

Witold Kosiński

Polsko–Japońska Wyższa Szkoła Technik Komputerowych

Hung Son Nguyen

Marcin Szczuka

Instytut Matematyki Uniwersytetu Warszawskiego

E-mail: wkos@pjwstk.edu.pl, son@mimuw.edu.pl, szczuka@mimuw.edu.pl

Inteligencja obliczeniowa — elementy

Problemy trudne do modelowania w sposób ścisły, zagadnienia trudne do rozwiązania metodami analitycznymi, niealgorytmizowalne, problemy obliczalne, ale nieefektywnie algorytmizowalne wymagają użycia innych niż klasyczne metod obliczeniowych. Metod takich dostarcza rozwijany przez matematyków i informatyków nowy kierunek badań zwany **inteligencją obliczeniową**. Jej rozwój datuje się od lat 60-tych ubiegłego wieku. Systemy powstające w ramach inteligencji obliczeniowej mają często wspólną cechę: w przypadkach trudnych przetwarzają informacje do postaci algorytmów i czynią to w powiązaniu z symboliczną reprezentacją.

Celem wykładu jest przedstawienie wybranych problemów stawianych przed inteligencją obliczeniową (IO) oraz metod i narzędzi, którymi ona się posługuje. W trakcie wykładu szczególna uwaga będzie poświęcona następującym zagadnieniom:

- zagadnienia aproksymacji,
- wnioskowanie aproksymacyjne,
- optymalizacja.

Wiele problemów związanych z zagadnieniami inteligencji obliczeniowej można sprowadzić do zagadnienia *aproksymacji funkcji* zadanej w pewnej skończonej liczbie punktów. Często mamy w praktyce do czynienia z pewnym (zwykle ograniczonym) zbiorem punktów (obserwacji, eksperymentów, rekordów w bazie danych), z którymi są stowarzyszone odpowiadające im decyzje, akcje lub wyniki numeryczne. Naszym zadaniem jest skonstruowanie takiego modelu algorytmicznego, by dla nowych, wcześniej nie obserwowanych przypadków być w stanie podać właściwą akcję, odpowiedź, decyzję. W ujęciu matematycznym odpowiada to skonstruowaniu algorytmu realizującego przekształcenie, które musi być zgodne ze znanymi obserwacjami, a jednocześnie przedłużalne w sposób godny zaufania na resztę przestrzeni potencjalnych argumentów.

W dziedzinie inteligencji obliczeniowej zostało wypracowanych wiele metod, które pozwalają na radzenie sobie z trudnościami towarzyszącymi realizacji tego zadania. Wśród nich można wymienić takie podejścia jak sztuczne sieci neuronowe, nowoczesne techniki uczenia się statystycznego czy różnorodne podejścia wykorzystujące techniki wykrywania regularności w danych. Warto tu zaznaczyć, że o metodach wykorzystywanych w dziedzinie inteligencji obliczeniowej, na przykład sztucznych sieciach neuronowych, potrafimy w ścisły, matematyczny sposób udowodnić, że stanowią one bardzo silne schematy aproksymacyjne w zadaniach klasycznych. I tak, wspomniane wcześniej sieci neuronowe stanowią uniwersalne aproksymatory dla klasy $C[0, 1]$.

Zagadnienie aproksymacji funkcji dyskretnych z danych treningowych jest nazywane również *problemem uczenia się z przykładów*. Zapoznamy słuchaczy z obliczeniową

teorię uczenia się (COLT), w której rozpatrywane są problemy wyuczalności przestrzeni pojęć.

Istotną cechą wielu zaawansowanych systemów inteligentnych jest zdolność racjonalnego podejmowania decyzji. Niektóre proste problemy podejmowania decyzji można przedstawić jako wyżej przedstawione problemy aproksymacji funkcji z przestrzeni możliwych sytuacji w przestrzeń wartości decyzyjnych. Jednakże, do podejmowania skomplikowanych decyzji, zwłaszcza w warunkach niepewności lub niepełnej informacji, często musimy tworzyć system złożony z wielu prostszych komponentów aproksymujących, gdzie wykorzystane są pewne metody wnioskowania aproksymacyjnego, takie jak wnioskowanie w teorii zbiorów rozmytych lub przybliżonych. Zapoznamy słuchaczy z podstawami matematycznymi i przedstawimy niektóre typowe zastosowania tych metod.

W życiu codziennym często spotykamy się ze zjawiskami i pojęciami o charakterze wieloznacznym i nieprecyzyjnym. Dla posługiwania się nimi nie wystarcza klasyczna Boole'owska logika dwuwartościowa, ani trójwartościowa logika Łukasiewicza — potrzebna jest logika wielowartościowa. Jej obecnie najogólniejszym przypadkiem jest logika o ciągłych wartościach, utożsamianych z przedziałem $[0, 1]$, zwana *logiką rozmytą Zadeha*. Jej twórca wprowadził w 1965 r. pojęcie zbioru rozmytego, który jest scharakteryzowany przez tzw. funkcję przynależności, będącą rozszerzeniem klasycznej funkcji indykatorowej zbioru do wartości właśnie z przedziału $[0, 1]$. W wykładzie zajmiemy się krótką charakteryzacją zbiorów rozmytych, wnioskowania rozmytego, a także numerycznego posługiwania się liczbami niedokładnymi, zwanymi *skierowanymi liczbami rozmytymi*. Zostanie przedstawiona ich algebra, własności topologiczne, a także podstawowe twierdzenie o reprezentacji funkcjonałów nieliniowych ciągłych określonych na nich, a mających znaczenie dla operacji wyostrzania, tj. przypisywania liczbie rozmytej konkretnej, rzeczywistej wartości liczbowej. Operacje te są elementem sterowników rozmytych wykorzystujących rozmyte systemy wnioskujące (regułowe) do sterowania konkretnymi urządzeniami (typu pralki, szybkie japońskie koleje) czy procesami technologicznymi.

Metody analityczne dla zagadnień optymalizacji funkcji wielu zmiennych mają wtedy zastosowanie, gdy funkcja podlegająca optymalizacji, tj. funkcja celu, jest wystarczająco gładka, a liczba zmiennych nie jest zbyt duża. Skoro wiele problemów charakteryzuje się ogromną przestrzenią poszukiwań przy niegładkich funkcjach celu, to ani metody analityczne ani przeglądowe nie są efektywne; sięgamy wtedy po metody losowe. Wśród nich największą popularnością (i efektywnością) cieszą się *algorytmy ewolucyjne*. Stanowią one metodę wzorowaną na ewolucji naturalnej gatunków, w której są wykorzystywane procedury przeszukiwania przestrzeni oparte na doborze naturalnym osobników gatunku i dziedziczeniu, korzystające z ewolucyjnej zasady przeżycia osobników najlepiej przystosowanych. W algorytmach ewolucyjnych korzysta się z samej funkcji celu, a nie jej pochodnych, przeszukiwania prowadzi się wychodząc od pewnej populacji punktów, a reguły wyboru następnej populacji są probabilistyczne. W wykładzie zaznajomimy słuchaczy z podstawowymi terminami i metodami stosowanymi w klasycznych *algorytmach genetycznych*, które przeszukują dziedzinę problemu złożoną z zakodowanych w sposób binarny potencjalnych rozwiązań, a następnie z ich ogólnieniami.