Metody eksploracji danych

Przegląd metod SI

dr inż. Jacek Czerniak

Zakres przedmiotu

- Wprowadzenie do metod sztucznej inteligencji.
- Systemy ekspertowe: budowa, metody pozyskiwania wiedzy, mechanizmy wnioskowania.
- Odkrywanie asocjacji
- Odkrywanie wzorców sekwencji
- Klasyfikacja
- Grupowanie
- Eksploracja tekstu
- Wprowadzenie do teorii zbiorów przybliżonych.

Literatura

Podstawowa:

- Data Mining: Concepts and Techniques, J. Han, M. Kamber, Morgan Kaufman, 2000
- Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations, I. H. Witten, E. Frank, Morgan Kaufman, 2000
- Pricinciples of Data Mining, J. Hand, H. Mannila, P. Smyth, MIT Press, 2001
- Systemy uczące się, P. Cichosz, WNT, 2000
- Odkrywanie asocjacji: Algorytmy i struktury danych, T. Morzy, OWN, 2004

Forma zaliczenia

Wykład **15h**:

- Egzamin – test „20”
- 20 – pytań
- 20 min.
- 60% trafień zalicza (12 z 20)

www.jczerniak.ukw.edu.pl

Forma zaliczenia

Wykład **30h**:

- Egzamin pisemny (zerówka – ostatni wykład)
- Egzamin ustny (termin podstawowy)
- Egzamin ustny (termin poprawkowy - wrzesień)

www.ai.z.pl

Laboratorium **30h**:

Zaliczenie wszystkich bloków tematycznych

Sztuczna inteligencja

Inteligencja:
zdolność do wykorzystywania zgromadzonej wiedzy

Sztuczna inteligencja:
Modelowanie wiedzy, rozwiązywanie problemów niealgorytmizowalnych w oparciu o symboliczną reprezentację wiedzy.

Niebezpieczeństwa:
zastosowania wojskowe, rosnące tempo zmian społecznych, możliwość całkowitej automatyzacji wielu zawodów.

Definicja

Sztuczna inteligencja (*ang. Artificial Intelligence, AI*) to dziedzina nauki zajmująca się rozwiązywaniem zagadnień efektywnie niealgorytmizowalnych w oparciu o modelowanie wiedzy.

Inne definicje:

- AI to nauka mająca za zadanie nauczyć maszyny zachowań podobnych do ludzkich.
- AI to nauka o tym, jak nauczyć maszyny robić rzeczy które obecnie ludzie robią lepiej.
- AI to nauka o komputerowych modelach wiedzy umożliwiających rozumienie, wnioskowanie i działanie.

AI uważana jest za część informatyki.

AI i inne nauki

AI zaliczana jest do nauk kognitywnych.

AI to część ogólniejszej dziedziny, nazywanej Inteligencją Obliczeniową (*ang. Computational Intelligence*), której celem jest rozwiązywanie zagadnień efektywnie niealgorytmizowalnych przy pomocy obliczeń.

„Obszary badań naukowych powstają w wyniku skupienia się zainteresowania uczonych wokół różnych zjawisk. Nauki nie powstają w wyniku definicji ale zostają rozpoznane”

(A. Newell, 1973)

AI została rozpoznana jeszcze przed informatyką!

Skąd się to wzięło?

- Ramon Lull, XIII wiek, kataloński filozof i teolog, franciszkanin, „Ars magna generalis et ultimata” - systemu logicznego, obejmującego wszystkie gałęzie wiedzy.

- Gottfried F. Leibniz, 1646-1716.
  Czterodziałaniowa maszyna licząca w 1694 r,
  projekt maszyny działającej w systemie dwójkowym.

Pisząc o „rachunku filozoficznym” Leibniz wyraża nadzieję, że w przyszłości dzięki rozwojowi logiki matematycznej zamiast się spierać, wystarczy policzyć - Calculemus!

Problem Leibniza: jak większa liczba dzielona przez mniejszą może dać to samo co mniejsza przez większą?

Maszyny liczące

- Charles Babbage, 1792-1871, projekty maszyny różnicowej i maszyny analitycznej, „snującej myśli jak krosna Jacquarda snują włókna”.
  Maszynę różnicową zbudowano w 1992 roku, stoi w muzeum techniki w Science Museum, South Kensington, w Londynie.

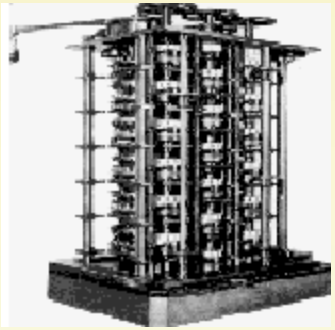

- John von Neumann, 1945, podał ogólny schemat działania uniwersalnego komputera, znanego jako „maszyna z Princeton”.

Informatyka

- 1949: Claude Shannon i teoria informacji;
  Norbert Wiener „Cybernetyka czyli sterowanie i komunikacja w zwierzęciu i maszynie”.
  McCulloch i Pitts - sieć nerwowa jako układu elementów logicznych.

- Allan Turing, 1912-1954, ojciec informatyki teoretycznej, rozważa w 1950 roku możliwości myślenia maszyn, formułuje „test Turinga” w pracy „Computing Machinery and Intelligence”.

Powstanie AI

- Marvin Minksky, 1956, nazwa "sztuczna inteligencja".
- Allen Newell, Herbert Simon, 1958 - General Problem Solver, próba stworzenia ogólnego programu do rozwiązywania problemów.
- Newell i Simon, 1975, AI jako nauka empiryczna, symboliczne systemy oparte na wiedzy jako model umysłu.

Inne źródła: logika, androidy i sterowanie, cybernetyka, rozwój informatyki, konferencja w 1956 roku na której sztuczna inteligencja otrzymała swoja nazwę.

- Allen Newell, wykłady Williama Jamesa na Harvard Univ 1988: „*Psychologia dojrzała już do zunifikowanych teorii poznania, czyli takich teorii, które postulują spójny system mechanizmów pozwalających wyjaśnić wszystkie aspekty działania umysłu*.”

Okresy rozwoju AI

Według Patrick’a Winston'a wyróżnić można kilka okresów:

- Era prehistoryczna: od maszyny analitycznej Charles'a Babbage (1842) do około 1960 roku.
- Era romantyczna, 1960-1965, kiedy przewidywano, że AI osiągnie swoje cele w ciągu 10 lat.
- Okres ciemności: 1965-1970, w którym niewiele się działo, opadł entuzjazm i pojawiły się głosy bardzo krytyczne.
- Renesans: 1970-1975, gdy zaczęto budować pierwsze systemy doradcze, użyteczne w praktyce.

Okresy rozwoju AI c.d.

- Okres partnerstwa: 1975-1980, gdy do badań nad AI wprowadzono metody kognitywistyki.
- Okres komercjalizacji: 1980-1990, gdy programy AI, a szczególnie systemy doradcze zaczęto sprzedawać komercyjnie.
- Wielkie projekty: CYC, 5 generacja; projekty hybrydowe CI; era agentów, elementy AI w wielu programach.

Zastosowania: wszędzie tam, gdzie nie ma pełnej teorii a wymagane są inteligentne decyzje.

Najbardziej udane: programy do obliczeń symbolicznych przy pomocy algebry komputerowej.

Kluczowe zagadnienia

- Rozwiązywanie problemów: gry i zagadki logiczne, gry planszowe, obliczenia symboliczne.

- Główne metody to szukanie i redukcja problemów. Mistrzowskie rezultaty: warcaby, szachy i inne, ale np. go wymaga bardziej wyrafinowanych technik. Obliczenia symboliczne przy pomocy programów algebry komputerowej.
- Rozumowanie logiczne, dowodzenie twierdzeń.
- Manipulowanie obiektami z bazy zapisanych jako dyskretne struktury danych, duże problemy, wybór istotnych faktów i hipotez wymaga AI. Projektowanie układów logicznych.

Kluczowe zagadnienia II

- Język naturalny: rozumienie języka, tłumaczenie maszynowe, rozumienie mowy mówionej.
  Budowa baz danych z tekstów, wiedza kontekstowa, rola oczekiwań w interpretacji znaczeń.

- Programowanie automatyczne lub autoprogramowanie.
  Opis algorytmów przy pomocy języka naturalnego, automatyczne pisanie programów, modyfikacja swojego własnego programu, programowanie dostępu do baz danych dla menedżerów.

- Ekspertyza, systemy doradcze, inżynieria wiedzy.
  Reprezentacja wiedzy, dialog z systemem, wyjaśnianie rozumowania, akwizycja wiedzy często nieuświadomionej.

Kluczowe zagadnienia III

- Robotyka i wizja, rozpoznawanie obrazu, kształtów i cech przedmiotów, kontrola ruchu.
  Programy manipulujące kończynami robotów, optymalizacja ruchów, planowanie sekwencji czynności, integracja senso-motoryczna na poziomie przed-symbolicznym.
  Integracja z metodami CI kontroli i analizy obrazów.

- Systemy i języki: to narzędzia dla pracy w AI i jednocześnie jej produkty uboczne.
  Języki programowania, idee time-sharing, przetwarzanie list, debugowanie są ubocznym wynikiem badań nad AI.
  LISP, Prolog, wiele języków specjalistycznych rozwinięto dla potrzeb AI.

Kluczowe zagadnienia IV

- Uczenie się - głównie w systemach inteligencji obliczeniowej, na razie słabo zintegrowane z AI.
  Uczenie się na przykładach, przez analogię, w klasycznych systemach AI prawie nie występuje.
  Uczenie maszynowe: dość ezoteryczny, lecz bardzo ważny dział AI, metody statystyczne, rozpoznawania struktur (*ang. pattern recognition*), sieci neuronowe, logika rozmyta, algorytmy ewolucyjne i wiele innych.

- Zagadnienia filozoficzne AI.
  Czy maszyny mogą myśleć?
  Czy mogą być twórcze?
  Czy mogą być świadome?
  Jakie są ograniczenia ich możliwości?

Trzy inspiracje AI

- Rozwój informatyki i matematyki,
- Obserwacje natury
- Obserwacje zjawisk cywilizacyjnych

„*Nie trzeba naśladować ruchu skrzydeł, żeby stworzyć samolot*”

prof. Rodney Brooks, AI Lab, MIT

http://people.csail.mit.edu/brooks/

Obszary Sztucznej Inteligencji

- Algorytmy genetyczne
  - Programowanie ewolucyjne
  - Programowanie genetyczne
- Sieci neuronowe
- Systemy mrówkowe
- Systemy wieloagentowe
- Systemy rozmyte
- Data mining
- Zbiory przybliżone
- Systemy ekspertowe
- Symulowane wyżarzanie
- Poszukiwanie tabu i in.

Algorytmy Genetyczne

Badania nad algorytmami genetycznymi oraz obliczeniami ewolucyjnymi zainspirowane zostały teorią Darwina dotyczącą naturalnej selekcji i zdolności do przetrwania jedynie najsilniejszych osobników populacji. Algorytmy genetyczne to programy, które w sposobie rozwiązywania problemów naśladują naturalny fenomen ewolucji.

Algorytmy Genetyczne c.d.

Przez długi okres wielkie populacje dokonywały naturalnej selekcji na drodze reprodukcji oraz mutacji. Idąc w ich ślady programy wykorzystujące algorytmy genetyczne tworzą populację z możliwych rozwiązań danego problemu. Następnie, poprzez kilkakrotne przeprowadzenie procesów przypadkowej selekcji i wariacji, stwarzane są kolejne generacje programu, z których każda charakteryzuje się zwiększeniem jakości rozwiązania. W konsekwencji algorytmy genetyczne sterują ewolucją rozwiązań za pomocą procesów genetycznych. W przeciwieństwie do ewolucji naturalnej, program komputerowy tworzy i ocenia tysiące generacji w kilka sekund.

Programowanie Ewolucyjne

Inicjatorem programowania ewolucyjnego był Lawrence Fogel (1966 rok). Pierwotnie było ono wykorzystywane do przewidywania ewentualnych zmian w środowisku mogących wystąpić na skutek rozwoju sztucznej inteligencji. W tym przypadku otoczenie opisywane było sekwencją symboli, zaś dane wyjściowe tworzył nowy symbol wyprodukowany przez rozwinięty algorytm. Wyjściowy symbol maksymalizował funkcję wypłaty oceniającą dokładność dokonanego przewidywania.

Programowanie Ewolucyjne c.d.

W końcowym stadium eksperymentu maszyny w nim wykorzystane tworzyły chromosomową reprezentację jednostek, która w oparciu o interpretację symboli dostarczała sensowne odzwierciedlenie rzeczywistych zachowań ludzkich. We wczesnych latach dziewięćdziesiątych David Fogel dokonał próby uogólnienia wszystkich technik programowania ewolucyjnego, aby umożliwić rozwiązanie złożonych problemów z zakresu klasyfikacji i optymalizacji numerycznej.

Sieci Neuronowe

Sztuczne Sieci Neuronowe powszechnie znane jako sieci neuronowe, to sieci składające się z wielu prostych procesorów dysponujących niewielką ilością pamięci lokalnej. Procesory te, zwane inaczej jednostkami, są wzajemnie połączone za pomocą licznych kanałów komunikacyjnych umożliwiających przesyłanie zakodowanych danych numerycznych. Jednostki posługują się własnymi danymi lokalnymi bądź wykorzystują dane wejściowe otrzymywane drogą połączenia.

Sieci Neuronowe c.d.

Pomysł zbudowania sieci neuronowej zrodził się z potrzeby stworzenia sztucznego systemu umożliwiającego skomplikowane, a może nawet inteligentne, obliczenia podobne do tych, które są realizowanych przez umysł ludzki. Większość sieci neuronowych posiada pewien zasób szkolących je reguł, za pomocą których modyfikują one stopień ważności poszczególnych połączeń na podstawie dostępnych im danych. Przykłady oraz wykazy wydajności umożliwiają "nauczenie" sieci neuronowych generalizacji wykraczającej poza dane instruktażowe. W konsekwencji sieci neuronowe są niezmiernie przydatne przy rozpoznawaniu wzorów. Mogą być zatem "kształcone" do wykrywania złożonych relacji pomiędzy danymi wyjściowymi, nawet w tych przypadkach, gdy statystyczne rozmieszczenie tych danych jest nieznane.

Neuron

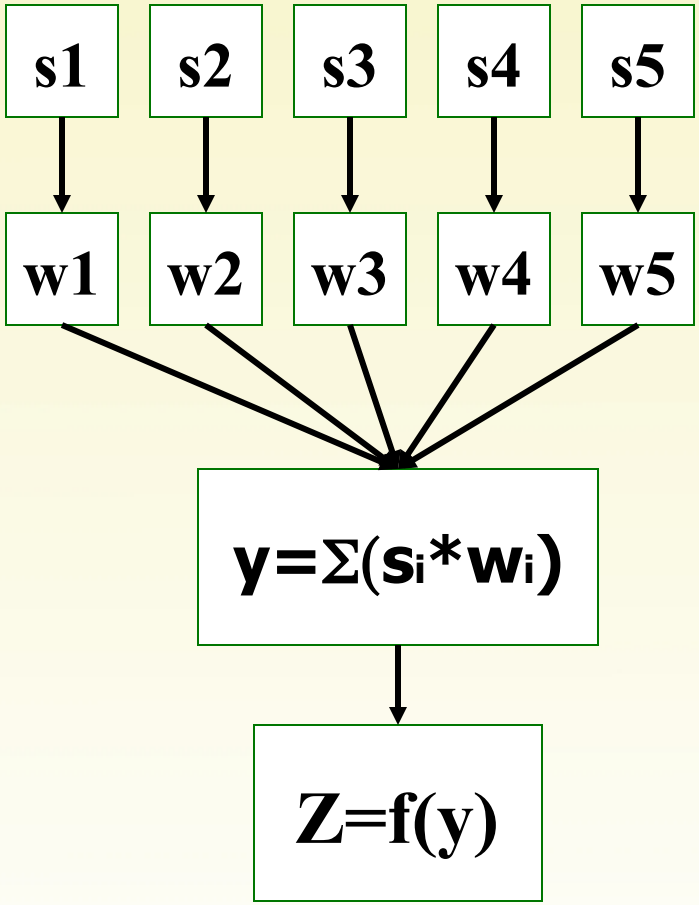

Sygnały wejściowe

Wagi

Sumator

Aktywator
Z - odpowiedź neuronu

Sieć neuronowa

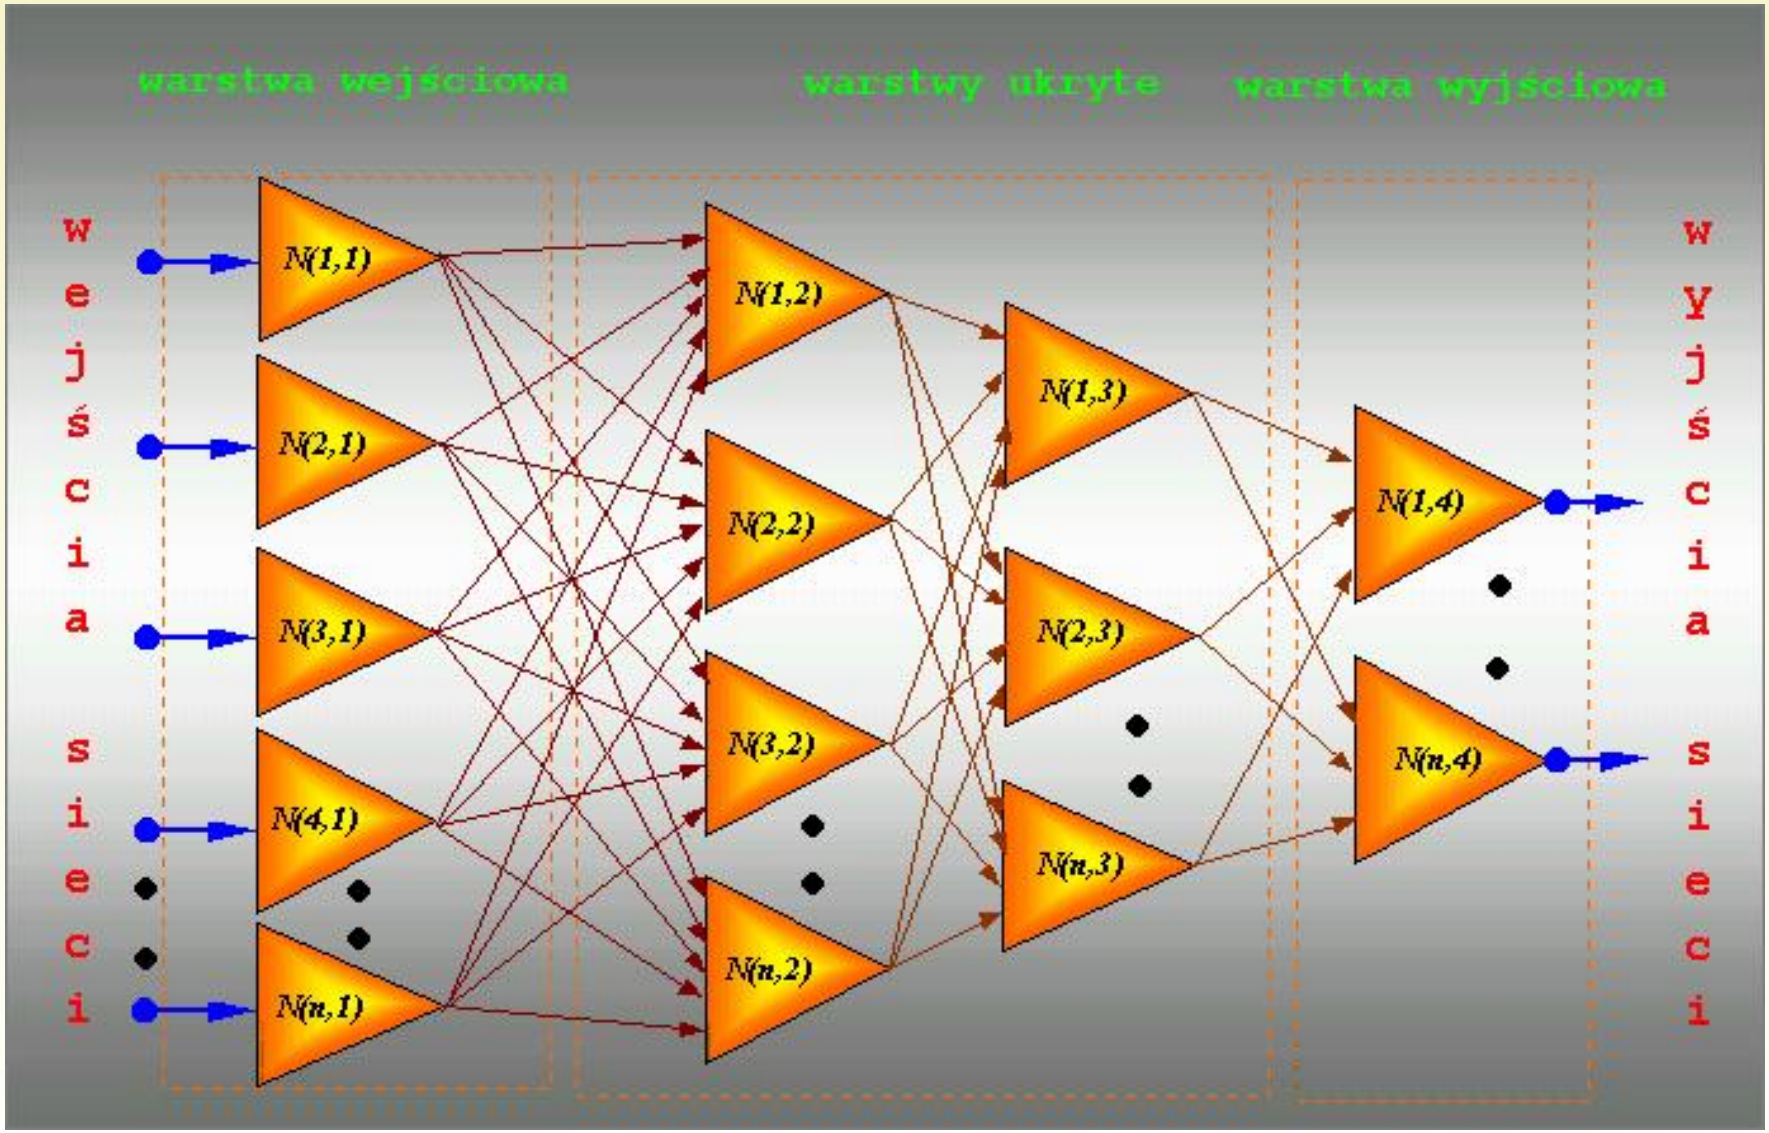

Sieci neuronowe - zastosowanie

- Rozpoznawanie wzorców (znaków, liter, kształtów, sygnałów mowy, sygnałów sonarowych)
- Klasyfikowanie obiektów
- Prognozowanie i ocena ryzyka ekonomicznego
- Prognozowanie zmian cen rynkowych (giełdy, waluty)
- Ocena zdolności kredytowej
- Ocena wniosków ubezpieczeniowych
- Rozpoznawanie wzorów podpisów
- Prognozowanie zapotrzebowania na energię elektryczną
- Diagnostyka medyczna
- Dobór pracowników
- Prognozowanie sprzedaży
- Analizowanie zachowań klienta w supermarketach
- Aproksymowanie wartości funkcji

Uczenie metodą wstecznej propagacji błędów

Przygotowanie dwóch ***ciągów*** danych: ***uczącego*** i ***weryfikującego***

Po przetworzeniu wektora wejściowego, nauczyciel porównuje wartości otrzymane z wartościami oczekiwanymi i informuje sieć czy odpowiedź jest poprawna, a jeżeli nie, to jaki powstał błąd odpowiedzi.

Błąd ten jest następnie propagowany do sieci ale w odwrotnej niż wektor wejściowy kolejności (od warstwy wyjściowej do wejściowej) i na jego podstawie następuje taka korekcja wag w każdym neuronie, aby ponowne przetworzenie tego samego wektora wejściowego spowodowało zmniejszenie błędu odpowiedzi

Ciąg weryfikujący służy do sprawdzenia czy system prawidłowo rozwiązuje zadania

Systemy mrówkowe

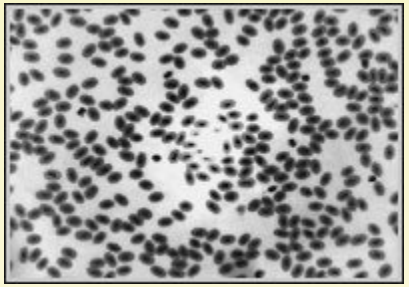

- Systemy mrówkowe, znane również jako algorytmy mrówkowe, to systemy wielu przedstawicieli, w których zachowanie poszczególnego przedstawiciela-komputera inspirowane jest rzeczywistym zachowaniem mrówek. Mając dane źródło pożywienia posiadające wiele ścieżek dostępu, kolonia mrówek dotrze do niego przy użyciu najkrótszej i najefektywniejszej trasy. Mechanizm tego procesu jest następujący.

Systemy mrówkowe c.d.

- Niektóre gatunki mrówek podczas wędrówki z mrowiska w kierunku źródła pożywienia pozostawiają na podłożu substancję chemiczną zwaną feromonem. Gdy proces ten powtarza się, feromon pozostawiany jest przez mrówki w coraz większych ilościach na coraz krótszych odcinkach. Kiedy inne mrówki dojdą do punktu decyzyjnego, którym jest skrzyżowanie wielu możliwych ścieżek, dokonują wyboru trasy na podstawie ilości pozostawionej przez poprzedniczki substancji. Po kilku chwilach już prawie wszystkie mrówki używają najkrótszej ścieżki ze względu na najwyższą koncentrację znajdującego się na niej feromonu.

Systemy mrówkowe c.d.

- Algorytmy mrówkowe wykorzystywane w programach komputerowych symulują pozostawianie feromonu wzdłuż wykorzystywanych ścieżek. Wielokrotne użycie algorytmu pozwala na zidentyfikowanie trasy optymalnej. Algorytmy mrówkowe są najlepszym przykładem systemu bazującego na inteligencji masowej. Wykorzystywane są do rozwiązywania licznych problemów optymalizacji, począwszy od klasycznego problemu komiwojażera, a skończywszy na wyznaczaniu tras w sieciach telekomunikacyjnych.

Systemy wieloagentowe

- Modele oparte na systemach wieloagentowych to programy komputerowe, które próbują symulować różnorodne złożone zjawiska za pomocą wirtualnych „agentów”, reprezentujących elementy systemu biznesowego. Zachowania tych agentów są zaprogramowane jako proste reguły.

Systemy wieloagentowe c.d.

- Uruchomione modele realistycznie obrazują działanie danego biznesu. Podejście do programowania może być bardzo rożnorodne; począwszy od wykorzystania analiz „if-then” (takich jak w systemach eksperckich) aż do skomplikowanych maszynowych algorytmów uczących (takich jak sieci neuronowe, które pozwalają agentom uczyć się i modyfikować zachowanie podczas symulacji. Parametry modelu odzwierciedlają badaną sytuację, a model poddany jest wielokrotnym iteracjom. Modele wieloagentowe oparte są na danych historycznych, dzięki czemu możliwe jest zapewnienie sytuacji, w której model dokładnie odtwarza zachowanie rzeczywistego systemu.

Systemy wieloagentowe c.d.

- Modele wieloagentowe mogą być źródłem wartościowych informacji na temat dynamiki systemów rzeczywistych, które naśladują. Dzieki wchodzeniu we wzajemne interakcje poszczgólnych agentów w modelu, symulacja pokazuje jak ich zbiorowe zachowanie wpływa na cały system. Symulacje te stanowią potężne strategiczne narzędzia dla analiz „what-if”: zmiana charakterystyki agenta lub zasad, którym on podlega jest łatwo dostrzegalna w dostarczonym przez model wyniku końcowym symulacji. Bardzo ważny jest również fakt, że komputer jest czasem w stanie wygenerować strategie, których użytkownik nigdy by nie rozważył.

Systemy rozmyte

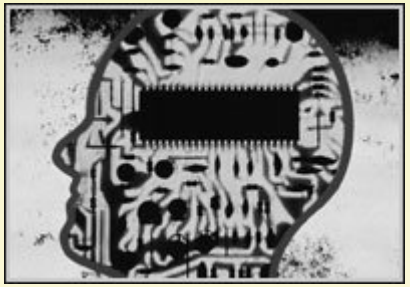

- Tradycyjne programy komputerowe wymagają precyzji: włącz-wyłącz, tak-nie, dobrze-źle. Jednakże w świecie rzeczywistym nie wszystko można opisać w tak jednoznaczny sposób. Na systemy rozmyte składa się wiele różnych pojęć i technik umożliwiających najlepsze zobrazowanie informacji nieprecyzyjnych, nieokreślonych bądź niekonkretnych. Systemy rozmyte tworzą swoje własne reguły opierające się na aproksymacjach lub subiektywnych wartościach, jak również niekompletnych czy też dwuznacznych danych.

Systemy rozmyte c.d.

- Dla przykładu, informacje takie jak "gorący" czy "drogi" nie nadają się do bezpośredniego wykorzystania przez tradycyjne algorytmy. Systemy rozmyte są narzędziem umożliwiającym zdefiniowanie takich właśnie informacji za pomocą wyrażeń logicznych zawierających określone nieścisłości. W przeciwieństwie do tradycyjnych programów wykorzystujących proste reguły IF-THEN, systemy rozmyte bazują na zestawieniach modelujących ludzki sposób myślenia, które mogą być interpretowane zarówno przez komputery jak i profesjonalnych ekspertów.

Data mining

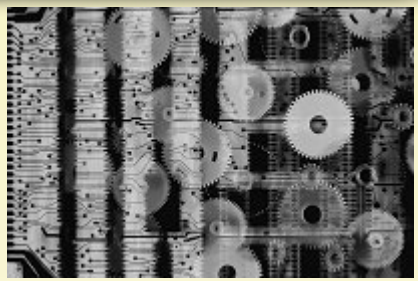

- Data mining to proces budowania modeli i równań, które opisują najistotniejsze, zwykle drobiazgowe charakterystyki zbioru danych. Najczęściej proces rozpoczyna się od znalezienia naturalnych podziałów w danych, w których pojawiają się logiczne grupy. Grupy te można następnie uporządkować w segmenty, które mają określone znaczenie dla biznesu. Na podstawie tych klasyfikacji i podziałów, można zbudować modele, które zdolne są do prognozowania w oparciu o nowe dane wprowadzone do systemu.

Data mining c.d.

- Istnieje wiele różnych podejść do tworzenia modeli z danych. Większość bazuje na zaawansowanych metodach statystycznych, takich jak regresja liniowa i nieliniowa. Metody te są ważne, ale nie zaspokajają wszystkich możliwych potrzeb modeli danych oraz nie zawsze identyfikują wszystkie najistotniejsze cechy danych. Inne, niestatystyczne metody, takie jak drzewa decyzyjne i sieci neuronowe – technika modelowania danych powstała w wyniku komputerowego modelowania ludzkiego mózgu.

Zbiory przybliżone

$$O_i'' \longleftrightarrow 1/2O_2(g) + 2e' \quad V_{Sn}''' + SnO_2 \longleftrightarrow O_2(g) + 4e' + Sn_{Sn}^X$$

$$O_O^X \longleftrightarrow 1/2O_2(g) + V_O^{\cdot\cdot} + 2e' \quad O_i'' \longleftrightarrow 1/2O_2(g) + 2e'$$

$$V_{Sr}'' + V_{Sn}''' + SrSnO_3 \longleftrightarrow 3/2O_2(g) + 6e' + Sr_{Sr}^X + Sn_{Sn}^X$$

$$V_{Sn}''' + SnO_2 \longleftrightarrow O_2(g) + 4e' + Sn_{Sn}^X \quad V_{Sn}''' + 4e' + SnO_2$$

$$1/2O_2(g) \longleftrightarrow O_i'' + 2V_{Sn}''' + SnO_2 \longleftrightarrow O_2(g) + 4e' + Sn_{Sn}^X$$

- Teoria zbiorów przybliżonych wykorzystywana jest do badania nieprecyzyjności, ogólnikowości i niepewności w procesie analizy danych. Koncentruje się ona na dostarczaniu ogromnym zbiorom danych niezbędnych wzorów, reguł oraz informacji. Źródłem tej teorii są liczne badania z zakresu analizy i reprezentacji w technikach informatycznych przeprowadzane przez polskich matematyków i informatyków w latach siedemdziesiątych.

Zbiory przybliżone c.d.

- Autorem koncepcji zbiorów przybliżonych jest **profesor Zdzisław Pawlak**, który ogłosił podstawy tej teorii w 1982 roku. Następnie została ona rozwinięta do postaci aplikacji *data mining* przez profesora Andrzeja Skowrona. Teoria zbiorów przybliżonych wykorzystywana jest przez liczne aplikacje medyczne, farmakologiczne, inżynierskie, produkcyjne i bankowe.

Symulowane wyżarzanie

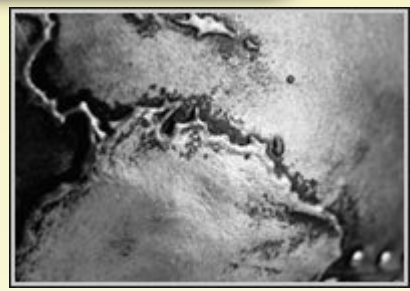

- Zasada przeprowadzania wyżarzania symulowanego została zaczerpnięta z metalurgii: kawałek metalu jest ogrzewany (atomy są wzbudzone termicznie), a następnie pozostawiany do powolnego ostygnięcia. Powolne i regularne chłodzenie się metalu pozwala atomom na obniżenie poziomu swej energii do momentu znalezienia się w stanie metastabilnym (o minimalnej energii).

Symulowane wyżarzanie c.d.

- Gwałtowne ochłodzenie zamroziłoby je na przypadkowych pozycjach, na których aktualnie by się znajdowały. Otrzymana w rezultacie struktura metalu jest silniejsza i bardziej stabilna. Poprzez symulowanie procesu wyżarzania za pomocą programu komputerowego jesteśmy w stanie znaleźć rozwiązania trudnych i złożonych zadań. Zamiast minimalizowania energii bloku metalu (czy maksymalizowania jego wytrzymałości) program od ręki minimalizuje lub maksymalizuje funkcje celu związane z problemem.

Symulacja zdarzeń nieciągłych

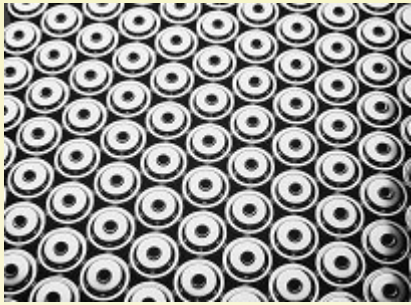

- Symulacja zdarzeń nieciągłych to metoda budowania modeli komputerowych pozwalająca obserwować zachowanie systemu w czasie. Modele są wykonywane w środowisku symulacyjnym i generują wyniki, które pozwalają zajrzeć w głąb systemu oraz stanowią podstawę do podejmowania decyzji.

Symulacja zdarzeń nieciągłych c.d.

- Jednym z obszarów, w którym symulacja jest powszechnie stosowana, jest tworzenie nowych systemów, zwłaszcza tych, które wymagają dużych inwestycji kapitałowych. Symulacja może na przykład być używana do testowania działania linii montażowych, aby ustalić możliwy przerób, poziom wykorzystania operatorów i potencjalne trudności. Dalsza symulacja pozwala oszacować najlepsze miejsce dla magazynów przetwarzania i poziomy ich wykorzystania.

Systemy ekspertowe

- Systemem ekspertowym zwykło nazywać się system informatyczny, który wspomaga działanie eksperta lub je w jakiejś dziedzinie zastępuję. Oznacza to, iż zakłada się istnienie jakiegoś rodzaju inteligencji wbudowanej w system, która pozwoli rozwiązywać problemy dotychczas nieznane ale mieszczące się w domenie do jakiej dedykowany jest system. Zwykle stawia się wymóg aby użytkownik mógł prześledzić drogę wnioskowania logicznego jaką przebył system.
- Wszystko o czym mówiliśmy do teraz jest jakimś rodzajem systemu ekspertowego (esperckiego)

Pozyskiwanie i przetwarzanie danych

- Systemy rozmyte
- Data mining
- Sieci neuronowe
- Zbiory przybliżone
- Uczenie się ze wzmocnieniem

Podział funkcjonalny SI c.d.

Optymalizacja

- Strategie ewolucyjne
- Algorytmy genetyczne
- Symulowane wyżarzanie
- Przeszukiwanie tabu
- Systemy mrówkowe
- Optymalizacja rojem cząstek
- Programowanie ewolucyjne

Podział funkcjonalny SI c.d.

Modelowanie

- Systemy wieloagentowe
- Systemy rozmyte
- Programowanie genetyczne

Symulacja i prognozowanie

- Systemy wieloagentowe
- Symulacja zdarzeń nieciągłych

Sztuczna inteligencja -test Turinga

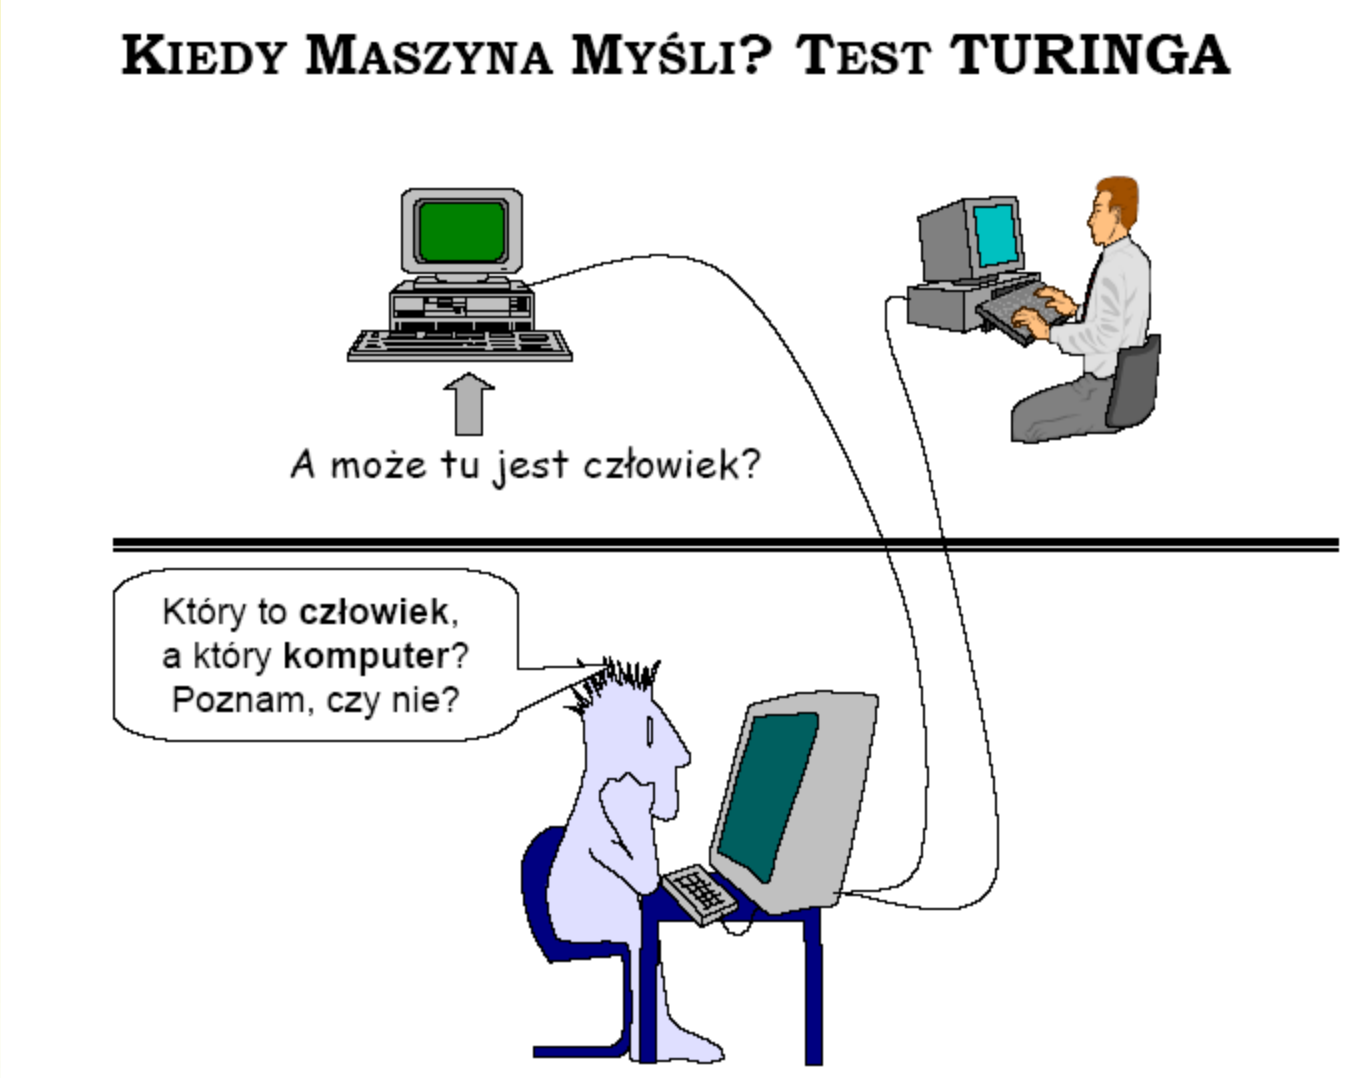

Przyszłość w 2020 r.

Media, telekomunikacja i technologie informacyjne połączą się ze sobą.

Komputery staną się niezbędnymi partnerami w podejmowaniu decyzji

Pierwsze serwery WWW 3D pokażą możliwości cyberprzestrzenii

Większość transakcji w elektronicznych sklepach i urzędach będzie się odbywać pomiędzy człowiekiem i awatarami lub pomiędzy samymi awatarami(wcieleniami)

Tradycyjne nauczanie zastępowane będzie automatycznym

Pojawią się pierwsze komercyjne roboty-służba domowa

A może będzie całkiem inaczej ...

Literatura

1. J. Chromiec, E. Strzemieczna, Sztuczna inteligencja. Podstawowe metody konstrukcji i analizy systemów eksperckich (Akademicka Oficyna Wydawnicza, Warszawa 1994)
2. E. Chwiałkowska, Sztuczna Inteligencja w Systemach Eksperckich (MIKOM 1991)
3. Z. Hippe, Zastosowanie metod sztucznej inteligencji w chemii (PWN, Warszawa 1993)
4. J. Mulawka, Sztuczna Inteligencja (1995)
5. M.J. Kasperski, Sztuczna Inteligencja. Droga do myślących maszyn. Helion 2003
6. A. Piegat, Modelowanie i sterowanie rozmyte, Exit 1999
7. J.Arabas, Wykłady z algorytmów ewolucyjnych, WNT 2004
8. Z.Michalewicz, Algorytmy genetyczne + struktury danych = programy ewolucyjne, WNT 1999
9. S.Osowski, Sieci neuronowe w ujęciu algorytmicznym, WNT 1996

Dziękuję za uwagę

jczerniak@ukw.edu.pl