

# Programowanie Współbieżne

Algorytmy

# Sortowanie przez scalanie (mergesort)

Algorytm :

1. **JEŚLI** jesteś rootem **TO**: pobierz/wczytaj tablice do posortowania

**JEŚLI\_NIE** to pobierz tablicę do posortowania od rodzica

# Sortowanie przez scalanie (mergesort)

2. **JEŚLI** ilość elementów tablicy  $> 2$  i (ilość procesów  $< \max$  procesów) [tu można dodać czy tablica nie jest już posortowana lub inny warunek zatrzymania dzielenia] **TO**


- twórz 2 procesy i wyślij im po jednej części tablicy (najlepiej w miarę równe).
- czekaj na posortowane 2 tablice
- scal w jedną posortowaną

**JEŚLI\_NIE** to posortuj to co masz. (w szczególnym przypadku będzie to 1 liczba do oddania lub dwie do porównania).


# Sortowanie przez scalanie (mergesort)

3. **JEŚLI** jesteś rootem **TO** wyświetl/zapisz wynik  
**JEŚLI\_NIE** to odeślij rodzicowi posortowaną tablicę.

# Sortowanie przez scalanie



# Sortowanie przez scalanie




# Sortowanie oscylacyjne

Dla ciągu długości  $n$  tworzymy dwa zestawy procesów.

$A_1, A_2, \dots, A_n$

$B_0, B_1, \dots, B_n$



# Sortowanie oscylacyjne

Zadania typu  $A_i$  działają następująco:

- otrzymują 2 liczby
- mniejszą przesyłają do  $B_{i-1}$
- większą do  $B_i$ .


# Sortowanie oscylacyjne

Zadania typu  $B_i$  działają następująco:


- otrzymują 2 liczby
- mniejszą przesyłają do  $A_i$
- większa do  $A_{i+1}$

Elementy skrajne nic nie robią tylko oddają liczbę  
Po  **$2n$**  cyklach mamy gotowy wynik


# Sortowanie oscylacyjne




# Sortowanie oscylacyjne




# Sortowanie oscylacyjne




# Sortowanie oscylacyjne



# Sortowanie oscylacyjne



# Sortowanie oscylacyjne



# Mnożenie macierzy

## Zastosowanie:

- w matematyce, rozwiązywanie układów równań liniowych Metodą Gaussa
- Zapisanie obiektów geometrycznych w przestrzeni liniowej w fizyce tzw. Tensory
- Grafika trójwymiarowa, transformacje

# Mnożenie macierzy

## Definicja

Iloczynem macierzy  $\mathbf{A}=[a_{ij}]_{n \times p}$  przez macierz  $\mathbf{B}=[b_{ij}]_{p \times m}$  nazywamy taką macierz  $\mathbf{C}=[c_{ij}]_{n \times m}$  piszemy  $\mathbf{C}=\mathbf{A} \cdot \mathbf{B}$ , że

$$c_{ij} = \sum_{k=1}^p a_{ik} \cdot b_{kj} \quad \text{dla } i=1,2,\dots,n; j=1,2,\dots,m$$

# Mnożenie macierzy

$$\begin{array}{c}
 A \in M_{m \times k} \qquad B \in M_{k \times n} \qquad C \in M_{m \times n} \\
 \left( \begin{array}{cccc} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & a_{2k} \\ \dots & & & \\ a_{m1} & a_{m2} & \dots & a_{mk} \end{array} \right) \cdot \left( \begin{array}{c|ccc} b_{11} & b_{12} & \dots & b_{1n} \\ b_{21} & b_{22} & \dots & b_{2n} \\ \dots & & & \\ b_{k1} & b_{k2} & \dots & b_{kn} \end{array} \right) = \left( \begin{array}{cccc} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ \dots & & & \\ c_{m1} & c_{m2} & \dots & c_{mn} \end{array} \right) \\
 [a_{11} \ a_{12} \ \dots \ a_{1k}] \begin{bmatrix} b_{11} \\ b_{21} \\ \dots \\ b_{k1} \end{bmatrix} = c_{11}
 \end{array}$$

# Mnożenie macierzy

Kilka przydatnych właściwości:

*Jeżeli  $A, B$  oraz  $C$  są macierzami o odpowiednich wymiarach to:*

1.  $A(BC) = (AB)C$
2.  $(AB) = (A)B$
3.  $(A+B)C = AC + BC$
4.  $C(A+B) = CA + CB$
5.  $IA = A$ , gdy  $A_{n \times n}$  i  $I_{n \times n}$

# Mnożenie macierzy

## Algorytm „dziel i rządź”

Uzyskanie macierzy **C** jest wynikiem niezależnych operacji arytmetycznych na wierszach macierzy **A** i kolumnach **B**. Stąd intuicyjny sposób podziału zadania na wiele wątków, tak by każdy obliczył niezależnie element macierzy **C**. Takich podziałów w tym wypadku musi być  $m * n$  (liczba wątków). Koszt operacji wynosi  $O(n^3)$ .


# Mnożenie macierzy

Każdy element  $A_{ij}$   $B_{jk}$   $C_{ik}$  to mała podmacierz na której wykonujemy takie same operacje jak na pojedynczych elementach.

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \quad B = \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} \quad C = \begin{bmatrix} C_{11} & C_{12} \\ C_{21} & C_{22} \end{bmatrix}$$

# Mnożenie macierzy

Przykład:

$$\begin{bmatrix} 0 & 1 & 2 & 3 \\ 1 & 4 & 1 & 2 \\ 0 & 2 & 2 & 1 \\ 1 & 2 & 1 & 2 \end{bmatrix} \cdot \begin{bmatrix} 0 & 1 & 2 & 0 \\ 2 & 3 & 1 & 2 \\ 1 & 1 & 2 & 3 \\ 0 & 1 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 4 & 8 & 5 & 11 \\ 9 & 16 & 8 & 13 \\ 6 & 9 & 6 & 11 \\ 5 & 10 & 6 & 9 \end{bmatrix}$$


Takie mnożenie można rozbić na 4 działania analogiczne do poniższego

$$\begin{bmatrix} 0 & 1 \\ 1 & 4 \end{bmatrix} \cdot \begin{bmatrix} 0 & 1 \\ 2 & 3 \end{bmatrix} + \begin{bmatrix} 2 & 3 \\ 1 & 2 \end{bmatrix} \cdot \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 2 & 3 \\ 8 & 13 \end{bmatrix} + \begin{bmatrix} 2 & 5 \\ 1 & 3 \end{bmatrix} = \begin{bmatrix} 4 & 8 \\ 9 & 16 \end{bmatrix}$$

# Mnożenie macierzy

## Metoda „Strassena”

- Z tak podzielonej macierzy wylicz 7 pomocniczych macierzy  $m_i$  o rozmiarze  $n/2$

$$m_1 = (A_{12} - A_{22}) * (B_{21} + B_{22})$$

$$m_2 = (A_{11} + A_{22}) * (B_{11} + B_{22})$$

$$m_3 = (A_{11} - A_{21}) * (B_{11} + B_{12})$$

$$m_4 = (A_{11} + A_{12}) * B_{22}$$

$$m_5 = A_{11} * (B_{12} - B_{22})$$

$$m_6 = A_{22} * (B_{21} - B_{11})$$

$$m_7 = (A_{21} + A_{22}) * B_{11}$$

# Mnożenie macierzy

Oblicz składowe  $C_{ij}$  macierzy wynikowej  $C$

$$C_{11} = m_1 + m_2 - m_4 + m_6$$

$$C_{12} = m_4 + m_5$$

$$C_{21} = m_6 + m_7$$

$$C_{22} = m_2 - m_3 + m_5 - m_7$$

Koszt powyższego algorytmu szacuje się na  $O(n^{\log_2 7})$

# Mnożenie macierzy

## Algorytm „canona”

- Zakładamy że mamy sieć zadań  $m \times m$ .
- Każdy proces ( $t_{ij}$  gdzie  $0 < i, j < m$ ) wewnątrz zawiera bloki  $C_{ij}$ ,  $A_{ij}$  i  $B_{ij}$ .
- Na wstępie algorytmu proces na przekątnej diagonalnej ( $t_{ij}$  gdzie  $i=j$ ) przesyła swój blok  $A_{ii}$  do wszystkich innych procesów w rzędzie  $i$ .
- Po transmisji  $A_{ii}$ , wszystkie zadania obliczają  $A_{ii} \times B_{ij}$  i dodają wynik do  $C_{ij}$ .
- W kolejnym kroku kolumna bloków macierzy  $B$  jest obracana. Tzn.  $t_{ij}$  przesyła swój blok  $t_{(i-1)j}$ . Proces  $t_{0j}$  przesyła swój blok  $B$  do  $t_{(m-1)j}$ .

# Mnożenie macierzy


- Teraz procesy powracają do kroku pierwszego.
- $A_{i(i+1)}$  jest podstawową informacją dla wszystkich innych procesów w rzędzie  $i$ .
- Algorytm jest dalej kontynuowany. Po  $m$  iteracjach macierz  $C$  zawiera wynik mnożenia  $AxB$ , a obracana macierz  $B$  przyjmuje swoją początkową postać.

# Mnożenie macierzy

$$\begin{matrix} & A & & B & & C \\ \begin{bmatrix} 0 & 1 & 2 \\ 1 & 0 & 3 \\ 2 & 2 & 1 \end{bmatrix} & \cdot & \begin{bmatrix} 1 & 1 & 3 \\ 0 & 1 & 2 \\ 2 & 3 & 0 \end{bmatrix} & = & \begin{bmatrix} 4 & 7 & 2 \\ 7 & 10 & 3 \\ 4 & 7 & 10 \end{bmatrix} \end{matrix}$$

|   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|
| 0 | 1 | 0 | 1 | 1 | 0 | 2 | 3 | 0 |
| 1 | 0 | 0 | 0 | 1 | 0 | 3 | 2 | 0 |
| 2 | 2 | 0 | 2 | 3 | 0 | 1 | 0 | 0 |

# Mnożenie macierzy




Z macierzy A bierzemy wartości leżące na diagonalnej

Przysyłamy do sąsiadów w tym samym wierszu.


Mnożymy wartości przesyłane z wartościami macierzy B i dodajemy do wyniku w C

# Mnożenie macierzy



Kolumny macierzy B „rolujemy” w dół.

# Mnożenie macierzy




Obniżamy diagonalną o jeden w dół.

Przysyłamy do sąsiadów w tym samym wierszu.


Mnożymy wartości przesyłane z wartościami macierzy B i dodajemy do wyniku w C

# Mnożenie macierzy



Kolumny macierzy B „rolujemy” w dół.

# Mnożenie macierzy




Obniżamy diagonalną o jeden w dół.

Przysyłamy do sąsiadów w tym samym wierszu.

Mnożymy wartości przesyłane z wartościami macierzy B i dodajemy do wyniku w C

# Mnożenie macierzy w 3D



# Algorytm Genetyczny

- Algorytm genetyczny - rodzaj algorytmu przeszukującego przestrzeń alternatywnych rozwiązań problemu w celu wyszukania rozwiązań najlepszych.
- Zaliczany do grona algorytmów ewolucyjnych
- Twórcą jest John Henry Holland

# Algorytm Genetyczny

- Problem definiuje środowisko
- Populacja – zbiór osobników
- Genotyp – zbiór informacji przypisany do pojedynczego osobnika
- Fenotyp – zbiór cech osobnika podlegajacemu ocenie funkcji przystosowania
- Funkcja przystosowania modeluje środowisko
- Chromosomy – części składowe genotypu
- Geny – elementy chromosomu

# Algorytm Genetyczny

## Wspólne cechy algorytmów genetycznych

- Stosowanie operandów genetycznych takich jak krzyżowanie i mutacja, które dostosowane są do postaci rozwiązań
- Równoległe przeszukiwanie przestrzeni rozwiązań, startujące z różnych punktów
- Ukierunkowanie przestrzeni poszukiwań następuje na podstawie informacji o jakości rozwiązania (funkcja przystosowania)
- Celowe wprowadzenie elementów losowych

# Algorytm Genetyczny

## Podstawowy algorytm

- Losowana populacja początkowa (inicjacja)
- Rozwój osobników, ocena ich przystosowania
- Sprawdzenie warunku wyjścia
- Losowanie (najlepsi mają największe szanse)
- Zastosowanie operatorów genetycznych
  - Krzyżowanie
  - Mutacja
- Powstaje nowe pokolenie. Tu algorytm wraca do punktu 2.

# Algorytm Genetyczny

## Kodowanie

- Chromosom przedstawiamy zwykle jako wektor genów
- Geny reprezentowane są przez liczby binarnych, całkowitych lub rzeczywistych (genów)
- Kodowanie logarytmiczne
- Struktury drzewiaste

# Algorytm Genetyczny

## Ocena

- Chromosomy są parametrem funkcji oceny  $f(x)$
- Badając wartość  $f(x)$  wiemy w jaki sposób jest przystosowany osobnik o chromosomie  $x$
- Przy optymalizacji, szukamy maximum lub minimum  $f(x)$

# Algorytm Genetyczny

## Dobór naturalny

- Według koła ruletki
  - Całe koło ruletki odpowiada sumie wartości funkcji przystosowania wszystkich chromosomów danej populacji.
  - Dla każdego chromosomu  $ch_i$ , dla  $i=1,2,\dots,N$ , gdzie  $N$  liczebność populacji, odpowiada wycinek koła zgodnie ze wzorem  $Ch_i = p_s * 100$   
Gdzie prawdopodobieństwo wyrażone jest

$$p_s(ch_i) = \frac{F(ch_i)}{\sum_{i=1}^N F(ch_i)} \text{ przy } (i=1,2,\dots,N)$$

- $F(ch_i)$  oznacza funkcję przystosowania chromosomu  $ch_i$
- Losowanie odbywa się  $N$  razy

# Algorytm Genetyczny


## Dobór naturalny

- Metoda elitarna
  - najlepszy osobnik przechodzi bez zmian
- Metoda turniejowa
  - Osobniki dzielone są na grupy i z poszczególnych grup wybierane najlepsze rozwiązania.
- Metoda rankingowa.
  - Rozwiązania sortowane są według jakości rozwiązania i nadawane rangi. Potem zwykle funkcją liniową wybiera się odpowiednią liczbę osobników poczynając od najlepszego

# Algorytm Genetyczny

## Krzyżowanie

- Podstawowe poprzez cięcie w wybranym punkcie (locus)



# Algorytm Genetyczny

## Inne metody krzyżowania

- Krzyżowanie z częściowym odwzorowaniem (PMX)
- Krzyżowanie z porządkowaniem (OX)

# Algorytm Genetyczny

## Przykład

- Znalezienie maximum funkcji  $f(x)=x^2$  w przedziale  $0..31$
- Wybieramy system kodowania zmiennej decyzyjnej  $x$  (5b)
- Populacja złożona z 4 ciągów  
01101  
11000  
01000  
10011

# Algorytm Genetyczny

## Przykład

| Nr ciągu | Populacja początkowa | Wartość x | f(x) | prawdopodobieństwo | Oczekiwana liczba kopii | Liczba kopii wylosowanych | Wylosowana pula rodzicielska | Losowo wybrany partner | Losowy punkt krzyżowania | Nowa populacja | x  | f(x) |
|----------|----------------------|-----------|------|--------------------|-------------------------|---------------------------|------------------------------|------------------------|--------------------------|----------------|----|------|
| 1        | 01101                | 13        | 169  | 0,14               | 0,58                    | 1                         | 011101                       | 2                      | 4                        | 01100          | 12 | 144  |
| 2        | 11000                | 24        | 576  | 0.49               | 1,92                    | 2                         | 110100                       | 1                      | 4                        | 11001          | 25 | 625  |
| 3        | 01000                | 8         | 64   | 0,06               | 0,22                    | 0                         | 111000                       | 4                      | 2                        | 11011          | 27 | 729  |
| 4        | 10011                | 19        | 361  | 0,31               | 1,23                    | 1                         | 101011                       | 3                      | 2                        | 10000          | 16 | 256  |
| suma     |                      |           | 1170 | 1,00               | 4                       | 4                         |                              |                        |                          |                |    | 1754 |
| średnia  |                      |           | 293  | 0,25               | 1                       | 1                         |                              |                        |                          |                |    | 439  |
| maksimum |                      |           | 576  | 0,49               | 1,97                    | 2                         |                              |                        |                          |                |    | 729  |

# Algorytm Genetyczny

Zastosowanie w programowaniu współbieżnym

- Głównie układ master-slaves
  - Master zleca procesom roboczym rozwój populacji, całych grup lub tylko pojedynczych osobników na proces
  - Procesy Slave zwracają wartość funkcji przystosowania
  - Master decyduje o doborze naturalnym
- W układzie P2P
  - Dobór naturalny bez procesu zarządzającego.
  - Wymiana chromosomów bezpośrednia.

# Algorytm Mrówkowy

Kilka słów na temat mrówek

- Są praktycznie ślepe
- Mają bardzo dobre zmysły węchu
- Mają znikome mózgi.
- Gdy działają w stadzie potrafią znaleźć najkrótszą drogę pomiędzy pożywieniem a mrowiskiem
- Korzystają z feromonów i zjawiska stygmergii (zjawisko pośredniej komunikacji poprzez wywoływanie zmian w środowisku i odczytywanie ich)
- Mrówki maszerując zostawiają na swej drodze feromon
- Feromony nieustannie parują
- Mrówki podczas decyzji którą z dróg wybrać kierują się intensywnością zapachu feromonu.

# Algorytm Mrówkowy


## Działanie algorytmu

- Mrówki losowo rozchodzą się z mrowiska szukając pożywienia.
- Te mrówki które trafią krótszą drogą, szybciej wrócą po swoich śladach
- Na krótszych trasach liczba mrówek w jednostce czasu jest większa a więc i odświeżanie śladu feromonowego jest intensywniejsze
- Trasy dłuższe, jako rzadziej odwiedzane wyparowują.


# Algorytm Mrówkowy

Działanie algorytmu w przypadku podjęcia decyzji

- Mrówki mają ustaloną trasę




- Gdy trafią na przeszkodę część pójdzie z jednej strony część z drugiej



# Algorytm Mrówkowy

Działanie algorytmu w przypadku podjęcia decyzji


- Mrówki idące krótszą drogą szybciej łączą ślady feromonowe dając jednocześnie sygnał dla pozostałych mrówek która trasa jest lepsza.



# Algorytm Mrówkowy

Działanie algorytmu w przypadku podjęcia decyzji

- Z czasem mrówki zoptymalizują swoją trasę.



# Algorytm Mrówkowy

Wyszukiwanie najlepszej trasy w problemie komiwojażera

- Punkt startu - dowolny
- Cel pojedynczej mrówki – odwiedzić wszystkie miasta tylko 1 raz
- Poruszanie się po krawędziach grafu
- Mrówki działają iteracyjnie
- Feromon nakładany dopiero po znalezieniu tras przez wszystkie mrówki w danej iteracji (algorytm CAS – Cycle Ant System)
- Ilość feromonu odwrotnie proporcjonalna do znalezionej drogi lub nakładana tylko przez najlepszą mrówkę

# Algorytm Mrówkowy

Wyszukiwanie najlepszej trasy w problemie komiwojażera

- Na początku każda krawędź ma równą ilość feromonu
- Każda mrówka wybiera sobie dowolny punkt startu
- Wybierając kolejny i-ty węzeł na swojej trasie kieruje się tablicą decyzyjną

$$A_i = [a_{ij}(t)]_{[N_i]}$$

# Algorytm Mrówkowy

Elementy tablicy decyzyjnej określone są wzorem:

$$a_{ij} = \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{l \in N_i} [\tau_{il}(t)]^\alpha [\eta_{il}]^\beta} \quad \forall j \in N_i$$

- $\tau_{ij}$  - ilość feromonu pomiędzy węzłem  $i$  oraz  $j$
- $\eta_{ij} = \frac{c}{d_{ij}}$  Wartość heurystyczna informująca o atrakcyjności danego połączenia punktu  $i$  oraz  $j$ .  $c$  to stała  $d$  odległość pomiędzy  $i$  a  $j$
- $N_i$  - zbiór możliwych połączeń wychodzących z węzła  $i$
- $\alpha\beta$  – parametry dostrajające algorytm, można nimi regulować jaki udział w podjęciu decyzji ma heurystyka a jaki ilość feromonu.

# Algorytm Mrówkowy

Prawdopodobieństwo wybrania węzła  $j \in N_i^k$  dla  $k$  mrówek w pozycji  $i$  podczas  $t$ -iteracji jest:

$$p_{ij}^k(t) = \frac{a_{ij}(t)}{\sum_{l \in N_i^k} a_{il}(t)}$$

Gdzie  $N_i^k \subseteq N_i$  jest zestawem sąsiednich węzłów nie odwiedzonych.

# Algorytm Mrówkowy

Gdy wszystkie mrówki znajdą drogę wybieramy najlepszą z nich lub proporcjonalnie dla wszystkich uaktualniamy ilość feromonu na każdej krawędzi wchodzącej w skład trasy poprzez dodanie  $m/L$  feromonu gdzie  $m$  stała,  $L$  – długość znalezionej trasy.

Do tego dochodzi jeszcze parowanie. Z każdej krawędzi grafu odparowujemy pewną stałą część feromonu:

$$\tau_{ij} = \tau_{ij} * \rho$$