

MC458 — Projeto e Análise de Algoritmos I

C.C. de Souza C.N. da Silva O. Lee P.J. de Rezende

1º Semestre de 2018

Programação Dinâmica

Programação Dinâmica: Conceitos Básicos

- Tipicamente o paradigma de programação dinâmica aplica-se a problemas de **otimização**.
- Podemos utilizar programação dinâmica em problemas onde há:
 - **Subestrutura Ótima:** As soluções ótimas do problema incluem soluções ótimas de subproblemas.
 - **Sobreposição de Subproblemas:** O cálculo da solução através de recursão implica no recálculo de subproblemas.

Programação Dinâmica: Conceitos Básicos (Cont.)

- A técnica de **programação dinâmica** visa evitar o recálculo desnecessário das soluções dos subproblemas.
- Para isso, soluções de subproblemas são armazenadas em **tabelas**.
- Para que o algoritmo de programação dinâmica seja eficiente, é preciso que o número total de subproblemas a serem resolvidos seja pequeno (polinomial no tamanho da entrada).

Problema: Multiplicação de Matrizes

Calcular o número mínimo de operações de multiplicação escalar para computar a matriz M dada por:

$$M = M_1 \times M_2 \times \dots \times M_i \dots \times M_n$$

onde M_i é uma matriz de b_{i-1} linhas e b_i colunas, para todo $i \in \{1, \dots, n\}$.

- Matrizes são multiplicadas aos pares sempre. Então, é preciso encontrar uma parentização (agrupamento) ótimo para a cadeia de matrizes.
- Para calcular a matriz M' dada por $M_i \times M_{i+1}$ são suficientes $b_{i-1} * b_i * b_{i+1}$ multiplicações entre os elementos de M_i e M_{i+1} .

- **Exemplo:** Qual é o mínimo de multiplicações escalares para computar $M = M_1 \times M_2 \times M_3 \times M_4$ com $b = \{200, 2, 30, 20, 5\}$?
- As possibilidades de parentização são:

$$\begin{aligned} M &= (M_1 \times (M_2 \times (M_3 \times M_4))) \rightarrow 5.300 \text{ multiplicações} \\ M &= (M_1 \times ((M_2 \times M_3) \times M_4)) \rightarrow 3.400 \text{ multiplicações} \\ M &= ((M_1 \times M_2) \times (M_3 \times M_4)) \rightarrow 4.500 \text{ multiplicações} \\ M &= ((M_1 \times (M_2 \times M_3)) \times M_4) \rightarrow 29.200 \text{ multiplicações} \\ M &= (((M_1 \times M_2) \times M_3) \times M_4) \rightarrow 152.000 \text{ multiplicações} \end{aligned}$$

- A ordem das multiplicações faz **muita** diferença!

- Poderíamos calcular o número de multiplicações para **todas as possíveis** parentizações.
- O número de possíveis parentizações é dado pela recorrência:

$$P(n) = \begin{cases} 1, & n = 1 \\ \sum_{k=1}^{n-1} P(k) \cdot P(n-k) & n > 1, \end{cases}$$

- Mas $P(n) \in \Omega(4^n/n^2)$: a estratégia de força bruta é **impraticável!**

- Inicialmente, para todo (i, j) tal que $1 \leq i \leq j \leq n$, vamos definir as seguintes matrizes:

$$M_{i,j} = M_i \times M_{i+1} \times \dots \times M_j.$$

- Agora, dada uma parentização ótima, existem dois pares de parênteses que identificam o **último par** de matrizes que serão multiplicadas. Ou seja, existe k tal que $M = M_{1,k} \times M_{k+1,n}$.
- Como a parentização de M é ótima, as parentizações no cálculo de $M_{i,k}$ e $M_{k+1,n}$ devem ser ótimas também. Caso contrário, seria possível obter uma parentização de M ainda melhor!
- Eis a **subestrutura ótima** do problema: a parentização ótima de M inclui a parentização ótima de $M_{i,k}$ e $M_{k+1,n}$.

- De forma geral, se $m[i, j]$ é número mínimo de multiplicações que devem ser efetuadas para computar $M_{i,j} = M_i \times M_{i+1} \times \dots \times M_j$, então $m[i, j]$ é dado por:

$$m[i, j] := \min_{i \leq k < j} \{m[i, k] + m[k + 1, j] + b_{i-1} * b_k * b_j\}.$$

- Podemos então projetar um algoritmo recursivo (indutivo) para resolver o problema.

MinimoMultiplicacoesRecursivo(b, i, j)

▷ **Entrada:** Vetor b com as dimensões das matrizes e os índices i e j que delimitam o início e término da subcadeia.

▷ **Saída:** O número mínimo de multiplicações escalares para computar a multiplicação da subcadeia. Esse valor é registrado em uma tabela ($m[i, j]$), bem como o índice da divisão em subcadeias ótimas ($s[i, j]$).

- se $i = j$ então devolva 0
- $m[i, j] := \infty$
- para $k := i$ até $j - 1$ faça
- $q := \text{MinimoMultiplicacoesRecursivo}(b, i, k) + \text{MinimoMultiplicacoesRecursivo}(b, k + 1, j) + b[i - 1] * b[k] * b[j]$
- se $m[i, j] > q$ então
- $m[i, j] := q ; s[i, j] := k$
- devolva $m[i, j]$.

Efetuando a Multiplicação Ótima

- É muito fácil efetuar a multiplicação da cadeia de matrizes com o número mínimo de multiplicações escalares usando a tabela s , que registra os índices ótimos de divisão em subcadeias.

MultiplicaMatrizes(M, s, i, j)

▷ **Entrada:** Cadeia de matrizes M , a tabela s e os índices i e j que delimitam a subcadeia a ser multiplicada.

▷ **Saída:** A matriz resultante da multiplicação da subcadeia entre i e j , efetuando o mínimo de multiplicações escalares.

- se $i < j$ então
- $X := \text{MultiplicaMatrizes}(M, s, i, s[i, j])$
- $Y := \text{MultiplicaMatrizes}(M, s, s[i, j] + 1, j)$
- devolva $\text{Multiplica}(X, Y, b[i - 1], b[s[i, j]], b[j])$
- senão devolva M_i ;

Algoritmo Recursivo - Complexidade

- O número mínimo de operações feitas pelo algoritmo recursivo é dada pela recorrência:

$$T(n) \geq \begin{cases} 1, & n = 1 \\ 1 + \sum_{k=1}^{n-1} [T(k) + T(n-k) + 1] & n > 1, \end{cases}$$

- Portanto, $T(n) \geq 2 \sum_{k=1}^{n-1} T(i) + n$, para $n > 1$.
- É possível provar (por substituição) que $T(n) \geq 2^{n-1}$, ou seja, o algoritmo recursivo tem complexidade $\Omega(2^n)$. Ainda é impraticável!

- A ineficiência do algoritmo recursivo deve-se à **sobreposição de subproblemas**: o cálculo do mesmo $m[i, j]$ pode ser requerido em vários subproblemas.
- Por exemplo, para $n = 4$, $m[1, 2]$, $m[2, 3]$ e $m[3, 4]$ são computados duas vezes.
- O número de total de $m[i, j]$'s calculados é $O(n^2)$ apenas!
- Portanto, podemos obter um algoritmo mais eficiente se evitarmos recálculos de subproblemas.

- Existem duas técnicas para evitar o recálculo de subproblemas:
 - **Memorização**: Consiste em manter a estrutura recursiva do algoritmo, registrando em uma tabela o valor ótimo para subproblemas já computados e verificando, antes de cada chamada recursiva, se o subproblema a ser resolvido já foi computado.
 - **Programação Dinâmica**: Consiste em preencher uma tabela que registra o valor ótimo para cada subproblema de forma apropriada. Isto é, a computação do valor ótimo de cada subproblema depende somente de subproblemas já previamente computados. E elimina-se completamente a recursão.

Algoritmo de Memorização

MinimoMultiplicacoesMemorizado(b, n)

1. **para** $i := 1$ **até** n **faça**
2. **para** $j := 1$ **até** n **faça**
3. $m[i, j] := \infty$
4. **devolva** $Memorizacao(b, 1, n)$

Memorizacao(b, i, j)

1. **se** $m[i, j] < \infty$ **então devolva** $m[i, j]$
2. **se** $i = j$ **então** $m[i, j] := 0$
3. **senão**
4. **para** $k := i$ **até** $j - 1$ **faça**
5. $q := Memorizacao(b, i, k) +$
 $Memorizacao(b, k + 1, j) + b[i - 1] * b[k] * b[j];$
6. **se** $m[i, j] > q$ **então** $m[i, j] := q; s[i, j] := k$
7. **devolva** $m[i, j]$

Algoritmo de Programação Dinâmica

- O uso de programação dinâmica é preferível pois elimina completamente o uso de recursão.
- O algoritmo de programação dinâmica para o problema da multiplicação de matrizes torna-se trivial se computarmos, para valores crescentes de u , o valor ótimo de todas as subcadeias de tamanho u .


Algoritmo de Programação Dinâmica

MinimoMultiplicacoes(b)


- ▷ **Entrada:** Vetor b com as dimensões das matrizes.
- ▷ **Saída:** As tabelas m e s preenchidas.

 1. **para** $i = 1$ **até** n **faça** $m[i, i] := 0$
 - ▷ calcula o mínimo de todas sub-cadeias de tamanho $u + 1$
 2. **para** $u = 1$ **até** $n - 1$ **faça**
 3. **para** $i = 1$ **até** $n - u$ **faça**
 4. $j := i + u; m[i, j] := \infty$
 5. **para** $k = i$ **até** $j - 1$ **faça**
 6. $q := m[i, k] + m[k + 1, j] + b[i - 1] * b[k] * b[j]$
 7. **se** $q < m[i, j]$ **então**
 8. $m[i, j] := q; s[i, j] := k$
 9. **devolva** (m, s)


Algoritmo de Programação Dinâmica - Exemplo



Algoritmo de Programação Dinâmica - Exemplo



Algoritmo de Programação Dinâmica - Exemplo



Algoritmo de Programação Dinâmica - Exemplo

	1	2	3	4
1	0	12000	9200	
2		0	1200	
3			0	3000
4				0

m

	1	2	3	4
1	-	1	1	
2		-	2	
3			-	3
4				-

s

{ 200, 2, 30, 20, 5 }

$$b_0 * b_1 * b_3 = 200 * 2 * 20 = 8000$$

$$b_0 * b_2 * b_3 = 200 * 30 * 20 = 120000$$

Algoritmo de Programação Dinâmica - Exemplo

	1	2	3	4
1	0	12000	9200	
2		0	1200	1400
3			0	3000
4				0

m

	1	2	3	4
1	-	1	1	
2		-	2	3
3			-	3
4				-

s

{ 200, 2, 30, 20, 5 }

$$b_1 * b_2 * b_4 = 2 * 30 * 5 = 300$$

$$b_1 * b_3 * b_4 = 2 * 20 * 5 = 200$$

Algoritmo de Programação Dinâmica - Exemplo

	1	2	3	4
1	0	12000	9200	3400
2		0	1200	1400
3			0	3400
4				0

m

	1	2	3	4
1	-	1	1	1
2		-	2	3
3			-	3
4				-

s

{ 200, 2, 30, 20, 5 }

$$b_0 * b_1 * b_4 = 200 * 2 * 5 = 2000$$

$$b_0 * b_2 * b_4 = 200 * 30 * 5 = 30000$$

$$b_0 * b_3 * b_4 = 200 * 20 * 5 = 20000$$

Algoritmo de Programação Dinâmica - Exemplo

	1	2	3	4
1	0	12000	9200	3400
2		0	1200	1400
3			0	3000
4				0

m

	1	2	3	4
1	-	1	1	1
2		-	2	3
3			-	3
4				-

s

$$M1 \left(((M2 \cdot M3) \cdot M4) \right)$$

- A complexidade de tempo do algoritmo é dada por:

$$\begin{aligned}
 T(n) &= \sum_{u=1}^{n-1} \sum_{i=1}^{n-u} \sum_{k=i}^{i+u-1} \Theta(1) \\
 &= \sum_{u=1}^{n-1} \sum_{i=1}^{n-u} u \Theta(1) \\
 &= \sum_{u=1}^{n-1} u(n-u) \Theta(1) \\
 &= \sum_{u=1}^{n-1} (nu - u^2) \Theta(1).
 \end{aligned}$$

O Problema Binário da Mochila

O Problema da Mochila

Dada uma mochila de capacidade W (inteiro) e um conjunto de n itens com tamanho w_i (inteiro) e valor c_i associado a cada item i , queremos determinar quais itens devem ser colocados na mochila de modo a **maximizar** o valor total transportado, respeitando sua capacidade.

- Podemos fazer as seguintes suposições:
 - $\sum_{i=1}^n w_i > W$;
 - $0 < w_i \leq W$, para todo $i = 1, \dots, n$.

- Como

$$\sum_{u=1}^{n-1} nu = n^3/2 - n^2/2$$

e

$$\sum_{u=1}^{n-1} u^2 = n^3/3 - n^2/2 + n/6.$$

Então,

$$T(n) = (n^3/6 - n/6) \Theta(1).$$

- A complexidade de tempo do algoritmo é $\Theta(n^3)$.
- A complexidade de espaço é $\Theta(n^2)$, já que é necessário armazenar a matriz com os valores ótimos dos subproblemas.

O Problema Binário da Mochila

- Podemos formular o problema da mochila com **Programação Linear Inteira**:

- Criamos uma variável x_i para cada item: $x_i = 1$ se o item i estiver na solução ótima e $x_i = 0$ caso contrário.
- A modelagem do problema é simples:

$$\max \sum_{i=1}^n c_i x_i \quad (1)$$

$$\sum_{i=1}^n w_i x_i \leq W \quad (2)$$

$$x_i \in \{0, 1\} \quad (3)$$

- (1) é a **função objetivo** e (2-3) o **conjunto de restrições**.

O Problema Binário da Mochila

- Como podemos projetar um algoritmo para resolver o problema?
- Existem 2^n possíveis subconjuntos de itens: um algoritmo de força bruta é **impraticável!**
- É um problema de otimização. **Será que tem subestrutura ótima?**
- Se o item n estiver na solução ótima, o valor desta solução será c_n mais o valor da melhor solução do problema da mochila com capacidade $W - w_n$ considerando-se só os $n - 1$ primeiros itens.
- Se o item n não estiver na solução ótima, o valor ótimo será dado pelo valor da melhor solução do problema da mochila com capacidade W considerando-se só os $n - 1$ primeiros itens.

O Problema Binário da Mochila - Complexidade Recursão

- A complexidade do algoritmo recursivo para este problema no **pior caso** é dada pela recorrência:

$$T(k, d) = \begin{cases} 1, & k = 0 \text{ ou } d = 0 \\ T(k - 1, d) + T(k - 1, d - w_k) + 1 & k > 0 \text{ e } d > 0. \end{cases}$$

- Portanto, no **pior caso**, o algoritmo recursivo tem complexidade $\Omega(2^n)$. É impraticável!
- Mas há **sobreposição de subproblemas**: o recálculo de subproblemas pode ser evitado!

O Problema Binário da Mochila

- Seja $z[k, d]$ o valor ótimo do problema da mochila considerando-se uma capacidade d para a mochila que contém um subconjunto dos k primeiros itens da instância original.
- A fórmula de recorrência para computar $z[k, d]$ para todo valor de d e k é:


$$z[0, d] = 0$$

$$z[k, 0] = 0$$

$$z[k, d] = \begin{cases} z[k - 1, d], & \text{se } w_k > d \\ \max\{z[k - 1, d], z[k - 1, d - w_k] + c_k\}, & \text{se } w_k \leq d \end{cases}$$


Mochila - Sobreposição de Subproblemas

- Considere vetor de tamanhos $w = \{2, 1, 6, 5\}$ e capacidade da mochila $W = 7$. A árvore de recursão seria:



- O subproblema $z[1, 1]$ é computado duas vezes.

- O número total máximo de subproblemas a serem computados é nW .
- Isso porque tanto o tamanho dos itens quanto a capacidade da mochila são **inteiros!**
- Podemos então usar programação dinâmica para evitar o recálculo de subproblemas.
- Como o cálculo de $z[k, d]$ depende de $z[k - 1, d]$ e $z[k - 1, d - w_k]$, preenchemos a tabela linha a linha.



O Problema Binário da Mochila - Algoritmo

Mochila(c, w, W, n)

▷ **Entrada:** Vetores c e w com valor e tamanho de cada item, capacidade W da mochila e número de itens n .

▷ **Saída:** O valor máximo do total de itens colocados na mochila.

1. **para** $d := 0$ **até** W **faça** $z[0, d] := 0$
2. **para** $k := 1$ **até** n **faça** $z[k, 0] := 0$
3. **para** $k := 1$ **até** n **faça**
4. **para** $d := 1$ **até** W **faça**
5. $z[k, d] := z[k - 1, d]$
6. **se** $w_k \leq d$ **e** $c_k + z[k - 1, d - w_k] > z[k, d]$ **então**
7. $z[k, d] := c_k + z[k - 1, d - w_k]$
8. **devolva** ($z[n, W]$)

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

		d							
		0	1	2	3	4	5	6	7
k	0	0	0	0	0	0	0	0	0
	1	0							
	2	0							
	3	0							
	4	0							

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0							
3	0							
4	0							

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0							
4	0							

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0							

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

k \ d	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

Mochila - Complexidade

- Claramente, a complexidade do algoritmo de programação dinâmica para o problema da mochila é $O(nW)$.
- É um algoritmo **pseudo-polinomial**: sua complexidade depende do **valor** de W , parte da entrada do problema.
- O algoritmo não devolve o subconjunto de valor total máximo, apenas o valor máximo.
- É fácil recuperar o subconjunto a partir da tabela z preenchida.

Mochila - Recuperação da Solução

MochilaSolucao(z, n, W)

▷ **Entrada:** Tabela z preenchida, capacidade W da mochila e número de itens n .

▷ **Saída:** O vetor x que indica os itens colocados na mochila.

para $i := 1$ **até** n **faça** $x[i] := 0$

MochilaSolucaoAux(x, z, n, W)

devolva (x)

MochilaSolucaoAux(x, z, k, d)

se $k \neq 0$ **então**

se $z[k, d] = z[k - 1, d]$ **então**

$x[k] := 0$; *MochilaSolucaoAux*($x, z, k - 1, d$)

senão

$x[k] := 1$; *MochilaSolucaoAux*($x, z, k - 1, d - w_k$)

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

k \ d	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

Mochila - Exemplo

- Exemplo: $c = \{10, 7, 25, 24\}$, $w = \{2, 1, 6, 5\}$ e $W = 7$.

d \ k	0	1	2	3	4	5	6	7
0	0	0	0	0	0	0	0	0
1	0	0	10	10	10	10	10	10
2	0	7	10	17	17	17	17	17
3	0	7	10	17	17	17	25	32
4	0	7	10	17	17	24	31	34

$$x[1] = x[4] = 1, \quad x[2] = x[3] = 0$$

- O algoritmo de recuperação da solução tem complexidade $O(n)$.
- Portanto, a complexidade de tempo e de espaço do algoritmo de programação dinâmica para o problema da mochila é $O(nW)$.
- É possível economizar memória, registrando duas linhas: a que está sendo preenchida e a anterior. Mas isso inviabiliza a recuperação da solução.

Subcadeia comum máxima (cont.)

- É um problema de otimização. **Será que tem subestrutura ótima?**
- **Notação:** Seja S uma cadeia de tamanho n . Para todo $i = 1, \dots, n$, o prefixo de tamanho i de S será denotado por S_i .
- **Exemplo:** Para $S = ABCDEFG$, $S_2 = AB$ e $S_4 = ABCD$.
- **Definição:** $c[i, j]$ é o tamanho da subcadeia comum máxima dos prefixos X_i e Y_j . Logo, se $|X| = m$ e $|Y| = n$, $c[m, n]$ é o valor ótimo.

Definição: Subcadeia

Dada uma cadeia $S = a_1 \dots a_n$, dizemos que $S' = b_1 \dots b_p$ é uma *subcadeia* de S se existem p índices $i(j)$ satisfazendo:

- (a) $i(j) \in \{1, \dots, n\}$ para todo $j \in \{1, \dots, p\}$;
- (b) $i(j) < i(j+1)$ para todo $j \in \{1, \dots, p-1\}$;
- (c) $b_j = a_{i(j)}$ para todo $j \in \{1, \dots, p\}$.

- **Exemplo:** $S = ABCDEFG$ e $S' = ADFG$.

Problema da Subcadeia Comum Máxima

Dadas duas cadeias de caracteres X e Y de um alfabeto Σ , determinar a maior subcadeia comum de X e Y

Subcadeia comum máxima (cont.)

- **Teorema (subestrutura ótima):** Seja $Z = z_1 \dots z_k$ a subcadeia comum máxima de $X = x_1 \dots x_m$ e $Y = y_1 \dots y_n$, denotado por $Z = \text{SCM}(X, Y)$.
 - 1 Se $x_m = y_n$ então $z_k = x_m = y_n$ e $Z_{k-1} = \text{SCM}(X_{m-1}, Y_{n-1})$.
 - 2 Se $x_m \neq y_n$ então $z_k \neq x_m$ implica que $Z = \text{SCM}(X_{m-1}, Y)$.
 - 3 Se $x_m \neq y_n$ então $z_k \neq y_n$ implica que $Z = \text{SCM}(X, Y_{n-1})$.
- **Fórmula de Recorrência:**

$$c[i, j] = \begin{cases} 0 & \text{se } i = 0 \text{ ou } j = 0 \\ c[i-1, j-1] + 1 & \text{se } i, j > 0 \text{ e } x_i = y_j \\ \max\{c[i-1, j], c[i, j-1]\} & \text{se } i, j > 0 \text{ e } x_i \neq y_j \end{cases}$$

Subcadeia comum máxima (cont.)

SCM(X, m, Y, n, c, b)

```

01. para  $i = 0$  até  $m$  faça  $c[i, 0] := 0$ 
02. para  $j = 1$  até  $n$  faça  $c[0, j] := 0$ 
03. para  $i = 1$  até  $m$  faça
04.   para  $j = 1$  até  $n$  faça
05.     se  $x_i = y_j$  então
06.        $c[i, j] := c[i - 1, j - 1] + 1$ ;  $b[i, j] := "\diagdown"$ 
07.     senão
08.       se  $c[i, j - 1] > c[i - 1, j]$  então
09.          $c[i, j] := c[i, j - 1]$ ;  $b[i, j] := "\leftarrow"$ 
10.       senão
11.          $c[i, j] := c[i - 1, j]$ ;  $b[i, j] := "\uparrow"$ ;
12.   devolva  $(c[m, n], b)$ .
```

Subcadeia comum máxima - Exemplo

- Exemplo: $X = abcb$ e $Y = bdcab$, $m = 4$ e $n = 5$.

Y		b	d	c	a	b
X	0	1	2	3	4	5
0	0	0	0	0	0	0
a	1	0	0	0	1	1
b	2	0	1	1	1	2
c	3	0	1	1	2	2
b	4	0	1	1	2	3

Y		(b)	d	(c)	a	(b)
X	0	1	2	3	4	5
0						
a	1	↖	↑	↑	↘	←
(b)	2		↘	←	←	↑
(c)	3		↑	↑	↘	←
(b)	4		↘	↑	↑	↑

Relembrando a Fórmula de Recorrência:

$$c[i, j] = \begin{cases} 0 & \text{se } i = 0 \text{ ou } j = 0 \\ c[i - 1, j - 1] + 1 & \text{se } i, j > 0 \text{ e } x_i = y_j \\ \max\{c[i - 1, j], c[i, j - 1]\} & \text{se } i, j > 0 \text{ e } x_i \neq y_j \end{cases}$$

Subcadeia comum máxima - Complexidade

- Claramente, a complexidade do algoritmo é $O(mn)$.
- O algoritmo não encontra a subcadeia comum de tamanho máximo, apenas seu tamanho.
- Com a tabela b preenchida, é fácil encontrar a subcadeia comum máxima.

Subcadeia comum máxima (cont.)

- Para recuperar a solução, basta chamar $Recupera_MSC(b, X, m, n)$.

Recupera_SCM(b, X, i, j)

```

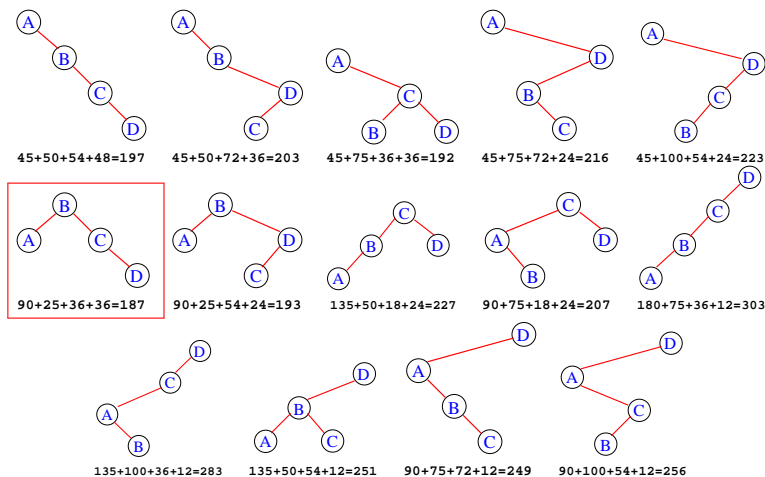
1. se  $i = 0$  e  $j = 0$  então devolva
2. se  $b[i, j] = "\diagdown"$  então
3.    $Recupera\_MSC(b, X, i - 1, j - 1)$ ; imprima  $x_i$ 
4. senão
5.   se  $b[i, j] = "\uparrow"$  então
6.      $Recupera\_MSC(b, X, i - 1, j)$ 
7.   senão
8.      $Recupera\_MSC(b, X, i, j - 1)$ 
```

Subcadeia comum máxima - Complexidade

- A determinação da subcadeia comum máxima é feita em tempo $O(m + n)$ no **pior caso**.
- Portanto, a complexidade de tempo e de espaço do algoritmo de programação dinâmica para o problema da subcadeia comum máxima é $O(mn)$.
- Note que a tabela b é dispensável, podemos economizar memória recuperando a solução a partir da tabela c . Ainda assim, o gasto de memória seria $O(mn)$.
- Caso não haja interesse em determinar a subcadeia comum máxima, mas apenas seu tamanho, é possível reduzir o gasto de memória para $O(\min\{n, m\})$: basta registrar apenas a linha da tabela sendo preenchida e a anterior.

Listando as árvores

Não! Número de árvores de busca pode ser muito grande!!



Exercício: Calcule o número de árvores distintas com n nós.


Problema da Árvore de Busca Ótima

Problema da Árvore de Busca

Dados elementos $(e_1 < e_2 < \dots < e_n)$, e sabendo-se que cada e_i será consultado $f(e_i)$ vezes, construir uma árvore de busca binária, tal que o total de nós acessados seja mínimo para se realizar as $\sum_{i=1}^n f(e_i)$ consultas.

Aplicações: Construção de dicionários estáticos, processadores de texto, verificadores de ortografia.

Exemplo: Considere quatro chaves: $A < B < C < D$ e total de consultas $f(A) = 45$, $f(B) = 25$, $f(C) = 18$ e $f(D) = 12$.



Total de nós acessados nesta árvore = 207


Podemos construir todas as árvores e escolher a melhor?

Propriedades da árvore de busca ótima

Definição Se T é uma árvore binária de busca e v é um vértice, denotamos por $T(v)$ a subárvore enraizada em v contendo todos os vértices de T abaixo de v .

No exemplo anterior temos $A < B < C < D$.

Pergunta: Em uma árvore de busca T , podemos ter $T(B)$ nesta forma?




Não: Pois C deveria estar em $T(B)$.

Conclusão: Se T é uma árvore de busca, e v é um vértice de T , então $T(v)$ contém apenas elementos consecutivos.

Propriedades da árvore de busca ótima (Cont.)

Sejam T uma árvore de busca ótima, e_j um vértice de T e digamos que $T(e_j) = \{e_i, \dots, e_{j-1}, e_j, e_{j+1}, \dots, e_k\}$. Então:

- no ramo esquerdo deve haver os elementos e_i, \dots, e_{j-1} .
- no ramo direito deve haver os elementos e_{j+1}, \dots, e_k .
- as sub-árvores de $\{e_i, \dots, e_{j-1}\}$ e $\{e_{j+1}, \dots, e_k\}$ devem ser ótimas.



- O número total de acessos à raiz em uma árvore de busca é a soma do número de acessos a todos os nós na árvore.
- Qualquer $e_j \in \{e_i, \dots, e_k\}$ é candidato a ser raiz.

Definição recursiva da solução ótima

Idéia: Gerar árvores de busca a partir de árvores de busca de tamanhos menores

Estratégia: Bottom-Up

Seja $A(e_i, \dots, e_k) :=$ número de nós acessados em uma árvore ótima contendo $\{e_i, \dots, e_k\}$.

Então:

$$A(\emptyset) = 0$$

$$A(e_i, \dots, e_k) = \min_{i \leq j \leq k} \{A(e_i, \dots, e_{j-1}) + A(e_{j+1}, \dots, e_k)\} + \sum_{\ell=i}^k f(e_\ell)$$

Daí, se deduz que:

$$A(e_i) = f(e_i)$$

Tabela $M (n \times n + 1)$

Item \ Tam.Seq.	0	1	...	t	...	n
e_1	0	$f(e_1)$	$M(1, n)$
e_2	0	$f(e_2)$	
\vdots	\vdots	\vdots	
e_i	0	$f(e_i)$...	$M(i, t) := A(e_i, \dots, e_k)$...	
\vdots	0	\vdots	...			
e_k	0	$f(e_k)$...			
\vdots	0	\vdots	...			
e_n	0	$f(e_n)$				

onde $k = i + t - 1$

$$A(\emptyset) = 0$$

$$A(e_i) = f(e_i)$$

$$A(e_i, \dots, e_k) = \min_{i \leq j \leq k} \{A(e_i, \dots, e_{j-1}) + A(e_{j+1}, \dots, e_k)\} + \sum_{\ell=i}^k f(e_\ell)$$

Tabela $M (n = 4)$

$$M(1, 1), M(2, 1), M(3, 1), M(4, 1)$$

$$M(1, 2), M(2, 2), M(3, 2)$$


$$M(1, 3), M(2, 3)$$

$$M(1, 4)$$

Árvores ótimas de tamanho 1




Árvores ótimas de tamanho 2



Árvores ótimas de tamanho 3



Árvores ótimas de tamanho 4



ÁRVORE-BUSCA(e_1, \dots, e_n, f)

```

1 para  $i \leftarrow 0$  até  $n + 1$  faça  $M(i, 0) \leftarrow 0$ 
2 para  $t \leftarrow 1$  até  $n$  faça (*  $t =$  tamanho *)
3   para  $i \leftarrow 1$  até  $n - t + 1$  faça (*  $i =$  pos. inicial *)
4      $S \leftarrow f(e_i) + f(e_{i+1}) + \dots + f(e_{i+t-1})$ 
5      $M(i, t) \leftarrow \min_{0 \leq t' \leq t-1} \{M(i, t') + M(i + t' + 1, t - t' - 1)\} + S$ 

```

Solução em $M(1, n)$.

Teorema

O algoritmo ÁRVORE-BUSCA encontra o valor da árvore de busca ótima em tempo $O(n^3)$.

O algoritmo apresentado para resolver o Problema da Árvore Ótima apenas determina o número total de acessos aos nós para se realizar todas as consultas.

Modifique o algoritmo de maneira que dele se possa obter a árvore de busca ótima.