

AULA 10

- Última aula antes da P1.
- Prova será entregue no dia 11/8 com prazo para devolução 17/8 (inadiável)

MAIS ALGUNS EXEMPLOS DE DIVIDIR E CONQUISTAR

— Algoritmo de Strassen: multiplicação matricial
(1969)

Queremos calcular $C = A \cdot B$, em que A e B (e consequentemente também C) são matrizes $n \times n$. Assuma, por simplicidade, que n é potência de 2.

- Algoritmo "ingênuo":

$$C_{ij} = \sum_{k=1}^n a_{ik} \cdot b_{kj}$$

Tempo: $O(n^3)$ somas e multiplicações

- Dividir e conquistar "ingênuo"

Multiplicação em blocos:

$$\overbrace{\begin{pmatrix} r & s \\ t & u \end{pmatrix}}^A = \overbrace{\begin{pmatrix} a & b \\ c & d \end{pmatrix}}^B \overbrace{\begin{pmatrix} e & f \\ g & h \end{pmatrix}}^C$$

$$r = ae + bg$$

$$s = af + bh$$

$$t = ce + dg$$

$$u = cf + dh$$

8 multiplicações de matrizes $\frac{n}{2} \times \frac{n}{2}$, calculadas recursivamente

$$\text{Tempo: } \begin{cases} T(1) = O(1) \\ T(n) = 8T(\frac{n}{2}) + O(n^2) \end{cases}$$

$$\text{Portanto, } T(n) = \Theta(n^3)$$

Pelo Teorema Mestre

$$a = 8$$

$$b = 2$$

$$\log_b a = 3$$

- Para melhorar a complexidade precisamos de um D&C mais "esperto", reduzindo o número de multiplicações matriciais recursivas.

- Algoritmo de Strassen:

$$\begin{pmatrix} r & s \\ t & u \end{pmatrix} = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \begin{pmatrix} e & f \\ g & h \end{pmatrix}$$

Calcule:

$$P_1 = a \cdot (f - h)$$

$$P_2 = (a + b) \cdot h$$

$$P_3 = (c + d) \cdot e$$

$$P_4 = d \cdot (g - e)$$

$$P_5 = (a + d) \cdot (e + h)$$

$$P_6 = (b - d) \cdot (g + h)$$

$$P_7 = (a - c) \cdot (e + f)$$

E depois, calcule:

$$r = P_5 + P_4 - P_2 + P_6$$

$$s = P_1 + P_2$$

$$t = P_3 + P_4$$

$$u = P_5 + P_1 - P_3 - P_7$$

Somente 7 multiplicações de matrizes $\frac{n}{2} \times \frac{n}{2}$, calculadas recursivamente

Isso funciona? Surpreendentemente, SIM!

Veja, por exemplo:

$$\begin{aligned} r &= \overbrace{(a+d)(e+h)}^{P_5} + \overbrace{d(g-e)}^{P_4} - \overbrace{(a+b)h}^{P_2} + \overbrace{(b-d)(g+h)}^{P_6} \\ &= \overbrace{ae+ah+de+dh} + \overbrace{dg-de} - \overbrace{ah-bh} + \overbrace{bg+bh-dg-dh} \\ &= ae + bg \end{aligned}$$

Mesmo para s, t e u .

Agora o tempo é $\begin{cases} T(1) = O(1) \\ T(n) = 7T(\frac{n}{2}) + O(n^2) \end{cases}$

$$T(n) = \Theta(n^{\log_2 7})$$

$$T(n) = O(n^{2,81})$$

Comportamento assintótico.
Vale a pena para matrizes
grandes! Recursão não
precisa descer até os escalares!

Em 1990, Coppersmith-Vinograd: $O(n^{2.376})$

Em 2014, François Le Gall: $O(n^{2.373})$ arXiv:1401.7714

⋮

— Transformada de Fourier Rápida (FFT)

Seja $\vec{x} = \begin{pmatrix} x_0 \\ x_1 \\ \vdots \\ x_{N-1} \end{pmatrix}$ um vetor em $\mathbb{C}^N$, assumindo $N=2^n$

Digamos que o vetor $\vec{y} = \begin{pmatrix} y_0 \\ y_1 \\ \vdots \\ y_{N-1} \end{pmatrix}$ dado por

$$y_k = \sum_{j=0}^{n-1} x_j e^{\frac{2\pi i}{N} kj}$$

é a Transformada de Fourier Discreta de $\vec{x}$.

- Note que $\vec{y} = F\vec{x}$, em que $F_{jk} = e^{\frac{2\pi i}{N}jk}$

- Então, temos um produto de matriz $N \times N$ por um vetor $N \times 1$. Pelo método "ingênuo", a complexidade é $O(N^2)$.
- Podemos melhorar, usando o algoritmo FFT de Cooley & Tukey (1965), um dos mais importantes da história!
- Fundamenta-se em um resultado anterior de Danielson & Lanczos (1942), que por sua vez inspira-se em resultados anteriores de Runge (1903, 1905). Até Gauss trabalhou em problema similar, ainda que em casos particulares.

Teorema (de Danielson & Lanczos): Sejam $\vec{x}$ e $\vec{y}$ vetores em $\mathbb{C}^N$, t.q. $\vec{y} = F\vec{x}$. Então

$$y_k = y_k^{\text{PAR}} + e^{\frac{2\pi i}{N}k} y_k^{\text{IMPAR}},$$

em que

$$y_k^{\text{PAR}} = \sum_{j=0}^{\frac{n}{2}-1} x_{2j} e^{\frac{2\pi i}{N}kj}$$

$$y_k^{\text{IMPAR}} = \sum_{j=0}^{\frac{n}{2}-1} x_{2j+1} e^{\frac{2\pi i}{N}kj}$$

Essa é a base para construir um algoritmo D&C para Transf. de Fourier:

- Dividir vetor $\vec{x}$ entre índices pares e ímpares, $O(n)$
- Resolver cada metade recursivamente
- Combinar resultados parciais usando fórmula de Danielson & Lanczos

A complexidade então fica

$$\begin{cases} T(1) = O(1) \\ T(n) = 2T(\frac{n}{2}) + O(n) \end{cases}$$

Logo,

$$T(n) = \Theta(n \log n).$$

- Muitas aplicações!

Uma aplicação muito interessante é multiplicação de polinômios, que pode ser feita de modo mais eficiente por meio da FFT! (Fica como "exercício" para os curiosos.)

MAIS UM EXEMPLO DE PROGRAMAÇÃO DINÂMICA

— Qual a ordem ótima para avaliar o produto de n matrizes?

M	$=$	M_1	$\times$	M_2	$\times \dots \times$	M_j	$\times \dots \times$	M_n
dimensões:		$[r_0 \times r_1]$		$[r_1 \times r_2]$		$[r_{j-1} \times r_j]$		$[r_{n-1} \times r_n]$

Exemplo:

$$M = M_1 \times M_2 \times M_3 \times M_4$$

$[10 \times 20]$	$[20 \times 50]$	$[50 \times 1]$	$[1 \times 100]$
------------------	------------------	-----------------	------------------

Se fizermos $M_1 \times (M_2 \times (M_3 \times M_4))$ temos 125.000 operações

Se fizermos $(M_1 \times (M_2 \times M_3)) \times M_4$ temos 2.200 operações

*Assumindo, por simplicidade, que o produto de uma matriz $n \times p$ por uma matriz $p \times r$ gaste npr operações

- Algoritmo "ingênuo" de força bruta: testar todas as possibilidades de parênteses: tempo $O(2^n)$

Argumento: $P(n)$: número de formas que podemos pôr os parênteses em n matrizes

$$P(n) = \begin{cases} 1, & \text{se } n=1 \\ \sum_{k=1}^{n-1} P(k)P(n-k), & \text{se } n \geq 2 \end{cases}$$

- Vejamos a estrutura da solução ótima:

Seja m_{ij} o custo mínimo para computar $M_i \times \dots \times M_j$ para $1 \leq i \leq j \leq n$.

Então,

$$m_{ij} = \begin{cases} 0, & \text{se } i=j \\ \min_{i \leq k < j} \{m_{ik} + m_{k+1,j} + r_{i-1} r_k r_j\}, & \text{se } j > i \end{cases}$$

Argumento:

$$\underbrace{(M_i \times M_{i+1} \times \dots \times M_k)}_{\substack{\text{custo mínimo: } m_{ik} \\ \text{matriz resultante: } r_{i-1} \times r_k}} \times \underbrace{(M_{k+1} \times \dots \times M_j)}_{\substack{\text{custo mínimo: } m_{k+1,j} \\ \text{matriz resultante: } r_k \times r_j}}$$

- Método de programação dinâmica calcula os m_{ij} em ordem crescente da diferença dos subíndices
 - Primeiro m_{ii} para todo i
 - Depois $m_{i,i+1}$
 - Depois $m_{i,i+2}$
 - e assim por diante

Exemplo: $r = 10, 20, 50, 1, 100$

Primeiro, $m_{11} = 0$ $m_{22} = 0$ $m_{33} = 0$ $m_{44} = 0$

Depois, $m_{12} = 10000$ $m_{23} = 1000$ $m_{34} = 5000$

Depois, $m_{13} = 1200$ $m_{24} = 3000$

Finalmente, $m_{14} = 2200$ é o custo mínimo para multiplicar todas as matrizes.

Algoritmo (como em Cormen et al.)

dados: vetor $r[1..n]$

para $i := 1, \dots, n$ efetuar

$m[i, i] := 0$

para $l := 2, \dots, n$ efetuar $\rightarrow$ comprimento da cadeia

para $i := 1, \dots, n-l+1$ efetuar $\rightarrow$ quando $l=2 \Rightarrow i=1..n-1$
 $l=n \Rightarrow i=1..1$

$j := i+l-1 \rightarrow$ quando $i=1 \Rightarrow j=2..n$
 $i=n-1 \Rightarrow j=n$

$m[i, j] := \infty$

para $k := 1, \dots, j-1$ efetuar

$q := m[i, k] + m[k+1, j] + r[i-1] \cdot r[k] \cdot r[j]$

se $q < m[i, j]$ então

$m[i, j] := q$

$s[i, j] := k$

retornar m, s

(i, j) indica
qual entrada
da matriz será
preenchida

Exemplo :

$$n = 4$$

$$r = (10, 20, 50, 1, 100)$$

i	m	j	1	2	3	4
	5					
1			0	10.000 ₁	1.200 ₁	2.200 ₃
2				0	1.000 ₂	3.000 ₃
3					0	5000 ₃
4						0

$$\left((M_1) \times (M_2 \times M_3) \right) \times (M_4)$$