Projeto e Análise de Algoritmos (2025-1)

Flávio L. C. de Moura*

2 de junho de 2025

Programação Dinâmica

A metodologia conhecida como programação dinâmica foi inventada pelo matemático americano Richard Bellman por volta de 1950 como um método genérico para otimizar processos de decisão. Assim, a palavra programação está mais relacionada com a ideia de planejamento, e não com programação de computadores. Depois de se estabelecer como uma importante técnica em Matemática Aplicada, a programação dinâmica passou a ser utilizada como uma estratégia de 'dividir e conquistar' juntamente com uma tabela [3], pois ao invés de resolver os subproblemas recursivamente, os mesmos são resolvidos sequencialmente e as soluções são armazenadas em uma tabela. Desta forma, esta metodologia é utilizada para resolver problemas subdividindo-os em subproblemas como na estratégia de dividir e conquistar, mas com uma diferença fundamental: os subproblemas se sobrepõem, e para evitar que o mesmo subproblema seja calculado mais de uma vez, os resultados são armazenados em uma tabela.

Números de Fibonacci

Considere o problema de computar o n-ésimo número de Fibonacci:

$$F_n = \begin{cases} 0, & \text{se } n = 0 \\ 1, & \text{se } n = 1 \\ F_{n-1} + F_{n-2}, & \text{se } n > 1 \end{cases} \tag{1}$$

Complexidade exponencial

Uma implementação direta da definição acima nos permite analisar a complexidade $T(n)$ necessária para computar o n-ésimo número de Fibonacci pela seguinte equação de recorrência:

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

*flaviomoura@unb.br

que tem solução exponencial, i.e. $T(n) = O(2^n)$. De fato, $\forall n > 1, T(n) = T(n-1)+T(n-2) \Rightarrow 2\,T(n-2) \leq T(n) \leq 2\,T(n-1)$. De acordo com a paridade de n, temos os seguintes casos:

1. n é par: $\sqrt{2}^n/2 = 2^{n/2-1} = 2^{n/2-1}T(2) \leq T(n) \leq 2^{n-1}T(1) = 2^{n-1}$

2. n é ímpar: $\sqrt{2}^{n-1} = 2^{(n-1)/2}T(1) \leq T(n) \leq 2^{n-1}T(1) = 2^{n-1}$

Consequentemente, $T(n) = O(2^n)$ e $T(n) = \Omega(\sqrt{2}^n)$, ou seja, $T(n)$ é limitada tanto inferiormente quanto superiormente por funções de classe de complexidade exponencial.

Mais precisamente, temos que $T(n) = \Theta(\phi^n)$, onde $\phi = \frac{1+\sqrt{5}}{2}$. Este resultado é coerente com os limites anteriores pois $\sqrt{2} < \phi = \frac{1+\sqrt{5}}{2} < 2$.

Complexidade linear

Note que o problema neste caso é que cada subproblema foi calculado diversas vezes. A ideia para resolver este problema de forma mais eficiente é evitar refazer computações já feitas anteriormente preenchendo a entrada f[i] do vetor f com o i-ésimo número de Fibonacci:

Algorithm 1: fib(n)

```
1 f[i] = i, if i < 2;
2 for i = 2 to n do
3 |   f[i] = f[i − 1] + f[i − 2]
4 end
5 return f[n]
```

No pseudocódigo acima, a linha 1 é executada em tempo constante, o **for** das linhas 2-4 é executado $n-1$ vezes, de forma que o tempo de execução deste algoritmo é linear!

Observações

Os problemas que podem ser resolvidos usando programação dinâmica normalmente estão relacionados com *otimização*. No exemplo anterior, encontramos uma forma de *minimizar* o número de somas necessárias para calcular fib(n). Tipicamente, a tabela vai conter os valores correspondentes a todas as chamadas recursivas de forma que o algoritmo principal não precisará fazer nenhuma chamada recursiva já que as mesmas já foram resolvidas e armazenadas na tabela. Por exemplo, no pseudocódigo acima, no momento de calcular f[k], os valores f[$k-1$] e f[$k-2$] já foram computados.

Para que esta metodologia possa ser aplicada é importante que o problema a ser resolvido satisfaça o *princípio da subestrutura ótima*: as soluções ótimas do problema contêm as soluções ótimas dos subproblemas. Programação Dinâmica pode ser vista como uma troca entre espaço e tempo, onde o tempo de execução é reduzido ao custo de espaço extra.

O problema do corte das hastes

Consideremos um outro problema de otimização: o problema do corte das hastes [1]. Suponha que uma empresa deseja cortar hastes de forma a maximizar o valor total obtido pela venda dos pedaços cortados. Assumiremos os seguintes fatos:

1. O corte não tem custo;

2. As hastes são cortadas em pedaços cujos comprimentos são números inteiros.

3. O preço de uma haste de comprimento $i \geq 1$ é igual a p_i.

O problema do corte das hastes pode, então, ser apresentado da seguinte forma: Dados uma haste de comprimento n e uma tabela de preços $P = \langle p_1, p_2, \ldots, p_n \rangle$ para a haste de comprimento $1 \leq i \leq n$, determine a melhor forma de cortar a haste de comprimento n de forma a obter o valor máximo da venda dos pedaços resultantes do corte.

De quantas formas distintas podemos cortar uma haste de comprimento n?

Recorrência

Note que temos $n - 1$ possíveis pontos de corte em uma haste de comprimento n.

Suponha que uma solução ótima divide a haste em $1 \leq k \leq n$ pedaços. Assim, $n = i_1 + i_2 + \ldots + i_k$, onde i_j denota o comprimento do j-ésimo pedaço da haste. O valor a ser obtido a partir da venda destes k pedaços é $v(n) = p_{i_1} + p_{i_2} + \ldots + p_{i_k}$. Nosso objetivo é determinar k de forma que $v(n)$ seja máximo. A recursão que corresponde ao valor máximo a ser obtido é dada por:

$$v(n) = \max\{p_n, v(1) + v(n-1), v(2) + v(n-2), \ldots, v(n-1) + v(1)\}$$

Podemos simplificar esta recursão observando que a divisão da haste consiste em fazer o primeiro corte obtendo um pedaço de comprimento i que não será mais dividido, e um segundo pedaço de comprimento $n - i$ que ainda será dividido de forma a maximizar o valor a ser obtido:

$$v(n) = \max_{1 \leq i \leq n} \{p_i + v(n-i)\} \tag{2}$$

Pseudocódigo força bruta

O pseudocódigo a seguir implementa a computação correspondente à recursão.

Algorithm 2: corte-haste(p, n)

```
1 if n = 0 then
2 |  return 0;
3 end
4 q ← −∞;
5 for i = 1 to n do
6 |  q ← max{q, p[i]+ corte-haste(p, n − i)};
7 end
8 return q;
```

O tempo $T(n)$ de execução deste algoritmo é dado por

$$T(n) = \begin{cases} 1, & n = 0 \\ 1 + \sum_{j=0}^{n-1} T(j), & n > 0 \end{cases}$$

que tem solução exponencial.

Isto não é surpreendente porque o algoritmo corte-haste considera todas as 2^{n-1} possíveis formas de cortar uma haste de comprimento n.

Pseudocódigo (programação dinâmica)

Utilizando programação dinâmica, cada subproblema será resolvido apenas uma vez:

Algorithm 3: corte-hasteDP(p, n)

```
1  let r[0..n] be a new array;
2  r[0] = 0;
3  for j = 1 to n do
4  |  q = −∞;
5  |  for i = 1 to j do
6  |  |  q = max{q, p[i] + r[j − i]};
7  |  end
8  |  r[j] = q;
9  end
10 return r[n];
```

O tempo $T(n)$ de execução deste algoritmo é determinado pelo número de vezes que o **for** das linhas 5-7 é executado:

$$T(n) = \sum_{j=1}^{n} \sum_{i=1}^{j} 1 = \sum_{j=1}^{n} j = \frac{n.(n+1)}{2}$$

e portanto o algoritmo é quadrático no tamanho da entrada.

Observe que o pseudocódigo acima retorna o valor máximo que pode ser obtido com a venda dos pedaços da haste, mas não nos diz como decompor a haste. O pseudocódigo a seguir, além de retornar o valor máximo $r[n]$, também retorna o vetor $s[0..n]$ contendo

Multiplicação de uma cadeia de matrizes.

Queremos computar o produto $A_1 \cdot A_2 \cdot \ldots \cdot A_n$ de forma a executar o menor número possível de multiplicações.

Multiplicação de matrizes

Utilizaremos o algoritmo padrão para multiplicação de duas matrizes:

Algorithm 4: mult-matrix(A, B)

```
1  if A.columns ≠ B.rows then
2  |  error "incompatible dimensions"
3  end
4  else
5  |  let C be a new A.rows × B.columns matrix;
6  |  for i = 1 to A.rows do
7  |  |  for j = 1 to B.columns do
8  |  |  |  c_ij = 0;
9  |  |  |  for k = 1 to A.columns do
10 |  |  |  |  c_ij = c_ij + a_ik.b_kj
11 |  |  |  end
12 |  |  end
13 |  end
14 |  return C
15 end
```

O número exato de multiplicações $T(n)$ realizadas pelo algoritmo acima corresponde ao número de vezes que a linha 10 é executada: Suponha que as dimensões das matrizes A e B sejam, respectivamente iguais a $p \times q$ e $q \times r$, ou seja, a matriz A possui p linhas e q colunas, enquanto que a matriz B possui q linhas e r colunas. Então o total de multiplicações é dado por:

$$\sum_{i=1}^{p}\sum_{j=1}^{r}\sum_{k=1}^{q} 1 = \sum_{i=1}^{p}\sum_{j=1}^{r} q = \sum_{i=1}^{p}(r.q) = p.q.r$$

Em particular, se $n = p = q = r$ então $T(n) = n^3$.

Exemplo

Assim, para multiplicarmos duas matrizes de dimensões respectivamente iguais a 10×4 e 4×20, realizaremos $10.4.20 = 800$ multiplicações. Suponha que estejamos interessados em multiplicar as matrizes A, B e C (nesta ordem) de dimensões respectivamente iguais a 10×4, 4×20 e 20×32. Sabendo que o produto de matrizes é associativo, o produto $A.B.C$ pode ser realizado de duas formas distintas, a saber: $(A.B).C$ ou $A.(B.C)$. O número de multiplicações necessárias para computar o produto $(A.B).C$ utilizando o algoritmo acima é igual ao número de multiplicações para computar o produto $A.B$, que já sabemos ser igual a 800, mais o número de multiplicações necessárias para computar o produto de $A.B$ com C, que é igual a $10.20.32 = 6400$; ou seja, no total precisamos de $800 + 6400 = 7200$ multiplicações para computar o produto $(A.B).C$. Para computar o produto $A.(B.C)$ precisamos de $4.20.32 = 2560$ multiplicações para computar $B.C$, mais $10.4.32 = 1280$ multiplicações para computar o produto de A com $B.C$ perfazendo um total de $2560 + 1280 = 3840$ multiplicações. Portanto, é mais "econômico" multiplicar $A.(B.C)$ do que $(A.B).C$. Este exemplo, nos leva a um problema mais geral que tentaremos resolver:

Complexidade do método de força bruta

Suponha que queiramos multiplicar n matrizes $A_1, A_2, \ldots, A_n$ $(n \geq 1)$. Isto é, queremos computar o produto $A_1.A_2.\ldots.A_n$. Como fazer isto de forma a realizar o menor número de multiplicações possível? Em outras palavras, como devemos associar o produto $A_1.A_2.\ldots.A_n$ de forma a minimizar o número de multiplicações a serem realizadas?

Para motivarmos a utilização de programação dinâmica para resolver este problema, vejamos que a abordagem ingênua (força-bruta) não é eficiente. A abordagem ingênua consiste em escolher a melhor dentre todas as associações possíveis para o produto $A_1, A_2, \ldots, A_n$. Seja $P(n)$ o número total de distintas formas de associar o produto em consideração. Quando $n = 1$, temos apenas uma matriz, e portanto $P(1) = 1$. Quando $n > 1$ então para cada $1 \leq k \leq n-1$ temos $P(k)$ formas de associar o produto $A_1.A_2.\ldots.A_k$, e $P(n-k)$ formas de associar o produto $A_{k+1}.A_{k+2}.\ldots.A_n$. Desta forma, o número total de distintas formas de associar o produto $A_1, A_2, \ldots, A_n$ é dado pela recorrência:

$$P(n) = \begin{cases} 1, & \text{se } n = 1 \\ \displaystyle\sum_{k=1}^{n-1} P(k).P(n-k), & \text{se } n > 1 \end{cases} \tag{3}$$

É possível mostrar que $P(n) = \Omega(2^n)$, e portanto a solução ingênua (força bruta) é exponencial.

Solução via Programação Dinâmica

- Subestrutura ótima

  Antes de construirmos uma solução usando programação dinâmica, vejamos que este problema satisfaz o princípio da subestrutura ótima. Denote o produto $A_i.A_{i+1}\ldots A_j$, onde $i \leq j$ por $A_{i..j}$. Agora suponha que uma associação ótima para $A_{i..j}$ separa o produto entre A_k e A_{k+1} para algum $i \leq k \leq j$, *i.e.* a associação ótima será dada pela associação ótima de $A_{i..k}$ e $A_{k+1..j}$. Em seguida, uma solução será recursivamente construída para o produto $A_{i..k}$ (e para $A_{k+1..j}$).

  Questão: Será que a parentização construída para $A_{i..k}$ na parentização de $A_{i..j}$ é uma solução ótima para $A_{i..k}$? Sim, pois uma possível solução mais eficiente para $A_{i..k}$ nos permitiria substituí-la na solução de $A_{i..j}$ produzindo uma solução melhor do que a ótima, o que é uma contradição.

- Recorrência

  Se denotarmos por $m[i,j]$ o número mínimo de multiplicações necessárias para computar o produto $A_{i..j}$ $(i \leq j)$, então podemos caracterizar o problema de determinar o número mínimo de multiplicações para computar o produto $A_{i..j}$ através da recursão

  $m[i,j] = m[i,k] + m[k+1,j] + p_{i-1}.p_k.p_j$ para algum $i \leq k \leq j$.

  mas qual é o valor de k que devemos tomar? Precisamos considerar todos os valores possíveis para descobrirmos qual minimiza o número de multiplicações:

$$m[i,j] = \begin{cases} 0, & \text{se } i = j \\ \min\limits_{i \leq k \leq j}\{m[i,k] + m[k+1,j] + p_{i-1}.p_k.p_j\}, & \text{se } i < j \end{cases} \tag{4}$$

  Observe que para calcular $m[i,j]$ precisamos conhecer os valores $m[i,k]$ e $m[k+1,j]$ para todo $i \leq k \leq j-1$, ou seja, precisamos conhecer todos os pares de valores $m[i,i]$ e $m[i+1,j]$, $m[i,i+1]$ e $m[i+2,j]$, ..., $m[i,j-1]$ e $m[j,j]$.

  Assim, precisamos considerar todos os valores possíveis de $1 \leq k \leq n$, mas em que ordem devemos preencher a matriz m? A partir da diagonal principal da matriz m, uma vez que $m[i,i] = 0$ para todo $1 \leq i \leq n$.

$$m[1,n] = \min_{1 \leq k \leq n}\{m[1,k] + m[k+1,n] + p_0.p_k.p_n\} \tag{5}$$

onde a dimensão da matriz A_i $(1 \leq i \leq n)$ é igual a $p_{i-1} \times p_i$.

- Pseudocódigo

  O pseudocódigo a seguir recebe como argumento o vetor $p = \langle p_0, p_1, \ldots, p_n \rangle$ contendo as dimensões das matrizes

  $(A_1)_{p_0 \times p_1}, (A_2)_{p_1 \times p_2}, \ldots, (A_n)_{p_{n-1} \times p_n},$

  e retorna as matrizes $m[1..n, 1..n]$ e $s[1..n-1, 2..n]$, onde $m[i, j]$ corresponde ao número mínimo de multiplicações necessárias para computar o produto $A_{i..j}$, e $s[i, j]$ contém o índice k que indica como o produto $A_{i..j}$ deve ser separado:

Algorithm 5: matrix-chain-order(p)

```
1  n ← p.length − 1;
2  let m[1..n, 1..n] and s[1..n − 1, 2..n] be new tables;
3  for i = 1 to n do
4  |  m[i, i] ← 0;
5  end
6  for l = 2 to n do
7  |  for i = 1 to n − l + 1 do
8  |  |  j ← i + l − 1;
9  |  |  m[i, j] ← ∞;
10 |  |  for k = i to j − 1 do
11 |  |  |  q ← m[i, k] + m[k + 1, j] + p_{i−1}.p_k.p_j;
12 |  |  |  if q < m[i, j] then
13 |  |  |  |  m[i, j] ← q;
14 |  |  |  |  s[i, j] ← k;
15 |  |  |  end
16 |  |  end
17 |  end
18 end
```

  – Parentização ótima

Algorithm 6: print-optimal-parens(s, i, j)

```
1 if i == j then
2 |   print A_i;
3 end
4 else
5 |   print "(";
6 |   print-optimal-parens(s, i, s[i, j]);
7 |   print-optimal-parens(s, s[i, j] + 1, j);
8 |   print ")";
9 end
```

A complexidade de tempo de matrix-chain-order é $\Theta(n^3)$ e complexidade de espaço $\Theta(n^2)$.

Exercícios

1. Use o método da substituição para mostrar que a recorrência

$$P(n) = \begin{cases} 1, & \text{se } n = 1 \\ \sum_{k=1}^{n-1} P(k).P(n-k), & \text{se } n > 1 \end{cases} \tag{6}$$

   é $\Omega(2^n)$.

2. Mostre que a recorrência

$$T(n) = \begin{cases} 1, & n = 0 \\ 1 + \sum_{j=0}^{n-1} T(j), & n > 0 \end{cases}$$

   tem solução $T(n) = 2^n$.

3. Considere o seguinte problema: Há uma fila de n moedas cujos valores são alguns inteiros positivos $c_1, c_2, ..., c_n$, não necessariamente distintos. O objetivo é pegar a quantidade máxima de dinheiro sujeita à restrição de que não se pode pegar duas moedas adjacentes na fila inicial.

   (a) Construa uma recorrência para calcular o montante máximo $F(n)$ que pode ser obtido de uma fila com n moedas.

Solução.

$$F(n) = \begin{cases} 0, & \text{se } n = 0 \\ c_1, & \text{se } n = 1 \\ \max(c_n + F(n-2), F(n-1)), & \text{se } n > 1 \end{cases}$$

(b) Qual a complexidade da abordagem de força bruta para este problema?

Solução.
A solução é exponencial. Para isto basta notar a semelhança da recorrência acima com a função de Fibonacci.

(c) Construa uma solução utilizando programação dinâmica e faça a análise assintótica da sua solução.

Solução.
A ideia é ir armazenando as soluções dos problemas menores no vetor F (abordagem *bottom up*) de forma que o mesmo subproblema não será computado mais de uma vez. A entrada do algoritmo é o vetor C contendo os valores $c_1, c_2, \ldots, c_n$ das moedas.

```
1 F[0] ← 0;
2 F[1] ← C[1];
3 for i = 2 to n do
4 |   F[i] ← max(C[i] + F[i − 2], F[i − 1]);
5 end
6 return F[n];
```

O algoritmo é linear, isto é, $\Theta(n)$.

4. Construa um algoritmo eficiente para calcular o coeficiente binomial $C(n, k)$, também denotado por $\binom{n}{k}$, sem utilizar multiplicações. Em seguida, faça a análise assintótica do seu algoritmo.

Solução.

Algorithm 7: Binomial(n, k)

```
for i = 0 to n do
    for j = 0 to min(i, k) do
        if j = 0 or j = i then
            C[i, j] ← 1;
        end
        else
            C[i, j] ← C[i − 1, j − 1] + C[i − 1, j];
        end
    end
end
return C[n, k];
```

$$T(n) = \sum_{i=0}^{n}(\sum_{j=0}^{\max(i,k)} 1) \leq \sum_{i=0}^{n}(\sum_{j=0}^{k} 1) = \sum_{i=0}^{n}(k+1) = (n+1)(k+1) = O(n.k).$$

Leitura complementar:

- [2] (Capítulo 14)
- [1] (Capítulo 15)
- [3] (Capítulo 14)

Referências

[1] T. H. Cormen, C. E. Leiserson, R. L. Rivest, and C. Stein. *Introduction to Algorithms, Third Edition*. The MIT Press, 3rd edition, 2009.

[2] Thomas H. Cormen, Charles E. Leiserson, Ronald L. Rivest, and Clifford Stein. *Introduction to Algorithms*. MIT Press, Cambridge, MA, USA, 4 edition, April 2022.

[3] A. V. Levitin. *Introduction to the Design and Analysis of Algorithms, Third Edition*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 2012.