

Projeto e Análise de Algoritmos

A. G. Silva

Baseado nos materiais de
Fernandes, Feofiloff, Pina, Roman – USP
Souza, Silva, Lee, Rezende, Miyazawa – Unicamp
Monteforte – UFABC

25 de maio de 2018

Conteúdo programático

- Introdução (4 horas/aula)
- Notação Assintótica e Crescimento de Funções (4 horas/aula)
- Recorrências (4 horas/aula)
- Divisão e Conquista (12 horas/aula)
- Grafos (4 horas/aula)
- Buscas (4 horas/aula)
- Algoritmos Gulosos (8 horas aula)
- Programação Dinâmica (8 horas/aula)
- NP-Compleitude e Reduções (6 horas/aula)
- Algoritmos Aproximados e Busca Heurística (6 horas/aula)

Cronograma

- **02mar** – Apresentação da disciplina. Introdução.
- **09mar** – *Prova de proficiência/dispensa.*
- **16mar** – Notação assintótica. Recorrências.
- **23mar** – *Dia não letivo.* Exercícios.
- **30mar** – *Dia não letivo.* Exercícios.
- **06abr** – Recorrências. Divisão e conquista.
- **13abr** – Divisão e conquista. Ordenação.
- **20abr** – Ordenação. Estatística de ordem.
- **27abr** – **Primeira avaliação.**
- **04mai** – Estatística de ordem. Grafos. Buscas.
- **11mai** – Buscas. Algoritmos gulosos.
- **18mai** – Algoritmos gulosos.
- **25mai** – Algoritmos gulosos. Programação dinâmica .
- **01jun** – *Dia não letivo.* Exercícios.
- **08jun** – *Semana Acadêmica.* Exercícios.
- **15jun** – Programação dinâmica. NP-Completeness e reduções.
- **22jun** – Exercícios (*copa*).
- **29jun** – **Segunda avaliação.**
- **06jul** – **Avaliação substitutiva** (*opcional*).

Algoritmos gulosos: conceitos básicos

- São aqueles que, a cada decisão:
 - Sempre escolhem a alternativa que parece mais promissora naquele instante: critério guloso – **decisão localmente ótima!**
 - Nunca reconsideram essa decisão
 - Uma escolha que foi feita nunca é revista
 - Não há *backtracking*

Algoritmos gulosos – caminho mínimo

Problema do(s) Caminho(s) Mínimo(s)

Seja G um grafo **orientado** e suponha que para cada aresta (u, v) associamos um **peso** (custo, distância) $w(u, v)$. Usaremos a notação (G, w) .

- **Problema do Caminho Mínimo entre Dois Vértices:**

Dados dois vértices **s** e **t** em (G, w) , encontrar um caminho (de peso) mínimo de **s** a **t**.

- Aparentemente, este problema não é mais fácil do que o

Problema dos Caminhos Mínimos com Mesma Origem:

Dados (G, w) e **s** $\in V[G]$, encontrar para cada vértice **v** de G , um caminho mínimo de **s** a **v**.

Subestrutura ótima de caminhos mínimos

Teorema. Seja (G, w) um grafo orientado e seja

$$P = (v_1, v_2, \dots, v_k)$$

um **caminho mínimo** de v_1 a v_k .

Então para quaisquer i, j com $1 \leq i \leq j \leq k$

$$P_{ij} = (v_i, v_{i+1}, \dots, v_j)$$

é um **caminho mínimo** de v_i a v_j .

Representação de caminhos mínimos

- Usamos uma idéia similar à usada em Busca em Largura nos algoritmos de caminhos mínimos que veremos.
- Para cada vértice $v \in V[G]$ associamos um predecessor $\pi[v]$.
- Ao final do algoritmo obtemos uma **Árvore de Caminhos Mínimos** com raiz s .
- Um caminho de s a v nesta árvore é um caminho mínimo de s a v em (G, w) .

Estimativa de distâncias

- Para cada $v \in V[G]$ queremos determinar $dist(s, v)$, o peso de um caminho mínimo de s a v em (G, w) (distância de s a v .)
- Os algoritmos de caminhos mínimos associam a cada $v \in V[G]$ um valor $d[v]$ que é uma estimativa da distância $dist(s, v)$.

Inicialização

INITIALIZE-SINGLE-SOURCE(G, s)

- 1 **para cada** vértice $v \in V[G]$ **faça**
- 2 $d[v] \leftarrow \infty$
- 3 $\pi[v] \leftarrow \text{NIL}$
- 4 $d[s] \leftarrow 0$



O valor $d[v]$ é uma **estimativa superior** para o peso de um caminho mínimo de s a v .

Ele indica que o algoritmo encontrou até aquele momento um caminho de s a v com peso $d[v]$.

O caminho pode ser recuperado por meio dos predecessores $\pi[]$.

Relaxação

Tenta melhorar a estimativa $d[v]$ examinando (u, v) .





$RELAX(u, v, w)$

- 1 **se** $d[v] > d[u] + w(u, v)$
- 2 **então** $d[v] \leftarrow d[u] + w(u, v)$
- 3 $\pi[v] \leftarrow u$

Relaxação dos vizinhos

Em cada iteração o algoritmo seleciona um vértice u e para cada vizinho v de u aplica $\text{RELAX}(u, v, w)$.



$\text{RELAX}(u, v, w)$

- 1 se $d[v] > d[u] + w(u, v)$ faça
- 2 $d[v] \leftarrow d[u] + w(u, v)$
- 3 $\pi[v] \leftarrow u$

Caminhos Mínimos

Veremos três algoritmos baseados em relaxação para tipos de instâncias diferentes de Problemas de Caminhos Mínimos.

- G é acíclico: aplicação de ordenação topológica
- (G, w) não tem arestas de peso negativo: algoritmo de Dijkstra
- (G, w) tem arestas de peso negativo, mas não contém ciclos negativos: algoritmo de Bellman-Ford.

Caminhos mínimos em grafos acíclicos


Entrada: grafo orientado acíclico $G = (V, E)$ com função peso w nas arestas e uma origem s .

Saída: vetor $d[v] = dist(s, v)$ para $v \in V$
e uma **Árvore de Caminhos Mínimos** definida por $\pi[]$.


DAG-SHORTEST-PATHS(G, w, s)

- 1 Ordene topologicamente os vértices de G
- 2 **INITIALIZE-SINGLE-SOURCE**(G, s)
- 3 **para cada** vértice u na ordem topológica **faça**
- 4 **para cada** $v \in Adj[u]$ **faça**
- 5 **RELAX**(u, v, w)


Exemplo




Exemplo




Exemplo




Exemplo




Exemplo



Exemplo



Exemplo



DAG-SHORTEST-PATHS(G, w, s)

- 1 Ordene topologicamente os vértices de G
- 2 **INITIALIZE-SINGLE-SOURCE**(G, s)
- 3 **para cada** vértice u na ordem topológica **faça**
- 4 **para cada** $v \in \text{Adj}[u]$ **faça**
- 5 **RELAX**(u, v, w)

Linha(s)	Tempo total
1	$O(V + E)$
2	$O(V)$
3-5	$O(V + E)$

Complexidade de **DAG-SHORTEST-PATHS**: $O(V + E)$

Algoritmo de Dijkstra

O algoritmo de Dijkstra recebe um grafo orientado (G, w) (sem arestas de peso negativo) e um vértice s de G

e devolve

- para cada $v \in V[G]$, o peso de um caminho mínimo de s a v
- e uma Árvore de Caminhos Mínimos com raiz s .
Um caminho de s a v nesta árvore é um caminho mínimo de s a v em (G, w) .

Algoritmo de Dijkstra

DIJKSTRA(G, w, s)

1 INITIALIZE-SINGLE-SOURCE(G, s)

2 $S \leftarrow \emptyset$

3 $Q \leftarrow V[G]$

4 **enquanto** $Q \neq \emptyset$ **faça**

5 $u \leftarrow \text{EXTRACT-MIN}(Q)$

6 $S \leftarrow S \cup \{u\}$

7 **para cada** vértice $v \in \text{Adj}[u]$ **faça**

8 RELAX(u, v, w)

O conjunto Q é implementado como uma fila de prioridade.


O conjunto S não é realmente necessário, mas simplifica a análise do algoritmo.

Intuição do algoritmo


Em cada iteração, o algoritmo de DIJKSTRA

- escolhe um vértice u fora do conjunto S que esteja mais próximo a esse e acrescenta-o a S ,
- atualiza as distâncias estimadas dos vizinhos de u e
- atualiza a **Árvore dos Caminhos Mínimos**.


Exemplo (CLRS modificado)




Exemplo (CLRS modificado)




Exemplo (CLRS modificado)




Exemplo (CLRS modificado)




Exemplo (CLRS modificado)



Exemplo (CLRS modificado)



Exemplo (CLRS modificado)



Complexidade de tempo

DIJKSTRA(G, w, s)

```
1  INITIALIZE-SINGLE-SOURCE( $G, s$ )
2   $S \leftarrow \emptyset$ 
3   $Q \leftarrow V[G]$ 
4  enquanto  $Q \neq \emptyset$  faça
5       $u \leftarrow \text{EXTRACT-MIN}(Q)$ 
6       $S \leftarrow S \cup \{u\}$ 
7      para cada vértice  $v \in \text{Adj}[u]$  faça
8          RELAX( $u, v, w$ )
```

Depende de como a fila de prioridade Q é implementada.

Complexidade de tempo

A fila de prioridade Q é mantida com as seguintes operações:

- **INSERT** (implícito na linha 3)
- **EXTRACT-MIN** (linha 5) e
- **DECREASE-KEY** (implícito em **RELAX** na linha 8).

São executados (no máximo) $|V|$ operações **EXTRACT-MIN**.

Cada vértice $u \in V[G]$ é inserido em S (no máximo) uma vez e cada aresta (u, v) com $v \in \text{Adj}[u]$ é examinada (no máximo) uma vez nas linhas 7-8 durante todo o algoritmo. Assim, são executados no máximo $|E|$ operações **DECREASE-KEY**.

Complexidade de tempo

No total temos $|V|$ chamadas a **EXTRACT-MIN** e $|E|$ chamadas a **DECREASE-KEY**.

- Implementando Q como um vetor (coloque $d[v]$ na posição v do vetor), **INSERT** e **DECREASE-KEY** gastam tempo $\Theta(1)$ e **EXTRACT-MIN** gasta tempo $O(V)$, resultando em um total de $O(V^2 + E) = O(V^2)$.
- Implementando a fila de prioridade Q como um min-heap, **INSERT**, **EXTRACT-MIN** e **DECREASE-KEY** gastam tempo $O(\lg V)$, resultando em um total de $O((V + E) \lg V)$.
- Usando **heaps de Fibonacci** (**EXTRACT-MIN** é $O(\lg V)$ e **DECREASE-KEY** é $O(1)$) a complexidade reduz para $O(V \lg V + E)$.

Arestas/ciclos de peso negativo

- O algoritmo de Dijkstra resolve o Problema dos Caminhos Mínimos quando (G, w) não possui arestas de peso negativo.
- Quando (G, w) possui arestas negativas, o algoritmo de Dijkstra não funciona (Exercício).
- Uma das dificuldades com arestas negativas é a possível existência de ciclos de peso negativo ou simplesmente ciclos negativos.

Ciclos negativos — uma dificuldade

- Se um ciclo negativo **C** é atingível a partir da fonte **S**, em princípio o problema não tem solução pois o “caminho” pode passar ao longo do ciclo infinitas vezes obtendo caminhos cada vez menores.
- Naturalmente, podemos impor a restrição de que os caminhos tem que ser **simples**, sem repetição de vértices. Entretanto, esta versão do problema é **NP-difícil**.
- Assim, vamos nos restringir ao Problema de Caminhos Mínimos **sem ciclos negativos**.

O algoritmo de Bellman-Ford

O algoritmo de Bellman-Ford recebe um grafo orientado (G, w) (possivelmente com arestas de peso negativo) e um vértice origem s de G

Ele devolve um valor booleano

- FALSE se existe um ciclo negativo atingível a partir de s , ou
- TRUE e neste caso devolve também uma **Árvore de Caminhos Mínimos** com raiz s .


O algoritmo de Bellman-Ford

BELLMAN-FORD(G, w, s)

```
1  INITIALIZE-SINGLE-SOURCE( $G, s$ )
2  para  $i \leftarrow 1$  até  $|V[G]| - 1$  faça
3      para cada aresta  $(u, v) \in E[G]$  faça
4          RELAX( $u, v, w$ )
5  para cada aresta  $(u, v) \in E[G]$  faça
6      se  $d[v] > d[u] + w(u, v)$ 
7          então devolva FALSE
8  devolva TRUE
```

Complexidade de tempo: $O(VE)$


Exemplo (CLRS)



Ordem:

$(t, x), (t, y), (t, z), (x, t), (y, x), (y, z), (z, x), (z, s), (s, t), (s, y)$.


Exemplo (CLRS)



Ordem:

$(t, x), (t, y), (t, z), (x, t), (y, x), (y, z), (z, x), (z, s), (s, t), (s, y)$.


Exemplo (CLRS)



Ordem:

$(t, x), (t, y), (t, z), (x, t), (y, x), (y, z), (z, x), (z, s), (s, t), (s, y)$.


Exemplo (CLRS)



Ordem:

$(t, x), (t, y), (t, z), (x, t), (y, x), (y, z), (z, x), (z, s), (s, t), (s, y)$.

Exemplo (CLRS)



Ordem:

$(t, x), (t, y), (t, z), (x, t), (y, x), (y, z), (z, x), (z, s), (s, t), (s, y)$.

Caminhos mínimos entre todos os pares

O problema agora é dado um grafo (G, w) encontrar para todo para u, v de vértices um caminho mínimo de u a v .

Obviamente podemos executar $|V|$ vezes um algoritmo de Caminhos Mínimos com Mesma Origem.

- Se (G, w) não possui arestas negativas podemos usar o algoritmo de Dijkstra implementando a fila de prioridade como

um vetor: $|V|.O(V^2 + E) = O(V^3 + VE)$ ou

min-heap binário: $|V|.O(E \lg V) = O(VE \lg V)$ ou

heap de Fibonacci: $|V|.O(V \lg V + E) = O(V^2 \lg V + VE)$.

- Se (G, w) possui arestas negativas podemos usar o algoritmo de Bellman-Ford: $|V|.O(VE) = O(V^2E)$.

O algoritmo de Floyd-Warshall

Veremos agora um método direto para resolver o problema que é assintoticamente melhor se G é denso.

O algoritmo de Floyd-Warshall baseia-se em programação dinâmica e resolve o problema em tempo $O(V^3)$.

O grafo (G, w) pode ter arestas negativas, mas suporemos que **não** contém ciclos negativos.

Vamos adotar a convenção de que (i, j) não é uma aresta de G então $w(i, j) = \infty$.

Estrutura de um caminho mínimo

Seja $P = (v_1, v_2, \dots, v_k)$ um caminho (simples).

Um vértice **intermediário** de P é qualquer vértice de P distinto de v_1 e v_k , ou seja, em $\{v_2, \dots, v_{k-1}\}$.

Para simplificar, suponha que $V = \{1, 2, \dots, n\}$.

Estrutura de um caminho mínimo


Sejam i e j dois vértices de G . Considere todos os caminhos cujos **vértices intermediários** pertencem a $\{1, \dots, k\}$. Seja P um caminho mínimo entre todos eles.

O algoritmo de Floyd-Warshall explora a relação entre P e um caminho mínimo de i a j com vértices intermediários em $\{1, \dots, k - 1\}$.

Se k não é um vértice intermediário de P então P é um caminho mínimo de i a j com vértices intermediários em $\{1, \dots, k - 1\}$.

Estrutura de um caminho mínimo

- Se k é um vértice intermediário de P então P pode ser dividido em dois caminhos P_1 (com início em i e fim em k) e P_2 (com início em k e fim em j).



- P_1 é um caminho mínimo de i a k com vértices intermediários em $\{1, \dots, k-1\}$
- P_2 é um caminho mínimo de k a j com vértices intermediários em $\{1, \dots, k-1\}$.

Recorrência para caminhos mínimos

Seja $d_{ij}^{(k)}$ o peso de um caminho mínimo de i a j com vértices intermediários em $\{1, 2, \dots, k\}$.

Quando $k = 0$ então $d_{ij}^{(0)} = w(i, j)$.

Temos a seguinte recorrência:

$$d_{ij}^{(k)} = \begin{cases} w(i, j) & \text{se } k = 0, \\ \min(d_{ij}^{(k-1)}, d_{ik}^{(k-1)} + d_{kj}^{(k-1)}) & \text{se } k \geq 1. \end{cases}$$

Assim, queremos calcular a matrix $D^{(n)} = (d_{ij}^{(n)})$ com $d_{ij}^{(n)} = \text{dist}(i, j)$.

Algoritmo de Floyd-Warshall

A entrada do algoritmo é a matriz $W = (w(i,j))$ com $n = |V|$ linhas e colunas.


A saída é a matriz $D^{(n)}$.

FLOYD-WARSHALL(W)

```
1   $D^{(0)} \leftarrow W$ 
2  para  $k \leftarrow 1$  até  $n$  faça
3      para  $i \leftarrow 1$  até  $n$  faça
4          para  $j \leftarrow 1$  até  $n$  faça
5               $d_{ij}^{(k)} \leftarrow \min(d_{ij}^{(k-1)}, d_{ik}^{(k-1)} + d_{kj}^{(k-1)})$ 
6  devolva  $D^{(n)}$ 
```

Complexidade: $O(V^3)$

Algoritmo de Floyd-Warshall – exemplo




K = 0

	1	2	3	4
1	0	8	inf	1
2	inf	0	1	inf
3	4	inf	0	inf
4	inf	2	9	0

K = 1

	1	2	3	4
1	0	8	inf	1
2	inf	0	1	inf
3	4	inf	0	inf
4	inf	2	9	0




K = 2

	1	2	3	4
1	0	8	inf	1
2	inf	0	1	inf
3	4	12	0	5
4	inf	2	9	0

K = 3

	1	2	3	4
1	0	8	9	1
2	inf	0	1	inf
3	4	12	0	5
4	inf	2	3	0

Algoritmo de Floyd-Warshall – exemplo



K = 4

	1	2	3	4
1	0	8	9	1
2	5	0	1	6
3	4	12	0	5
4	7	2	3	0

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

Como encontrar os caminhos?

O algoritmo precisa devolver também uma matriz $\Pi = (\pi_{ij})$ tal que $\pi_{ij} = \text{NIL}$ se $i = j$ ou se não existe caminho de i a j , e caso contrário, π_{ij} é o predecessor de j em algum caminho mínimo a partir de i .

Podemos computar os predecessores ao mesmo tempo que o algoritmo calcula as matrizes $D^{(k)}$. Determinamos uma seqüência de matrizes $\Pi^{(0)}, \Pi^{(1)}, \dots, \Pi^{(n)}$ e $\pi_{ij}^{(k)}$ é o predecessor de j em um caminho mínimo a partir de i com vértices intermediários em $\{1, 2, \dots, k\}$.

Quando $k = 0$ temos

$$\pi_{ij}^{(0)} = \begin{cases} \text{NIL} & \text{se } i = j \text{ ou } w(i, j) = \infty, \\ i & \text{se } i \neq j \text{ e } w(i, j) < \infty. \end{cases}$$

Como encontrar os caminhos?

Para $k \geq 1$ procedemos da seguinte forma. Considere um caminho mínimo P de i a j .

Se k não aparece em P então tomamos como predecessor de j o predecessor de j em um caminho mínimo de i a j com vértices intermediários em $\{1, 2, \dots, k-1\}$.

Caso contrário, tomamos como predecessor de j o predecessor de j em um caminho mínimo de k a j com vértices intermediários em $\{1, 2, \dots, k-1\}$.

Formalmente,

$$\pi_{ij}^{(k)} = \begin{cases} \pi_{ij}^{(k-1)} & \text{se } d_{ij}^{(k-1)} \leq d_{ik}^{(k-1)} + d_{kj}^{(k-1)}, \\ \pi_{kj}^{(k-1)} & \text{se } d_{ij}^{(k-1)} > d_{ik}^{(k-1)} + d_{kj}^{(k-1)}. \end{cases}$$

Exercício. Incorpore esta parte no algoritmo!

Passos do projeto de algoritmos gulosos: resumo

- 1 Formule o problema como um **problema de otimização** no qual uma escolha é feita, restando-nos então resolver um único subproblema a resolver.
- 2 Provar que existe sempre uma solução ótima do problema que atende à **escolha gulosa**, ou seja, a escolha feita pelo algoritmo guloso é segura.
- 3 Demonstrar que, uma vez feita a escolha gulosa, o que resta a resolver é um subproblema tal que se combinarmos a resposta ótima deste subproblema com o(s) elemento(s) da escolha gulosa, chega-se à solução ótima do problema original.

Esta é a parte que requer mais engenhosidade!

Normalmente a prova começa com uma solução ótima *genérica* e a modificamos até que ela inclua o(s) elemento(s) identificados pela escolha gulosa.

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**.
- Logo, para que o algoritmo de programação dinâmica seja eficiente, é preciso que o número total de subproblemas que devem ser resolvidos seja pequeno (polinomial no tamanho da entrada).

Programação dinâmica – números de Fibonacci

Números de Fibonacci

$$F_0 = 0 \quad F_1 = 1 \quad F_n = F_{n-1} + F_{n-2}$$

n	0	1	2	3	4	5	6	7	8	9
F_n	0	1	1	2	3	5	8	13	21	34

Algoritmo recursivo para F_n :

FIBO-REC (n)

1 **se** $n \leq 1$

2 **então devolva** n

3 **senão** $a \leftarrow$ **FIBO-REC** ($n - 1$)

4 $b \leftarrow$ **FIBO-REC** ($n - 2$)

5 **devolva** $a + b$

Consumo de tempo

FIBO-REC (n)

```
1  se  $n \leq 1$ 
2    então devolva  $n$ 
3    senão  $a \leftarrow$  FIBO-REC ( $n - 1$ )
4           $b \leftarrow$  FIBO-REC ( $n - 2$ )
5          devolva  $a + b$ 
```

Tempo em segundos:

n	16	32	40	41	42	43	44	45	47
tempo	0.002	0.06	2.91	4.71	7.62	12.37	19.94	32.37	84.50

$$F_{47} = 2971215073$$

Consumo de tempo

FIBO-REC (n)

```
1  se  $n \leq 1$ 
2    então devolva  $n$ 
3    senão  $a \leftarrow$  FIBO-REC ( $n - 1$ )
4           $b \leftarrow$  FIBO-REC ( $n - 2$ )
5          devolva  $a + b$ 
```

$T(n) :=$ número de somas feitas por FIBO-REC (n)

linha	número de somas
1-2	= 0
3	= $T(n - 1)$
4	= $T(n - 2)$
5	= 1
$T(n)$	= $T(n - 1) + T(n - 2) + 1$

Recorrência

$$T(0) = 0$$

$$T(1) = 0$$

$$T(n) = T(n-1) + T(n-2) + 1 \text{ para } n = 2, 3, \dots$$

A que classe Ω pertence $T(n)$?

A que classe O pertence $T(n)$?

Solução: $T(n) > (3/2)^n$ para $n \geq 6$.

n	0	1	2	3	4	5	6	7	8	9
T_n	0	0	1	2	4	7	12	20	33	54
$(3/2)^n$	1	1.5	2.25	3.38	5.06	7.59	11.39	17.09	25.63	38.4

Recorrência

Prova: $T(6) = 12 > 11.40 > (3/2)^6$ e $T(7) = 20 > 18 > (3/2)^7$.

Se $n \geq 8$, então

$$T(n) = T(n-1) + T(n-2) + 1$$

$$\begin{aligned} & \text{hi} \\ & > (3/2)^{n-1} + (3/2)^{n-2} + 1 \end{aligned}$$

$$= (3/2 + 1) (3/2)^{n-2} + 1$$

$$> (5/2) (3/2)^{n-2}$$

$$> (9/4) (3/2)^{n-2}$$

$$= (3/2)^2 (3/2)^{n-2}$$

$$= (3/2)^n .$$


Logo, $T(n)$ é $\Omega((3/2)^n)$.

Verifique que $T(n)$ é $O(2^n)$.

Consumo de tempo

Consumo de tempo é **exponencial**.

Algoritmo resolve subproblemas muitas vezes.



Resolve subproblemas muitas vezes

FIBO-REC (5)

 FIBO-REC (4)

 FIBO-REC (3)

 FIBO-REC (2)

 FIBO-REC (1)

 FIBO-REC (0)

 FIBO-REC (1)

 FIBO-REC (2)

 FIBO-REC (1)

 FIBO-REC (0)

 FIBO-REC (3)

 FIBO-REC (2)

 FIBO-REC (1)

 FIBO-REC (0)

 FIBO-REC (1)

FIBO-REC(5) = 5

Resolve subproblemas muitas vezes

FIBO-REC (8)

FIBO-REC (7)

FIBO-REC (6)

FIBO-REC (5)

FIBO-REC (4)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (4)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (5)

FIBO-REC (4)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (6)

FIBO-REC (5)

FIBO-REC (4)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (4)

FIBO-REC (3)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

FIBO-REC (1)

FIBO-REC (2)

FIBO-REC (1)

FIBO-REC (0)

Programação dinâmica

"Dynamic programming is a fancy name for divide-and-conquer with a table. Instead of solving subproblems recursively, solve them sequentially and store their solutions in a table. The trick is to solve them in the right order so that whenever the solution to a subproblem is needed, it is already available in the table. Dynamic programming is particularly useful on problems for which divide-and-conquer appears to yield an exponential number of subproblems, but there are really only a small number of subproblems repeated exponentially often. In this case, it makes sense to compute each solution the first time and store it away in a table for later use, instead of recomputing it recursively every time it is needed."

I. Parberry, Problems on Algorithms, Prentice Hall, 1995.

Algoritmo de programação dinâmica

FIBO (n)

```
1   $f[0] \leftarrow 0$   
2   $f[1] \leftarrow 1$   
3  para  $i \leftarrow 2$  até  $n$  faça  
4       $f[i] \leftarrow f[i-1] + f[i-2]$   
5  devolva  $f[n]$ 
```

Note a tabela $f[0 \dots n-1]$.

f					*	*	??			
-----	--	--	--	--	---	---	----	--	--	--

Consumo de tempo (e de espaço) é $\Theta(n)$.

Algoritmo de programação dinâmica

Versão com economia de espaço.

```
FIBO (n)  
0  se n = 0 então devolva 0  
1  f_ant  $\leftarrow$  0  
2  f_atual  $\leftarrow$  1  
3  para i  $\leftarrow$  2 até n faça  
4      f_prox  $\leftarrow$  f_atual + f_ant  
5      f_ant  $\leftarrow$  f_atual  
6      f_atual  $\leftarrow$  f_prox  
7  devolva f_atual
```

Consumo de tempo é $\Theta(n)$.

Consumo de espaço é $\Theta(1)$.

Versão recursiva eficiente

MEMOIZED-FIBO (f, n)

- 1 **para** $i \leftarrow 0$ **até** n **faça**
- 2 $f[i] \leftarrow -1$
- 3 **devolva** LOOKUP-FIBO (f, n)

LOOKUP-FIBO (f, n)

- 1 **se** $f[n] \geq 0$
- 2 **então devolva** $f[n]$
- 3 **se** $n \leq 1$
- 4 **então** $f[n] \leftarrow n$
- 5 **senão** $f[n] \leftarrow$ LOOKUP-FIBO($f, n - 1$)
 $+ \text{LOOKUP-FIBO}(f, n - 2)$
- 6 **devolva** $f[n]$

Não recalcula valores de f .

Programação dinâmica – multiplicação de cadeias de matrizes

Multiplicação de Cadeias de Matrizes

Problema: Multiplicação de Matrizes

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

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

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.
- Consideraremos que para calcular a matriz M' dada por $M_i \times M_{i+1}$ são necessárias $b_{i-1} * b_i * b_{i+1}$ multiplicações entre os elementos de M_i e M_{i+1} .

Multiplicação de Cadeias de Matrizes (Cont.)

- **Exemplo:** Qual é o mínimo de multiplicações escalares necessárias 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:
 - $M = (M_1 \times (M_2 \times (M_3 \times M_4))) \rightarrow 5.300$ multiplicações
 - $M = (M_1 \times ((M_2 \times M_3) \times M_4)) \rightarrow 3.400$ multiplicações
 - $M = ((M_1 \times M_2) \times (M_3 \times M_4)) \rightarrow 4.500$ multiplicações
 - $M = ((M_1 \times (M_2 \times M_3)) \times M_4) \rightarrow 29.200$ multiplicações
 - $M = (((M_1 \times M_2) \times M_3) \times M_4) \rightarrow 152.000$ multiplicações
- A ordem das multiplicações faz **muita** diferença !

Multiplicação de Cadeias de Matrizes (Cont.)

- 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 $P(n) \in \Omega(4^n/n^{\frac{3}{2}})$, a estratégia de força bruta é impraticável !

Multiplicação de Cadeias de Matrizes (Cont.)

- 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 $M = M_{i,k} \times M_{k+1,j}$.

- Como a parentização de M é ótima, as parentizações no cálculo de $M_{i,k}$ e $M_{k+1,j}$ 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 $M_{k+1,j}$.

Multiplicação de Cadeias de Matrizes (Cont.)

- De forma geral, se $m[i, j]$ é número mínimo de multiplicações que deve ser efetuado para computar $M_i \times M_{i+1} \times \dots \times M_j$, 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.

Multiplicação de Matrizes - Algoritmo Recursivo

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 necessário 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 ($s[i, j]$).

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

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

Algoritmo Recursivo - Complexidade

- O número mínimo de operações feita 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 impraticável !

Algoritmo Recursivo - Complexidade


- 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.

Memorização x Programação Dinâmica

- 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. Elimina completamente a recursão.

Algoritmo de Memorização

- Árvore de recursão do algoritmo de memorização para multiplicação de cadeia de matrizes **Memorizacao**($b, 1, 4$)
 - As chamadas às subárvores em cinza são trocadas por consultas a valores já calculados e *memorizados* (ou, se preferir, o neologismo “*memoizados*”) na tabela



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 .

MinimoMultiplicacoes(b)

▷ **Entrada:** Vetor b com dimensões das matrizes.



▷ **Saída:** As tabelas m e s preenchidas.

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

Algoritmo de Programação Dinâmica – exemplo

- Cadeia de $n = 6$ matrizes com as seguintes dimensões:

matriz		A_1	A_2	A_3	A_4	A_5	A_6
dimensão		30×35	35×15	15×5	5×10	10×20	20×25
vetor b	30	35	15	5	10	20	25



$$m[2, 5] = \min \begin{cases} m[2,2] + m[3,5] + b[1] * b[2] * b[5] = 0 + 2500 + 35 \cdot 15 \cdot 20 & = 13000 \\ m[2,3] + m[4,5] + b[1] * b[3] * b[5] = 2625 + 1000 + 35 \cdot 5 \cdot 20 & = 7125 \\ m[2,4] + m[5,5] + b[1] * b[4] * b[5] = 4375 + 0 + 35 \cdot 10 \cdot 20 & = 11375 \end{cases}$$

IMPRIMA-PARENTIZACAO-OTIMA(s, i, j)

```
1: se  $i = j$  então  
2:   imprima " $A_i$ "  
3: senão  
4:   imprima "("  
5:   IMPRIMA-PARENTIZACAO-OTIMA( $s, i, s[i, j]$ )  
6:   IMPRIMA-PARENTIZACAO-OTIMA( $s, s[i, j] + 1, j$ )  
7:   imprima ")"
```

No exemplo anterior, se for feita a chamada
IMPRIMA-PARENTIZACAO-OTIMA($s, 1, 6$)
será impresso:

$$((A_1(A_2A_3))((A_4A_5)A_6))$$

Algoritmo de Programação Dinâmica - Exemplo

	i i+1 i+2 i+3 j						
i							
i+1							
i+2							
i+3							
j							

Algoritmo de Programação Dinâmica - Exemplo

	1	2	3	4
1	0			
2		0		
3			0	
4				0

m

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

s

Algoritmo de Programação Dinâmica - Exemplo

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

m

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

s

{ 200, 2, 30, 20, 5 }

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

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

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

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

{ 200, 2, 30, 20, 5 }

IMPRIMA-PARENTIZACAO-OTIMA(s, i, j)

- 1: **se** $i = j$ **então**
- 2: imprima " A_i "
- 3: **senão**
- 4: imprima "("
- 5: IMPRIMA-PARENTIZACAO-OTIMA($s, i, s[i, j]$)
- 6: IMPRIMA-PARENTIZACAO-OTIMA($s, s[i, j] + 1, j$)
- 7: imprima ")"

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 ((M2 . M3) . M4)

- A complexidade de tempo do algoritmo é dada por:

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

- 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.

Programação dinâmica – o problema binário da mochila

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 $i = 1, \dots, n$.

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

- 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:

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

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

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

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!

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.

Mochila - Programação Dinâmica

- 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.



$$z[k,d] = \max \{ z[k-1,d], z[k-1,d-w[k]] + c[k] \}$$

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 $W = 7$.

$\begin{array}{c} d \\ \diagdown \\ k \end{array}$	0	1	2	3	4	5	6	7
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 $W = 7$.

k \ d	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							
3	0							
4	0							

Mochila - Exemplo

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

k \ d	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							
4	0							

Mochila - Exemplo

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

$\begin{matrix} d \\ \backslash k \end{matrix}$	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 $W = 7$.

$\begin{smallmatrix} d \\ \backslash k \end{smallmatrix}$	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 $W = 7$.

$\begin{smallmatrix} d \\ \backslash k \end{smallmatrix}$	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 $W = 7$.

$\begin{matrix} d \\ \backslash k \end{matrix}$	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	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 $W = 7$.

$\begin{smallmatrix} d \\ \backslash k \end{smallmatrix}$	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 $W = 7$.

$\begin{smallmatrix} d \\ \backslash k \end{smallmatrix}$	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 $W = 7$.

$\begin{array}{c} d \\ \backslash k \end{array}$	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

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

Mochila - Complexidade

- 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.

Programação dinâmica – subcadeia comum máxima

Subcadeia comum máxima

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.)

- 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.

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. $c[i, j] := c[i - 1, j - 1] + 1$; $b[i, j] := \text{"↖"}$
07. **senão**
08. **se** $c[i, j - 1] > c[i - 1, j]$ **então**
09. $c[i, j] := c[i, j - 1]$; $b[i, j] := \text{"←"}$
10. **senão**
11. $c[i, j] := c[i - 1, j]$; $b[i, j] := \text{"↑"}$;
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	0	1	1
b	2	0	1	1	1	1	2
c	3	0	1	1	2	2	2
b	4	0	1	1	2	2	3

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

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** $b[i, j] = "\nwarrow"$ **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.