

Sztuczna inteligencja – wprowadzenie

Sławomir Samolej

Slajdy zostały przygotowane
na podstawie materiałów
opublikowanych na

(<http://wazniak.mimuw.edu.pl/>)

Dziękuję kolegom Maciejowi
Kusemu oraz Tomaszowi
Żabińskiemu za pomoc w
przygotowywaniu materiałów
dydaktycznych do tego wykładu

Literatura

- G. Luger, *Artificial intelligence*, Wydawnictwa Naukowo-Techniczne, w przygotowaniu (lub wersja angielska).
- P. Cichosz, *Systemy uczące się*, Wydawnictwa Naukowo-Techniczne, Warszawa 2000.
- S. Osowski, *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwa Naukowo-Techniczne, Warszawa 1999.
- J. Arabas, *Wykłady z algorytmów ewolucyjnych*, Wydawnictwa Naukowo-Techniczne, Warszawa 2001.

Definicje (1)

- Naturalna „ludzka” inteligencja:

Inteligencja jest zdolnością do (poprawnego, sprawnego itd.) rozwiązywania zadań intelektualnych, które zazwyczaj uchodzą za trudne.

- Sztuczna inteligencja:

Sprawne rozwiązywanie zadań, które według powszechnej opinii wymagają inteligencji, jeśli są wykonywane przez człowieka.

Koncepcje sztucznej inteligencji

System inteligentny to:

- system, który myśli jak człowiek,
- system, który myśli racjonalnie,
- system, który zachowuje się jak człowiek,
- system, który zachowuje się racjonalnie.

Definicje (2)

- „Słaba” sztuczna inteligencja:
rozwiązywanie „trudnych” zadań w sposób umożliwiający praktyczne zastosowania.
- „Mocna” sztuczna inteligencja:
zdolność do myślenia w sposób w pewnym stopniu dający się porównywać z myśleniem ludzkim.

Sztuczna inteligencja jako dyscyplina nauk technicznych

Sztuczna inteligencja w „słabym” rozumieniu może być traktowana jako gałąź informatyki. Jest zbliżona do szeregu innych pokrewnych dyscyplin, takich jak automatyczne sterowanie, robotyka czy statystyka. Ważnymi źródłami inspiracji dla inteligentnych technik obliczeniowych są niektóre osiągnięcia nauk nietechnicznych, takich jak biologia i psychologia.

Zadania sztucznej inteligencji (1)

- **Przeszukiwanie -**

znajdowanie zadowalających rozwiązań bez pełnego przeglądania wszystkich możliwości, a więc dokonanie niewyczerpującego przeszukiwania przestrzeni rozwiązań.

Wiele zadań praktycznych, dla których należy znaleźć rozwiązania spełniające pewne ustalone kryteria i ograniczenia, można potraktować jako konkretne przypadki ogólnego zadania przeszukiwania.

Przeszukiwana przestrzeń obejmuje potencjalne rozwiązania zadania (także niekompletne, nie spełniające ograniczeń, niskiej jakości) i w interesujących praktycznie przypadkach jest zbyt duża, aby przy użyciu maksymalnych dostępnych obecnie i w wyobrażalnej przyszłości mocy obliczeniowych rozważyć każdy jej element mogło być przeprowadzone w akceptowalnym czasie.

Zadania sztucznej inteligencji (2)

- **Wnioskowanie**

jest procesem stosowania reguł wnioskowania w sposób skutecznie i efektywnie prowadzący do określonego celu wnioskowania, którym zazwyczaj jest uzyskania pewnego docelowego stwierdzenia.

Wnioskowanie jest procesem przetwarzania wiedzy, w wyniku którego na podstawie pewnego zbioru znanych stwierdzeń wyprowadza się nowe stwierdzenia. Wnioskowanie wykonywane przez człowieka może przebiegać zarówno w sposób formalny, w którym wszystkie stwierdzenia zapisane są w ustalonym precyzyjnym języku, wyprowadzanie nowych stwierdzeń rządzi się ustalonymi precyzyjnie regułami, jak i nieformalny, w którym stwierdzenia formułowane są w języku naturalnym, a wyprowadzanie nowych stwierdzeń odbywa się ze znacznym udziałem intuicji. SI stosuje wnioskowanie formalne.

Zadania sztucznej inteligencji (3)

- **Uczenie się -**

proces zmiany zachodzącej w systemie na podstawie doświadczeń, która prowadzi do poprawy jego jakości działania rozumianej jako sprawność rozwiązywania stojących przed systemem zadań.

Zdolność do uczenia się jest powszechnie uważana za jeden z najważniejszych przejawów inteligencji. Przez uczenie się rozumiemy, w najprostszym ujęciu, zdobywanie wiedzy lub umiejętności (a także doskonalenie dotychczas posiadanej wiedzy lub umiejętności), na podstawie wspomagających informacji, takich jak doświadczenia czy przykłady...

Najpopularniejsze rodziny algorytmów stosowane w rozwiązaniach problemów inteligencji obliczeniowej

- Logika rozmyta
- Sztuczne sieci neuronowe
- Systemy ekspertowe
- Algorytmy genetyczne

Logika rozmyta

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

Definicja zbioru rozmytego

Punktem wyjścia jest pojęcie zbioru rozmytego, które jest uogólnieniem pojęcia zbioru. Rozważmy zbiór wartości D . Każdy podzbiór $A \in D$ może być opisany za pomocą funkcji charakterystycznej χ_A , zdefiniowanej następująco:

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


Z kolei **zbiór rozmyty** A będący podzbiorem D ma tę cechę, że elementy mogą do niego należeć tylko częściowo (w pewnym stopniu). Odpowiednikiem funkcji charakterystycznej χ_A jest funkcja przynależności χ_μ , przyjmująca wartości $0 \leq \mu_A(x) \leq 1$. Wartość 0 funkcji przynależności oznacza, że element nie należy do zbioru, zaś wartość większa od zera oznacza przynależność do A .

Wnioskowanie rozmyte

Wnioskowanie jest procesem polegającym na sprawdzaniu możliwości wyprowadzenia formuły ze zbioru innych formuł, przy znanych regułach.

Wnioskowanie rozmyte przebiega według takiego samego schematu jak wnioskowanie „w logice klasycznej”, z tym że definicje reguł wnioskowania ulegają modyfikacjom uwzględniającym konieczność posługiwania się wartościami „prawdziwości” z zakresu $[0,1]$.



Prosty regulator rozmyty (FLC)




Regulator obserwuje liczbowe wartości wielkości wejściowe. Wartości te są następnie poddawane rozmywaniu: są zamieniane na ich jakościowe odpowiedniki - wartości lingwistyczne, na przykład „mały”, „średni” i „duży”. (Formalnie rzecz ujmując, dla każdej wielkości wejściowej i dla każdej z jej wartości lingwistycznych definiujemy opisującą ją funkcję zdaniową). Wynikiem rozmywania jest utworzenie wielu stwierdzeń, typu „x1 jest mały”, których stopień prawdziwości wynika z wartości funkcji zdaniowych dla obserwowanych wartości wejściowych.

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

Symulacja FLC – sterowanie przyspieszeniem



odległość	prędkość	przyspieszenie
mała	Mała	duże-
średnia	Mała	małe-
duża	Mała	małe-
mała	Średnia	duże+
średnia	Średnia	małe-
duża	Średnia	małe-
mała	Duża	małe+
średnia	Duża	duże-
duża	Duża	małe-



Rozważmy trzy przypadki wielkości wejściowych:

- | | | |
|----|------------------|----------------|
| 1. | odległość
30 | prędkość
50 |
| 2. | odległość
100 | prędkość
50 |
| 3. | odległość
30 | prędkość
65 |



Wartości lingwistyczne są dla tych przypadków następujące (odczytujemy je z wykresów funkcji przynależności):

1		odległość	prędkość
	mała	0,6	0,3
	średnia	0,4	0,7
	duża	0	0
2		odległość	prędkość
	mała	0	0,3
	średnia	1	0,7
	duża	0	0
3		odległość	prędkość
	mała	0,6	0
	średnia	0,4	1
	duża	0	0


Reguły wraz ze stopniem prawdziwości konkluzji

1	odległość	prędkość	przyspieszenie	min(odległość, prędkość)
	mała	Mała	duże-	0,3
	średnia	Mała	małe-	0,3
	mała	Średnia	duże+	0,6
	średnia	Średnia	małe-	0,4
2	odległość	prędkość	przyspieszenie	min(odległość, prędkość)
	mała	Średnia	duże+	0,3
	średnia	Średnia	małe-	0,7
3	odległość	prędkość	przyspieszenie	min(odległość, prędkość)
	mała	Średnia	duże+	0,6
	średnia	Średnia	małe-	0,4

Po dokonaniu wyostrzenia przyspieszenie samochodu w przykładowych przypadkach ma wynosić:



1	0.15
2	0.14
3	0,305



Zastosowania systemów rozmytych:


- Systemy w samochodach
 - Automatyczne skrzynie biegów
 - Sterowanie napędem 4x4
 - Sterowanie samochodami autonomicznymi
- Elektronika użytkowa
 - Systemy Hi-Fi
 - Kserokopiarki
 - Aparaty i kamery
 - Pralki
- AGD
 - Kuchenki mikrofalowe
 - Lodówki
 - Tostery
 - Odkurzacze
 - Pralki
- Kontrola powietrza
 - Klimatyzacje, nawilżacze

Zalety/wady systemów rozmytych


- Zalety:
 - Matematyczne podstawy są bardzo proste
 - Modyfikacji można dokonać dodając lub usuwając reguły
 - Systemy radzą sobie z nieprecyzyjnymi, zniekształconymi i zaszumionymi danymi wejściowymi
 - Są łatwe do skonstruowania i zrozumienia
 - Wiedzę o pracy systemu można pozyskać od eksperta doświadczonego w operowaniu daną instalacją
 - Jest to metoda rozwiązania złożonego problemu w wielu aspektach życia codziennego, w tym medycyny, przypomina rozumowanie i podejmowanie decyzji przez człowieka.
- Wady:
 - Nie mam systematycznej metody projektowania tych systemów
 - Są zrozumiałe tylko gdy są proste
 - Nadają się do rozwiązania problemów, gdzie nie potrzeba wysokiej dokładności

Inspiracja sztucznych sieci neuronowych

Idea sieci neuronowej naśladuje strukturę ludzkiego mózgu, złożonego z komórek nerwowych (neuronów) połączonych z „sensorami” i ze sobą według określonych zasad. Neuron odbierając impulsy elektryczne z *dendrytów* może przekazać je dalej przez *axon* lub zablokować ich przekazanie.







Przykładowy model neuronu




$$y_{in} = b + \sum_{i=1}^n x_i \cdot w_i$$

Funkcje aktywacji




Matematyczna realizacja sztucznej sieci neuronowej

Sztuczne sieci neuronowe są złożone z wielu węzłów, które imitują neurony w ludzkim mózgu. Neurony są połączone ze sobą łącznikami przekazującymi na wejścia innych neuronów obliczone wartości. Każdy z węzłów może pobrać dane wejściowe i wykonać na nich proste operacje. Rezultaty operacji można przesłać kolejnym neuronom. Z każdym łącznikiem jest powiązana **waga** przez którą mnoży się przesyłaną przez niego wartość. Sieć może zostać nauczona przez ustalenie wag.



Wielowarstwowy perceptron


Przykładem sieci neuronowych, chyba najbardziej rozpowszechnionym, jest **perceptron wielowarstwowy**.



Działanie sieci neuronowej (1)

- Węzeł grafu sieci odpowiada pojedynczemu neuronowi. Krawędź odpowiada połączeniu między neuronami (tzw. połączenie synaptyczne) – jest skierowana od wyjścia jednego do wejścia drugiego neuronu, co odpowiada jednokierunkowemu przepływowi danych.
- Neuron działa w taki sposób, że dokonuje się ważonego sumowania wartości wejść, obliczając wartość zwaną pobudzeniem.
- Wyjście neuronu powstaje w wyniku podania pobudzenia na funkcję aktywacji


Działanie sieci neuronowej (2)




Neurony zgrupowane są w warstwy w taki sposób, że między neuronami tej samej warstwy nie ma połączeń, a połączenia występują jedynie między neuronami sąsiadujących warstw. Wyróżnia się warstwę neuronów wyjściowych (zwaną krótko warstwą wyjściową), których wyjście jest jednocześnie wyjściem z sieci. Pozostałe warstwy są nazywane ukrytymi, gdyż wyjścia neuronów w nich się znajdujących nie są „widoczne” na wyjściu sieci.

Dla neuronów wyjściowych można przyjąć, że funkcja aktywacji jest funkcją liniową.

Właściwości sieci neuronowych








- Sieć neuronowa jest uniwersalnym aproksymatorem.
- Może być „nauczona” jak ma aproksymować.




Problem „przeuczenia”

- Zbyt mały zbiór uczący lub zbyt długie uczenie może spowodować wyszukanie błędnych prawidłowości.



Głębokie uczenie

- Większość metod głębokiego uczenia stosuje architektury sieci neuronowych i często nazywane są głębokimi sieciami neuronowymi.
- Termin „głęboki” odnosi się zwykle do liczby ukrytych warstw sieci neuronowej. Tradycyjnie sieci zawierają tylko 2-3 ukryte warstwy, podczas gdy sieci głębokie mogą ich mieć 150.
- Sieci głębokie muszą być uczone z zastosowaniem dużej ilości danych uczących, a sieci uczą się wprost z danych, bez potrzeby ich wcześniejszego „objaśniania” przez osobę nadzorującą proces uczenia.
- Najczęściej jako system do głębokiego uczenia stosuje się konwolucyjne sieci neuronowe (convolutional neural network).



Dlaczego stosujemy sztuczne sieci neuronowe?

- Z zastosowaniem sztucznych sieci neuronowych możemy znaleźć rozwiązania, dla których stworzenie algorytmu jest trudne lub nie istnieje
- Sieci uczą się na przykładach, nie musimy ich precyzyjnie programować
- Po nauczaniu tworzą program działający nawet szybciej, niż konwencjonalne rozwiązania

Zastosowania sztucznych sieci neuronowych

- Szeroko pojęta klasyfikacja
 - Rozpoznawanie mowy
 - Rozpoznawanie tekstu
 - Sprawdzenie autentyczności podpisu
 - Rozpoznawanie twarzy
 - Wykrywanie i predykcja usterek w procesach przemysłowych

Systemy ekspertowe

- Systemy ekspertowe to aplikacje do rozwiązywania złożonych problemów z danej dziedziny na poziomie wysokiej inteligencji i ekspertyzy.
- Charakteryzują się:
 - Wysoką wydajnością
 - Łatwością w użytkowaniu
 - „Solidnością” – podają wyniki odpowiadające skondensowanej wiedzy wielu specjalistów z dziedziny.

Możliwości systemów ekspertowych


- Doradzanie
- Instruktaż i asystowanie w podejmowaniu decyzji
- Demonstrowanie
- Dostarczanie rozwiązań
- Diagnozowanie
- Wyjaśnianie
- Interpretowanie wejścia
- Przewidywanie rezultatów
- Uzasadnianie konkluzji
- Sugerowanie alternatywnych opcji

Systemy ekspertowe nie są w stanie

- Zastąpić osób w ostatecznym podjęciu decyzji
- Przetwarzać ludzkich zdolności
- Podać prawidłowe wyjście, jeśli nie dysponują adekwatną bazą wiedzy
- Ulepszyć swoją wiedzę

Składniki systemu ekspertowego

- Baza wiedzy
- System wnioskowania
- Interfejs użytkownika




Baza wiedzy

- Zawiera specyficzną dla dziedziny wiedzę pochodzącą od ekspertów
- Od bazy wiedzy zależy „inteligencja” systemu ekspertowego
- Jest zorganizowana w postaci danych i wiedzy na temat danego zagadnienia.
- Jest ostatecznie zapisana jako zbiór reguł (IF-THEN-ELSE)
- Ważną rolę w tworzeniu bazy wiedzy pełnią „Knowledge Engineers” – osoby, które „koduja” wiedzę ekspercką w język reguł.


System wnioskowania

- Stosuje reguły wielokrotnie do faktów uzyskanych z wcześniejszych zastosowań reguł.
- Dodaje nową wiedzę do bazy
- Rozwiązuje konflikty, kiedy wiele reguł może być zastosowanych do tych samych reguł.

Odpowiedź na pytanie „Co się stanie?”



Odpowiedź na pytanie „Dlaczego coś się stało?”



Interfejs użytkownika

- Użytkownik nie musi być ekspertem w obsłudze komputera
- Najwygodniej jest „wypowiedzieć” fakty...

Znane zastosowania systemów ekspertowych


Application	Description
Projektowanie	Projektowanie obiektów i samochodów
Medycyna	Systemy diagnozujące przyczyny choroby na podstawie zaobserwowanych informacji
Systemy monitorujące	Ciągle porównywanie danych pomiarowych z wiedzą systemu eksperckiego w celu wykrycia awarii, np. wycieku z ropociągu
Sterowanie procesami	Sterowanie procesami przemysłowymi w oparciu o monitoring
Wiedza	Znajdowanie usterek w samochodach, systemach komputerowych
Finanse/Hnadel	Wykrywanie możliwych defraudacji, podejrzanych transakcji, zarządzanie zasobami w liniach lotniczych

Algorytmy genetyczne - opis

Algorytm genetyczny jest techniką optymalizacji stosującą przeszukiwanie inspirowaną genetyką i selekcją naturalną. Jest często używany do znajdowania optymalnego lub bliskiego optymalnemu rozwiązania trudnych problemów, które przy podejściu klasycznym/tradycyjnym wymagałyby długiego czasu do uzyskania wyników. Jest często stosowany do rozwiązywania problemów optymalizacyjnych w badaniach i uczeniu maszynowym.

Optymalizacja - wprowadzenie

Optymalizacja to proces poprawiania. W każdym procesie mamy zbiór wejść i zbiór wyjść.



Optymalizacja odnosi się do znajdowania takiego zestawu wartości wejść żeby uzyskać najlepsze wartości wyjść. Definicja „najlepsze” zmienia się w zależności od problemu, ale z matematycznego punktu widzenia odnosi się do maksymalizacji lub minimalizacji jednej lub wielu funkcji celu poprzez manipulowanie parametrami wejściowymi

Zbiór wszystkich możliwych wartości wejść stanowi przestrzeń przeszukiwania. W przestrzeni istnieje punkt lub zbiór punktów dających optymalne rozwiązanie. Celem optymalizacji jest znalezienie tego punktu lub zbioru punktów w przestrzeni przeszukiwania.

Algorytm genetyczny – wstęp

Problem definiuje środowisko, w którym istnieje pewna populacja osobników. Każdy z osobników ma przypisany pewien zbiór informacji stanowiących jego genotyp, a będących podstawą do utworzenia fenotypu. Fenotyp to zbiór cech podlegających ocenie funkcji przystosowania modelującej środowisko. Innymi słowy - genotyp opisuje proponowane rozwiązanie problemu, a funkcja przystosowania ocenia, jak dobre jest to rozwiązanie.

Genotyp składa się z chromosomów, gdzie zakodowany jest fenotyp i ewentualnie pewne informacje pomocnicze dla algorytmu genetycznego. Chromosom składa się z genów.

Wspólnymi cechami algorytmów ewolucyjnych, odróżniającymi je od innych, tradycyjnych metod optymalizacji, są:

1. stosowanie operatorów genetycznych, które dostosowane są do postaci rozwiązań,
2. przetwarzanie populacji rozwiązań, prowadzące do równoległego przeszukiwania przestrzeni rozwiązań z różnych punktów,
3. w celu ukierunkowania procesu przeszukiwania wystarczającą informacją jest jakość aktualnych rozwiązań,
4. celowe wprowadzenie elementów losowych.


Zapis algorytmu

Najczęściej działanie algorytmu przebiega następująco:

1. Losowana jest pewna populacja początkowa.
2. Populacja poddawana jest ocenie (**selekcja**). Najlepiej przystosowane osobniki biorą udział w procesie **reprodukcji**.
3. Genotypy wybranych osobników poddawane są operatorom ewolucyjnym:
 1. są ze sobą kojarzone poprzez złączanie genotypów rodziców (**krzyżowanie**),
 2. przeprowadzana jest **mutacja**, czyli wprowadzenie drobnych losowych zmian.
4. Rodzi się drugie (kolejne) **pokolenie**. Aby utrzymać stałą liczbę osobników w populacji te najlepsze (według funkcji oceniającej fenotyp) są powielane, a najgorsze usuwane. Jeżeli nie znaleziono dostatecznie dobrego rozwiązania, algorytm powraca do kroku drugiego. W przeciwnym wypadku wybieramy najlepszego osobnika z populacji - jego genotyp to uzyskany wynik.

Zapis algorytmu

- schemat



Zastosowania algorytmów genetycznych

- Optymalizacja
- Ekonomia
- Sieci neuronowe (do trenowania)
- Współbieżność – algorytmy genetyczne mają dobre możliwości uwspółbieżnienia
- Przetwarzanie obrazów
- Planowanie tras pojazdów
- Rozkłady jazdy
- Uczenie maszynowe
- Generowanie trajektorii robotów
- Parametryczne projektowanie samolotów
- Analiza DNA
- Optymalizacja wielokryteriowa
- Rozwiązywanie problemu komiwojażera i jego zastosowania (problemy rozkładu jazdy i pakowania).

Inne aparaty matematyczne sztucznej inteligencji

- Zbiory przybliżone
- Systemy neuronowo-rozmyte

Współczesne praktyczne zastosowanie SI (1)

- Technologie oparte na logice rozmytej – powszechnie stosowane do np. sterowania przebiegiem procesów technologicznych w fabrykach w warunkach "braku wszystkich danych".
- Systemy ekspertowe – systemy wykorzystujące bazę wiedzy (zapisaną w sposób deklaratywny) i mechanizmy wnioskowania do rozwiązywania problemów.
- Maszynowe tłumaczenie tekstów – systemy tłumaczące nie dorównują człowiekowi, robią intensywne postępy, nadają się szczególnie do tłumaczenia tekstów technicznych.
- Sieci neuronowe – stosowane z powodzeniem w wielu zastosowaniach łącznie z programowaniem "inteligentnych przeciwników" w grach komputerowych.
- Uczenie się maszyn – dział sztucznej inteligencji zajmujący się algorytmami potrafiącymi uczyć się podejmować decyzje bądź nabywać wiedzę.
- Eksploracja danych – omawia obszary, powiązanie z potrzebami informacyjnymi, pozyskiwaniem wiedzy, stosowane techniki analizy, oczekiwane rezultaty.

Współczesne praktyczne zastosowanie SI (2)

- Rozpoznawanie obrazów – stosowane są już programy rozpoznające osoby na podstawie zdjęcia twarzy lub rozpoznające automatycznie zadane obiekty na zdjęciach satelitarnych.
- Rozpoznawanie mowy i rozpoznawanie mówców – stosowane już powszechnie na skalę komercyjną.
- Rozpoznawanie pisma (OCR) – stosowane już masowo np. do automatycznego sortowania listów, oraz w elektronicznych notatnikach.
- Sztuczna twórczość – istnieją programy automatycznie generujące krótkie formy poetyckie, komponujące, aranżujące i interpretujące utwory muzyczne, które są w stanie skutecznie "zmylić" nawet profesjonalnych artystów, w sensie, że nie rozpoznają oni tych utworów jako sztucznie wygenerowanych.
- W ekonomii, powszechnie stosuje się systemy automatycznie oceniające m.in. zdolność kredytową, profil najlepszych klientów, czy planujące kampanie reklamowe. Systemy te poddawane są wcześniej automatycznemu uczeniu na podstawie posiadanych danych (np. klientów banku, którzy regularnie spłacali kredyt i klientów, którzy mieli z tym problemy).

Porażki SI (1)

Nie udało się zbudować:

- *Programów skutecznie wygrywających w niektórych grach. Jak dotąd nie ma programów skutecznie wygrywających w go, brydża sportowego i polskie warcaby, mimo że podejmowano próby ich pisania. Trzeba jednak przyznać, że programy do gry w szachy, w które zainwestowano jak dotąd najwięcej wysiłku i czasu spośród wszystkich tego rodzaju programów, osiągnęły bardzo wysoki poziom, ogrywając nawet mistrza świata Garriego Kasparowa w maju 1997.*
- *Programu, który by umiał idealnie naśladować człowieka, rozmawiając przy użyciu tekstu i potrafiłby przejść test Turinga. Istnieją programy do konwersacji z komputerem, ale każdy człowiek, który miał z nimi wcześniej do czynienia, w krótkim czasie jest w stanie zorientować się, że rozmawia z maszyną, a nie innym człowiekiem.*

Przykłady zadań sztucznej inteligencji

- **Układanie planu lekcji**
- **Gra w szachy**
- **Dowodzenie twierdzeń**
- **Sterowanie mobilnym robotem**
- **Diagnostyka medyczna**

System wnioskowania (1)

- **Wprowadza się alfabet języka**
 - **Symbole stałych:** oznaczane za pomocą liter $a, b, c \dots$
 - **Symbole zmiennych:** oznaczane za pomocą liter $x, y, z \dots$
 - **Symbole funkcyjne:** oznaczane za pomocą liter $f, g, h, \dots$; każdy symbol funkcyjny ma ustaloną liczbę argumentów.
 - **Symbole predykatowe:** oznaczane za pomocą liter P, Q, R ; każdy symbol predykatowy ma ustaloną liczbę argumentów.
 - **Operatory logiczne:** $\neg$ (negacja), $\wedge$ (koniunkcja), $\vee$ (alternatywa), $\rightarrow$ (implikacja), $\leftrightarrow$ (równoważność).
 - **Kwantyfikatory:** kwantyfikator ogólny $\forall$, kwantyfikator szczegółowy $\exists$.
 - **Nawiasy:** $(,)$, w razie potrzeby także inne.

System wnioskowania (2)

- **Wprowadza się formuły atomowe i złożone z zastosowaniem symboli predykatowych, stałych, zmiennych i operatorów logiki**
- **Wprowadza się semantykę języka logiki – jak przypisać formułom znaczenie**

System wnioskowania (3)

- **Wprowadza się system wnioskowania** - formalny aparat umożliwiający prowadzenie procesu wnioskowania - wyprowadzania nowych formuł z pewnego początkowego zbioru znanych formuł, nazywanego bazą wiedzy.
- Systemy wnioskowania dla języka logiki predykatów obejmują dwa składniki.
 - **Aksjomaty:** formuły, których prawdziwość przyjmowana jest bez dowodu.
 - **Reguły wnioskowania:** wzorce opisujące dozwolone sposoby bezpośredniego wyprowadzania nowych formuł ze znanych formuł.

Wnioskowanie na podstawie niepewnej wiedzy (1)

Wiedza pochodząca od człowieka może być **niedoskonała**. Stosując do takiej wiedzy metody zakładające doskonałą wiedzę (tradycyjne systemy wnioskowania) jesteśmy narażeni na uzyskiwanie wniosków, które nie muszą być prawdziwe i o których prawdziwości nie potrafimy nic powiedzieć. Celowe jest w związku z tym wyposażanie systemów wnioskujących na podstawie niedoskonałej wiedzy w specjalne mechanizmy jej przetwarzania, dzięki którym będzie możliwe charakteryzowanie rodzaju i stopnia niedoskonałości wiedzy pochodzącej od człowieka, a także nowej wiedzy wyprowadzonej na jej podstawie przez system wnioskujący.

Rodzaje niedoskonałości wiedzy

niepewność: prawdziwość niektórych stwierdzeń nie jest pewna,

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

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

W przypadku wiedzy **niepewnej** mamy do czynienia ze stwierdzeniami, o których w ogólnym przypadku nie można powiedzieć z pewnością, że są prawdziwe albo fałszywe. Potrzebne są w tym celu jakieś metody charakteryzowania stopnia przekonania o prawdziwości stwierdzeń - zarówno należących do początkowej bazy wiedzy, jak i uzyskiwanych w wyniku głosowania. **Niepełność** wiedzy oznacza, że status prawdziwości pewnych stwierdzeń potrzebnych do wnioskowania nie jest znany. Może to wymagać założenia ich prawdziwości w celu przeprowadzenia wnioskowania, lecz z pozostawieniem możliwości rewizji tego wnioskowania, gdyby następnie pojawiła się wiedza zaprzeczająca temu założeniu. **Niedokładność** polega na niemożności precyzyjnego odróżnienia w dziedzinie, na temat której zapisujemy wiedzę, obiektów należących do pewnej relacji od obiektów do niej nienależących.

Metody przetwarzania niedoskonałej wiedzy

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

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

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

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

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

Metody przetwarzania niedoskonałej wiedzy

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

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

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

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

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