

AED2 - Aula 01

Apresentação, estruturas de dados, tabelas de símbolos e hash tables

“É esperado de um projetista de algoritmos que ele entenda o problema a resolver e compreenda as ferramentas a sua disposição, para assim tomar decisões embasadas de projeto”.

Apresentação do curso

Princípios de projeto de algoritmos e estrutura de dados, com ênfase no porquê das coisas.

O que é um algoritmo?

- É uma receita para resolver um problema.

Por que estudar algoritmos?

- São importantes para inúmeras áreas da computação, como roteamento de redes, criptografia, computação gráfica, bancos de dados, biologia computacional, inteligência artificial, otimização combinatória, etc.
- Relevantes para inovação tecnológica pois, para resolver um problema computacional normalmente existem diversas soluções viáveis, por vezes com características e desempenho muito dispare. Neste curso vamos apresentar ferramentas para que vocês possam desenvolver estas variadas soluções, bem como continuar a desenvolver suas capacidades para avaliar a qualidade das mesmas.
- Eles são interessantes, divertidos e desafiadores, pois o desenvolvimento de algoritmos mistura conhecimento técnico com criatividade.

Habilidades que serão desenvolvidas:

- Tornar-se um melhor programador.
- Melhorar habilidades analíticas.
- Aprender a pensar algorítmicamente.

Principais tópicos do curso:

- Tabelas de espalhamento (hash tables).
- Árvores de busca.
- Ordenação.
- Busca de palavras.
- Busca em grafos.

Esses tópicos serão permeados por noções de análise de corretude e eficiência de algoritmos.

Comparação com outras áreas:

- Literatura, pensem na diferença entre ser alfabetizado e ser capaz de escrever um romance.
- Construção civil, pensem na diferença entre projetar uma casa e projetar pontes, edifícios, estradas, portos.

Ler/estudar por conta:

- Leiaute - apêndice A do livro “Algoritmos em linguagem C” ou www.ime.usp.br/~pf/algoritmos/aulas/layout.html
- Documentação - capítulo 1 do livro “Algoritmos em linguagem C” ou www.ime.usp.br/~pf/algoritmos/aulas/docu.html

Estruturas de dados

Visão geral:

- usadas para organizar dados permitindo acesso rápido aos mesmos.
- não existe estrutura perfeita, cada uma é eficiente para algumas operações e ineficiente para outras.
- parcimônia, escolha a estrutura de dados mais simples que suporta todas as operações requisitadas pela sua aplicação.

Objetivos:

- conhecer uma variedade de estruturas de dados.
- entender os pontos fortes e fracos de cada uma, permitindo escolher onde utilizá-las.
- saber como implementar e modificar as estruturas de dados para atender a necessidades específicas que surjam em suas aplicações.

Motivação para escolha de certa estrutura de dados:

- meu algoritmo realiza muitas operações que são baratas na estrutura de dados em questão?

Tabelas de símbolos

Uma tabela de símbolos:

- também é chamada de dicionário
- corresponde a um conjunto de itens,
 - em que cada item possui uma chave e um valor.
- é uma estrutura dinâmica, isto é,

- suporta operações de inserção e remoção, além da busca.
- trata-se de um Tipo de Dado Abstrato, pois
 - o foco está no propósito da estrutura, e não em sua implementação.

Vamos começar a pensar na implementação de uma tabela de símbolos

- e nas estruturas de dados que podemos usar para tanto

Queremos armazenar e acessar dados com facilidade a partir de suas chaves

- as chaves podem ser nomes, IPs, configurações, etc.

Como exemplo, vamos supor que queremos criar uma lista de telefones.

- uma ideia é utilizar um vetor indexado pelas chaves
 - ou seja, pelos nomes das pessoas
- a vantagem dessa abordagem é que o tempo de acesso é constante ($O(1)$).
- se as chaves estiverem num intervalo bem comportado, por exemplo, inteiros entre 1 e 1000, isso é viável.
 - infelizmente (ou não), nomes raramente são inteiros entre 1 e 1000.
- insistindo nessa ideia, podemos converter/considerar a representação numérica/binária de cada nome
 - e usar esse número para indexar o vetor
 - qual o problema dessa abordagem? Qual será o tamanho do vetor resultante?
 - no caso dos nomes teríamos uma posição para cada nome possível
 - considerando que cada caracter tem 26 possibilidades e um nome pode ter até 30 caracteres
 - o vetor teria $26^{30} \approx 2,81 \cdot 10^{42} \approx 2^{141}$ posições.
 - como comparação, o armazenamento total disponível na Terra é da ordem de 10^{25} bits.
 - em geral, o tamanho serial da ordem de 2^n , sendo n o número de bits da chave.

O tamanho do vetor no exemplo anterior deixa claro que essa abordagem é inviável.

- mas existe uma estrutura de dados que
 - suporta busca, inserção e remoção em tempo constante ($O(1)$)
 - e ocupa espaço proporcional ao número de elementos armazenados.

Tabelas de espalhamento (hash tables)

Trata-se de uma implementação bastante popular e eficiente para tabelas de símbolos.

Hash tables propriamente implementadas suportam operações de consulta, inserção e remoção muito eficientes, i.e., tempo constante ($O(1)$) por operação.

- a eficiência das operações depende da hash table ter tamanho adequado e uma boa função de espalhamento (hash function)
 - vale destacar que é fácil implementar uma função de espalhamento problemática.
- além disso, a hash table não dá garantia de eficiência de pior caso,
 - pois sempre podem existir conjuntos de dados patológicos.

Aplicações:

- manutenção de variáveis conhecidas em compiladores.
- bloquear tráfego de certos IPs.
- detectar duplicatas.
- 2-sum problem:
 - dado um vetor v de tamanho n e um inteiro t , encontrar os pares de elementos em v cuja soma é igual a t .

Abordagens para o 2-sum problem:

- busca exaustiva, i.e., para cada elemento em v verificar se cada um dos $n-1$ outros elementos somados ao primeiro resulta em t . Eficiência $\Theta(n^2)$

```
int twoSumBruteForce(int v[], int n, int t)
{
    int i, j;
    for (i = 0; i < n; i++)
        for (j = i + 1; j < n; j++)
            if (v[i] + v[j] == t)
                return 1;
    return 0;
}
```

- ordenação + buscas binárias. Eficiência $\Theta(n \log n)$
 - bônus: é possível substituir a parte das buscas binárias por uma passagem linear no vetor ordenado. Como?

```
int twoSumBinarySearch(int v[], int n, int t)
{
    int i, j, y;
    sort(v, n);
    for (i = 0; i < n; i++)
    {
        y = t - v[i];
        if (binarySearch(v, n, y))
            return 1;
    }
}
```

```
}  
return 0;  
}
```

- percorrer o vetor inserindo cada elemento numa hash table e, em seguida, percorrê-lo novamente consultando, para cada elemento e, se seu complemento ($t - e$) está na hash table. Eficiência $\Theta(n)$

```
int twoSumHashTable(int v[], int n, int t)  
{  
    int i, j, y;  
    int h[n];  
    for (i = 0; i < n; i++)  
        insertHashTable(h, n, v[i]);  
    for (i = 0; i < n; i++)  
    {  
        y = t - v[i];  
        if (lookupHashTable(h, n, y))  
            return 1;  
    }  
    return 0;  
}
```