

Zadanie 3 — Załóżmy, że mamy dostęp do bazy zakupów klientów w sieci hurtowni środków chemicznych z poprzedniego roku. W ciągu roku 10^7 klientów odwiedza ją 10 razy i za każdym razem kupuje średnio 10 różnego typu produktów z puli 200 dostępnych typów produktów. Załóżmy że znaleźliśmy w tej bazie danych dwóch klientów którzy zakupili choć raz ten sam koszyk produktów. Czy jest to czysty przypadek?

2 Model MapReduce

Zadanie 4 — Wymień jakie aspekty działania systemu MapReduce są poza zasięgiem programisty. Które elementy kontroluje programista?

Zadanie 5 — Wracamy do zadania "Word Count". Przepisz algorytmy które już napisałaś w języku Scala do programów działających w paradygmacie Map Reduce

Zadanie 6 — Zaprojektuj algorytm MapReduce który dostaje bardzo duży zbiór liczb całkowitych i produkuje na wyjściu jednocześnie:

1. Największą liczbę, najmniejszą liczbę.
2. Średnią wszystkich liczb.
3. Ten sam zbiór ale bez powtórzeń.
4. Liczbę różnych elementów bez powtórzeń.

Zadanie 7 — Niech $x \oplus y = x + y + 1$ oraz $x \otimes y = xy + x + y$ dla $x, y \in \mathbb{R}$. Pokaż, że są to działania łączne i przemienne na \mathbb{R} . Wskazówka: Spróbuj to zrobić z minimalną liczbą rachunków; rozważ funkcje $f(x) = x + 1$ oraz $g(x) = x - 1$; zauważ, że $g \circ f = Id$.

Zadanie 8 — Podaj kilka przykładów działań nieprzemiennych. Podaj kilka przykładów działań które nie są łączne.

Zadanie 9 — Pokaż, że operacje $\min(x, y)$ i $\max(x, y)$ są przemienne i łączne. Czy operacja $s(x, y) = \frac{x+y}{2}$ jest łączna?

Zadanie 10 — Wymień jakie aspekty działania systemu MapReduce są poza zasięgiem programisty. Które elementy kontroluje programista?

Zadanie 11 — Zaprojektuj algorytm MapReduce który dostaje bardzo duży zbiór liczb całkowitych i produkuje na wyjściu:

1. Największą liczbę.
2. Średnią wszystkich liczb.
3. Ten sam zbiór ale bez powtórzeń.
4. Liczbę różnych elementów bez powtórzeń.

Zadanie 12 — Zaprojektuj algorytm MapReduce, który wyznacza złączenie dwóch relacji o schemacie $R(A,B,C)$ i $S(X,Y,Z)$ według połączenia $B=X$ oraz $C=Y$, czyli wyznacz tabelę

$$\{(A, Y) : (\exists B, C)(R(A, B, C) \wedge S(B, C, Y))\} .$$

Zadanie 13 — (Odwrócenie grafu) Dany jest graf w postaci listy sąsiadów: $[w, [w_{i,1}, w_{i,2}, \dots, w_{i,n_i}]]$ zapisany w zbiorze tekstowym, np.

```
[  
  [1, [3,4,5]],  
  [2, [1,3]],  
  [3, [4,5]],  
  [4, [1,2]],  
  [5, [4,5]]  
]
```

Zastosuj technologię MapReduce do zbudowania grafu z odwróconymi linkami.

Zadanie 14 — Niech $F : ((\mathbb{N} \setminus \{0\}) \times \mathbb{R})^2 \rightarrow (\mathbb{N} \setminus \{0\}) \times \mathbb{R}$ będzie funkcją określoną wzorem

$$F([c_1, x_1], [c_2, x_2]) = [c_1 + c_2, \frac{c_1 x_1 + c_2 x_2}{c_1 + c_2}]$$

1. Pokaż, że F jest działaniem przemianym i łącznym.
2. Oznaczmy przez \odot działanie $x \odot y = F(x, y)$. Znajdź zwartą formułę dla

$$[c_1, x_1] \odot [c_2, x_2] \odot \dots \odot [c_n, x_n] .$$

3. Zastosuj tę własność funkcji do zastosowania combainera dla problemu wyznaczania średniej i wariancji.

Zadanie 15 — Zastosuj metodę map-reduce do wyznaczenia średniej geometrycznej i harmonicznej.

Zadanie 16 — Zastosuj metodę map-reduce do wyznaczenia wszystkich anagramów występujących w zbiorze tekstowym.

Zadanie 17 — Multizbiorem o skończonym nośniku Ω nazywamy funkcję $F : \Omega \rightarrow \mathbb{N}$. Dla $F, G : \Omega \rightarrow \mathbb{N}$ określamy $(F \cup G)(\omega) = \max\{F(\omega), G(\omega)\}$, $(F \cap G)(\omega) = \min\{F(\omega), G(\omega)\}$, $(F \setminus G)(\omega) = \max\{F(\omega) - G(\omega), 0\}$. Zaprojektuj map-reduce algorytm do wyznaczania tych trzech operacji. Algorytm na wejściu dostaje listę elementów zbioru

$$\{(1, \omega, F(\omega)) : \omega \in \Omega \wedge F(\omega) > 0\} \cup \{(2, \omega, G(\omega)) : \omega \in \Omega \wedge G(\omega) > 0\}$$

Zadanie 18 — (To nie jest zadanie na MapReduce) W pliku TwoCollisions.csv, do którego link znajduje się na stronie wykładu, w każdej linii znajduje się (NumerHotelu, NumerDnia, NumerOsoby). Znajdź takie osoby, które w dwóch różnych dniach znajdowały się w tym samym hotelu.

Zadanie 19 — Zastosuj dwukrotnie MapReduce do swojej książki którą używałeś do zadania z Word - Count zrób listę pięciu najczęściej powiązanych wyrazów z danym słowem. Przez powiązane słowa rozumiemy słowa występujące obok siebie (po usunięciu stop-words). Oczywiście oprogramować masz to zadanie w paradygmacie MapReduce.

Spróbuj zastosować otrzymaną listę do wygenerowania losowego paragrafu ze swojej książki.

Zadanie 20 — Niech (G, E) będzie grafem skierowanym. Dla $g \in G$ oznaczamy $inDeg(g) = |\{y \in G : (y, g) \in E\}|$ oraz $outDeg(g) = |\{y \in G : (g, y) \in E\}|$. Zaprojektuj w MapReduce procedury służące do wyznaczania listy $\{(g, inDeg(g), outDeg(g)) : g \in G\}$. Napisz również procedurę do wyznaczania średnich stopni $\frac{1}{n} \sum \{inDeg(g) : g \in G\}$ oraz $\frac{1}{n} \sum \{outDeg(g) : g \in G\}$.

Zastosuj opracowane algorytmy to wyznaczenia średnich stopni dla grafu "Stanford web graph", który możesz znaleźć na stronie <http://snap.stanford.edu/data/web-Stanford.html>

Zadanie 21 — Niech (G, E) będzie grafem. Współczynnikiem klasteryzacji wężła $g \in G$ nazywamy liczbę

$$c(g) = \frac{2}{|N_g|(|N_g| - 1)} |N_g \cap E| ,$$

gdzie $N_g = \{a : \{g, a\} \in E\}$. Zaprojektuj w MapReduce procedury służące do wyznaczania listy $\{(g, c(g), outDeg) : g \in G\}$. Napisz również procedurę do wyznaczania średniej wartości $\frac{1}{n} \sum \{c(g) : g \in G\}$

Zastosuj opracowane algorytmy to wyznaczenia średnich stopni dla grafu "Stanford web graph" (musisz przerobić ten graf na graf nieskierowany).

Zadanie 22 — Mamy n serwerów (wartości liczbowe sprawdzaj dla $n = 3000$). Prawdopodobieństwo zepsucia się jednego serwera podczas wykonania zadania map-reduce przez pojedynczy serwer w czasie T wynosi p (przyjmij dla obliczeń numerycznych, że $p = \frac{1}{3000}$). Przyjmij, że zdarzenia polegające na zepsuciu się serwera w kolejnych slotach czasowych o długości T są niezależne.

1. Oblicz prawdopodobieństwo poprawnego zakończenia całego zadania

2. Dzielimy teraz serwery na 3 grupy po 1000 serwerów. Każde zadania wykonujemy na trzech serwerach (po jednym z każdej grupy). Czas wykonania zadania wynosi teraz $3T$. Jakie jest teraz prawdopodobieństwo poprawnego zakończenia zadania?

Zadanie 23 — Załóżmy, że dwie macierze A, B rozmiaru $2n \times 2n$ zostały podzielone na bloki

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

rozmiaru $n \times n$

1. Pokaż, że

$$A \cdot B = \begin{bmatrix} A_{11} \cdot B_{11} + A_{12} \cdot B_{21} & A_{11} \cdot B_{12} + A_{12} \cdot B_{22} \\ A_{21} \cdot B_{11} + A_{22} \cdot B_{21} & A_{21} \cdot B_{12} + A_{22} \cdot B_{22} \end{bmatrix}$$

2. Spróbuj sformułować i udowodnić bardziej ogólny fakt.

Zadanie 24 — Nadal zajmujemy się wybraną przez Ciebie książką podzieloną na rozdziały. Teraz dla każdego słowa oraz każdego rozdziału wyznacz współczynniki TF.IDF.

1. Dla każdego rozdziału wyznacz 20 wyrazów o najwyższym współczynniku TF.IDF
2. Napisz funkcję realizującą następujące zadanie: wprowadzasz do niej słowo, a ona zwraca listę najbardziej pasujących rozdziałów (czyli posortuj rozdziały wg parametru FT.IDF).

3 Funkcje haszujące

Zadanie 25 — Załóżmy, że $\mathcal{H} = \{h_1, \dots, h_n\}$ jest rodziną k -niezależnych funkcji haszujących ze zbioru D w zbiór skończony R , czyli, że dla dowolnych $x_1, \dots, x_k \in D$ oraz $y_1, \dots, y_k \in R$ mamy

$$\Pr_{h \leftarrow \mathcal{H}}(h(x_1) = y_1 \wedge \dots \wedge h(x_k) = y_k) = \frac{1}{|R|^k}.$$

Pokaż, że dla dowolnego $m \leq k$ jest ona również m -niezależna.

Zadanie 26 — Rozważmy funkcję haszującą zadaną wzorem $h(x) = x \bmod 21$. Stosujemy ją do liczb podzielnych przez pewną stałą c . Dla jakich stałych c jest to odpowiednia funkcja haszująca, czyli dla jakich stałych c można się spodziewać, że rozkład załadowania kubeków $\{0, \dots, 20\}$ będzie jednostajny?

Zadanie 27 — Znajdź wzór na rząd elementu $k \in \{0, \dots, n-1\}$ w grupie $C_n = (\{0, \dots, n-1\}, \oplus_n)$? Jaki jest związek tego zadania z poprzednim zadaniem?

Zadanie 28 — Mamy n kubeków. Rzucamy do nich k kul.

1. Oszacuj k taki aby z dużym prawdopodobieństwem doszło do 3-kolizji, czyli aby a jakimś kubku znalazły się 3 kulki.
2. Sprawdź eksperymentalnie otrzymany wynik
3. Uogólnij zadanie na a -kolizje
4. Wyznacz w podobny sposób wartość oczekiwaną liczby pustych urn. Kiedy (dla jakich k) ta liczba staje się mniejsza od 1.

Zadanie 29 — Dwóch studentów ma dzban wypełniony 8 litrami napoju. Mają do dyspozycji dzbanek o pojemności 5 litrów oraz drugi dzbanek o pojemności 3 litrów. Chcą podzielić się równo napojem. Jak mogą to zrobić? Zagadanie to można potraktować jako system przepisujący o stanie początkowym $(8, 0, 0)$. Możemy to zadanie próbować rozwiązać tak: losowo wybieramy dwie różne liczby i, j ze zbioru $\{1, 2, 3\}$ i próbujemy przelać napój z i -tego pojemnika do j -tego pojemnika; iterujemy to błędnie losowo tak długo aż dojdziemy do stanu $(4, 4, 0)$. Jednak jest to kiepskie rozwiązanie - algorytm taki wpada bardzo często w pętle. Zastosuj technikę śledzenia przebiegu do unikania zapętleń. Oprogramuj to w języku Python.

4 Podobieństwo tekstów

Zadanie 30 — Pokaż, że funkcja $d(A, B) = |A \Delta B|$ jest metryką na przestrzeni niepustych skończonych podzbiorów ustalonego zbioru X .

Zadanie 31 — Niech $f : [0, \infty) \rightarrow [0, \infty)$ będzie funkcją rosnącą i wklęsłą.

1. Pokaż, że dla $a, b \geq 0$ mamy $f(a + b) \leq f(a) + f(b)$.

Wskazówka: Zauważ, że możemy założyć, że $a + b > 0$; następnie zauważ, że $a = (a + b) \frac{a}{a+b}$ oraz $b = (a + b) \frac{b}{a+b}$ i zastosuj nierówność Jensena dla funkcji wklęsłych.

2. Załóżmy dodatkowo, że $f(0) = 0$. Niech d będzie metryką na zbiorze X . Pokaż, że funkcja $\rho(x, y) = f(d(x, y))$ jest również metryką na zbiorze X .
3. Pokaż, że jeśli $\epsilon \in (0, 1)$ oraz d jest metryką na zbiorze X , to funkcja $\rho(x, y) = d(x, y)^\epsilon$ jest metryką na zbiorze X .
4. Pokaż, że jeśli d jest metryką na zbiorze X , to funkcja $\rho(x, y) = \frac{d(x, y)}{1 + d(x, y)}$ jest metryką na zbiorze X .

Zadanie 32 — Wybierzmy dwa losowe m -elementowe podzbiory A, B n -elementowego zbioru X . Jaka jest wartość oczekiwana podobieństwa Jaccarda $J(A, B)$?

Zadanie 33 — Korzystając z Twierdzenia o Gęstości Liczb Pierwszych (Prime Numbers Theorem) oszacuj liczbę liczb pierwszych z przedziału $[2^{64}, 2^{64} + 1000]$ i następnie wyznacz te liczby.

Zadanie 34 — (Twierdzenie Steinhausa) Niech d będzie metryką na zbiorze X . Ustalmy element $a \in X$ i zdefiniujmy funkcję

$$\rho(x, y) = \frac{2d(x, y)}{d(x, a) + d(y, a) + d(x, y)}$$

Celem tego zadania jest pokazanie, że ρ jest metryką na zbiorze X .

1. Pokaż najpierw, że jeśli $0 < p \leq q$ oraz $r \geq 0$ to $\frac{p}{q} \leq \frac{p+r}{q+r}$.
2. Wprowadź oznaczenia $p = d(x, y)$, $q = d(x, y) + d(x, a) + d(y, a)$ oraz $r = d(x, z) + d(y, z) - d(x, y)$ i zastosuj obserwację z poprzedniego punktu do pokazania nierówności trójkąta dla funkcji ρ .

Zadanie 35 — Zastosuj Twierdzenie Steinhausa do metryki $d(X, Y) = |X \Delta Y|$ na zbiorze skończonych podzbiorów zbioru Ω do pokazania, że funkcja $d(X, Y) = 1 - S(X, Y)$ (odległość Jaccarda) jest metryką.

Zadanie 36 — Załóżmy, że S jest takim podobieństwem obiektów przestrzeni Ω , że istnieje rodzina funkcji haszujących \mathcal{H} oraz prawdopodobieństwo na rodzinie \mathcal{H} takie, że dla dowolnych dwóch obiektów $A, B \in \Omega$ mamy

$$P_h[h(A) = h(B)] = S(A, B)$$

Pokaż, że wtedy funkcja $d(A, B) = 1 - S(A, B)$ jest metryką na zbiorze Ω .

Zadanie 37 — Uzupełnij szczegóły dowodu tego, że jeśli $\Omega = \{\omega_i : 1 \leq i \leq N\}$, π jest losową permutacją zbioru $\{1, \dots, N\}$ (wybieraną zgodnie z rozkładem jednostajnym), oraz $h_\pi(X) = \min\{k : \omega_{\pi(k)} \in X\}$ dla $X \subseteq \Omega$ to

$$P_\pi[h_\pi(A) = h_\pi(B)] = S(A, B).$$

Zadanie 38 — Napisz procedurę o specyfikacji `jaccard(f1:String,f2:String,k:Integer):Double`, która dla plików o nazwach `f1`, `f2` wyznacza ich k -gramy i następnie wylicza ich odległość Jaccarda. Przed wyznaczeniem k -gramów pliki powinny być oczyszczone (minimum to usunięcie znaków nowej linii, tabulatorów oraz podwójnych spacji)

1. Zastosuj tę procedurę do kilku wariantów swoich plików z algorytmami (zastosuj 4-gramy)
2. Zastosuj tę procedurę do porównania kolejnych rozdziałów analizowanej w Zadaniu 2 książki (zastosuj 7-gramy)

Zadanie 39 — Zastosuj metodę minhash do poprzedniego zadania. Twoja procedura powinna zależeć od parametru H który określa liczbę funkcji haszujących stosowanych do budowania sygnatury tekstu.

1. Przetestuj tę procedurę na danych z poprzedniego zadania dla $H \in \{50, 100, 250\}$ - porównaj aproksymację odległości Jaccarda z jej dokładnymi wartościami.

Pamiętaj o wygenerowaniu wspólnej rodziny funkcji haszujących dla wszystkich analizowanych tekstów.

Zadanie 40 — Napisz procedurę służącą do wyznaczania sygnatur kosinusowych plików tekstowych korzystających z 1024 losowych wektorów z \mathbb{R}^n (n tutaj oznacza moc wspólnego zbioru słów występujących w badanych dokumentach). Dokumenty reprezentowane mają być przez wektor częstotliwości słów. Zastosuj tę metodę do plików z Zadanie 2.

5 Streaming

Zadanie 41 — Niech C_n będzie wartością licznika Morrisa po n krotnym wywołaniu procedury INCREMENT. Niech $L_n = 2^{C_n}$.

1. Wyznacz wariancję zmiennej L_n oraz oblicz $\frac{\sigma(L_n)}{E(L_n)}$.
2. Zbadaj eksperymentalnie dokładność zastawu czterech liczników Morrisa. Jako estymator liczby n przyjmij $2^{(C_1(n)+C_2(n)+C_3(n)+C_4(n))/4}$.
3. Dla jakich n mamy $4 \log_2(\log_2(n)) < \log_2(n)$?

Zadanie 42 — Zaimplementuj Boyer–Moore’a Majority Algorithm.

1. Napisz najpierw funkcję której parametrem jest lista łańcuchów (List[String]).
2. Zaprojektuj następnie obiekt o dwóch metodach: add(x:String):Unit oraz get():String który realizuje ten algorytm.
3. Jaka jest złożoność obliczeniowa i pamięciowa tego algorytmu.

Zadanie 43 — Zaimplementuj Misra - Gries Algorithm.

1. Napisz najpierw funkcję której parametrami jest lista łańcuchów (List[String]) oraz liczba k określającą maksymalną liczbę śledzonych obiektów.
2. Zaprojektuj następnie obiekt o dwóch metodach: add(x:String):Unit oraz get():String który realizuje ten algorytm. Do utworzenia tego obiektu potrzebujesz jeden parametr k .
3. Jaka jest złożoność obliczeniowa i pamięciowa tego algorytmu.

Zadanie 44 — Algorytm HyperLogLog używa wartości $h(x) = (b_0 b_1 b_2 b_3 \dots)$ do wyznaczenia numeru inkrementowanego licznika ($i = (b_0 \dots b_{k-1})_2 + 1$) oraz do wyznaczenia z reszty ciągu bitów ($b_k b_{k+1} \dots$) do zwiększenia wartości licznika. Załóżmy, że $h(x)$ jest typu Int lub Long oraz, że $h(x) \geq 0$.

1. Jak można za pomocą operacji bitowych wyznaczyć z $h(x)$ ciąg ($b_0 \dots b_{k-1}$)?
2. Jak można za pomocą operacji bitowych wyznaczyć z $h(x)$ ciąg ($b_k b_{k+1} \dots$)?
3. Załóżmy, że $n \geq 0$. Co robi operacja $n \& (-n)$. Jak tą operację możesz wykorzystać do inkrementacji licznika.

Zadanie 45 — Zaimplementuj algorytm HyperLogLog.

1. Pobierz ze strony <http://ita.ee.lbl.gov/html/contrib/LBL-PKT.html> plik lbl-pkt-4. Wypakuj z niego plik lbl-pkt-4.tcp. Oto format danych: timestamp, (przenumerowany) source host, (przenumerowany) destination host, source TCP port, destination TCP port, liczba bajtów danych (zero dla "pure-ack" pakietów).
2. Zastosuj HupeLogLog do wyznaczenia liczby różnych source hostów, liczby różnych destination hostów oraz liczby różnych par (source, destination).

Zadanie 46 — Pokaż, że wielomian $w(x) = 1 + x + x^2$ jest nierozkładalny w pierścieniu $\mathbb{Z}_2[x]$. Rozważ ideał $(w) = \{\alpha \cdot w : \alpha \in \mathbb{Z}_2[x]\}$ w pierścieniu $\mathbb{Z}_2[x]$. Obliczenia będziemy prowadzić w pierścieniu ilorazowym $\mathbb{Z}_2[x]/(w)$.

1. Pokaż, że dla $\alpha, \beta \in \mathbb{Z}_2[x]$ mamy

$$((w) + \alpha = (w) + \beta) \equiv w | (\alpha - \beta)$$

2. Pokaż, że struktura $(\mathbb{Z}_2[x]/(w), +)$ jest izomorficzna z $(\mathbb{Z}_2^2, +)$.
3. Oznacz przez i zmienną x . Zauważ, że $\mathbb{Z}_2[x]/(w) = \{[0], [1], [i], [1+i]\}$.
4. Stosując oznaczenia: $\mathbf{0} = [0]$, $\mathbf{1} = [1]$, $\mathbf{i} = [i]$ oraz $\mathbf{1+i} = [1+i]$ wyznacz tabliczki dodawania i mnożenia w $\mathbb{Z}_2[x]/(w)$
5. Pokaż, że $\mathbf{1+i+i^2} = \mathbf{0}$.
6. Pokaż, że $\mathbb{Z}_2[x]/(w)$ jest czteroelementowym ciałem.

Zadanie 47 — Powtórz poprzednie zadanie dla wielomianu $w(x) = 1+x+x^3$. Skonstruujesz w ten sposób ciało 8 elementowe.

Zadanie 48 — Zbuduj ciało 9 elementowe.

Zadanie 49 — Niech F będzie ciałem. Niech a_1, \dots, a_4 będą parami różnymi elementami ciała F . Niech b_1, \dots, b_4 będą dowolnymi elementami ciała F . Niech

$$w(x) = \sum_{i=1}^4 b_j \prod_{j \neq i} \frac{x - a_j}{a_i - a_j}$$

(jest to wielomian interpolacyjny Lagrange'a stopnia 4). Pokaż, że w jest jednym wielomianem stopnia trzeciego z pierścienia $F[x]$ takim, że $w(a_1) = b_1$, $w(a_2) = b_2$, $w(a_3) = b_3$ oraz $w(a_4) = b_4$.

Zadanie 50 — Wygeneruj listę $\{h_1, \dots, h_{100}\}$ losowych wielomianów stopnia 3 nad ciałem \mathbb{Z}_{11} .

Wskazówka: W programie Mathematica można to zrobić za pomocą następującej funkcji:

`LP[p_]:=Module[{f,Function[x,Mod[RandomInteger[{0,p-1},4].{1,x,x^2,x^3},p]]];` .

1. Wyznacz moc zbioru $\{i \in \{1, \dots, 100\} : h_i(1) = 2\}$. Powtórz ten eksperyment kilka razy. Pamiętaj aby obliczenia wykonywać w ciele \mathbb{Z}_{11} .
2. Wygeneruj histogram wartości $\{h_i(1) : i \in \{1, \dots, 100\}\}$.

Zadanie 51 — Zapoznaj się z testem nierozkładalności wielomianów Rabina i pokaż, że wielomian $w(x) = x^{80} + x^9 + x^4 + x^2 + 1$ jest wielomianem nierozkładalnym nad ciałem \mathbb{Z}_2 . Oblicz $[x^{40}] \cdot [x^{40}]$ w ciele $\mathbb{Z}_2[x]/(w)$.

Zadanie 52 — Oprogramuj Geometric Histogram Streaming Window Algorithm M. Datara, A. Gionisa, P. Indyka i R. Motwaniego z pracy <http://www-cs-students.stanford.edu/~datar/papers/sicompstreams.pdf>

6 Page Rank

Zadanie 53 — Niech $A = (a_{ij})$ będzie kwadratową macierzą rozmiaru $n \times n$. Niech $x = (x_1, \dots, x_n) \in \mathbb{R}^n$. Pokaż, że

$$\|Ax^T\|_2 \leq \sqrt{\sum_{i,j} a_{ij}^2} \cdot \|x\|_2 .$$

(gdzie $\|(y_1, \dots, y_n)\|_2 = (\sum_i y_i^2)^{1/2}$). Wywnioskuj z tego, że jeśli λ jest wartością własną macierzy kolumnowo stochastycznej, to $|\lambda| \leq 1$.

Zadanie 54 — Załóżmy, że A jest macierzą kwadratową o współczynnikach rzeczywistych. Pokaż, że jeśli λ jest wartością własną macierzy A , to liczba $\bar{\lambda}$ (sprzężenie liczby λ) jest również wartością własną macierzy A .

Zadanie 55 — Załóżmy, że $A, B \in M_n(\mathbb{R})$ są kolumnowo stochastyczne.

1. Pokaż, że macierz $A \circ B$ jest kolumnowo stochastyczna.
2. Niech $\alpha \in [0, 1]$. Pokaż, że macierz $\alpha A + (1 - \alpha)B$ jest kolumnowo stochastyczna.
3. Podaj interpretacje probabilistyczne powyższych faktów.

Zadanie 56 — Załóżmy, że w grafie nie ma 'wiszących wierzchołków'. Niech v będzie wierzchołkiem bez linków do tego wierzchołka. Pokaż, że $pagerank(v) = \frac{1-\alpha}{n}$.

Zadanie 57 — Rozważmy gwiazdę rozmiaru $n + 1$, czyli graf o krawędziach $\{i \rightarrow n + 1, i = 1 \dots, n\}$. Wyznacz PageRank dla tego grafu.

Zadanie 58 — Wyznacz PageRank dla grafu $\{a \rightarrow b, b \rightarrow a, b \rightarrow c\}$.

Zadanie 59 — Napisz procedurę służącą do wygenerowania macierzy Google dla porządku liniowego rozmiaru n . Napisz procedurę 'naiwnego' obliczania PageRank metodą potęgową i zastosuj ją wyznaczenia PageRank dla tego liniowego porządku.

Zadanie 60 — Przeskanuj witrynę WWW któregoś z pracowników katedry. Wyznacz PageRank dla wszystkich wierzchołków tego grafu.

Zadanie 61 — Napisz pseudo-kod funkcji MAPPER i REDUCER służących do wykonania jednego kroku iteracyjnego wyznaczenia PageRank metodą polegającą na rozbięciu macierzy przejść M na k^2 bloków:

$$\begin{bmatrix} M_{11} & \dots & M_{1k} \\ \vdots & \vdots & \vdots \\ M_{k1} & \dots & M_{kk} \end{bmatrix} \circ \begin{bmatrix} V_1 \\ \vdots \\ V_k \end{bmatrix} = \begin{bmatrix} M_{11} \circ V_1 + \dots + M_{1k} \circ V_k \\ \vdots \\ M_{k1} \circ V_1 + \dots + M_{kk} \circ V_k \end{bmatrix}$$

1. Pokaż poprawność metody mnożenia macierzy przez wektor za pomocą podziału na bloki.
2. Niech R będzie pierścieniem łącznym. Pokaż, że

$$(M_{n \times n}(M_{k \times k}(R)), \circ) \cong (M_{(nk) \times (nk)}(R), \circ)$$

(gdzie $M_{m \times m}(R)$ oznacza zbiór macierzy kwadratowych wymiaru $m \times m$ o wyrazach z pierścienia R).

Zadanie 62 — Wybierz witrynę jednego z pracowników Katedry Informatyki. Sprawdź jej poprawność za pomocą narzędzi ze stron

- <https://validator.w3.org/>,
- <https://jigsaw.w3.org/css-validator/>
- <https://search.google.com/search-console/mobile-friendly>.

Sprawdź następnie poprawność meta-informacji i strukturę semantyczną głównej strony.

Zadanie 63 — Niech L oznacza zbiór wszystkich liniowych porządków na zbiorze $X = \{a, b\}$. Ile jest funkcji $F : L^n \rightarrow L$ spełniających zasadę Pareto?

Zadanie 64 — Niech L oznacza zbiór wszystkich liniowych porządków na zbiorze $X = \{a, b, c\}$. Ile jest funkcji $F : L^n \rightarrow L$ spełniających zasadę Pareto oraz zasadę uczciwości (niewrażliwości na trzecią możliwość)?

c.d.n.

Powodzenia,
Jacek Cichoń