

Wśród studentów panuje przekonanie, że na egzaminie dyplomowym pytają o tematy związane z ekspertyzą komisji. Do tego, ja uważam, że warto powtórzyć podstawy teoretyczne związane z tematem pracy, czyli w moim przypadku programowanie niskopoziomowe.

Komisja:

- prof. UAM dr hab. Tomasz Górecki - *Statystyka i nauczanie maszynowe*
- prof. UAM dr hab. Jacek Marciniak - *Sztuczna inteligencja, APO*
- dr. Tomasz Kowalski - *Sztuczna inteligencja*

1 Programowanie niskopoziomowe

1.1 Język maszynowy oraz języki wyższego rzędu. Kompilacja, interpretacja i konsolidacja programu

- W architekturze von Neumanna zakładamy, że komputer składa się z części:
 - procesora - wykonuje instrukcje
 - pamięci - przechowuje dane i instrukcje
 - wejścia/wyjścia - umożliwia komunikację z zewnątrz
- Język maszynowy to język, który umożliwia wydawanie instrukcji procesorowi
 - Każdy procesor ma swój zestaw rozpoznawanych instrukcji
 - Logicznie te instrukcje można pisać w postaci kodu "Assembly"
 - Każda instrukcja ma swój kod binarny
 - W cyklu procesor czyta instrukcje, dekoduje ją, wykonuje i zwraca wynik
- Języki wyższego rzędu to języki, które pozwalają na bardziej abstrakcyjne i wygodniejsze reprezentowanie logiki
- Przy pomocy kompilatora programy są przetwarzane na język maszynowy
 - Kompilator najpierw przetwarza kod źródłowy na jakąś reprezentację wewnętrzną
 - Reprezentacja wewnętrzna pozwala na podstawowe optymalizacje
 - Następnie przetwarza tą reprezentację wewnętrzną na język maszynowy
 - Wyjściem kompilatora są pliki obiektowe, zawierają one kod maszynowy, lecz mogą mieć wywołania do brakujących funkcji lub adresów
 - Język maszynowy składa się z sekcji; tekstu, dane i stosu
- Interpreter to program, który wykonuje programy w języku wyższego rzędu bez konieczności konwersji na język maszynowy
- Konsolidator to program, który łączy programy w jeden plik wykonywalny
 - Konsolidator zazwyczaj jest częścią kompilatora
 - Mając kilka plików obiektowych łączy je w jeden plik wykonywalny
 - W zależności od wymogów, koniecznym może być budowanie nowej przestrzeni nazw dla funkcji i zmiennych
 - Zazwyczaj konsolidator potrafi łączyć pliki obiektowe w inne pliki obiektowe, budując nową przestrzeń adresową

1.2 Pojęcie funkcji; przekazywanie parametrów i zwracanie wyniku. Czas życia i zakres ważności nazwy

- Funkcja to tylko miejsce w kodzie maszynowym, które może być wywołane przez inne miejsca w kodzie maszynowym
- Każdy język wyższego poziomu określa jeden sposób, w którym argumenty są przekazywane do funkcji
- Zazwyczaj w momencie wywołania funkcji, funkcja rezerwuje sobie przestrzeń na stosie, aby przechowywać lokalne zmienne i parametry funkcji
- Konkretnie miejsce przechowywania parametrów i zwracanej wartości to kwestia konwencji

1.3 Zarządzanie pamięcią. Wskaźniki, referencje i dereferencje. Dynamiczna alokacja pamięci, sarta

- Pamięć jest adresowana przez liczby całkowite
- Adresy fizycznej pamięci są adresowane ciągle i zarządza nią system operacyjny
- We współczesnych systemach operacyjnych pamięć jest adresowana przez wirtualne adresy, które są przekształcane na fizyczne przez mechanizm adresowania pamięci
- Wirtualne adresy nie muszą być ciągłe i nawet nie muszą mieć w danym momencie przypisanego fizycznego miejsca w pamięci
- W ten sposób do procesu mogą być dołączane strony pamięci, bez konieczności przerywania działania procesu
- Typowo alokator pilnuje podpiętej pamięci dynamicznej (heap), a w przypadku braku pamięci prosi system operacyjny o dodatkową pamięć

2 Systemy operacyjne

2.1 Systemy plików (atrybuty pliku, katalogi, dowiązania twarde i symboliczne).

2.2 Współbieżność, synchronizacja procesów: semaforey, semaforey binarne, monitory, problemy współbieżności (sekcja krytyczna, producent/konsument, czytelnicy i pisarze, n-filozofów)

- Poprzez odpowiednio szybkie zmienianie kontekstu procesora, można zapewnić praktycznie równoczesne wykonywanie zadań
- Logicznie jednak konieczne jest prawidłowe zarządzanie dostępem do zasobów współdzielonych
- Krytyczną sekcją nazywamy fragment kodu, który jest wykonywany przez więcej niż jeden proces, a dostęp do zasobów współdzielonych jest współbieżny
- W celu synchronizacji procesów istnieje wiele narzędzi, najprostszym jest semafor binarny w współdzielonej pamięci
- Zakleszczeniem jest sytuacja, w której n procesów nie może osiągnąć współbieżnego dostępu do zasobu, na skutek działania innych procesów.

3 Sztuczna Inteligencja

3.1 Czym jest sztuczna inteligencja. Sposoby definiowania sztucznej inteligencji. Test Turinga.

- Sztuczna inteligencja to zdolność komputera do wykonywania zadań, które wymagają inteligencji ludzkich. To znaczy, że sztuczna inteligencja jako dziedzina jest de facto rozbita na wiele poddziedzin, każda skupiona na konkretnym problemie; np.:

- rozumowanie
 - rozwiązywanie problemów
 - wnioskowanie
 - uczenie maszynowe
 - ...
- Zwyczajowo kategoryzujemy systemy sztucznej inteligencji w zależności od tego jak myślą i się zachowują. Systemy typu LLM docelowo mają myśleć i zachowywać się jak ludzie. Z kolei systemy szachowe wręcz przeciwnie.
 - Test Turinga miał docelowo sprawdzić, czy maszyna jest inteligentna czy nie, poprzez interakcję z człowiekiem.

3.2 Przeszukiwanie przestrzeni stanów. Wybrane algorytmy. Heurystyki.

- Poprzez zdefiniowanie dla problemu pewnej konkretnej przestrzeni stanów, a w niej kilka stanów początkowych i końcowych, możemy rozwiązać problem poprzez przeszukiwanie przestrzeni stanów
- Klasycznie przestrzeń stanów można zwiedzać przy pomocy algorytmów takich jak BFS, DFS, oraz algorytmu Dijkstry.
- W rozwiązywaniu takiego problemu szczególnie przydatne są heurystyki, które pozwalają poprawić efektywność przeszukiwania przestrzeni stanów w średnim przypadku.
- Dokładnie heurystyka to spekulatywny formalizm, którego nie da się udowodnić, lecz jest przydatny

3.3 Uczenie maszynowe. Regresja liniowa i logistyczna. Wykorzystanie sztucznych sieci neuronowych w sztucznej inteligencji.

- Nauczanie maszynowe to dziedzina sztucznej inteligencji, która skupia się na tworzeniu algorytmów, które mogą uczyć się z danych i wykonywać zadania, które są zazwyczaj wykonywane przez ludzi.
- Klasycznym przykładem zadania dla nauczania maszynowego jest klasyfikacja lub regresja
- Najprostszą metodą uczenia maszynowego jest dopasowanie parametrów pewnej funkcji pierwotnej, która opisuje zależność między zmiennymi, do danych. Przykładem takiej metodologii jest regresja liniowa lub logistyczna.
- Poprzez optymalizację matematyczną możemy znaleźć najlepsze parametry funkcji pierwotnej, które minimalizują funkcję błędu.
- Sieć neuronowa to wielokrotne złożenie funkcji liniowej
- Backpropagation, to zastosowanie reguły łańcuchowej do obliczania gradientu funkcji błędu, co umożliwia zastosowanie standardowych metod optymalizacji do trenowania sieci neuronowych.

4 Statystyka

4.1 Model jednej próby prostej. Rozkłady teoretyczne. Parametry modelu. Estymatory nieobciążone. Metoda największej wiarygodności.

- Model jednej próby prostej, to model statystyczny, w którym zakładamy, że obserwacja to losowa zmienna, niezależna od innych obserwacji, pochodząca z pewnego rozkładu teoretycznego
- Rozkłady teoretyczne to modele matematyczne, które opisują prawdopodobieństwo wystąpienia różnych wartości losowej zmiennej
- Modele teoretyczne mają parametry, które określają kształt rozkładu.
Na przykład, rozkład Bernoulliego ma jeden parametr p , który określa prawdopodobieństwo sukcesu.

- Estymator to funkcja, która na podstawie próby danych szacuje wartość parametru rozkładu teoretycznego *Chcemy wnioskować cechy populacji na podstawie próby, na przykład średnią*
- Nieobciążony estymator to taki, którego wartość oczekiwana jest równa rzeczywistej wartości parametru *Nieobciążony estymator, średnio po wielu próbach da prawidłową wartość*
- Metoda największej wiarygodności to metoda estymacji parametrów, która polega na znalezieniu takich wartości parametrów, które maksymalizują funkcję wiarygodności *Optymalizujemy parametry zakładanego rozkładu, tak aby prawdopodobieństwo uzyskania danych było jak największe*

4.2 Przedziały ufności. Konstrukcja dokładnych przedziałów ufności. Przybliżone przedziały ufności - metoda bootstrapowa.

- Przedział ufności to przedział, który z określonym poziomem ufności zawiera prawdziwą wartość parametru populacji *Dla danego estymatora, możemy powiedzieć z jaką pewnością uzyska wartość w danym zakresie*
- Dokładne przedziały ufności można skonstruować, korzystając z rozkładów statystycznych i właściwości estymatorów
- Metoda bootstrapowa to metoda przybliżonego konstruowania przedziałów ufności. Polega ona na zamienieniu estymatora w próbę;
 1. Zakładamy, że próba danych jest reprezentatywna
 2. Z oryginalnej próby losujemy z powtórzeniami B nowych prób
 3. Dla każdej z prób obliczamy estymator
 4. Analizujemy rozkład wartości estymatorów

Przy braku danych, symulujemy wiele próbek i patrzymy jak się zachowuje estymator

4.3 Testy statystyczne. Konstrukcja testów statystycznych. Hipotezy, poziom istotności testu, p-wartość

- Test statystyczny to procedura, która pozwala na podjęcie decyzji dotyczącej hipotezy statystycznej na podstawie danych z próby *Bierzemy jakąś statystykę (wzór) i sprawdzamy jak się zachowuje na zbiorze danych*
- Hipoteza zerowa to założenie, które testujemy, natomiast hipoteza alternatywna to założenie przeciwne *Wiążemy jakąś hipotezę z zachowaniem wcześniej zdefiniowanej statystyki*
- Poziom istotności testu (α) to maksymalne prawdopodobieństwo popełnienia błędu pierwszego rodzaju, czyli odrzucenia hipotezy zerowej, gdy jest ona prawdziwa *Zakładamy, że 5% czasu możemy błędnie odrzucić hipotezę zerową*
- P-wartość to prawdopodobieństwo uzyskania wyniku testu tak ekstremalnego jak obserwowany, zakładając, że hipoteza zerowa jest prawdziwa. *Mierzymy jak bardzo "ekstremalne" są nasze dane w stosunku do hipotezy zerowej*
- P-wartość mierzy odchylenie od hipotezy zerowej *Jeśli wynik jest mało ekstremalny, to hipoteza zerowa jest prawdopodobnie prawdziwa*
- Jeśli p-wartość jest mniejsza niż poziom istotności, to odrzucamy hipotezę zerową $p < \alpha \rightarrow$ *odrzucaamy H_0*
- Błąd pierwszego rodzaju (α) to odrzucenie prawdziwej hipotezy zerowej *Fałszywe pozytywne*
- Błąd drugiego rodzaju (β) to nieodrzućenie fałszywej hipotezy zerowej *Fałszywe negatywne*