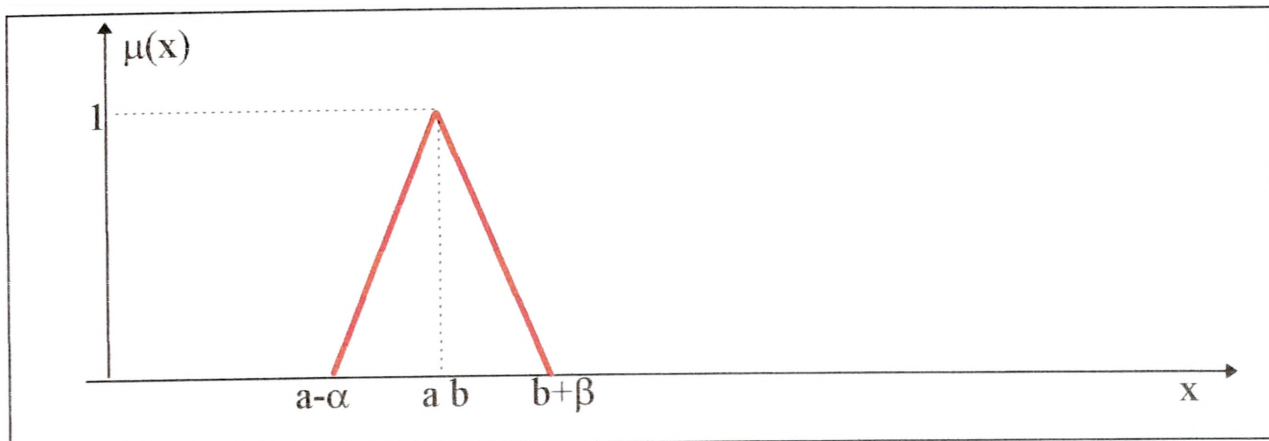


Rysunek 3. Wykres funkcji przynależności dla sumy dwóch zbiorów rozmytych

Weźmy pod uwagę liczby  $\alpha - \beta$ . W tej interpretacji liczba rozmyta L jest reprezentowana przez czwórkę  $(a, b, \alpha, \beta)$ . Pierwsze dwa parametry oznaczają przedział, w którym funkcja przynależności osiąga wartość 1. Trzeci i czwarty parametr oznaczają lewą i prawą szerokość rozkładu funkcji przynależności. Graficznie liczbą taką można przedstawić graficznie - rysunek 3.

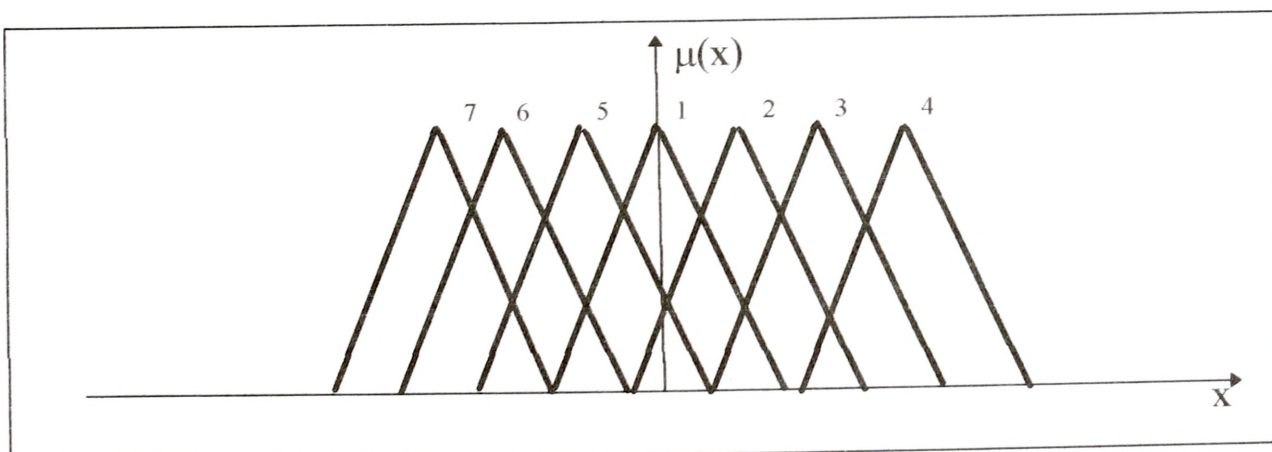
Podane informacje z teorii zbiorów rozmytych znalazły liczne zastosowania w realizacji systemów ekspertowych. Maszyna wnioskująca takich systemów działa na podstawie tzw. wnioskowania rozmytego, które można przeprowadzić dzięki odpowiedniej reprezentacji wiedzy opisującej dany problem za pomocą zbiorów rozmytych, a następnie zastosowaniu pewnych przekształceń danych wejściowych w postać końcową.

Koncepcję wnioskowania rozmytego najłatwiej wyjaśnić można graficznie. Weźmy pod uwagę liczbę rozmytą  $\alpha - \beta$ , w której dla uproszczenia założymy, że  $a=b$ . Dzięki temu reprezentacja upraszcza się z postaci trapezowej do trójkątnej (rysunek 4), ponieważ redukuje się przedział, w którym funkcja przynależności osiąga wartość 1.



Rysunek 4. Wykres funkcji sumy dwóch zbiorów rozmytych gdy  $a=b$

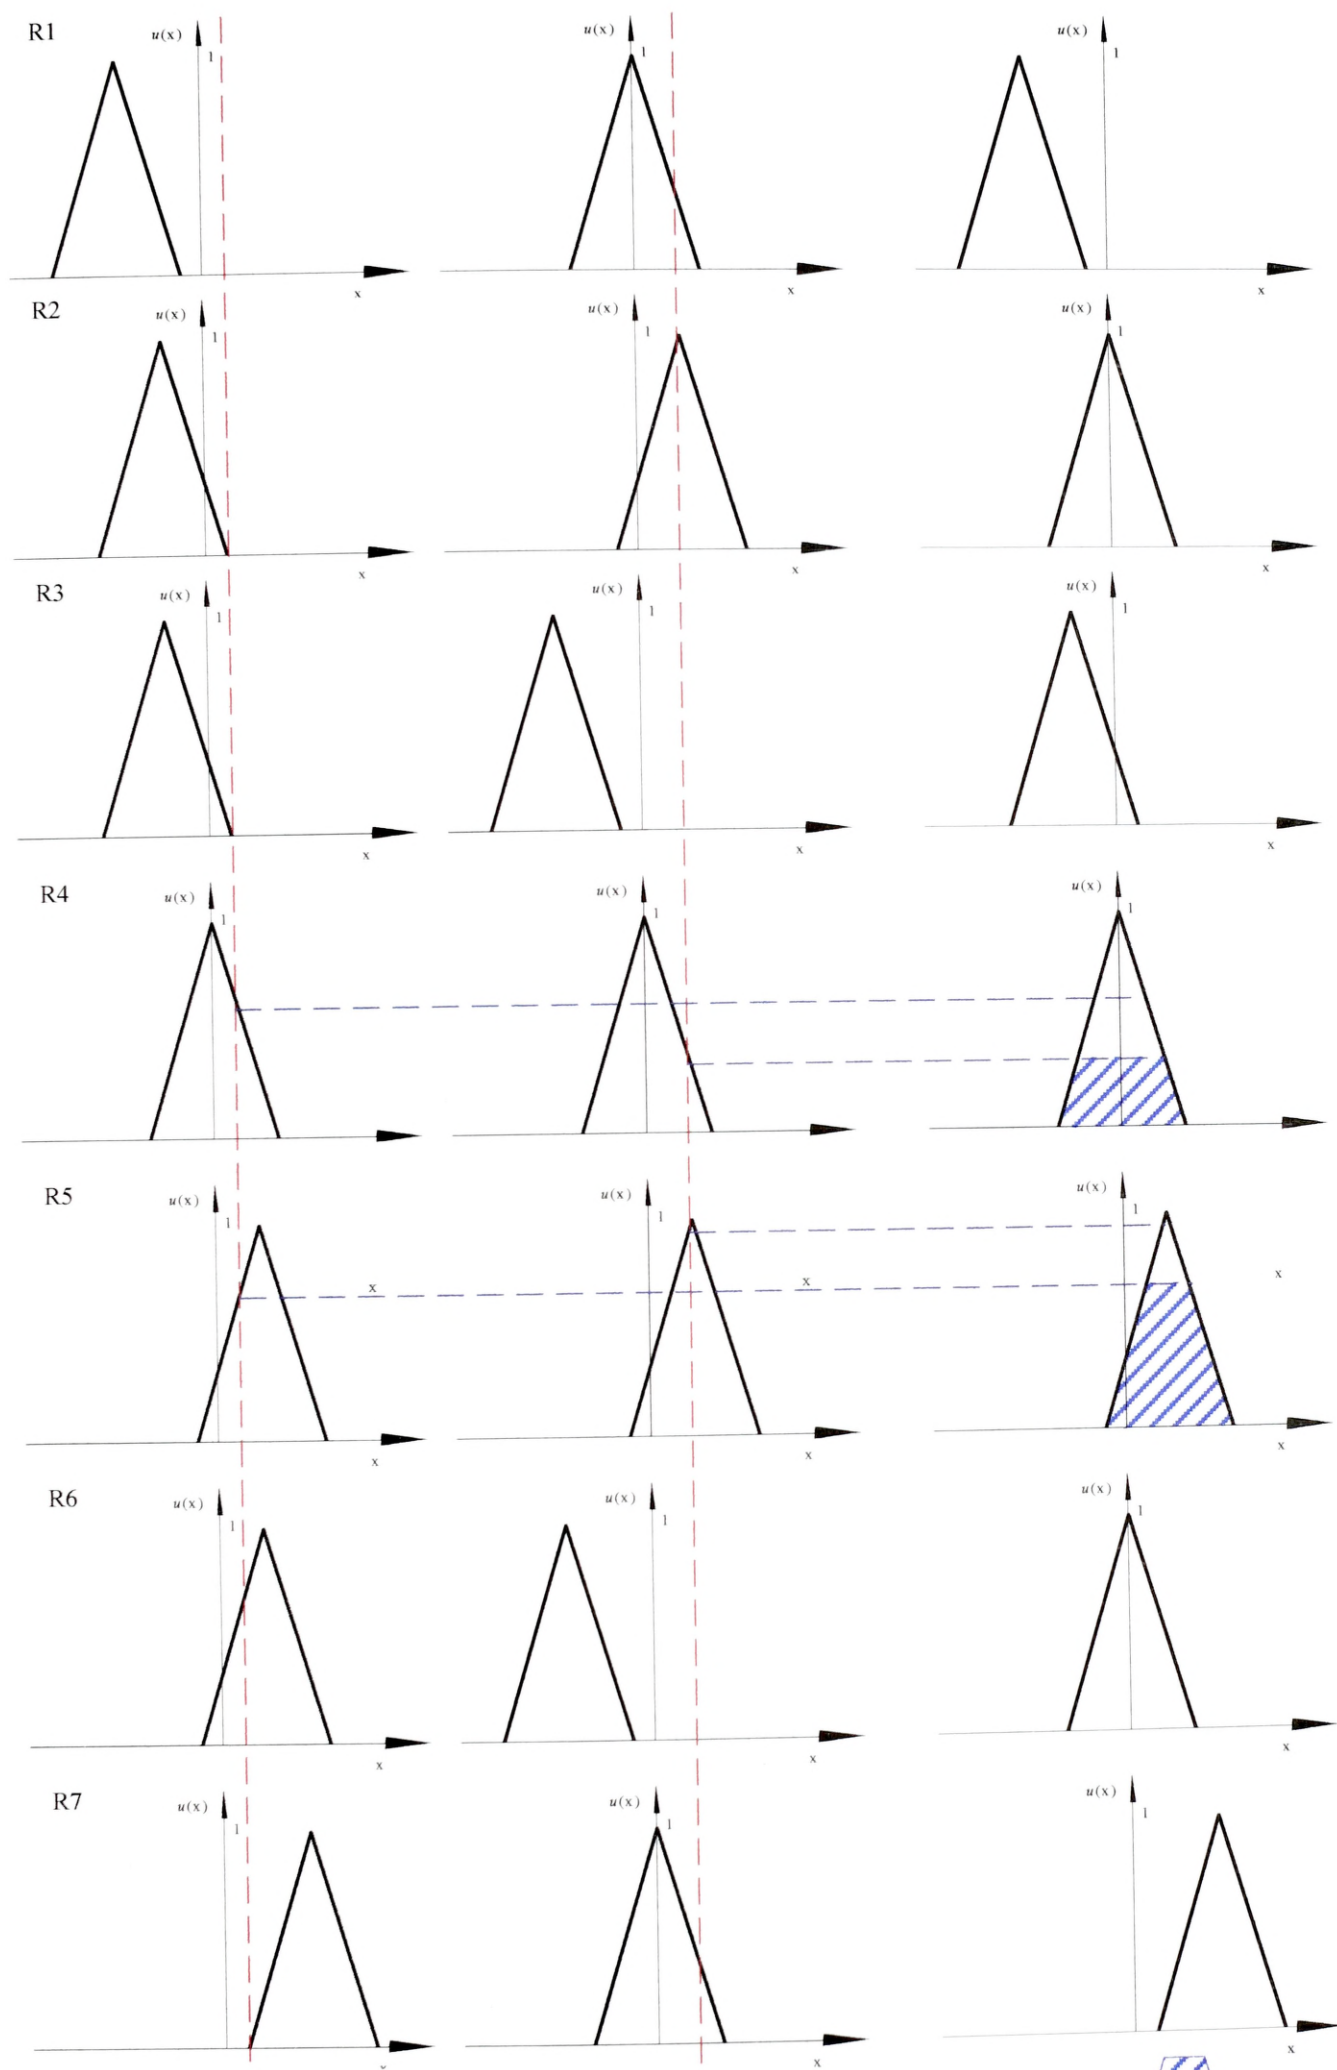
Spróbujmy teraz wyrazić za pomocą liczb rozmytych następujące pojęcia: 1) „wielkość  $x$  ma wartość bliską zeru”; 2) „wielkość  $x$  ma wartość małą dodatnią”; 3) „wielkość  $x$  ma wartość średnią dodatnią”; 4) „wielkość  $x$  ma wartość dużą dodatnią”; 5) „wielkość  $x$  ma wartość małą ujemną”; 6) „wielkość  $x$  ma wartość średnią ujemną”; 7) „wielkość  $x$  ma wartość dużą ujemną”. Zakładamy, że poszczególne liczby rozmyte będą przedstawione za pomocą funkcji przynależności o wykresach podanych na rysunku 5




Rysunek 5. Wykres funkcji przynależności w kształcie trójkątów

Pokazane wykresy mogą reprezentować pojęcia rozmyte występujące w częściach warunkowych i konkluzyjnych reguł. Aby to zilustrować rozważmy następujący zestaw reguł:

- R1 IF x ma wartość średnią ujemną  
AND y jest bliskie zera  
THEN z ma wartość średnią ujemną  
END IF
- R2 IF x ma wartość małą ujemną  
AND y ma wartość małą dodatnią  
THEN z jest bliskie zera  
END IF
- R3 IF x ma wartość małą ujemną  
AND y ma wartość małą ujemną  
THEN z ma wartość średnią ujemną  
END IF
- R4 IF x jest bliskie zera  
AND y jest bliskie zera  
THEN z jest bliskie zera  
END IF
- R5 IF x ma wartość małą dodatnią  
AND y ma wartość małą dodatnią  
THEN z ma wartość małą dodatnią  
END IF
- R6 IF x ma wartość małą dodatnią  
AND y ma wartość małą ujemną  
THEN z jest bliskie zera  
END IF
- R7 IF x ma wartość średnią dodatnią  
AND y jest bliskie zera  
THEN z ma wartość średnią dodatnią



Rysunek 6. Przykład wnioskowania rozmytego



Korzystając z wykresów funkcji przynależności podanych na rysunku 5, podany zestaw reguł możemy przedstawić w postaci graficznej jak na rysunku 6. Dwie pierwsze kolumny liczb rozmytych reprezentują części warunkowe reguł, trzecia kolumna reprezentuje pojęcia rozmyte zawarte w konkluzjach.

Urządzenia zewnętrzne współpracujące z systemem wnioskowania rozmytego nie są w stanie przetwarzać danych w postaci rozmytej. Z tego względu jest konieczna zamiana zbioru rozmytego na pewną wartość liczbową. Proces ten nosi nazwę defuzyfikacji. W wyniku tego procesu dokonuje się pewnego przekształcenia funkcji przynależności  $\mu(u)$  zbioru rozmytego w wartość  $u_0$  zmiennej  $u$ .

Na czym polega przebieg wnioskowania rozmytego. Jest ono dokonywane według następującego algorytmu:

- wyznacz wartości funkcji przynależności dla poszczególnych pojęć rozmytych występujących w warunkach reguł.
- na podstawie funkcji przynależności wyznacz obszary rozmyte odpowiadające zmiennej zawartej w konkluzji reguły.

Dokonaj zestawienia obszarów rozmytych wyznaczonych w punkcie 2.

Na podstawie otrzymanych obszarów rozmytych, wyznacz wynikowy obszar rozmyty.

Dokonaj defuzyfikacji wynikowego obszaru rozmytego.

Na rysunku 6 zilustrowany jest sposób przeprowadzania wnioskowania. W tym celu na wejście systemu podano wektor dwuelementowy o wielkościach  $x=x_1$  oraz  $y=y_1$ . Po wyznaczeniu odpowiadających temu wektorowi wartości funkcji przynależności, pokazano sposób wyznaczania obszarów rozmytych odpowiadających zmiennej z występującej w konkluzji reguł. Następnie dokonano zestawienia wyznaczonych dla poszczególnych reguł obszarów rozmytych, po czym określono wynikowy obszar rozmyty. W następnym kroku dokonano procesu defuzyfikacji, wyznaczając środek ciężkości wynikowego obszaru rozmytego. W rezultacie otrzymano aktualną wartość zmiennej z występującej w konkluzji reguł. W przytoczonym

przykładzie była tylko jedna zmienna w części konkluzyjnej. Ogólnie zestaw reguł i ich struktura mogą być bardziej rozbudowane. Systemy wykorzystujące rozumowanie rozmyte znalazły zastosowanie przy rozwiązywaniu różnych problemów w dziedzinie sterowania. Na przykład mogą być one użyte do sterowania odwróconym wahadłem. Opracowano także układy scalone o wielkim stopniu scalenia dokonujące wnioskowania podstawie logiki rozmytej.

## Zakończenie

W wyniku zakończonego pierwszego etapu budowy ekspertowego systemu oceny przeciwnika powietrznego w ramach badań rozwiązałem dwa problemy. Po pierwsze określiłem dla potrzeb badań zakres zastosowań systemów ekspertowych oraz sztucznej inteligencji. Przeanalizowałem podstawowe metody reprezentacji wiedzy oraz metody wnioskowania stosowane są w systemach ekspertowych. Wnioski z analizy umożliwią dobranie odpowiednich metod w systemie ekspertowym oceny działania przeciwnika powietrznego.

Analiza literatury z zakresu sztucznej inteligencji pozwoliła mi stwierdzić, że obecnie w etapie burzliwego rozwoju komputerów i oprogramowania, prowadzone są bardzo szerokim zakresie badania nad sztuczną inteligencją i jej zastosowanie w prawie wszystkich dziedzinach życia, od lotów kosmicznych do dobierania uczesania u fryzjera. Spośród tak szerokiego spektrum zainteresowania możliwe jest skonstruowanie systemu ekspertowego oraz inteligentnej bazy danych.

W przyszłym systemie eksperckim konieczne będzie zastosowanie metod reprezentowania wiedzy. Niektóre choć bardzo nowoczesne jak metoda sieci neuronowych dla potrzeb tego konkretnego programu nie będzie mogła mieć zastosowania. Wypada jednak rozpatrzyć możliwość skonstruowania narzędzia, opartego o sieć neuronową które mogło by na podstawie symptomów działania przeciwnika generować jego prawdopodobny charakter działań. Pozostałe metody będą mogły być wykorzystywane w mniejszym lub większym zakresie.

Uważam jednak , że podstawowymi metodami będą:

- rachunek zdań;
- stwierdzenia;
- regułowa reprezentacja wiedzy;
- sieci semantyczne;
- modele obliczeniowe.

Podczas konstrukcji algorytmu rozwiązywania problemów będzie istniała konieczność stosowania podstawowych metod wnioskowania : w przód, wstecz oraz mieszanego W mniejszym zakresie stosowane będą wnioskowanie rozmyte.

Na pytanie, które z metod reprezentacji wiedzy i wnioskowania będzie można zastosować i do rozwiązania jakich problemów, udzielenie odpowiedzi będzie możliwe dopiero po dokładnym przeanalizowaniu metod oceny przeciwnika powietrznego. Wprawdzie już teraz można powiedzieć, że do obliczania prostych zależności typu: taktyczny promień rażenia czy odstęp bombardowania stosować będzie można modele obliczeniowe.

## Literatura

1. Baborski A.: Efektywne zarządzanie a sztuczna inteligencja Wyd. Akademii Ekonomicznej im Oskara Langego. Wrocław 1994
2. Bubnicki Z.: Wstęp do systemów ekspertowych. PWN Warszawa 1990
3. Chromiec J., Strzemieczna E.: Sztuczna inteligencja. Akademicka Oficyna Wydawnicza PLJ. Warszawa 1994
4. Czogała E.: Elementy i metody teorii zbiorów rozmytych. PWN Warszawa 1985
5. Groszek Zb., Zdrodowski B.: Metodyka oceny zagrożenia wojsk lądowych uderzeniami środków napadu powietrznego. AON Warszawa 1994
6. Groszek Zb.: Metodyka oceny przeciwnika powietrznego na szczeblu taktycznym i operacyjno-taktycznym wojsk systemu OP RP, AON 1993
7. Hertz J., Krogh A., Palmer R.G.: Wstęp do teorii obliczeń neuronowych. WNT Warszawa 1993
8. Jagielski J.: Prognozowanie uderzeń ŚNP przeciwnika na obiekty obrony korpusu OPK metodą symulacji grafo-dynamicznej, ASG WP, 1984
9. Minsky M.: Steps Toward artificial intelligence. W: Computers and Thought. Mc Graw-Hill New York 1975
10. Mulawka J.: Systemy ekspertowe. Wydawnictwo Naukowo - Techniczne Warszawa 1996
11. Popov E.V. Ekspertnyje sistemy. Rosneije nieformalnych zadac w dialogie s EVM. Nauka Moskwa 1987
12. Strelau J.: O inteligencji człowieka. Wiedza powszechna. Warszawa 1987
13. Strelau J.: O inteligencji człowieka. Wiedza powszechna. Warszawa 1987
14. Świątnicki Zb.: Wojskowe systemy eksperckie. Bellona Warszawa 1995
15. Tadasiewicz R. Sieci neuronowe. Akademicka Oficyna Wydawnicza Warszawa 1993
16. Wójcik M.: Metody automatycznego wnioskowania, PWN Warszawa 1991

