

AI: systemy uczące się

Systemy uczące się (SUS, uczenie maszynowe, machine learning) – dziedzina wiedzy łącząca sztuczną inteligencję, statystykę i rozpoznawanie obrazów, która obejmuje budowę i analizę sztucznych systemów zdolnych do uczenia się na podstawie danych.

Uczeniem się systemu jest każda autonomiczna zmiana w systemie zachodząca na podstawie doświadczeń, która prowadzi do poprawy jakości jego działania. Zmiana dotyczy „parametrów” systemu, które reprezentują wiedzę lub umiejętności systemu (inaczej jego hipotezę) i decydują o jego działaniu.

System uczący się (uczeń) – program komputerowy wykorzystujący pewien abstrakcyjny „parametryzowany” algorytm rozwiązujący pewien problem. Uczenie się polega na dobraniu na podstawie doświadczeń (informacji trenującej) odpowiednich „parametrów”.

Wiedza może być:

- deklaratywna (opisująca obiekty, sytuacje, związki)
- proceduralna (umiejętności; opisująca strategię osiągnięcia celów)

Przykład – reprezentacja wiedzy dot. kolejności liter

Podejście deklaratywne:

Fakty: A stoi przed B, B stoi przed C, C stoi przed D, ...

Reguła: Jeżeli (X stoi przed Y) i (Y stoi przed Z) to (X stoi przed Z)

Podejście proceduralne:

Procedura, która porównuje kolejność liter wykorzystując ich kody ASCII

Dla naprawdę złożonych zadań trudno jest sformułować wprost ustalone, pełne i poprawne algorytmy ich rozwiązywania. Złożone problemy są trudne do opisu, często nie posiadają wystarczających modeli teoretycznych albo ich uzyskanie jest bardzo kosztowne.

Środowisko lub warunki ulegają zmianie po uruchomieniu programu. Program powinien posiadać zdolność adaptacji.

Inteligentne systemy powinny być w maksymalnym stopniu autonomiczne, czyli zdolne do działania bez (zbyt dużej) ingerencji człowieka, co nie jest możliwe bez adaptacyjności, zdolności do przystosowywania się do zmieniających się środowisk i wymagań.

Często zbiory dostępnych danych są zbyt duże i skomplikowane, aby można było wyszukiwać w nich zależności, klasyfikować obiekty itd. niezautomatyzowany.

Systemy uczące się klasyfikuje się w zależności od:

- metody reprezentacji wiedzy,
- sposobu używania wiedzy,
- źródła i postaci informacji trenującej oraz
- mechanizmu nabywania i doskonalenia wiedzy.

Reprezentacja symboliczna – zorganizowane napisy, którym można przypisać interpretację

np. $A \wedge B \rightarrow C$

Reprezentacja subsymboliczna – np. zbiory liczb lub łańcuchów binarnych, które łącznie reprezentują pewną wiedzę, wyrażoną zwykle w postaci niezrozumiałej dla człowieka


np. 001010100100100100001010101...

Przykłady metod reprezentacji wiedzy:


- drzewa decyzyjne
- reguły: IF $a > 5$ AND $b = 1$ THEN $C = \text{true}$
- formuły logiki predykatów: $\neg(a \vee b) \equiv \neg a \wedge \neg b$
- rozkłady prawdopodobieństw
- automaty skończone

Sposób używania wiedzy zdeterminowany jest zadaniem stojącym przed systemem. Do najbardziej typowych zadań należą:

- klasyfikacja, uczenie się pojęć



- aproksymacja funkcji (regresja)




Gdy źródłem informacji trenującej jest „nauczyciel”, który podpowiada pożądaną odpowiedź systemu, mówimy o uczeniu nadzorowanym.


Zadanie SUS – poprawne (pożądane) odpowiedzi na informacje wejściowe (wektory wejściowe).

Proces uczenia polega na określeniu algorytmu generowania tych odpowiedzi.

Informacja trenująca instruuje ucznia, co do właściwego sposobu odpowiadania.



Gdy informacja trenująca jest niedostępna, mamy do czynienia z uczeniem bez nadzoru. Wtedy system uczy się właściwych odpowiedzi wyłącznie na podstawie informacji wejściowej. Przykładem uczenia bez nauczyciela jest grupowanie danych.



Inne metody uczenia:

- z wyrocznią (uczeń zadaje pytania)
- przez eksperymentowanie (np. obserwowanie konsekwencji generowania pewnych wyjść)
- ze wzmocnieniem (z krytykiem)

Mechanizm nabywania wiedzy ma najczęściej charakter indukcyjny – jednostkowa informacja trenująca jest generalizowana w celu uzyskania ogólnej wiedzy.

Indukcja – wnioskowanie, polegające na wyprowadzeniu ogólnych wniosków z przesłanek, które są poszczególnymi przypadkami tych wniosków. W naukach empirycznych metoda polegająca na wprowadzeniu uogólnień na podstawie eksperymentów i obserwacji faktów, formułowaniu i weryfikacji hipotez.

Strategie uczenia się można podzielić na:

- bezpośrednie zapisanie wiedzy
- pozyskiwanie wiedzy na podstawie instrukcji
- pozyskiwanie wiedzy na podstawie analogii
- pozyskiwanie wiedzy na podstawie przykładów
- Odkrycia w bazach danych (data mining)
- Inteligentne sterowanie
- Robotyka
- Inżynieria oprogramowania

- Diagnostyka medyczna i techniczna
- Klasyfikowanie dokumentów (selekcja stron www, identyfikacja spamu)
- Prognozowanie (pogody, giełdy, zapotrzebowania, ...)
- Rozpoznawanie obrazów (pisma, mowy, twarzy, genów, ...)
- Detekcja zdarzeń nietypowych
- Grupowanie obiektów (dokumentów, genów, ...)

Class-Specific Hough Forests for Object Detection



Each patch votes for the object centroid.

Votes from the three patches.

Hough image accumulates the votes from all patches.

Detection.


Human Pose Estimation using Body Parts Dependent Joint Regressors



Real-time Facial Feature Detection using Conditional Regression Forests




Learning Probabilistic Non-Linear Latent Variable Models for Tracking Complex Activities




Neural Network for Recognition of Handwritten Digits in C#




How I built a neural network controlled self-driving (RC) car! (<http://blog.davidsingleton.org/nrccar/>)




Learning to Prospectively Select Grasps (<http://www.cs.ou.edu/~fagg/research/robotics.html>)



Microarray data - supervised clustering of some of the 142 most significantly changed genes



Time Series Forecasting



Anomaly Detection and Localization in Crowded Scenes

