

Map-Reduce.

Mnożenie macierzy

Dane $A, B \in M_{n \times n}(\mathbb{R})$

$C \in L : A \cdot B (=C)$

$$A = (a_{ij})_{i,j=1..n}$$

$$B = (b_{jk})_{j,k=1..n}$$

$$C = (c_{lk})$$

$$c_{lk} = \sum_{j=1}^n a_{ij} \cdot b_{jk}$$

⊕ współczynniki $a_{ij} \cdot b_{jk}$

dane: $A : ("A", l, j, a_{ij})$

$B : ("B", j, k, b_{jk})$

map: $(("A", l, j, a_{ij})) \rightsquigarrow (j, ("A", l, a_{ij}))$

$(("B", j, k, b_{jk})) \rightsquigarrow (j, ("B", k, b_{jk}))$



reducer (j, L) {

$L = [(\overset{L_1}{A^a}, 1, a_{1j}), \dots, (A^a, n, a_{nj})]$

1) Posortuj L po pierwsz. wsp.

$[(\text{"B"}, 1, b_{j1}), \dots, (\text{"B"}, n, b_{jn})]$

2) Podziel $L \rightsquigarrow L_1, L_2$

3) forall $(\overset{L_1}{A^a}, l, x) \in L_1$

forall $(\text{"B"}, k, y) \in L_2$

emit $(l, k, x \cdot y)$

$x = a_{lj}$
 $y = b_{jk}$

}

URUCHAMIAMY II RAZ Map Red


1	1	$a_{11} \cdot b_{11}$
1	1	$a_{12} \cdot b_{21}$
1	1	$a_{13} \cdot b_{31}$

map $(1, j, \text{~~z~~}) \{ \text{emit}(l, y, z) \}$

reduce $((1, j), L) \{ \text{emit}(1, j, \sum L); \}$


HADOOP : 2 razy odpalić MR

SPARK : to można sterować
wewnątrz jednego odpalenia



lnny pousepat na $A \cdot B$

a_{ij}



b_{jk}



tu potrebujeme a_{i1}

tu b_{jk} je potrebne

$a_{i1} \cdot b_{1k}$
 $a_{i2} \cdot b_{2k}$

map ~~map~~ $(A, i, j, a_{ij}) \rightarrow ((i, 1), ("A", j, a_{ij})), ((i, 2), ("A", j, a_{ij})), \dots, ((i, n), ("A", j, a_{ij}))$
 $(B, j, k, b_{jk}) \rightarrow ((1, k), ("B", j, b_{jk})), \dots, ((n, k), ("B", j, k))$

reducer

ZADANIE

$\varphi((i, j)) \in \{0, \dots, R-1\}$

Wzrostanie:

many procesor 10 GHz.



Jaka odległość,
półowa światła
w jednym cyklu
procesora?
0


Method 3.

$$\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \circ \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} = \begin{bmatrix} A_{11}B_{11} + A_{12}B_{21} & \dots \\ A_{21}B_{11} + A_{22}B_{21} & \dots \end{bmatrix}$$

$$\mathcal{M}_{n \times n} = (\mathcal{M}_{n,n}(\mathbb{R}), +, \cdot)$$

$$\mathcal{M}_{k \times k}(\mathcal{M}_{n \times n}) \cong \mathcal{M}_{k \cdot n \times k \cdot n}$$

TW.



$$(A, i, j, a_{ij}) \rightarrow \left\{ \begin{array}{l} (i \text{ div } k, 0) \\ \dots \\ (i-1, k-1) \end{array} \right\} (A, i \bmod k, j \bmod k, a_{ij})$$


$$A = (a_{ij})_{i,j=0, \dots, kn-1}$$

$$C: \left[\underbrace{A_{11} \cdot B_{11} + A_{12} \cdot B_{21}}_n \right]$$

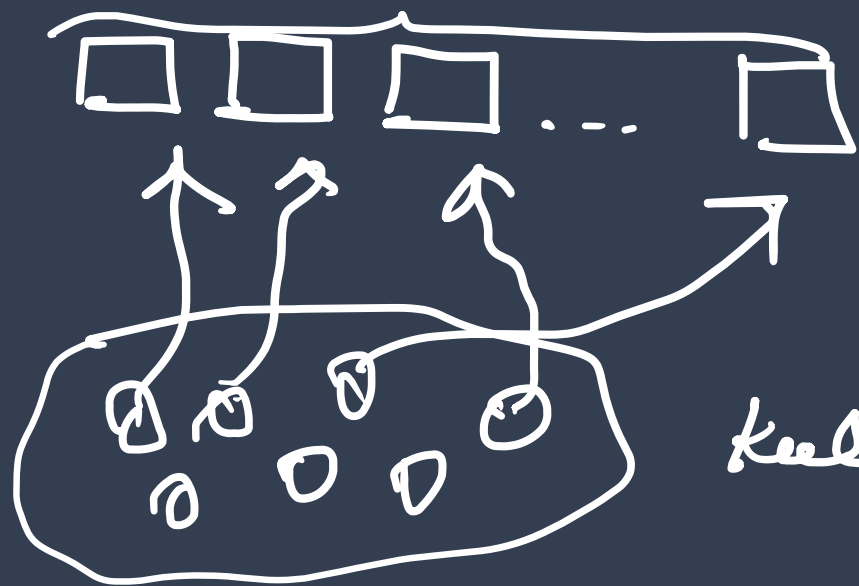
$$\frac{(kn)^2}{k} \mp \frac{(kn)^2}{k} = 2kn^2$$

$$(kn)^2 = k^2 n^2$$

HASHOWANIE



MODEL KULE-URNY



urny // reduce.

rozstawy kulki
w urny losowo, sortuj
kule // kłecze
niezależnie

1. paradoks urodzinowy:

\sim po \sqrt{n} urn są losujące

2. coupon coll. problem (CCP)

\sim n urn : znaleźć puste urny

iniekcje

suriekcje



$k \ll n$: Ile jest pustych urn? $k - L. Keel$

$$E[L] = \sum_{i=1}^n P[u_i \text{ jest pusta}] = n \cdot \left(\frac{n-1}{n}\right)^k \sim \frac{n}{e} \sim \frac{1}{3} n.$$

Wniosek: każde redukowanie R
nie może być zbyt duże
 $R \cdot \ln R$ \ll liczby różnych
kluczy

dane \rightsquigarrow (klucze, π)

Q: { universal hashing
k-independent hashing

Zat. zē many funkcje haskwey, ce

$$h: \Sigma \rightarrow \{0, 1, \dots, n-1\}$$

o bardzo podobny "lotarysh. probab."

• $h(x)$ - wybrat. sie jedyn. w $\{0, \dots, n-1\} = [n]$

• $x \neq y$: $h(x), h(y)$ sa niezolene od siebie
(z duzym prawdopodob.)


$$\text{Pr}[h(x) = h(y)] \cong \frac{1}{n}$$



$|\Sigma| \gg n$ h nie jest 1-1

BIG : MURMUR hash function

TYPOWE WYKORZYSTANIE :



$$\left\{ \begin{array}{l} S = \sum \\ S = \{x_1, x_2, \dots, x_n\} \end{array} \right.$$

$$u_{h(x)} \Rightarrow x$$

hash table
 $Q : x \in S \rightarrow$