

Busca Binária

Encontros Linearítmicos ($n \lg n$)

Fernando Kiotheka

UFPR

08/05/2020

O que é?

Algoritmo que permite que você reduza um espaço de busca finito exponencialmente em um ponto, em ordem de $\lg (\log_2)$.

Pré-requisitos

Somente é necessário que seja possível dividir o espaço de busca em duas partições usando um predicado $P(i)$ onde i é um índice do espaço de busca. Definiremos que se $P(i)$ é T, estamos na esquerda e o objetivo está para a direita, se F, estamos na direita.

- Espaço de busca ordenado. Exemplo:

$$E_n := \mathbb{N}_{[1,8)} = [{}_0 \mathbf{1}_1 \mathbf{2}_2 \mathbf{3}_3 \mathbf{4}_4 \mathbf{5}_5 \mathbf{6}_6 \mathbf{7}_7]$$
$$P(i) := E_b[i] < 5$$

- Espaço de busca unimodal. Exemplo:

$$E_n := [n^2 : x \in \mathbb{N}_{[-3,3)}] = [{}_0 \mathbf{9}_1 \mathbf{4}_2 \mathbf{1}_3 \mathbf{0}_4 \mathbf{1}_5 \mathbf{4}_6]$$
$$P(i) := (i = 0 \vee E_b[i - 1] > E_b[i])$$

Como?

A ideia é repetidamente pegar o meio do espaço de busca, verificar o predicado e reduzir o espaço de busca para um dos lados.

Por exemplo: $E_n := \mathbb{N}_{[1,8)}$ com $P(i) := E_n[i] \leq 2$:

$$E_n = [{}_0 \mathbf{1}_1 \mathbf{2}_2 \mathbf{3}_3 \mathbf{4}_4 \mathbf{5}_5 \mathbf{6}_6 \mathbf{7}_7]$$

$$E_n = [{}_0 \mathbf{1}_1 \mathbf{2}_2 \mathbf{3}_3 \mathbf{4}_4 \mathbf{5}_5 \mathbf{6}_6 \mathbf{7}_7]$$

$$E_n = [{}_0 \mathbf{1}_1 \mathbf{2}_2 \mathbf{3}_3 \mathbf{4}_4 \mathbf{5}_5 \mathbf{6}_6 \mathbf{7}_7]$$

Resultado: A posição 2 separa as duas metades.

Os detalhes

“Although the basic idea of binary search is comparatively straightforward, the details can be surprisingly tricky”

– Donald Knuth

É fácil errar por um (OB1) na hora de implementar o algoritmo. O que vou explicar se baseia em intervalos semi-abertos $[0, n)$ que tem algumas propriedades interessantes, mas você pode optar por outra implementação que é mais intuitiva para você.

Uma variação comum por exemplo é usar intervalos fechados $[0, n - 1]$, ou ainda algo maluco como $(-1, n)$. Depois da explicação, iremos estudar alguns outros exemplos.

Introdução do algoritmo

Temos um espaço de busca E_n :

$$E_n = [{}_0 1_1 2_2 3_3 4_4 5_5 6_6 7_7]$$

Aplicando a função binária $P(i) = E_n[i] \leq 2$ em E_n , obtemos E_b :

$$E_b = [{}_0 T_1 T_2 F_3 F_4 F_5 F_6 F_7]$$

Agora, trabalharemos neste novo espaço de busca.

Dividindo

Particionaremos o espaço de busca em subintervalos $[l_0, h_1)$.

1. Começamos com $l_0 := 0$ e $h_1 := |E_b| = 7$.

$$E_{b[0,7)} = [{}_0 T_1 T_2 F_3 F_4 F_5 F_6 F_7]$$

2. Pegamos o ponto médio $m_i := \lfloor (h_i + l_0)/2 \rfloor = 3$.
3. Como $E_b[3] = F$, o objetivo está para a esquerda.
4. Então fazemos $h_i := m_i$, reduzindo a busca pela metade.

$$E_{b[0,3)} = [{}_0 T_1 T_2 F_3]$$

Mas ainda não acabamos!

Dividindo de novo

1. Temos $l_0 := 0$ e $h_1 := 3$ da iteração anterior.

$$E_{b[0,3)} = [{}_0 T_1 T_2 F_3]$$

2. Pegamos o ponto médio $m_1 := \lfloor (h_1 + l_0)/2 \rfloor = 1$.
3. Como $E_b[1] = T$, o objetivo está para a direita.
4. Então fazemos $l_0 := m_1 + 1$, reduzindo a busca pela metade.

$$E_{b[2,3)} = [{}_2 F_3]$$

Mas ainda não chegamos a um único ponto!

Dividindo pela última vez

1. Temos $l_o := 2$ e $h_i := 3$ da iteração anterior.

$$E_{b[2,3)} = [{}_2 F_3]$$

2. Pegamos o ponto médio $m_i := \lfloor (h_i + l_o)/2 \rfloor = 2$.
3. Como $E_b[2] = F$, o objetivo está para a esquerda.
4. Então fazemos $h_i := m_i$, reduzindo a busca pela metade.

$$E_{b[2,2)} = [{}_2]$$

Chegamos então a um ponto que divide o espaço de busca, 2.

$$E_b = [{}_0 T_1 T_2 F_3 F_4 F_5 F_6 F_7]$$

Uma das implementações possíveis

Código 1 intervalo-0-n.cpp

```
int lo = 0;
int hi = n;
while (lo != hi) {
    // reescrito para evitar overflow
    int mi = lo + (hi - lo) / 2;
    if (P(mi)) {
        // direita
        lo = mi + 1;
    } else {
        // esquerda
        hi = mi;
    }
}
return lo; // ou hi, para o intervalo [0, n) tanto faz
```

Variações de implementação

Eu não uso o código anterior. Isso porque são possíveis algumas alterações para melhorar sua intuição:

- Alterar de `while (lo != hi)` para `while (lo < hi)` (não muda nada, mas talvez fique mais bonito)
- Alterar de `P(mi)` para `!P(mi)` e reordenar o `if` (acho mais intuitivo pensar primeiro esquerda, depois direita)
- Alterar o intervalo de $[0, n)$ para $[0, n - 1]$ ou $(-1, n)$ como veremos a seguir
- Ou ainda iterar sobre passos binários, como também veremos

Implementação $[0, n - 1]$

Variação frequentemente encontrada. Ao final, $lo = hi + 1$.

Código 2 intervalo-0-n-1.cpp

```
int lo = 0;
int hi = n - 1;
while (lo <= hi) {
    int mi = lo + (hi - lo) / 2;
    if (P(mi)) {
        lo = mi + 1;
    } else {
        hi = mi - 1;
    }
}
return lo;
```

Implementação $[0, n - 1]$ com variável auxiliar

O Erichto recomenda usar uma variável auxiliar para não errar.

Código 3 intervalo-0-n-1-aux.cpp

```
int lo = 0;
int hi = n - 1;
int ans;
while (lo <= hi) {
    int mi = lo + (hi - lo) / 2;
    if (P(mi)) {
        lo = mi + 1;
    } else {
        ans = mi;
        hi = mi - 1;
    }
}
return ans;
```

Implementação $(-1, n)$

Variação maluca. Sem mais +1s e -1s, ao final $lo + 1 = hi$.

Código 4 intervalo--1-n.cpp

```
int lo = -1;
int hi = n;
while (hi - lo > 1) {
    int mi = lo + (hi - lo) / 2;
    if (P(mi)) {
        lo = mi;
    } else {
        hi = mi;
    }
}
return hi;
```

Implementação de passo binário

Não é incomum, a sutileza encanta. Permite fazer múltiplas buscas num laço só, diferente do normal que fica ilegível ao combinar laços.

Código 5 passo-binario-reverso.cpp

```
int i = n;
for (int p = n; p >= 1; p /= 2) {
    while (i-p >= 0 && !P(i-p)) { i -= p; }
}
return i;
```

Código 6 passo-binario.cpp

```
int i = -1;
for (int p = n; p >= 1; p /= 2) {
    while (i+p < n && P(i+p)) { i += p; }
}
return i + 1;
```

Vamos aos predicados!

Todas as implementações descritas anteriores entregam o mesmo resultado dado o predicado certo, mas qual o predicado certo?

Depende do problema que a gente quer resolver.

Exemplos comuns que podem ser resolvidos em $\mathcal{O}(\lg n)$ são:

- Posição à esquerda ou à direita de valor em vetor ordenado
- Contagem de ocorrências de valor em vetor ordenado
- Posição de valor em vetor ordenado deslocado sem duplicados
- Posição de máximo/mínimo em vetor unimodal
- Raíz quadrada de um número (método de bisecção)
- i -ésimo elemento de união de vetores ordenados
- Elemento em vetor ordenado que é igual ao seu índice
- Otimização de problemas com solução gananciosa conhecida

Posição à esquerda ou à direita de valor

Esses são os predicados mais importantes para buscar elementos. Eles são tão importantes que uma versão que procura em vetores está disponível na biblioteca padrão:

- `lower_bound(início, fim, valor)`: $P(i) := v[i] < x$
- `upper_bound(início, fim, valor)`: $P(i) := v[i] \leq x$

Exemplo

$$v = [{}_0 1_1 2_2 2_3 3_4 3_5 5_6 5_7]$$

Quando o valor existe, retornam o intervalo de elementos $(a, b]$.

- `lower_bound(v, v + n, 3) - v = 3`
- `upper_bound(v, v + n, 3) - v = 5`

Quando está ausente, retornam o lugar onde ele deveria estar.

- `lower_bound(v, v + n, 4) - v = 5`
- `upper_bound(v, v + n, 4) - v = 5`

Contagem de ocorrências de valor

Fica fácil contar quantas ocorrências de um valor existem:

$$v = [0 \ 1 \ 2 \ 3 \ 3 \ 4 \ 3 \ 5 \ 5 \ 6 \ 5 \ 7]$$

No caso do elemento 3:

- $\text{lower_bound}(v, v + n, 3) - v = 2$
- $\text{upper_bound}(v, v + n, 3) - v = 5$
- $n_3 = 5 - 2 = 3$

E no caso de um elemento inexistente:

- $\text{lower_bound}(v, v + n, 4) - v = 5$
- $\text{upper_bound}(v, v + n, 4) - v = 5$
- $n_4 = 5 - 5 = 0$

Isso é simples devido ao uso de intervalos $[0, n)$:

- A diferença dos limites é o tamanho do intervalo.

Contagem de ocorrências de valor (continuado)

A implementação do passo binário, por exemplo, nos permite juntar as duas buscas em um código só:

Código 7 contagem-passo-binario.cpp

```
int l = n;
int r = n;

for (int p = n; p >= 1; p /= 2) {
    while (l-p >= 0 && !(v[l-p] < x)) { l -= p; }
    while (r-p >= 0 && !(v[r-p] <= x)) { r -= p; }
}

return r - l;
```

Posição de valor

Uma outra coisa simples para se fazer com esses predicados é devolver uma posição onde um valor aparece.

Dado que $n \neq 0$, podemos verificar a posição dada pelo predicado $P(i) := v[i] < x$ (`lower_bound`). Ela será a mais à esquerda.

Exemplo

$$v = [{}_0 1 \quad {}_1 2 \quad {}_2 2 \quad {}_3 3 \quad {}_4 3 \quad {}_5 5 \quad {}_6 5 \quad {}_7]$$

- $\text{lower_bound}(v, v + n, 3) - v = 3$. $v[3] = 3$.
- $\text{lower_bound}(v, v + n, 4) - v = 5$. $v[5] \neq 4$.
- $\text{lower_bound}(v, v + n, 5) - v = 5$. $v[5] = 5$.

Posição de valor (continuado)

Como isso é frequente, existe uma função da biblioteca padrão para tal, que caso não encontre o elemento, retorna o final do vetor:

- `binary_search(início, fim, valor)`

Isso também pode ser codificado em uma variação da busca binária:

Código 8 `posicao.cpp`

```
int lo = 0;
int hi = n;
while (lo != hi) {
    int mi = lo + (hi - lo) / 2;
    if (a[mi] < x) { lo = mi + 1; }
    else if (a[mi] == x) { return mi; }
    else { hi = mi; }
}
return NAO_ACHEI;
```

O problema dos elementos duplicados

Imagine que queremos achar o mínimo em um vetor ordenado que foi deslocado (ou alternativamente, um vetor que é decrescente e depois é crescente como uma parábola).

$$v_1 = [0 \ 2_1 \ 2_2 \ 2_3 \ 2_4 \ 2_5 \ 0_6 \ 2_7]$$

$$v_2 = [0 \ 2_1 \ 0_2 \ 2_3 \ 2_4 \ 2_5 \ 2_6 \ 2_7]$$

O algoritmo começa verificando o meio do vetor, mas para qual lado devemos prosseguir?

- Não podemos usar as bordas como apoio pois elas são iguais ao elemento escolhido
- Pensando num caso geral, é impossível saber em qual lado o mínimo se encontra sem verificar todos os elementos

Então aqui temos um problema no mínimo $\mathcal{O}(n)$ por natureza (a menos que existam mais restrições que possam nos ajudar).

Posição de valor em vetor deslocado sem duplicados

Vamos pegar dois exemplos:

$$v_1 = [0 \ 4_1 \ 5_2 \ 6_3 \ 7_4 \ 9_5 \ 1_6 \ 2_7]$$

$$v_2 = [0 \ 8_1 \ 2_2 \ 3_3 \ 4_4 \ 5_5 \ 6_6 \ 7_7]$$

Primeiro, resolvemos o problema do vetor estar deslocado.

Queremos um predicado que divida o vetor desta forma:

$$v_{1b} = [0 \ T_1 \ T_2 \ T_3 \ T_4 \ T_5 \ F_6 \ F_7]$$

$$v_{2b} = [0 \ T_1 \ F_2 \ F_3 \ F_4 \ F_5 \ F_6 \ F_7]$$

Podemos se ancorar nas bordas para fazer predicados:

$$P(i) := v[0] \leq v[i]$$

$$P(i) := v[n-1] < v[i]$$

Assim obtemos dois vetores ordenados para procurar o valor.

Posição de máximo/mínimo em vetor unimodal

Uma função unimodal é aquela que tem um único ponto de máximo ou mínimo. Desde que seja sempre possível saber se um ponto está no lado crescente ou decrescente, podemos achá-lo.

$$v_{\min} = [0 \ 4_1 \ 3_2 \ 2_3 \ 1_4 \ 2_5 \ 4_6 \ 5_7]$$

$$v_{\max} = [0 \ 1_1 \ 2_2 \ 4_3 \ 5_4 \ 4_5 \ 3_6 \ 2_7]$$

Como nesse vetor não há elementos duplicados lado a lado, é possível sempre saber se estamos na parte decrescente ou crescente:

$$P_{\min}(i) := (i + 1 < n \wedge v[i] > v[i + 1])$$

$$P_{\max}(i) := (i + 1 < n \wedge v[i] < v[i + 1])$$

Assim obtemos essa divisão:

$$v_{\min b} = v_{\max b} = [0 \ T_1 \ T_2 \ T_3 \ F_4 \ F_5 \ F_6 \ F_7]$$

Que retorna o índice indexado em 0 do mínimo ou máximo.

Trabalhando com números reais...

Vimos como achar posição de máximo/mínimo em um vetor, mas nos problemas é bem mais comum fazermos uma otimização em números reais. O método é exatamente o mesmo, porém o predicado verifica um valor real. Sugestões:

- Sempre que possível evite usar `double`, `float` e variáveis. Geralmente o problema pede uma precisão específica, então utilize inteiros que representam precisões maiores (1000 para representar 10.00)
- Se você optar pelo uso de números reais, cuidado com a função de comparação. Para comparar números reais é preciso sempre pensar em uma constante mínima (ϵ)
- Alternativamente, é frequente rodar a busca binária uma quantidade fixa de vezes a fim de que o valor convirja para um valor específico.

Exemplo: Achar a raiz quadrada com ϵ

Código 9 raiz-quadrada-epsilon.cpp

```
double lo = 0;
double hi = x;
while (hi - lo > EPS) {
    double mi = lo + (hi - lo) / 2;
    if (mi*mi < x) {
        lo = mi;
    } else {
        hi = mi;
    }
}
return lo;
```

ϵ	1e-1	1e-2, 1e-3	1e-4	1e-5, 1e-6, 1e-7
Valor	1.375	1.41406	1.41418	1.41421

Exemplo: Achar a raiz quadrada com iterações

Código 10 raiz-quadrada-iteracoes.cpp

```
double lo = 0;
double hi = x;
for (int i = 0; i < IT; i++) {
    double mi = lo + (hi - lo) / 2;
    if (mi*mi < x) {
        lo = mi;
    } else {
        hi = mi;
    }
}
return lo;
```

Iterações	1	3	4	8	14	18
Valor	1	1.25	1.375	1.41406	1.41418	1.41421

O resto desse papo

Outros exemplos ficarão como exercício para o leitor. Literalmente. Preparei um contest com uma boa quantidade de exercícios para praticar a busca binária em vários exemplos diferentes, boa sorte!

- Querem ler alguns dos problemas e tirar dúvidas?
- Todos os slides e códigos estão no site