

Inżynieria Mechatroniczna

Podstawy Sztucznej Inteligencji i Ucznienia Głębokiego:
1: Wprowadzenie, Optymalizacja

Ziemowit Dworakowski
 AGH w Krakowie

1

Zanim zaczniemy...

Prezentacje wykładowe (i wszystkie pozostałe materiały z przedmiotu) będą dostępne na mojej stronie 2 dni przed danym wykładem lub laboratorium:

<http://galaxy.agh.edu.pl/~zdw/students.html>

Sugeruję robienie notatek tylko dotyczących rzeczy których NIE MA na slajdach. Podczas wykładu warto się skupić na zrozumieniu pojęć i toku rozumowania, łatwiej o zapamiętanie treści, gdy zrozumiecie ogólną ideę.

Przedmiot rusza po raz pierwszy – więc traktujemy go eksperymentalnie. Informacja zwrotna od Was jest kluczowa, jeśli coś nie idzie tak jak powinno, nie czekajcie do końca przedmiotu, dajcie znać od razu

2





Dr hab. inż. Ziemowit Dworakowski, zdw@agh.edu.pl
 (koordynator kursu MEI)
 Konsultacje: D3, 4.17, wtorek, 9:00 – 11:00
 Zakres ekspertyzy:
AI, systemy decyzyjne, optymalizacja przetwarzanie sygnałów i obrazu

Dr inż. Krzysztof Holak, holak@agh.edu.pl
 (koordynator kursu IME)
 Konsultacje: Czwartek, 9:00– 11:00
 Zakres ekspertyzy:
Systemy wizyjne, przetwarzanie obrazów i filmów, signal processing

Mgr inż. Adam Machynia, machynia@agh.edu.pl
 Konsultacje: D3, 4.08, Czwartek, 10:00 – 11:30
 Zakres ekspertyzy:
AI, przetwarzanie obrazu, przetwarzanie sygnałów

Zespół

Prosimy o powiadomienie mailowe odpowiedniego prowadzącego przed konsultacjami

3

Po co jest ten przedmiot?

Pokażemy Wam, jak działają „metody AI”

Pokażemy Wam, jak „metody AI” działają w inżynierii

Nauczmy Was przetwarzania rzeczywistych zbiorów danych (w tym sygnałów czasowych i obrazów) z zastosowaniem uczenia maszynowego i AI

Pokażemy Wam nieco z aktualnego stanu wiedzy

Będziecie w stanie podjąć decyzję, czy temat jest interesujący i czy chcecie się nim zająć w przyszłości

Nauczmy Was sposobu myślenia, który pozwoli zrozumieć metody AI (również te dopiero powstające) ... i projektować swoje własne systemy decyzyjne

4

Jak zorganizowany jest przedmiot?

Mamy:

14 wykładów

13 laboratoriów

Optymalizacja

Uczenie maszynowe

Przetwarzanie obrazów

Metaparametry

Uczenie głębokie i zaawansowane AI

- ★ Testy
- ★ Poprawa testów / duży test
- ★ Odpowiedzi na pytania (możliwe zawsze, choć nieczęste)



5

OK, ale jak dostać zaliczenie?

- Trzeba zaliczyć wszystkie instrukcje (każda kończy się oceną)
- Trzeba zaliczyć wszystkie testy

Ocena końcowa = średnia wszystkich ocen

6

Laboratoria wykorzystują **odwroconą klasę**:

- Przygotowujecie się do zajęć w domu (Sugeruję wykonanie zadań oznaczonych „na 3.0”)
- Im więcej zadań ukończycie na laboratoriach – tym wyższą ocenę otrzymujecie
- Nie będzie konieczności pisania sprawozdań, pod warunkiem że wykonacie co najmniej zadania „na 3.0” w trakcie zajęć **oraz** wszystkie zadania oznaczone jako konieczne (*) podcza **następnych** zajęć.

(Szczegóły znajdują się w pierwszej instrukcji laboratoryjnej)

7

Co w przypadku nieprzewidzianych trudności?

Brak zaliczenia laboratorium (z powodu słabego przygotowania lub nieobecności) wymaga przygotowania standardowego raportu z kompletu zadań + jednego dodatkowego (wybranego przez nauczyciela). Można tak zrobić do trzech razy podczas semestru.

Na koniec semestru będzie możliwość poprawy dowolnych trzech (z sześciu) testów. Więcej braków będzie wymagało zaliczenia kolokwium z kompletu materiału z zajęć.

8

Czy w tym pokoju znajduje się stół?

Tzn. co z CzatemGPT (i wszystkimi innymi narzędziami GenAI)?

Co jest konieczne:

- Informacja o sposobie użycia AI – jeśli jej używacie (np. „raport przygotowany z zastosowaniem CzataGPT w celu...”)
- Branie odpowiedzialności za swoją pracę (tzn. jeśli używalicie genAI np. do przygotowania kodów, nadal musicie je rozumieć i być w stanie wyjaśnić – jakby były Wasze)

Co jest OK:

- Używanie GenAI do poprawiania błędów w kodach
- Używanie GenAI do przygotowywania fragmentów raportów z promptów – przy czym prompty należy zachować do wglądu na prośbę nauczyciela
- Używanie GenAI do poprawy pisowni

Czego nie można robić:

- Używać GenAI w jakiegokolwiek formie podczas zajęć, chyba, że nauczyciel wyraźnie wyrazi na to zgodę
- Używać GenAI do pisania i przepisywania kodów

Dlaczego?

Ponieważ instrukcje laboratoryjne już teraz zapewniają prawie-kompletne kody – a celem zajęć jest nauczenie Was o co w nich chodzi i jak ich używać.

9

Optymalizacja

10

Rzeczywisty problem

- Jak zarządzać linią lotniczą by zmaksymalizować zysk?
- Jak zaprojektować samochód, by był wytrzymały, ale tani i cichy?
- Jak spędzić czas na studiach w najszybszy sposób?

↓ Opis problemu

↓ Parametryzacja

Parametry

Informują: czym możemy „sterować”, na co mamy wpływ?

x_1
 x_2
 x_3
 x_4
...
 x_n

Które wartości parametrów są „najlepsze”?

Optymalizacja

Optymalizacja oznacza poszukiwanie globalnego optimum funkcji celu zdefiniowanej w przestrzeni parametrów

11

Jak odpowiadać na takie pytania?

Jakość
Wartość funkcji celu

Funkcja celu

Uprośćmy do wyłączenie jednego parametru: x_1

Wartość parametru

To jakoby przesuwając suwak, szukając najlepszego położenia...

Jeśli parametry są dwa... x_1 x_2

Po prostu pracujemy z dwoma suwakami

Wartość OF

Funkcja celu

Parametr 1

Parametr 2

12

Jak odpowiadać na takie pytania?

Jakość **Wartość funkcji celu** **Funkcja celu**

Uprośćmy do wyłącznie jednego parametru: x_1

Jeśli parametry są dwa... x_1 x_2

A jeśli jest więcej...? x_1 x_2 x_3 x_4 ...

Wartość parametru

To jakby przesuwac suwak, szukając najlepszego położenia...

Po prostu pracujemy z dwoma suwakami

Bez zmian! Nie będziemy jedynie w stanie zobaczyć funkcji, ale ona „nadal tam jest”!

13

Jak odpowiadać na takie pytania?

~~$f(p) \rightarrow \frac{df(p)}{dp}$~~

Poszukujemy ekstremum, gdzie pochodna się zeruje...

W typowych problemach nie znamy równania funkcji. Zatem jedynym sposobem na rozwiązanie problemu jest podejście metodą „prób i błędów”

14

Jak odpowiadać na takie pytania?

Generujemy kandydatów do sprawdzenia...

... losowo („random method“)

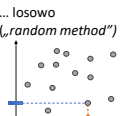
... lub w sposób zorganizowany (metoda „grid search“)

Generator p $f(p)$ Tester

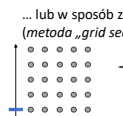
15


Jak odpowiadać na takie pytania?

... losowo („random method“)



... lub w sposób zorganizowany (metoda „grid search“)



 Działa dobrze, pod warunkiem, że nie ma zbyt wielu parametrów (Tylko kilka „suwaków“)

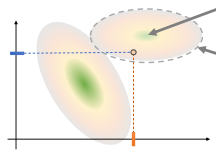
Zupełnie nie działa jeśli ilość parametrów jest duża (mniej więcej: większa niż 3)

Tutaj wykonaliśmy 25 „prób“ (5*5)

3D -> 125
4D -> 625
10D -> 9 765 625 prób...

16

Metoda 1+1



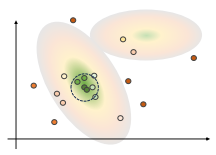
Taki punkt nazywany jest **lokalnym minimum funkcji celu** (to punkt, który ma najniższą wartość w swoim niezzerowym otoczeniu)

Ale jeśli zaczniemy optymalizację wewnątrz **obszaru przyciągania minimum lokalnego**, nie znajdziemy minimum globalnego!

Jak sobie poradzić z tym problemem?

17

Metoda 1+1



Algorytm:


```

Zaczynaj od losowo wygenerowanego kandydata  $p_c$ 
↓
Sprawdź jego wartość funkcji celu:  $f(p_c)$ 
↓
Jeśli jest jak do tej pory najlepsza, zachowaj ją:  $p_b = p_c$ 
↓
Wygeneruj nowego kandydata w sąsiedztwie zachowanego punktu:  $p_c = p_b + S \cdot r$ 
(S to wielkość sąsiedztwa, r to wektor losowy)
↓
* Jeśli progres się zatrzymał, zmniejsz S
* Jeśli S jest bardzo małe i progres się zatrzymał, zakończ optymalizację
    
```

- Dobra skalowalność w średnio-wysoką wymiarowość przestrzeni parametrów
- Relatywnie łatwa w konfiguracji
- Działa również w przypadku nieciągłej przestrzeni parametrów

18

Metoda gradientowa



Koncepcja:

Zacznijmy ponownie od dowolnego punktu
 ↓
 Sprawdźmy „teren dookoła” by ocenić gdzie funkcja opada najszybciej
 ↓
 Wykonajmy duży krok w kierunku największego spadku


*Będziemy podążać w stronę minimum przez cały czas – ale możemy też wokół niego oscylować...
 Więc ponownie możemy zredukować wielkość kroku w przypadku braku postępów!*

Możemy również poprawić metodę poprzez dodanie bezwładności (momentum) – by pozwolić jej „nabrać prędkości”

A ponieważ metoda również będzie przyciągana przez minima lokalne, możemy uruchomić ją kilkakrotnie (multistart)

19

Metoda gradientowa



Algorytm:

→ Zacznij od losowo wygenerowanego kandydata p_0
 ↓
 Wyznacz gradient funkcji celu wokół kandydata: $\nabla f(p_0)$
 ↓
 Wykonaj krok w kierunku największego spadku gradientu: $p_1 = p_0 - \epsilon \cdot \nabla f(p_0)$
 Ten punkt staje się nowym kandydatem: $p_1 \leftarrow p_0$
 ↓
 - W przypadku braku progresu zmniejsz ϵ
 - Powtarzaj określoną ilość iteracji lub aż do wyzerowania gradientu
 ↓
 (możesz rozpoznać metodę kilkakrotnie, zapisując najlepszy rezultat)

- Dobra skalowalność w przestrzenie wysoko-wymiarowe
- Łatwa w konfiguracji
- Wymaga ciągłej (różniczkowalnej) funkcji celu

20

Porada dnia

Wydaje się, że metoda gradientowa powinna być ZAWSZE uruchamiana w wersji wielostartowej. Ale okazuje się, że to nieprawda. W wielu praktycznych problemach optymalizacyjnych, im więcej parametrów mamy do dyspozycji, tym większa szansa, że minimum jest w rzeczywistości tylko jedno (lub jest ich wiele, ale wszystkie mają podobną głębokość) ...

Wyobraźmy sobie grupę ludzi wykonujących wspólnie duży projekt:



Im więcej ludzi, tym łatwiej rozdzielić pomiędzy nich zadania!

21

Reprezentacje wiedzy

22

Reprezentacja 1:

Wektor proporcji składników



x1 – ilość wody [litry]
x2 – ilość mąki [gramy]
x3 – drożdże [gramy]
x4 – nasiona [gramy]
...



Łatwiej tutaj zbudować „solver” i szybko dotrzemy do minimum. Ale minimum w tej uproszczonej reprezentacji wcale nie musi być optimum globalnym...

Mamy tu konfiguracyjną decyzję do podjęcia:
Im bardziej złożona i elastyczna reprezentacja, tym potencjalnie lepszy rezultat końcowy.
Ale odnalezienie go może być dużym wyzwaniem...

Reprezentacja 2:

Proces, z opisem działań i wejść



x1 – Akcja: dodać mąkę
x2 – Objętość: k gramów
x3 – Akcja: dodać drożdże
x4 – Objętość: k gramów
...



Mamy tu bardzo wiele złożonych parametrów. Proces optymalizacji może się zapętlić, być przyciągany przez minima lokalne... Być może nie osiągniemy w ogóle żadnego minimum...

23

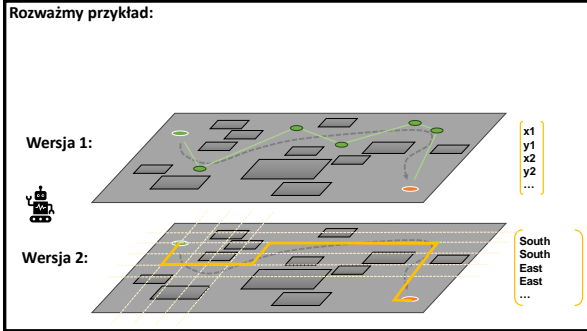
Projekt reprezentacji w praktyce:

Warto rozważyć:

- **Nad czym właściwie mamy kontrolę?**
(Nie zajmujemy się zmiennymi, których nie można kontrolować)
- **Co nam mówi ekspercka wiedza kontekstowa?**
(W większości typowych zastosowań można znaleźć kogoś, kto potrafi przynajmniej zasugerować właściwy tok postępowania)
- **Jak dużo czasu i zasobów jesteśmy w stanie przeznaczyć na zadanie?**
(im mniej danych (pomiarów, symulacji) i czasu, tym prostsza musi być reprezentacja)
- **Jak trudno wykonać test wartości funkcji celu?**
(czyli: ile czasu zajmuje przejście od wartości parametrów do uzyskania odpowiadającej im wartości funkcji celu?)

24

Rozważmy przykład:



25

Funkcja celu może być:

- Jednokryterialna lub wielokryterialna




To oznacza, że mamy więcej niż jeden cel optymalizacji
(np.: zaprojektować samochód tak tani, jak to możliwe,
ale tak bezpieczny, jak to możliwe)

1) Możemy skleić wszystkie kryteria
w jedno używając średniej ważonej

2) Możemy zastosować
Front Pareto

$$Q = W_1 \cdot \frac{1}{C} + W_2 \cdot \frac{1}{S}$$



Tzn. szukamy zbioru różnych rozwiązań
a potem porównujemy je ze sobą
odrzucając obiektywnie gorsze (pod
względem wszystkich kryteriów)

26

Funkcja celu może być:

- Jednokryterialna lub wielokryterialna
- Ciągła (różniczkowalna) lub dyskretna



To oznacza, że wartości parametrów mogą być zmieniane z
dowolną dokładnością (np. możemy zmienić szerokość karoserii
samochodu z dowolną dokładnością, ale nie możemy dodać 2/3
fotela do auta)

Dyskretna przestrzeń parametrów oznacza, że nie możemy
zastosować metody gradientowej

27

Funkcja celu może być:

- Jednokryterialna lub wielokryterialna
- Ciągła (różniczkowalna) lub dyskretna
- Z ograniczeniami lub bez ograniczeń

↓

To oznacza, że wszystkie wartości parametrów są dopuszczalne

↓

To oznacza, że istnieją pewne dodatkowe warunki, które trzeba spełnić – np. projektując trajektorię nie możemy legalnie znaleźć się na autostradzie na rowerze lub na chodniku jadąc samochodem

Możemy albo zbudować reprezentację uniemożliwiającą wybór „nielegalnych” rozwiązań albo „ulegalniać” je już po odnalezieniu

28

Powtórka:

1. Podaj definicję optymalizacji i jej praktyczne przykłady (w tym: optymalizację z ograniczeniami, wielokryterialną, dyskretną lub ciągłą, itd.)
2. Wyjaśnij dlaczego wybór reprezentacji i poprawna parametryzacja są istotne – i jakie ryzyka są związane z tym krokiem
3. Wyjaśnij zasadę działania algorytmów losowego i *grid search*
4. Wyjaśnij zasadę działania, zalety, podaj algorytm i zilustruj algorytm 1+1
5. Wyjaśnij zasadę działania, zalety, podaj algorytm i zilustruj algorytm gradientowy
6. Czym są minima lokalne i jak możemy sobie z nimi poradzić w optymalizacji?

29
