# Processamento de Strings

SCC 5900 - Projeto Algoritmos

# Veja o código abaixo

```
11  int main(){
12      char text[1000],pattern[100];
13
14      fgets(text, 1000, stdin);
15      fgets(pattern, 100, stdin);
16
17      text[strlen(text)-1] = '\0';
18      pattern[strlen(pattern)-1] = '\0';
19
20      int tam_t = strlen(text);
21      int tam_pat = strlen(pattern);
22
23      int i = 0;
24      char *p = text;
25
26      while (tam_t-i >= tam_pat && strncmp(p, pattern, tam_pat) ){
27          //cout << p << endl;
28          i++; p++;
29      }
30
31      if (tam_t-i >= tam_pat)
32          cout << "A sub string foi encontrada na posicao = " << i << endl;
33
34      return 1;
35  }
```

Qual a complexidade da busca?

O(n) ??? talvez, em textos normais…

texto =
AAAAAAAAAAB

Pattern =
AAAAB

O(nm)

# Este código é o mesmo, só que sem strncmp

```
28      int tam_t = strlen(text);
29      int tam_pat = strlen(pattern);
30
31
32      for (int i=0; i<tam_t; i++){
33          bool achou = true;
34          for (int j=0; j<tam_pat; j++){
35              if (i+j >= tam_t || text[i+j] != pattern[j])
36                  achou = false;
37          }
38          if (achou)
39              cout << "A sub string foi encontrada na posicao = " << i << endl;
40
41      }
42
43      return 1;
```

# O algoritmo  KMP (Knuth - Morris - Pratt) 1977

- Veja o caso de “AAAAAAAAAABB” e “AAAAB”
  - o algoritmo anterior vai, no início, sempre comparar todos os A’s para falhar miseravelmente, e sempre,  quando chegar no primeiro B
- É possível “pular” comparações, ao invés de deslocar o padrão caracter a caracter no texto?
- Ou seja, é possível evitar “recomparar” um caracter em T (texto) que já é o igual ao mesmo caracter em P (pattern) ?
- O algoritmo KMP faz exatamente isso.
- Vejamos..

# KMP

```
                1         2         3         4         5
    01234567890123456789012345678901234567890123456789012
T = I DO NOT LIKE SEVENTY SEV BUT SEVENTY SEVENTY SEVEN
P = SEVENTY SEVEN
    0123456789012
```

- O 1º caracter de P não casa com T[i], para i = 0 até 13
  - Neste caso, KPM se comporta como o algoritmo força bruta anterior, incrementando i em uma unidade…
- i = 14 e j = 0  (sempre associaremos o índice j ao padrão P), temos:

# KMP: i = 14, j = 0...

```
                1         2         3         4         5
    01234567890123456789012345678901234567890123456789012345678890
T = I DO NOT LIKE SEVENTY SEV BUT SEVENTY SEVENTY SEVEN
P =               SEVENTY SEVEN
                  0123456789012
```

- Temos 11 acertos em i = 14 até 24, e um erro em i = 25 (j = 11).
- O algoritmo força bruta continuaria em i = 15, mas KPM pode retomar em i=25
- A parte do padrão até antes do erro é: “SEVENTY SEV”
- SEV (tam=3) aparece no início (prefixo) e no fim (sufixo) da string.
  - é chamada de borda
- Não podemos simplesmente começar em i = 25 e j = 0, mas podemos voltar j = 3, pulando 11 - 3 = 8 caracteres (‘SEVENTY ‘), enquanto i permanece em 25.

# KMP

```
                1         2         3         4         5
    01234567890123456789012345678901234567890123456789012345678890
T = I DO NOT LIKE SEVENTY SEV BUT SEVENTY SEVENTY SEVEN
P =                       SEVENTY SEVEN
                          0123456789012
                                    1
                                  ^ then immediate mismatch at index i = 25, j = 3
```

- Neste ponto, a string antes do mismatch é “SEV”. Não há borda.
- Portanto, j = 0 ->> voltamos a comparar P a partir de seu início.
- Há erros de i = 25 até 29.

# KMP

```
          1         2         3         4         5
01234567890123456789012345678901234567890123456789
T = I DO NOT LIKE SEVENTY SEV BUT SEVENTY SEVENTY SEVEN
P =                               SEVENTY SEVEN
                                  0123456789012
                                            1
```

- Então temos um casamento entre i = 30 até i = 42
- temos uma borda de tam = 5 (“SEVEN”), então j = 5, pulando 13-5 = 8 caracteres., recomeçando a busca em i=43, quando temos um novo casamento!
- Este é um algoritmo eficiente!

```
          1         2         3         4         5
01234567890123456789012345678901234567890123456789
T = I DO NOT LIKE SEVENTY SEV BUT SEVENTY SEVENTY SEVEN
P =                                       SEVENTY SEVEN
                                          0123456789012
```

# KMP = como calcular o reset j no padrão

```
      0 1 2 3 4 5 6 7 8 9 0 1 2 3
P =   S E V E N T Y   S E V E N
b = -1 0 0 0 0 0 0 0 0 1 2 3 4 5
```

- KPM pré-processa o padrão no início, de forma a calcular o tamanho de todas as possíveis bordas, criando o vetor b. Observe acima...
- Se o “erro” ocorrer em j = 11 (após achar casamento para “SEVENTY SEV”), devemos recomeçar P em j = b[11] = 3
- O algoritmo tem complexidade O (n+m)

# KMP

```
11  void kmpPreProcess(int *b, char *pat, int tam_pat){
12      int i = 0, j = -1; b[0] = -1;
13
14      while (i < tam_pat){
15          while (j>=0 && pat[i] != pat[j]) // eh diferente... Reseta j, usando b .
16              j = b[j];
17          i++; j++;
18          b[i] = j;     // observe que b[i] so deixa de ser zero quando o padrao se repetir em pattern!
19      }
20  }
21
22  void kpmSearch(int *b, char *pat, char *text, int tam_pat, int tam_t){
23      int i = 0, j = 0;
24      while (i < tam_t){
25          while (j >= 0 &&  text[i] != pat[j])
26              j = b[j];
27          i++; j++;
28          if (j == tam_pat) { // opa... teve matching !!!
29              cout << "A sub string foi encontrada na posicao = " << i - j << endl;
30              j = b[j];        // prepara j para um provavel matching novo....
31          }
32      }
33  }
```

# Suffix Trie, Suffix Tree e Suffix Array

- Estas são estruturas de dados muito eficientes para manipulação de strings
- A motivação cresceu bastante com a evolução dos trabalhos em sequenciamento genético onde a busca por padrões em cadeias enormes é fundamental para o entendimento do processo.

# Suffix Trie

- Não é um “typo”. Trie vem de “information re**trie**val”
- Um sufixo i (ou $i^{th}$ sufixo) de uma string é uma substring que vai do $i^{th}$ caracter da string até último caracter da string
  - Seja a string STEVEN: o 2o sufixo é “EVEN”; o 4o sufixo é “EN” (indexação em 0)
- Uma sufix trie de um conjunto de strings S é uma árvore com todos os possíveis sufixos das strings em S
  - o rótulo de uma aresta representa um caracter
  - o nó (vértice) representa um sufixo indicado pela trilha de rótulos: sequência de arestas da raiz até o vértice.
  - cada vértice é conectado a possíveis outros 26 vértices (assumindo que usamos letras maiúsculas apenas)
  - cada vértice tem 2 flags booleanos para indicar: palavra ou sufixo.

# Suffix Trie

- Seja S = {“CAR”, “CAT”, “RAT”}
- Os sufixos = {“CAR”, “AR”, “R”, “CAT”, “AT”, “T”, “RAT”, “AT”, “T”};
- Ordenando e eliminando repetições = {“AR”, “AT”, “CAR”, “CAT”, “R”, “RAT”, “T”};

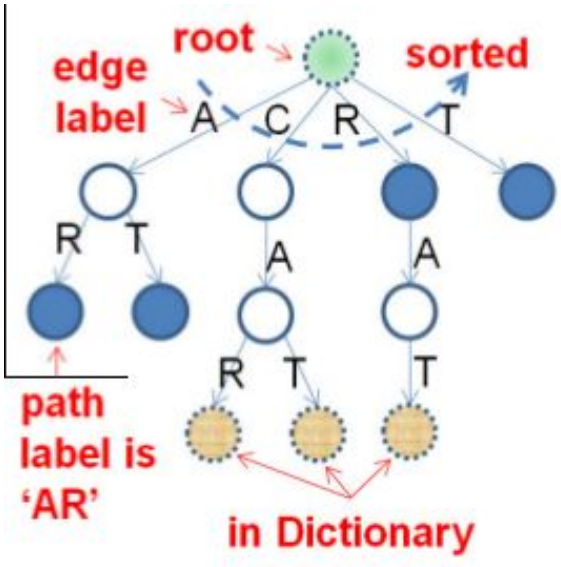


- **Bastante usado em dicionários.**
- **Uma vez construída, uma busca pode ser feita em O(m), onde m é o comprimento do padrão.**
- **Basta visitar os nós a partir da raíz**

# Suffix Tree

| i | Suffix |
|---|---|
| 0 | GATAGACA$ |
| 1 | ATAGACA$ |
| 2 | TAGACA$ |
| 3 | AGACA$ |
| 4 | GACA$ |
| 5 | ACA$ |
| 6 | CA$ |
| 7 | A$ |
| 8 | $ |

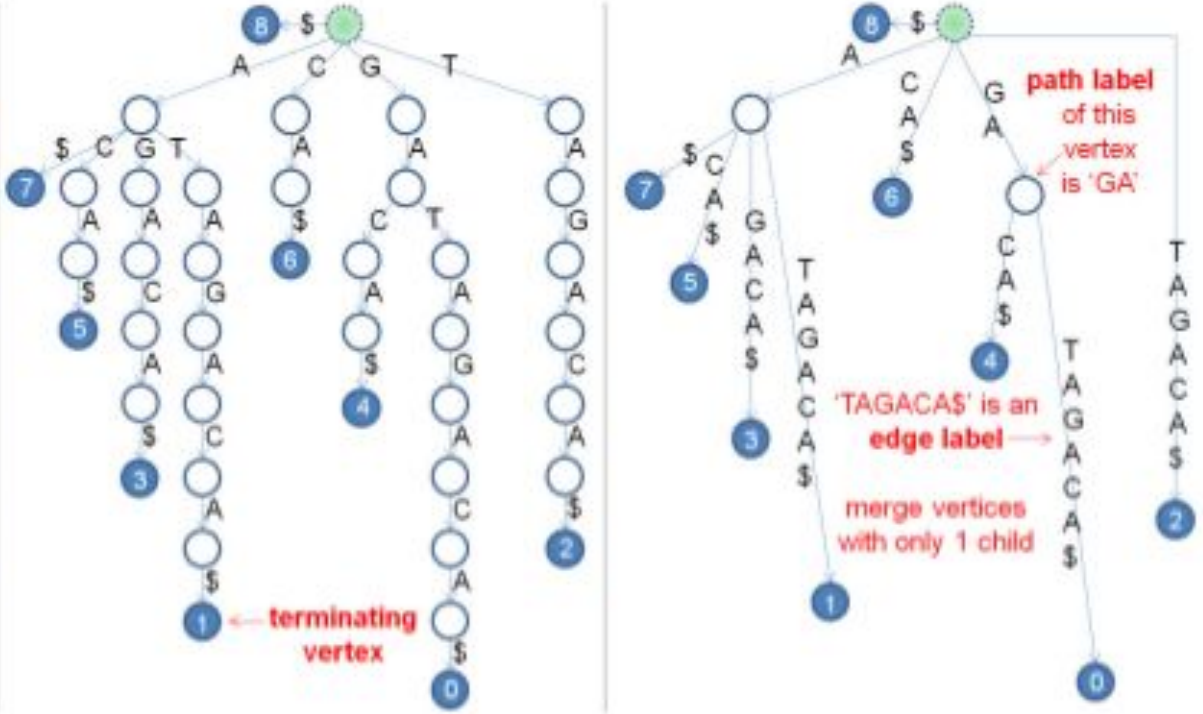


Figure 6.3: Suffixes, Suffix Trie, and Suffix Tree of T = 'GATAGACA$'

# Suffix Tree

- Em uma suffix trie, quanto maior a string mais vértices duplicados teremos
- Em uma suffix Tree, todos os vértices com apenas um filho são combinados (compressão de trilha!), reduzindo o número de nós.
- Obviamente, os rótulos agora serão maiores e representam um sufixo.
- a representação da árvores de sufixos é bem mais compacta que a da suffix trie, com no máximo 2n vértices
    - há no máximo n folhas para os n sufixos. Todos nós internos não raíz sempre se ramificam. Portanto, deve haver no máximo n-1 nós internos → Total = n folhas + n-1 nós internos + 1 raiz = 2n.

# Suffix Tree

- A implementação de árvores de sufixo não é trivial, especialmente se quisermos fazer com que a montagem da árvore seja de O(n), onde n é o tamanho do texto (dicionário).
- No entanto, é extremamente eficiente para diversas aplicações. Seja m o comprimento da string de busca. Seja z o nro de ocorrências de uma substring no texto.
  - Busca de substring (verifica se o padrão existe ou não): O(m)
  - Busca de todas ocorrências de uma substring: O(m + z)
  - Busca da substring mais longa: O(n)
  - Busca da substring comum mais longa em 2 substrings s1 e s2: construção da árvore O(tam(s1) + tam(s2)); busca: O(tam(s1) + tam(s2))

# Suffix Tree

- Sugiro um excelente material na web:
  - http://www.geeksforgeeks.org/ukkonens-suffix-tree-construction-part-1/
  - conceitos
  - disponibilização do código fonte
  - exemplos que podem ser executados no site.
- Vamos acompanhar toda a discussão neste material.

# Suffix Array - vetores de sufixos.

- bem mais fáceis de implementar que suffix trees
- embora não tão eficientes: O(n log n) na construção.
- buscas por padrões podem ser feitas em O(m logn)

# Suffix Array

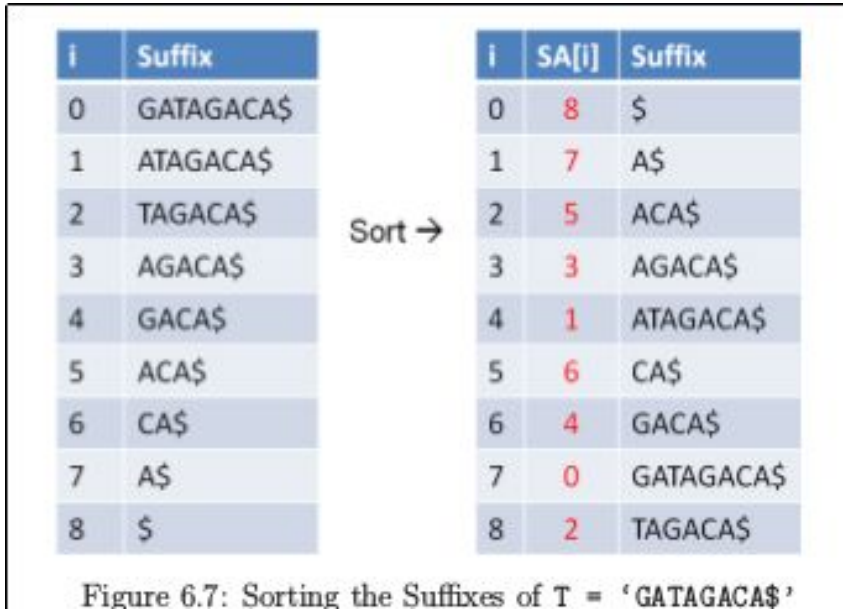

| i | Suffix |
|---|---|
| 0 | GATAGACA$ |
| 1 | ATAGACA$ |
| 2 | TAGACA$ |
| 3 | AGACA$ |
| 4 | GACA$ |
| 5 | ACA$ |
| 6 | CA$ |
| 7 | A$ |
| 8 | $ |

Sort →

| i | SA[i] | Suffix |
|---|---|---|
| 0 | 8 | $ |
| 1 | 7 | A$ |
| 2 | 5 | ACA$ |
| 3 | 3 | AGACA$ |
| 4 | 1 | ATAGACA$ |
| 5 | 6 | CA$ |
| 6 | 4 | GACA$ |
| 7 | 0 | GATAGACA$ |
| 8 | 2 | TAGACA$ |

Figure 6.7: Sorting the Suffixes of T = 'GATAGACA$'

vetor que armazena uma permutação de n índices de sufixos ordenados.

# suffix arrays X suffix trees

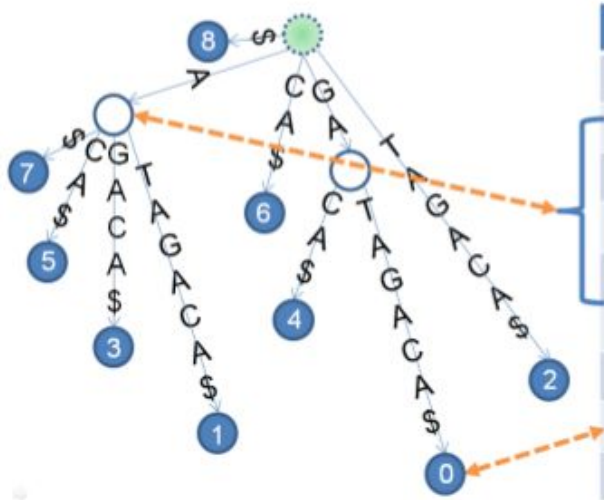


| i | SA[i] | Suffix |
|---|---|---|
| 0 | 8 | $ |
| 1 | 7 | A$ |
| 2 | 5 | ACA$ |
| 3 | 3 | AGACA$ |
| 4 | 1 | ATAGACA$ |
| 5 | 6 | CA$ |
| 6 | 4 | GACA$ |
| 7 | 0 | GATAGACA$ |
| 8 | 2 | TAGACA$ |

Figure 6.8: Suffix Tree and Suffix Array of T = 'GATAGACA$'

# suffix arrays - construção

```
#include <algorithm>
#include <cstdio>
#include <cstring>
using namespace std;

#define MAX_N 1010                              // first approach: O(n^2 log n)
char T[MAX_N];    // this naive SA construction cannot go beyond 1000 chars
int SA[MAX_N], i, n;                          // in programming contest settings

bool cmp(int a, int b) { return strcmp(T + a, T + b) < 0; }          // O(n)

int main() {
  n = (int)strlen(gets(T)); // read line and immediately compute its length
  for (int i = 0; i < n; i++) SA[i] = i; // initial SA: {0, 1, 2, ..., n-1}
  sort(SA, SA + n, cmp);      // sort: O(n log n) * cmp: O(n) = O(n^2 log n)
  for (i = 0; i < n; i++) printf("%2d\t%s\n", SA[i], T + SA[i]);
} // return 0;
```

# suffix arrays - Exemplo em string matching

- a procura por um padrão de tam=m em T de tam=n é O(m logn).
- Isso é logn vezes mais lento que na árvore de sufixos, mas é aceitável.
  - precisamos de 2 buscas binárias O(log n) nos O(m) sufixos ordenados
  - as duas buscas binárias
    - 1a → busca pelo menor i, tal que o prefixo do sufixo SA[i] casa com o padrão P
    - 2a → busca pelo maior i, tal que o prefixo do sufixo SA[i] casa com o padrão P

# suffix arrays - Exemplo em string matching