AED2 - Aula ~~17~~ 26.2
Busca de palavras em um texto, algoritmo de Boyer-Moore (good suffix heuristic)

Relembrando a definição do problema

Considere o problema de encontrar todas as ocorrências de
- uma sequência curta, que chamaremos de palavra,
- em uma sequência longa, que chamaremos de texto.

Mais formalmente, temos que

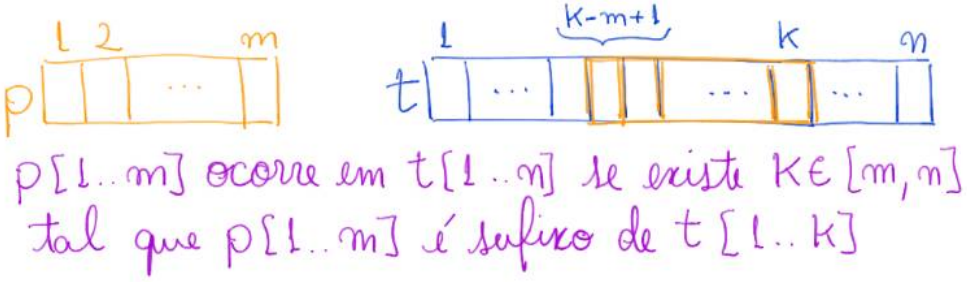

Para simplificar, vamos tratar do problema de determinar
- o número de ocorrências de p[1 .. m] em t[1 .. n].

Antes de prosseguir, vamos relembrar algumas convenções:
- Nossos algoritmos vão varrer o texto da esquerda para a direita
    - e cada vez que eles comparam a palavra com um subvetor do texto,
        - vamos varrer esse subvetor da direita para a esquerda.
- Em geral, as duas alternativas são equivalentes,
    - mas a heurística que veremos hoje exige que
        - a comparação seja feita no sentido contrário
            - ao da varredura do texto.
- **Atentar para onde isso será relevante.**

Algoritmo básico

Exemplo:

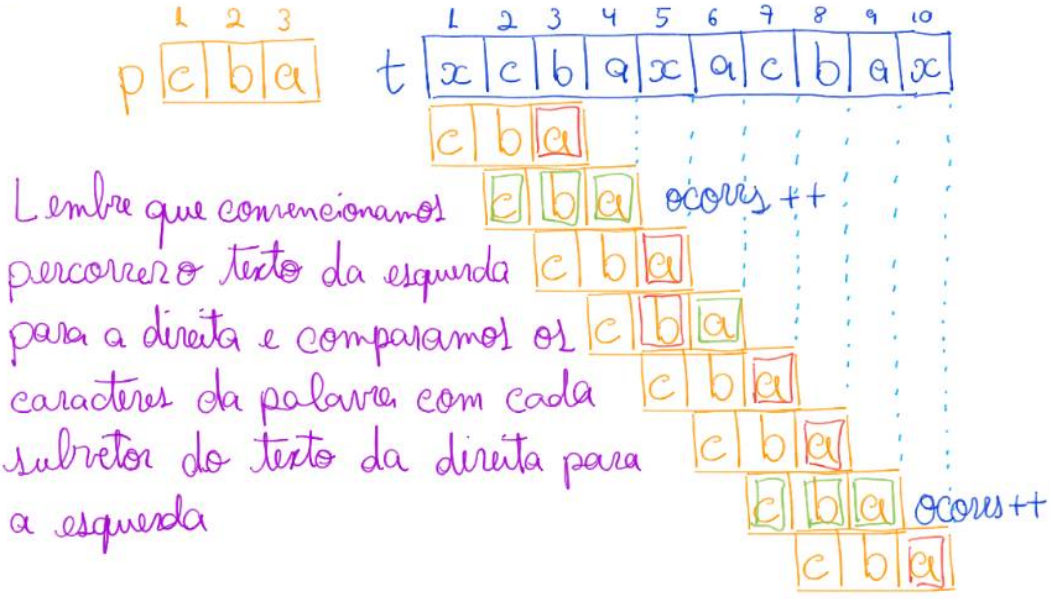

Código:

```
// Recebe vetores palavra[1..m] e texto[1..n], com m >= 1 e n >= 0,
// e devolve o número de ocorrências de palavra em texto.
int basico(char palavra[], int m, char texto[], int n) {
    int pos_t, desl_p, ocorrs;
    ocorrs = 0;
    for (pos_t = m; pos_t <= n; pos_t++) {
        desl_p = 0;
        // palavra[1..m] casa com texto[pos_t-m+1 .. pos_t]?
        while (desl_p < m &&
           palavra[m - desl_p] == texto[pos_t - desl_p])
            desl_p++;
        if (desl_p >= m)
            ocorrs++;
    }
    return ocorrs;
}
```

Eficiência de tempo:

- No pior caso, o tempo é O(mn),
    - pois o laço externo itera (n - m + 1) vezes
        - e o laço interno itera m vezes.
- No melhor caso o tempo é O(n - m + 1), pois o laço interno nunca itera.

Eficiência de espaço:

- O espaço adicional utilizado é constante.

Agora vamos estudar a segunda heurística do algoritmo de Boyer-Moore

- que utiliza critérios não triviais para avançar o índice pos_t no texto
    - com passos maiores que 1 a cada iteração.

Segundo algoritmo de Boyer-Moore

Vamos estudar a segunda heurística do algoritmo de Boyer-Moore,

- conhecida como “good suffix heuristic”.

Nos seguintes exemplos, considere que o algoritmo

- acabou de testar se p[1 .. m] é sufixo de t[1 .. pos_t]
    - e acabou detectando que p[m - desl_p .. m] = t[pos_t - desl_p .. pos_t].
- Então, responda à pergunta:
    - **Qual a próxima posição da palavra que pode emparelhar**
        - **com o trecho do texto que acabei de detectar?**

Exemplo 1:

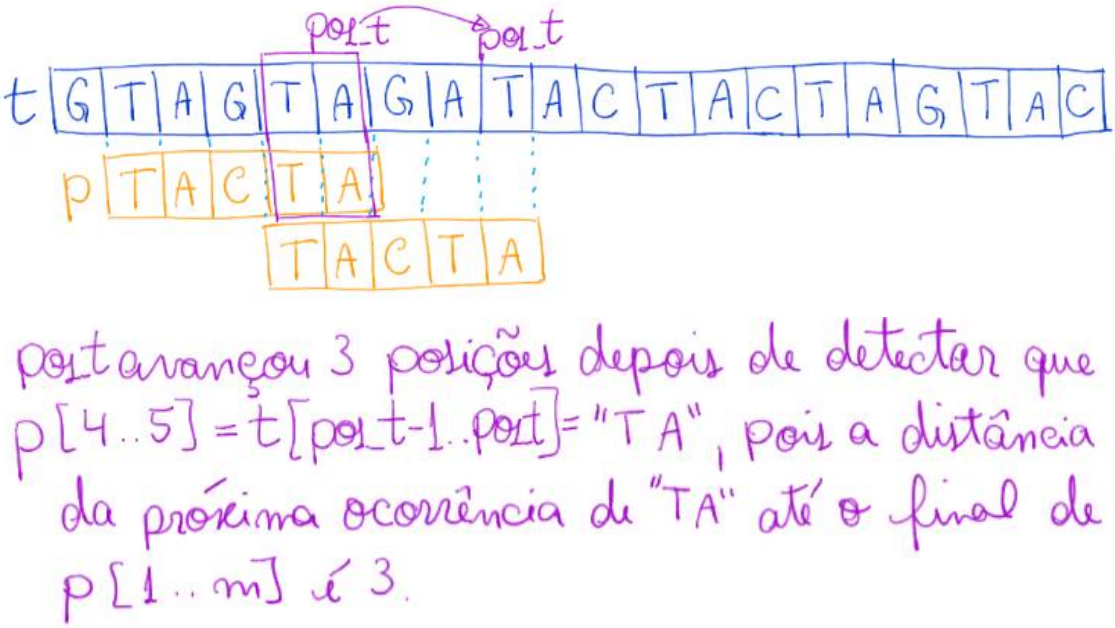

Exemplo 2:

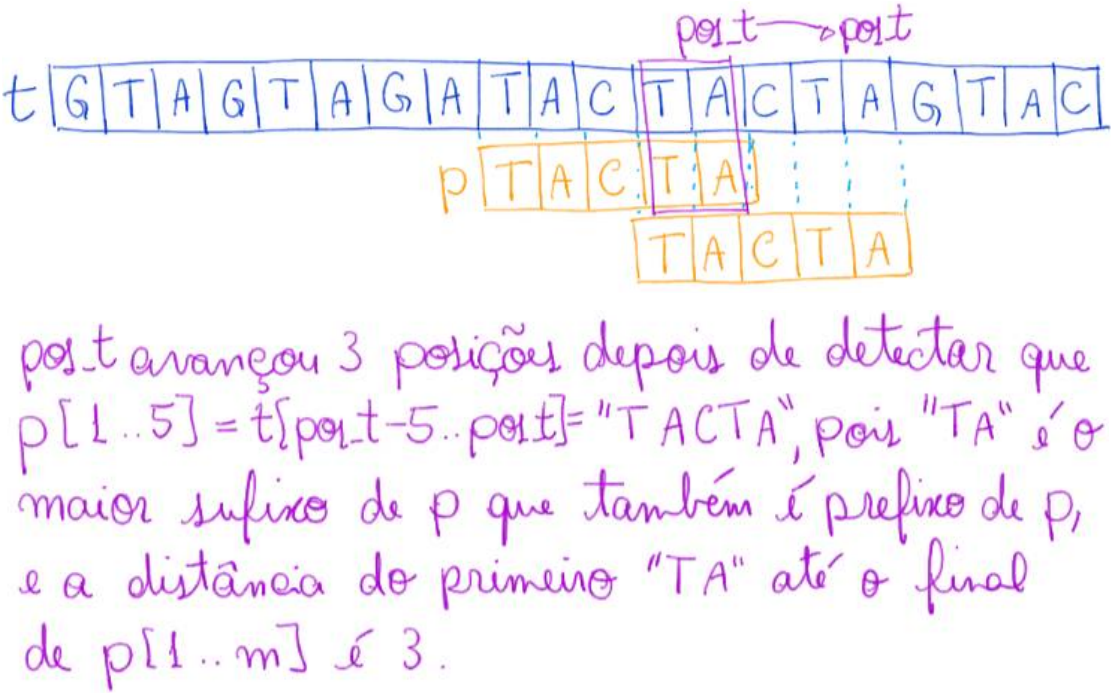

Ideia da “good suffix heuristic”:

- Suponha que um sufixo de p[1 .. m] coincide com um sufixo de t[1 .. pos_t],
  - i.e., p[m - desl_p .. m] = t[pos_t - desl_p .. pos_t],
    - para desl_p entre 1 e m.
- Agora, considere que a sequência no sufixo p[m - desl_p .. m]
  - não se repete mais em p[1 .. m].
- Neste caso, sabemos que podemos avançar pos_t
  - até que a primeira posição da palavra p esteja depois do pos_t atual,
    - i.e., pos_t += m.

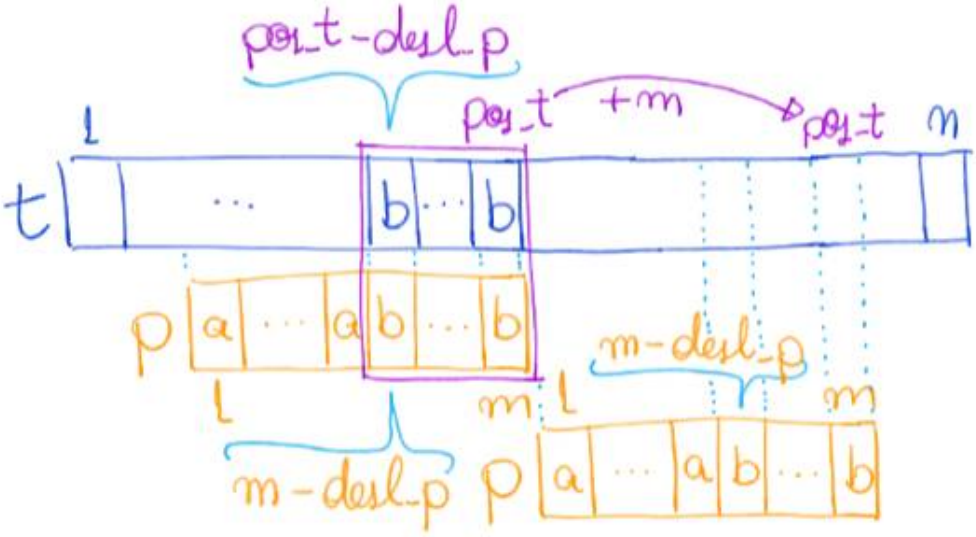

- Agora, considere que a sequência no sufixo p[m - desl_p .. m]
  - se repete em p[1 .. m] pelo menos uma vez
  - e a primeira repetição (contando da direita pra esquerda)
    - ocorre no subvetor p[q - desl_p .. q], com q < m.
- Neste caso, sabemos que podemos avançar pos_t
  - até que p[q] esteja alinhado com t[pos_t],
    - i.e., pos_t += m - q.
- Note que, pode haver intersecção entre p[m - desl_p .. m] e p[q - desl_p .. q],
  - i.e., é possível ocorrer q >= m - desl_p.

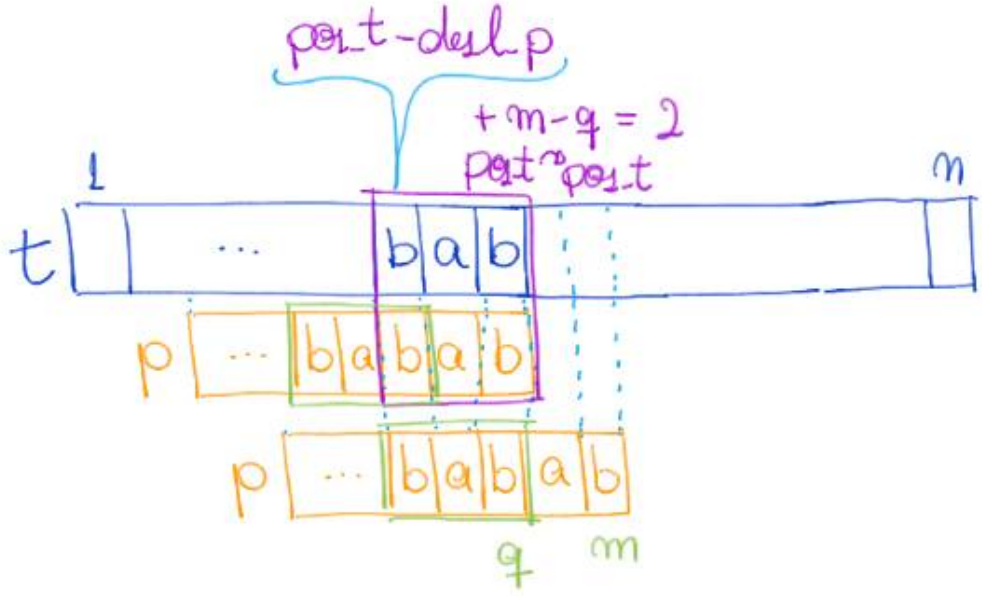

- Por fim, falta considerar um caso complementar
    - e possivelmente concomitante com os anteriores.
- Considere que a sequência p[m - desl_p .. m]
    - não se repete integralmente em p[1 .. m],
    - mas um sufixo dela pode aparecer no prefixo de p[1 .. m],
        - i.e., p[1 .. q] = p[m - q + 1 .. m], com q <= desl_p.
- Neste caso, sabemos que podemos avançar pos_t
    - até que p[q] esteja alinhado com t[pos_t],
        - i.e., pos_t += m - q.

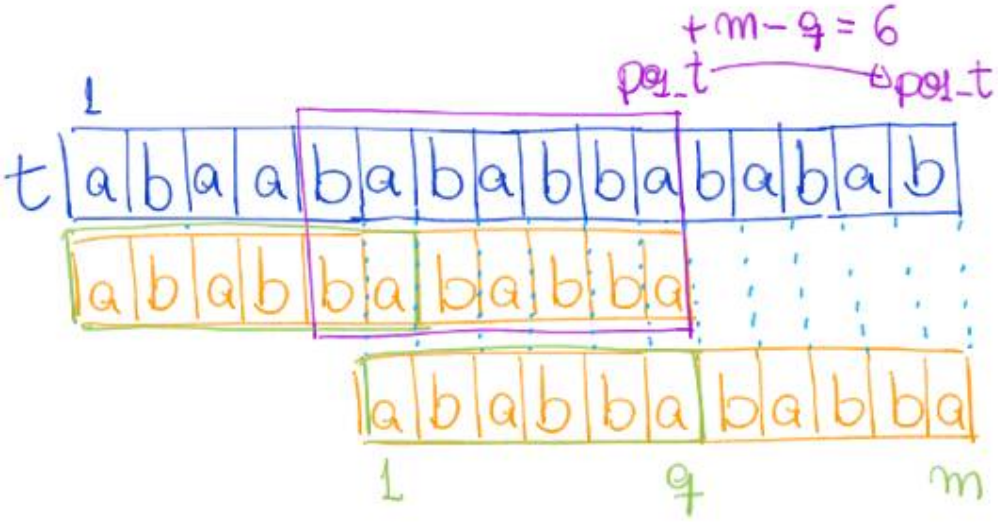

Sintetizando a ideia da “good suffix heuristic”:

- Para cada índice i entre 1 e m,
    - corresponde um sufixo p[i .. m].
- Queremos encontrar o maior índice q, tal que
    - p[i .. m] é sufixo de p[1 .. q], ou seja,
        - q marca a primeira repetição de p[i .. m] em p[1 .. m].
    - ou p[1 .. q] é sufixo de p[i .. m], ou seja,
        - q marca o maior prefixo de p[1 .. m]
            - que casa com o final de p[i .. m].
    - Se não existe tal q, então fazemos q = 0.
- Para implementar essa ideia e automatizar os saltos do índice pos_t,
    - precisamos fazer um pré-processamento da palavra p[1 .. m].

Neste pré-processamento, vamos

- alocar um vetor auxiliar alcance[1 .. m],
    - sendo que alcance[i] está associado ao sufixo p[i .. m],
- e vamos preencher alcance[i] com
    - o menor deslocamento (m - q) entre 1 e m
    - que alinha/emparelha corretamente
        - o final de p[1 .. m]
        - com o final de p[1 .. q].
- Mais formalmente, alcance[i] = (m - q)
    - sendo q o maior índice que satisfaz
        - p[i .. m] é sufixo de p[1 .. q]
        - ou p[1 .. q] é sufixo de p[i .. m].
    - Se não existe tal q, então alcance[i] deve receber o valor m.

Exemplo 3:

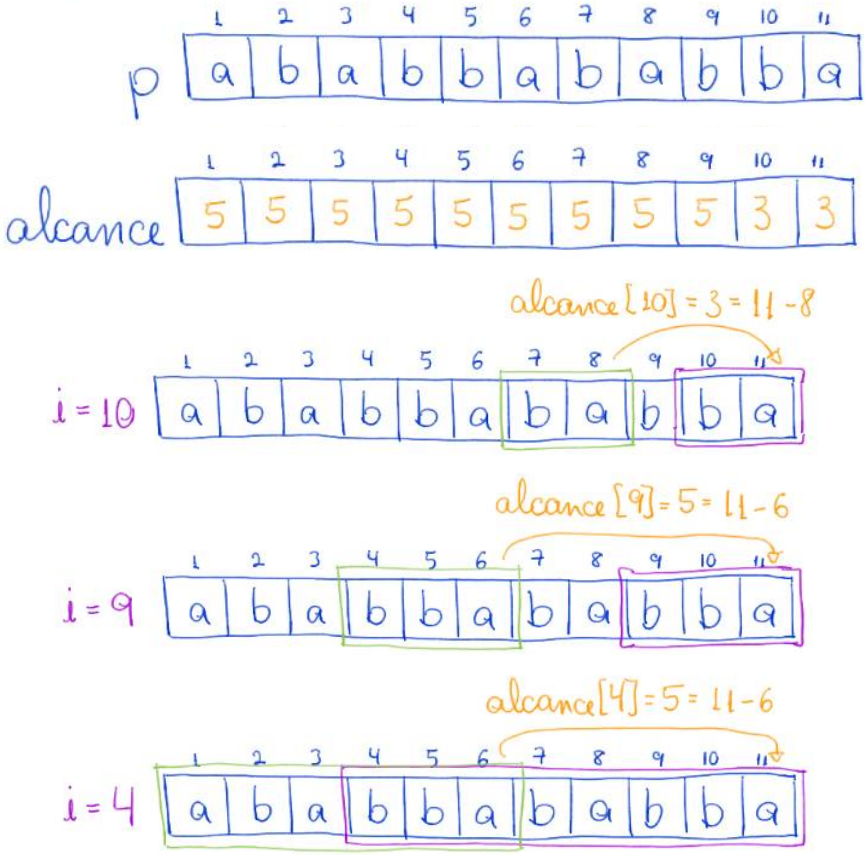

Exemplo 4:

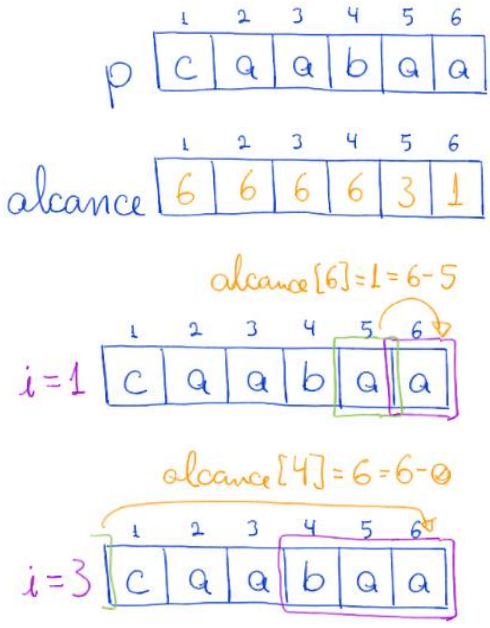

Código do pré-processamento:

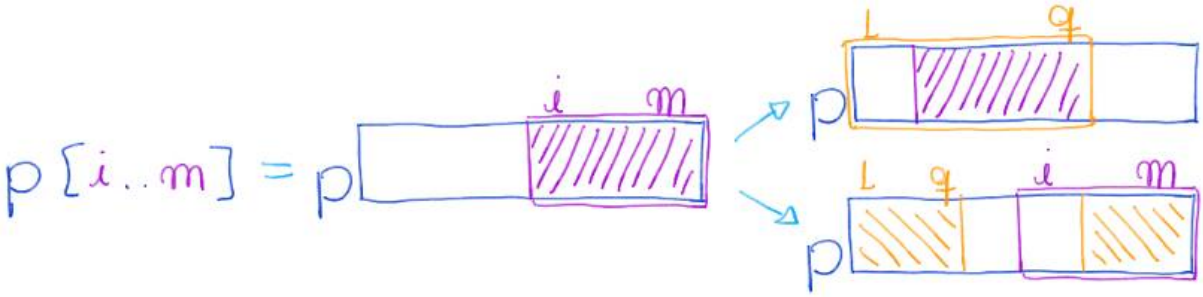


```c
int *preProcGoodSuff(char palavra[], int m) {
    int i, q, desl_p;
    int *alcance = malloc((m + 1) * sizeof(int));
    for (i = m; i >= 1; i--) {
        q = m - 1;
        desl_p = 0;
        // continua enquanto desl_p for menor que
        // o tamanho do sufixo palavra[i .. m]
        // e do prefixo palavra[1 .. q]
        while (desl_p < m - i + 1 && desl_p < q)
            if (palavra[m - desl_p] == palavra[q - desl_p])
                desl_p++;
            else
                q--, desl_p = 0;
        alcance[i] = m - q;
    }
    return alcance;
}
```

Eficiência de tempo:

- A fase de pré-processamento leva, no pior caso,
    - tempo proporcional ao cubo do tamanho da palavra,
        - i.e., O(m^3),
    - por exemplo, quando a primeira metade da palavra
        - é composta por ‘a’s e a segunda metade por ‘b’s.
- Vale destacar que o pré-processamento pode ser melhorado
    - para levar tempo quadrático no tamanho da palavra,
        - i.e., O(m^2),
    - se reaproveitarmos informações de uma iteração
        - do laço principal do pré-processamento para outra.
            - Que informações são essas?

Eficiência de espaço:

- o espaço adicional utilizado é proporcional ao tamanho da palavra,
    - i.e., O(m).

Ideia do algoritmo:

- Assim como o algoritmo anterior,
    - vamos percorrer o vetor texto[1 .. n] da esquerda para a direita
    - testando em cada iteração pos_t,
        - se palavra[1 .. m] é sufixo de texto[1 .. pos_t].
- No entanto, antes de incrementar pos_t para avançar no texto,
    - vamos utilizar a “good suffix heuristic”
        - em busca de um maior incremento para pos_t.

Exemplo 5:

- Neste exemplo vamos buscar p em t,
    - indo da esquerda para a direita,
- e saltando, a cada iteração,
    - de acordo com o deslocamento alcance[i]
        - do sufixo p[i .. m] terminado em t[pos_t],
            - que acabamos de detectar.

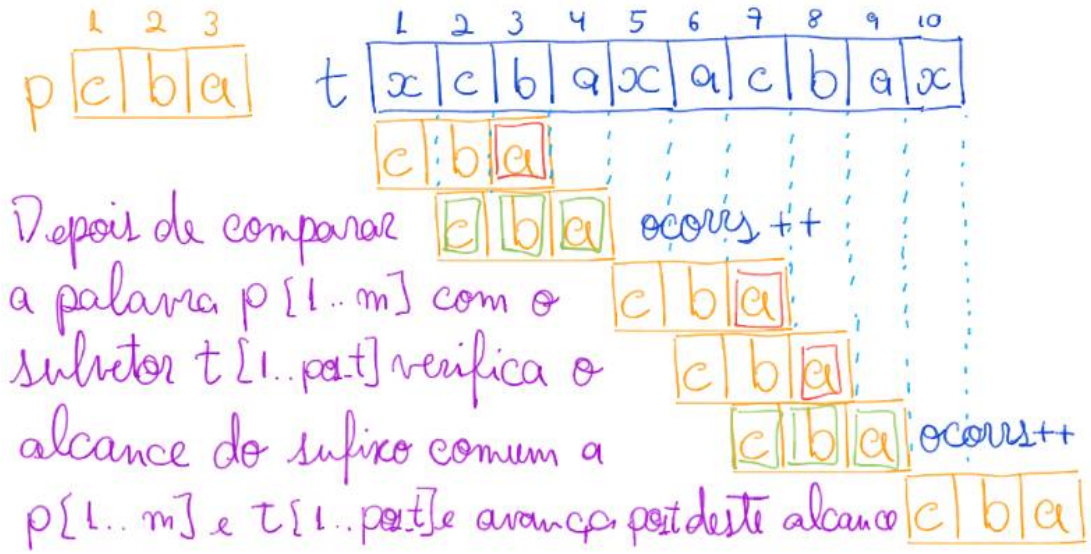

Código do algoritmo:

```
// Recebe vetores palavra[1..m] e texto[1..n],
// com m >= 1 e n >= 0, e devolve o número de
// ocorrências de palavra em texto.
int BoyerMoore2(char palavra[], int m, char texto[], int n) {
    int *alcance, pos_t, desl_p, ocorrs;
    // pré-processamento da palavra
    alcance = preProcGoodSuff(palavra, m);
    // busca da palavra no texto
    ocorrs = 0;
    pos_t = m;
    while (pos_t <= n) {
        desl_p = 0;
        // palavra[1..m] casa com p[pos_t-m+1..pos_t]?
        while (desl_p < m
           && palavra[m - desl_p] == texto[pos_t - desl_p])
            desl_p++; // ordem desse laço é importante?
```

```
        if (desl_p >= m)
            ocorrs++;
        if (desl_p == 0)
            pos_t += 1;
        else
            pos_t += alcance[m - desl_p + 1]; // por que + 1?
    }
    free(alcance);
    return ocorrs;
}
```

Invariante e corretude:

- Os invariantes principais são os mesmos do algoritmo básico.

Eficiência de tempo:

- Adicionalmente ao tempo gasto no pré-processamento, temos que
    - no pior caso ele leva tempo O(mn), pois
        - o laço externo itera (n - m + 1) vezes
            - e o laço interno itera m vezes.
        - Um exemplo, em que ele leva tempo O(n^2),
            - considere o mesmo cenário do algoritmo básico,
            - o texto de tamanho n tem apenas um caractere ‘x’,
            - e a palavra de tamanho n/2 tem o mesmo caractere ‘x’.
        - No entanto,
            - o pior caso deste algoritmo é mais raro
            - e o número de comparações médio é bem menor.
    - No melhor caso,
        - o caractere texto[pos_t] sempre casa com p[m]
            - e não aparece mais em p[1 .. m - 1],
                - ou seja, alcance[m] = m.
        - Com isso, pos_t avança em saltos de tamanho m,
            - e o número de comparações será da ordem de n / m.
        - Note que este valor é sublinear,
            - em relação ao tamanho do texto.

Eficiência de espaço:

- O espaço adicional é o mesmo daquele utilizado no pré-processamento,
    - i.e., O(m).

Terceiro algoritmo de Boyer-Moore

Corresponde à combinação dos dois algoritmos anteriores,

- i.e., escolhendo o maior incremento para pos_t a cada iteração.

Código:

```
// Recebe vetores palavra[1..m] e texto[1..n],
// com m >= 1 e n >= 0, e devolve o número de
// ocorrências de palavra em texto.
int BoyerMoore(char palavra[], int m, char texto[], int n) {
    int *alcance, *dist_ult, pos_t, desl_p, ocorrs, incr1, incr2;
    dist_ult = preProcBadCharac(palavra, m);
    alcance = preProcGoodSuff(palavra, m);
    ocorrs = 0;
    pos_t = m;
    while (pos_t <= n) {
        desl_p = 0;
        while (desl_p < m
           && palavra[m - desl_p] == texto[pos_t - desl_p])
            desl_p++;
        if (desl_p >= m)
            ocorrs++;
        if (pos_t == n)
            incr1 = 1;
        else
            incr1 = 1 + dist_ult[(int)texto[pos_t + 1]];
        if (desl_p == 0)
            incr2 = 1;
        else
            incr2 = alcance[m - desl_p + 1];
        pos_t += maximo(incr1, incr2);
    }
    free(dist_ult);
    free(alcance);
    return ocorrs;
}
```