

AED2 - Aula 13

Limitante inferior para ordenação baseada em comparações e bucket sort

“Encarando e transpondo barreiras”

Limitante inferior para ordenação baseada em comparações

Algoritmos de ordenação baseados em comparação são aqueles que

- só obtém informação sobre a sequência sendo ordenada
- através de uma função de comparação que
 - recebe dois elementos e diz qual deles é maior.

Exemplos destes algoritmos são:


- mergeSort, quickSort, heapSort, selectionSort, insertionSort e bubbleSort.

Para obter um limitante inferior para o número de operações

- que qualquer algoritmo de ordenação precisa realizar,
 - vamos comparar duas grandezas.

A primeira é o número de permutações distintas


- que uma sequência de tamanho n pode apresentar.



- Este número é $n!$,
 - pois qualquer um dos n elementos pode ser o primeiro,
 - qualquer dos $n - 1$ restantes pode ser o segundo,
 - e assim por diante.

A segunda grandeza é o número de sequências


- que um algoritmo consegue distinguir após realizar k comparações.



- Esse número é importante pois,
 - se o algoritmo obtiver as mesmas respostas das comparações
 - para duas sequências distintas,
 - ele executará da mesma forma para ambas,
 - devolvendo uma resposta errada em pelo menos um dos casos.
- Note que, no início todas as sequências são iguais para o algoritmo,
 - e que cada comparação entre um par de elementos
 - pode resultar em duas possibilidades,
 - o primeiro é maior que o segundo,
 - ou o segundo é maior que o primeiro.
- Podemos pensar que, na melhor das hipóteses,
 - cada comparação divide o espaço de busca em duas metades ou,
 - de modo complementar, dobra o número de sequências identificadas.
- Assim, no melhor caso, após k comparações,
 - conseguimos identificar 2^k sequências diferentes.

Para facilitar a visualização,

- podemos representar as possíveis comparações de um algoritmo
 - usando uma árvore binária de decisão,
 - na qual cada nó interno corresponde a uma comparação
 - e cada folha corresponde a uma sequência.



A altura desta árvore, ou seja,

- o caminho mais longo da raiz até uma folha,
 - corresponde a um limitante inferior para
 - a complexidade de tempo de pior caso do algoritmo.

Pelo princípio da casa dos pombos temos que

- se tivermos $n + 1$ pombos para serem colocados em n casas,
 - então pelo menos uma casa deverá conter dois ou mais pombos.

No nosso problema,

- os pombos são as $n!$ permutações de uma sequência de tamanho n ,
- as casas dos pombos são as 2^k sequências
 - que um algoritmo consegue identificar depois de k comparações.
- Se houverem mais pombos do que casas,
 - i.e., $2^k < n!$
 - então o algoritmo não conseguirá distinguir
 - entre duas sequências diferentes.
- Portanto, ele não ordenará corretamente ao menos uma delas.
- Assim, para que o algoritmo tenha chance de ordenar corretamente
 - $2^k \geq n!$

Para resolver a inequação vamos simplificar $n!$,

- substituindo-o por um limitante inferior

$$\begin{aligned}
 n! &= \overbrace{n \cdot (n-1) \cdot (n-2) \dots (n/2+1)(n/2)(n/2-1) \dots 2 \cdot 1}^{n/2 \text{ termos}} \\
 &\geq \underbrace{\frac{n}{2} \cdot \frac{n}{2} \cdot \frac{n}{2} \dots \frac{n}{2}}_{n/2 \text{ termos}} \cdot 1 \cdot 1 \dots 1 \cdot 1 \\
 &= (n/2)^{n/2}
 \end{aligned}$$

Simplificando $n!$

Assim,

- $2^h \geq n! \geq (n/2)^{n/2}$

Aplicando lg dos dois lados

- $h \geq (n/2) \lg(n/2) = \Omega(n \log n)$,
 - sendo que $\Omega(f(n))$ deve ser interpretado como
 - pelo da ordem de $f(n)$.

Assim, concluímos que

- qualquer algoritmo de ordenação baseado em comparações
 - precisa realizar pelo menos da ordem de $n \log n$ comparações
 - para ordenar uma sequência com n elementos.

Em vista dessa barreira, como podemos transpô-la?



Bucket sort

Este é um método eficiente para ordenar um conjunto com n elementos

- distribuídos uniformemente num intervalo de tamanho k .
- Primeiro, dividimos o intervalo de tamanho k em n baldes (buckets),
 - associando a cada balde uma fração de valor igual a k/n .



- Então colocamos cada elemento em seu respectivo balde.
- Em seguida ordenamos os elementos de cada balde,
 - o que leva tempo esperado constante,
 - já que cada balde deve ter um número pequeno de elementos,
 - uma vez que estes vieram de uma distribuição uniforme.



- Por fim, percorremos os baldes em ordem
 - e os elementos de cada balde, também em ordem,
 - copiando eles de volta para o vetor original.

Vamos ver como calcular os índices dos baldes:

$$v[i] \in [\text{lim-inf}, \text{lim-sup})$$




$$v[i] - \text{lim-inf}$$



$$(v[i] - \text{lim-inf}) / (\text{lim-sup} - \text{lim-inf})$$



$$(v[i] - \text{lim_inf}) / (\text{lim_sup} - \text{lim_inf}) * n$$


Índices dos baldes entre 0 e n-1

Códigos:

```
#define lim_inf 0
#define lim_sup 1

typedef struct celula
{
    double chave;
    struct celula *prox;
} Celula;

void bucketSort(double v[], int n)
{
    int i, j;
    Celula *p, *nova, *morta;
    Celula **baldes = (Celula **)malloc(n * sizeof(Celula *));
    // inicializando cada balde com uma lista com um nó cabeça
    for (j = 0; j < n; j++)
    {
        baldes[j] = (Celula *)malloc(sizeof(Celula));
        baldes[j]->prox = NULL;
    }
    // coloca cada elemento no balde correspondente
    for (i = 0; i < n; i++)
    {
        // j = (int)(v[i] * n);
        j = (int)((double)(v[i] - lim_inf) / (lim_sup - lim_inf) *
n);

        p = baldes[j];
        // já insere o elemento na ordem correta dentro do balde
```

```

    while (p->prox != NULL && p->prox->chave < v[i])
        p = p->prox;
    nova = (Celula *)malloc(sizeof(Celula));
    nova->chave = v[i];
    nova->prox = p->prox;
    p->prox = nova;
}
// põe os elementos dos baldes de volta no vetor
i = 0;
for (j = 0; j < n; j++)
{
    p = baldes[j]->prox;
    while (p != NULL)
    {
        v[i] = p->chave;
        i++;
        p = p->prox;
    }
}
// libera os baldes
for (j = 0; j < n; j++)
{
    p = baldes[j];
    while (p != NULL)
    {
        morta = p;
        p = p->prox;
        free(morta);
    }
}
free(baldes);
}

```

Eficiência de tempo esperado é $O(n)$,

- apenas se as chaves forem uniformemente distribuídas.
- Sem essa hipótese o tempo de pior caso do algoritmo é $O(n^2)$,

- pois muitos elementos podem se acumular num mesmo balde,
- e a ordenação deste pode levar tempo quadrático,
 - dependendo do método utilizado.
- Diante disso, vale a pena usar um método de ordenação $O(n \lg n)$,
 - para ordenar cada balde?
 - Em geral não, pois são esperados poucos elementos por balde,
 - e métodos como insertionSort são melhores para n pequeno.

Eficiência de espaço:

- Memória adicional da ordem de n ,
 - pois são utilizados n baldes e
 - n células, uma para cada elemento.

Estabilidade:

- A estabilidade depende da implementação da ordenação intrabalde.
- O código que estudamos não é estável, mas uma pequena modificação
 - na inserção/ordenação intra balde pode corrigir isso.
 - Que modificação é essa?

Bônus:

- O método de inserção em ordem intrabalde lembra
 - um algoritmo de ordenação que já estudamos.
 - Qual é esse algoritmo?