

WPROWADZENIE DO MASZYNOWEGO UCZENIA SIĘ

1. Definicja procesu uczenia się
2. Przykłady problemów rozwiązywanych przez systemy uczące się
3. Motywacje dla budowy systemów uczących się
4. Taksonomia metod maszynowego uczenia się
5. Rodzaje nabywanej wiedzy
6. Przegląd zagadnień i kierunków maszynowego uczenia się
7. Rys historyczny
8. Przykłady zastosowań praktycznych.

Co to jest maszynowe uczenie się ?

Maszynowe uczenie się (ang. *Machine Learning*) jest analizą procesów uczenia się oraz tworzeniem systemów, które doskonalą swoje działanie na podstawie doświadczeń z przeszłości.

Wykład dotyczy dwóch grup metod :

- symbolicznego/indukcyjnego uczenia się na przykładach (ang. *symbolic/inductive learning*)
- sztucznych sieci neuronowych (ang. *artificial neural networks*)

Co to jest maszynowe uczenie się ?

Maszynowe uczenie się (ang. *Machine Learning*)

– część sztucznej inteligencji (AI) lub inteligencji obliczeniowej (Computational Intelligence - CI).

Systemy uczące się – systemy adaptujące się, zmieniające swoje wewnętrzne parametry tak, aby rozpoznać charakter danych.

Inspiracje: informatyka, statystyka, rozpoznawanie struktur (ang. pattern recognition), psychologia i kognitywistyka.

ML umożliwia pozyskiwanie wiedzy na podstawie analizy zachowań ekspertów lub danych doświadczalnych, tj. **przykładów uczących**.

Często dane są w postaci przykładów.

Eksperci opisują sytuacje podając przykłady.

Wiedza otrzymana metodami ML może być lepsza niż wiedza bezpośrednio wydedukowana przez ludzi.

Czasami jest jedyną drogą budowy modeli, jeśli wiedza nie jest znana lub nie można jej pozyskać.

Dlaczego Maszynowe Uczenie się ?

Aktualne systemy informacyjne nie posiadają zdolności samokorekcji prostych błędów

Rozwój systemów doradczych w wielu dziedzinach - nabywanie wiedzy dla systemów eksperckich czy systemów z bazą wiedzy

Poszukiwanie informacji w "powodzi" danych
- systemy odkryć wiedzy w bazach danych

Wzrost zastosowań techniki analizy danych, teorii decyzji, sztucznej inteligencji w wielu komercyjnych dziedzinach oraz sferze badawczej

Budowanie inteligentnych systemów wyszukiwania i udostępniania informacji (także Internet !)

Rozwój komputerowych systemów przetwarzania i rozpoznawania obrazów

Prace nad rozumieniem ludzkiej mowy i przetwarzaniem języka naturalnego

Zastosowania w robotyce i sterowaniu

Inteligentne systemy kompresji danych

Tworzenie inteligentnych systemów edukacyjnych

Postęp w budowie systemów współpracy człowiek - maszyna

Rozwój badań nad ludzkim poznawaniem i uczeniem się

Definicja Procesu Uczenia się

(Definicja #1)

"Uczenie się oznacza zmiany w systemie, które mają charakter adaptacyjny w tym sensie, że pozwalają systemowi wykonać za następnym razem takie same zadanie lub zadania podobne bardziej efektywnie"

- Herbert Simon (1983)

(Definicja #2)

"System uczący się wykorzystuje zewnętrzne dane empiryczne w celu tworzenia i aktualizacji podstaw dla udoskonalonego działania na podobnych danych w przyszłości oraz wyrażania tych podstaw w zrozumiałej i symbolicznej postaci"

- Donald Miche (1991)

(Definicja #3)

"Uczenie się to konstruowanie i zmiana reprezentacji doświadczanych faktów. W ocenie konstruowanych reprezentacji bierze się pod uwagę:

- 1. wiarygodność** - określa stopień w jakim reprezentacja odpowiada rzeczywistości,
- 2. efektywność** - charakteryzuje przydatność reprezentacji do osiągnięcia danego celu.
- 3. poziom abstrakcji** - odpowiada zakresowi szczególności i precyzji pojęć używanych w reprezentacji; określa on tzw. moc opisową reprezentacji.

Reprezentacja jest rozumiana jako np. opisy symboliczne, algorytmy, modele symulacyjne, plany obrazu."

- Ryszard Michalski (1986)

Wspólne pojęcia w kolejnych definicjach:

- Wejście: dane empiryczne
- Zmiany i poprawa działania (miara oceny)
- Postulat zdobywania wiedzy, reprezentowania jej wewnątrz systemu i stosowania do wykonywania zadania (nacisk na zrozumiałość reprezentacji)

Wiedza (ang. knowledge) - definiuje się w kontekście danej metody ; **reprezentacja wiedzy**.

Przykłady problemów rozwiązywanych przez systemy uczące się

- Uczenie się rozpoznawania mowy
- Uczenie się kierowania pojazdem (np. ALVINN)
- Uczenie się klasyfikacji obiektów astronomicznych (NASA Sky Survey)
- Uczenie się rozgrywania pewnych gier (np. backgammon)
- Uczenie się rozpoznawania chorób na podstawie symptomów
- Uczenie się rozpoznawanie pisma na podstawie przykładów
- Uczenie się klasyfikowania tekstów do grup tematycznych
- Uczenie się aproksymacji nieznanej funkcji na podstawie próbek
- Uczenie się odnajdowania drogi w nieznanym środowisku
- Automatyczne odkrywanie zależności funkcyjnych w danych
- Przewidywanie trendów w danych finansowych

Dobrze zdefiniowane problemy uczenia się,

Uczenie = doskonalenie działania dla pewnych zadań na podstawie doświadczenia

- **doskonalenie dla pewnej klasy zadań T,**
- **z uwagi na miarę oceny P,**
- **oparte na doświadczeniu E**

Proste przykłady

Qubic (4x4x4, Tic Tac Toe)

T: Gra Kółka przeciwko Krzyżykowi

P: % wygranych gier

E: Możliwość gry przeciwko dobremu graczowi przez ponad 100 godzin

Rozpoznawanie adresu napisanego na kopercie

T: Rozpoznanie adresu odbiorcy napisanego na kopercie

P: % sortowanych listów poprawnie przypisanych do miasta odbiorcy

E: 100 tysięcy ręcznie napisanych adresów ze znanym adresem przeznaczenia

Kierowanie pojazdu przez robota

T: Prowadzenie przez robota pojazdu po autostradzie

P: $\text{Prędkość} / [(1 + \text{liczba_wypadków})^{1000}]$

E: Duża liczba treningowych zdjęć z kamery, pomiarów z sensorów oraz równoczesnych rejestracji "komend" sterowania

Diagnostyka medyczna

T: Rozpoznanie pewnej choroby u pacjentów na podstawie symptomów

P: % poprawnie zdiagnozowanych pacjentów

E: Reprezentatywna liczba pacjentów opisanych za pomocą symptomów, dla których znana jest poprawna decyzja diagnostyczna

Ocena zainteresowania transportem lotniczym

- T: Predykcja liczby pasażerów linii lotniczych (dla następnych lat z rocznym wyprzedzeniem)
- P: Poprawność przewidywania liczby pasażerów
- E: Trzy podstawowe wskaźniki przewozowe za okres ostatnich 10 lat.

Rozpoznawanie mówcy na podstawie jego głosu

- T: Niezależna od tekstu identyfikacja mówcy na podstawie zapisu jego głosu
- P: % poprawnych rozpoznań mówców
- E: Duża liczba przebiegów czasowych z rejestracji 20 mówców wypowiadających po jednym zdaniu

Motywacje dla budowy systemów uczących się

Zadania eksploracji i analizy danych, gdzie duże rozmiary zbiorów danych uniemożliwiają ich analizę w sposób nieautomatyczny (np. ekonomiczne lub medyczne bazy danych)

Środowiska gdzie system musi się dynamicznie dostosowywać do zmieniających się warunków (np. systemy sterowania)

Problemy które są złożone, trudne do opisu i często nie posiadają wystarczających modeli teoretycznych albo ich uzyskanie jest bardzo kosztowne lub mało wiarygodne.

Realizacja procesu uczenia się

- Dobrze zdefiniowane zadanie.
- Wybrane miary oceny (jedno, dobrze zdefiniowane kryterium).
- Co jest doświadczeniem (przykładami)?
- Czego należy się nauczyć?
- Jak reprezentować przykłady uczące?
- Jak reprezentować hipotezy/wiedzę?
- Jaki algorytm uczenia należy wybrać ?

Różnice między uczeniem się ludzkim a maszynowym

Pytanie: Czy uczenie się maszyn przypomina uczenie się ludzi?

Odpowiedź: NIE

Ludzkie uczenie się:

Uczenie się człowieka jest to wprowadzanie zmian do sposobu pracy jego umysłu,

Uczenie się jest procesem pozyskiwania nowej informacji, w którym główną czynnością jest przyswajanie wiedzy,

Uczeniem można nazwać zdobywanie wprawy na drodze ponawiania prób z małym lub żadnym udziałem świadomości.

Oczekiwania i ograniczenia wobec uczących się

Oczekuje się, że systemy powinny uczyć się korzystając z wiedzy fragmentarycznej, doskonalić się w trakcie pracy, gromadzić doświadczenia, tworzyć nowe pojęcia, indukcyjnie wyciągać wnioski.

Oczekiwane zadania systemów:

- formułowanie nowych pojęć,
- wykrywanie nieznanymi prawidłowości w danych,
- tworzenie reguł decyzyjnych,
- przyswajanie nowych pojęć i struktur drogą uogólnienia i analogii,
- modyfikowanie, uogólnianie i precyzowanie danych,
- zdobywanie wiedzy poprzez kontakt z otoczeniem,
- generowanie wiedzy zrozumiałej dla człowieka,
- wiele innych.

Ograniczenia systemów uczących się

- Zależność i niezależność systemu od otoczenia,
- Wiarygodność i poprawność generowanych wniosków:

"wiedza zdobyta w wyniku obserwacji faktów ma charakter tylko domyslny" (Popper)

rozumowanie przez indukcję nie zapewnia zachowania "prawdy" (ang. truth preserving), - tzn. nie można w pełni udowodnić prawdziwości wiedzy tworzonej drogą uogólnienia, choć można dowieść jej błędności.

- problemy wynikające z:
 - wprowadzenia danych niekompletnych,
 - wprowadzenia danych częściowo sprzecznych,
 - niezdefiniowania ograniczeń dziedzinowych.

Postulaty:

- wszelka wiedza wygenerowana przez maszynę powinna być oceniana i/lub kontrolowana przez człowieka (lub wg. kryteriów przez niego zdefiniowanych),
- Systemy powinny być zdolne do udzielania wyjaśnień,
- tworzona wiedza powinna być wyrażana w formie odpowiadającej opisom przyjętym przez człowieka i jego modelom myślowym (postulat zrozumiałości).

Klasyfikacja metod maszynowego uczenia się

W ogólności system zmieniać się może w dwojaki sposób:

- system nabywa "nową wiedzę" z zewnętrznych źródeł,
- system modyfikuje się samodzielnie poprzez intensywne wykorzystywanie posiadanej już wiedzy w sposób bardziej efektywny.

Stąd typowe metody maszynowego uczenia się dzieli się na:

- indukcyjne uczenie się (ang. *inductive learning*),
- tzw. zdobywanie wprawy (ang. *skill acquisition*) lub przyspieszone uczenie się (ang. *speedup learning*)

Wnioskowanie Indukcyjne opiera się na zbiorze faktów (obserwacji) oraz ewentualnym zbiorze hipotez a priori dotyczących tych faktów, a w wyniku daje najprawdopodobniejsze uogólnienie wyjaśniające te fakty.

Dedukcja - wyprowadzanie wniosków, które są logiczną konsekwencją posiadanej informacji.

Główne pradygmaty badawcze obejmują:

- modelowanie sieci neuronowych i techniki teorio-decyzyjne,
- symboliczne przyswajanie pojęć,
- uczenie się w wąskiej dziedzinie z intensywnym wykorzystaniem wiedzy.

Podejścia różnią się pod względem:

- posiadanej przez system wiedzy a priori
- sposobu reprezentowania i modyfikowania wiedzy w systemie

Systemy sztucznych sieci neuronowych :

- system składa się z sieci wzajemnie powiązanych prostych elementów realizujących pewną funkcję przetwarzania,
- system uczy się przyrostowo poprzez modyfikacje połączeń między elementami
- system rozpoczyna uczenie się od niewielkiej wiedzy początkowej (związanej z wyborem elementów oraz struktury połączeń w sieci),
- charakterystyczne jest wykorzystanie parametrów zmieniających się w trakcie uczenia w sposób ciągły
- Numeryczny charakter: sygnałów wejściowych i przetwarzanych, metod i algorytmów uczenia się

Symboliczne przyswajanie pojęć

(ang. symbolic concept acquisition)

- systemy uczą się budując symboliczną reprezentację danego zbioru pojęć, drogą analizy przykładów i kontrprzykładów tych pojęć
- Tworzone reprezentacje mają postać np.:
 - wyrażen logicznych,
 - reguł produkcji
 - drzew decyzyjnych
 - sieci semantycznych
- charakterystyczna cecha - jakościowa/symboliczna postać przetwarzanej informacji

Uczenie się w wąskiej dziedzinie z intensywnym wykorzystaniem wiedzy

(ang. Knowledge intensive domain-specific learning)

- system zawiera liczne (zdefiniowane z góry) pojęcia, struktury wiedzy, ograniczenia dziedzinowe, reguły heurystyczne i wbudowane na stałe transformacje odnoszące się do konkretnej dziedziny,
- Nie wszystkie niezbędne atrybuty i pojęcia są znane - system ma wygenerować nowe pojęcia.

Strategię uczenia się

System uczący się transformuje informacje dostarczone przez nauczyciela na nową postać, którą zapamiętuje. Sposób tej transformacji określa typ użytej strategii:

Podstawowe strategie

- uczenie się na pamięć,
- uczenie się przez instrukcję,
- uczenie się przez dedukcję,
- uczenie się przez analogię,
- uczenie się przez indukcję.

Podział metod maszynowego uczenia się

Różne kryteria podziału.

Podstawowy podział ze względu na sposób reprezentacji wiedzy pozyskiwanej przez system uczący się. Wyróżnia się:

- metody zorientowane na jawną reprezentację wiedzy (ang. *knowledge oriented methods* lub *symbolic methods*),
- metody, które nie tworzą jawnej reprezentacji wiedzy, tzw. metody „nieprzezroczyste” (ang. *black-box methods* lub *sub-symbolic methods*).

Podział ze względu na rodzaj informacji dostarczony w zbiorze przykładów:

- **uczenie nadzorowane** (ang. *supervised learning*),
- **uczenie nienadzorowane** (ang. *unsupervised learning*).

Rozszerzenie podziału uwzględniające źródło przykładów:

- uczenie się na podstawie zapytań (system otrzymuje odpowiedzi na pytania zadane „nauczycielowi”),
- uczenie się przez eksperymentowanie (system gromadzi doświadczenie eksperymentując ze swoim środowiskiem),
- uczenie się ze wzmocnieniem (system wykonuje pewne akcje i otrzymuje ocenę swojego działania).

Uczenie się przez indukcję (ang. learning by induction/ inductive learning)

Prowadzi od oceny dostarczonych przykładów do ich uogólnienia (generalizacji) na drodze rozumowania indukcyjnego.

Obejmuje dwie grupy metod:

- uczenie się nadzorowane
- uczenie się nienadzorowane

Uczenie nadzorowane (ang. supervised learning) - system otrzymuje zbiór przykładów uczących (learning examples) w postaci (x_i, y_i) i ma na celu nauczyć się funkcji f , takiej że $f(x_i) = y_i$ dla każdego i .

Określona liczba wartości y_i - klasy (classes) lub klasy decyzyjne (decision classes).

Dla pojedynczych klas (odnoszących się do pewnych pojęć) - definiuje się przykłady pozytywne (odnoszące się do tej klasy) i negatywne (odnoszące się do innych klas).

Uczenie się pojęć (ang. concept learning) - f jest definicją/uogólnieniem pojęcia, które wyjaśnia przykłady pozytywne i wyklucza negatywne.

Reprezentacja przykładów uczących

Przykłady – zbiór obiektów, których dotyczy nabywana wiedza; mogą to być przedmioty, osoby, obserwacje, ...

Atrybuty to pewne cechy charakteryzujące właściwości rozważanych obiektów.

Zbiór przykładów (obiektów) U jest opisany za pomocą skończonego, niepustego zbioru atrybutów $A = \{a_1, a_2, \dots, a_m\}$ i reprezentowany jest w postaci **tablicy informacyjnej**

$$IT = (U, A).$$

V_a – dziedzina atrybutu $a \in A$;

$a(x) \in V_a$ wartość atrybutu.

Atrybuty:

- **nominalne**, których dziedziny są zbiorami nieuporządkowanymi (tzn. dla dwóch wartości możliwe jest określenie wyłącznie relacji „=” lub „≠”),
- **porządkowe**, których dziedziny są zbiorami uporządkowanymi (tzn. możliwe jest określenie relacji porządku liniowego „<” na zbiorze wartości),
- **liczbowe**, których dziedziny są zdefiniowane na liczbowych skalach pomiarowych (przedziałowych lub ilorazowych).

Reprezentacja w postaci tablic informacyjnych:

Tabela 1. Zbiór przykładów opisujących samochody za pomocą zbioru 4 atrybutów {*Typ samochodu, Cena, Prędkość, Zużycie paliwa*}; Pierwsza kolumna zawiera numer identyfikujący samochód.

<i>lp.</i>	<i>Typ</i>	<i>Cena</i>	<i>Prędkość</i>	<i>Zużycie</i>
1	mały	akceptowalna	przeciętny	małe
2	duży	akceptowalna	szybki	średnie
3	kompakt	drogi	szybki	średnie
4	duży	drogi	szybki	wysokie
5	mały	drogi	wolny	średnie
6	kompakt	akceptowalna	przeciętny	średnie
7	kompakt	drogi	wolny	średnie
8	duży	drogi	przeciętny	wysokie
9	duży	akceptowalna	przeciętny	średnie

Tabela 2 Zbiór przykładów uczących opisujących grupę osób, ubiegających się o kredyt; Pierwsza kolumna zawiera numer identyfikujący osobę.

<i>lp.</i>	<i>Wiek</i>	<i>Sytuacja zawodowa</i>	<i>Staż pracy</i>	<i>Dochody</i>	<i>Cel kredytu</i>	<i>Ocena klienta</i>
1	młody	uczy się	0	300	K	ryzyko
2	średni	pracuje	2	1500	S	ryzyko
3	młody	pracuje	4	2600	M	dobra
4	starszy	pracuje	16	2300	D	dobra
5	średni	pracuje	10	1900	M	przeciętne
6	młody	uczy się	0	700	W	ryzyko
7	średni	bezrobotny	0	200	D	ryzyko
8	młody	pracuje	3	1400	K	przeciętne
9	średni	pracuje	11	1400	D	dobra
10	starszy	emeryt	0	1100	D	przeciętne
11	młody	uczy się	0	1500	W	przeciętne
12	średni	pracuje	17	2500	S	przeciętne
13	młody	bezrobotny	0	300	D	ryzyko
14	starszy	pracuje	21	5000	S	dobra
15	młody	pracuje	5	3700	M	dobra

Uczenie się pojęć

Pojęcie (ang. *concept*) – ogólne określenie oznaczające zbiór obiektów posiadających wspólne właściwości, które odróżniają je od innych pojęć.

Pojęcie to jedna z postaci wiedzy o świecie, używana do opisywania systemów interpretowania obserwacji oraz abstrakcyjnych idei.

Przykłady:

Pojęcia krzesła, psa, liter alfabetu, ...

Pojęcia – pozwalają na klasyfikowanie pewnych obiektów na zbiory (kategorie / klasy).

Pojedyncze pojęcie wyznacza podział zbioru obiektów na **przykłady pozytywne** oraz **przykłady negatywne** (kontrprzykłady) tego pojęcia.

Pojęcia wielokrotne – klasyfikacja

Uczenie się pojęć, cd.

Przykład ilustracyjny opisu samochodów:

Rozważane pojęcie - „*samochód, którym chciałbym jeździ*”

Do przykładów tego pojęcia zaliczmy samochody {2,3,6,9}.

Kontrprzykładami, czyli przykładami negatywnymi tego pojęcia, są samochody {1,4,5,7,8}.

Wspólne właściwości definiujące pojęcie:

$(\text{zużycie}=\text{średni}) \wedge ((\text{cena}=\text{akceptowalna}) \vee (\text{prędkość}=\text{szybki}))$

Definicja znana „nauczycielowi” – niedostępna jawnie systemowi uczącemu się.

Cel: system w trakcie procesu uczenia się ma odkryć / znaleźć nieznaną mu definicję pojęcia na podstawie dostarczonych przykładów problemów kontrprzykładów tego pojęcia.

Klasyfikacja przykładów

Przykład może być zaliczony do więcej niż dwóch kategorii.

Def: **klasyfikacji obiektów** $K = \{K_j : j = 1, \dots, r\}$,
gdzie dla każdych $i \neq j$ $K_i \cap K_j = \emptyset$ oraz $\bigcup_{j=1}^r K_j = U$.

K_j jest **klasą** (klasą decyzyjną lub kategorią).

Określenie pojęć / klas decyzyjnych - podane przez nauczyciela lub za pomocą dodatkowego atrybutu (wartości są etykietami klas).

Tablica decyzyjna DT jest tablicą informacyjną

$$(U, A \cup \{d\}),$$

gdzie $d \notin A$ jest wyróżnionym **atrybutem decyzyjnym**.
Elementy zbioru A nazywane są **atrybutami warunkowymi**.

Klasyfikacja

Dwa znaczenia terminu klasyfikacja:

1. Proces podziału zbioru obiektów (przykładów) na klasy (kategorie, pojęcia), gdzie klasa oznacza zbiór obiektów charakteryzujących się pewnymi wspólnymi własnościami.
2. Zakładając, że struktura klas jest wstępnie znana, celem jest poszukiwanie funkcji/reguły która pozwala klasyfikować nowe obiekty, tj. przypisać je do istniejących kategorii.

Inne terminy:

1. taksonomia
2. analiza dyskryminacyjna

Uczenie nadzorowane

Przykład uczący - $\langle \mathbf{x}_A, c(x) \rangle$.

Wartości $c(x)$ zdefiniowane na skali liczbowej \rightarrow zadanie aproksymacji funkcji.

Wartości $c(x)$ etykiety pojęć lub klas \rightarrow uczenie się pojęć lub klasyfikacji.

Uczenie się pojęć

Na zbiorze przykładów U określony jest zbiór pojęć C .

Pojęcie (docelowe / ang. *target concept, target function*):

$$\text{funkcja } c : U \rightarrow \{0,1\}$$

Ogólniej jest to funkcja $c : U \rightarrow C$, $|C| > 2$

Hipoteza – funkcja h przypisująca przykłady do pojęcia lub klasy ($h: U \rightarrow C$).

H – przestrzeń hipotez; Zawiera wszystkie dopuszczalne hipotezy jakie może skonstruować system uczący.

System uczący się wybiera hipotezę $h \in H$, która jest możliwie najlepszym przybliżeniem pojęcia docelowego.

Dla każdego $x \in U$, $h(x) = c(x)$.

Uwaga: dokładne nauczenie się każdego pojęcia docelowego $c \in C$ jest możliwe tylko wtedy, gdy $C \subseteq H$

Terminologia związana z indukcyjnym uczeniem się

Dziedzina X

Przykład uczący $x \in X$

Atrybut a_i

Klasa, pojęcie docelowe $C_i \subseteq X$ $c: X \rightarrow \{0,1\}$

$$C_i = \{x \in X : c(x)=i\}$$

Przykład etykietowany dla uczenia z nadzorem $\langle x, c(x) \rangle$

Przykład pozytywny dla pojęcia c - taki $x \in X$ że $c(x)=1$

Przykład negatywny dla pojęcia c - taki $x \in X$ że $c(x)=0$

Hipoteza h - funkcja $f: X \rightarrow \{0,1\}$

Przestrzeń hipotez H

Zbiór uczący

Błąd stosowania hipotezy h dla zbioru treningowego D

Indukcyjne ukierunkowanie (*inductive bias*)

Typy nabywanej wiedzy

- reguły decyzyjne
- drzewa decyzyjne
- parametry w równaniach algebraicznych
- gramatyki formalne
- wyrażenia logiczne
- grafy i sieci semantyczne
- programy

Rys historyczny

Okres pionierski (lata 1950-65)

wczesne prace nad modelami neuronowymi
strategie ewolucyjne

"Wieki ciemne" (1962-75)

pozyskiwanie wiedzy (Feigenbaum)
krytyczna analiza systemów perceptronowych (Minski, Papert 1969)

Renesans (1976-1987)

uczenie się struktur symbolicznych
sukcesy praktyczne nowych systemów

- META-DENDRAL (Buchanan 1978)
- AQ (Michalski 1980)
- ID3 (Quinlan 1983)

rozwój systemów wykorzystujących i przekształcających wiedzę
powrót zainteresowania sieciami neuronowymi (Rumelhart 1986, Hopfield, ...)
pojawienie się wielu różnorodnych metod uczenia się
rozwój konferencji naukowych i czasopism

Stan obecny (1988- ...)

intensywne badania nad wieloma metodami
eksperymentalne badania porównawcze (Statlog)
rozwój metod nie-symbolicznych (sieci neuronowe, algorytmy ewolucyjne)
obliczeniowa teoria uczenia się (Valiant)
systemy zintegrowane i wielostrategiczne
nacisk na zastosowania praktyczne
odkrywanie wiedzy w bazach danych

