

团体整体作战，不抛弃不放弃

第09讲 字符串

信息学院 (智能应用研究院)

欧 新 宇

建议课时：2

第4章 字符串

考核要点

- 考核大纲

字符串的模式匹配

- 复习要点

- 了解朴素模式匹配 (BF暴力匹配) 算法
- 重点掌握KMP匹配算法的原理
- 掌握next数组的推理过程, 能够手工求next数组
- 了解nextval数组的求解方法

第09讲 字符串


本讲作业

● 必做题

- ✓ 【课堂互动9.1】字符串的基本概念和BF匹配算法
- ✓ 【课堂互动9.2】KMP匹配算法
- ✓ 【课后作业09】字符串


● 选做题

- ✓ 【课前自测09】字符串
- ✓ 【扩展练习09】字符串



- 字符串的基本概念
- BF暴力匹配算法（朴素模式匹配）
- KMP匹配算法





字符串的基本概念

- / 字符串的定义
- / 字符串的抽象数据类型
- / 字符串的数据结构
- / 字符串的前缀、后缀和部分匹配

问题引入

模式匹配

查找功能:

给定一段文本，要求能够根据用户提供的特定关键词，找出关键词在文本中出现的位置。



用户给定的关键词或字符串被称为**模式串**，段落文本成为**目标串**，因此字符串匹配又称为模式匹配。

字符串的基本概念

什么是串

字符串 (String)，简称**串**，由**零个或多个字符**组成的**有限序列**，记作： $S = 'a_1a_2...a_n'$ ($n \geq 0$)

- S 是串名，单引号括起来的字符序列是串值， a_1 可以是字母、数字或其他字符
- 串中**字符的个数** n 称为**串的长度**， $n = 0$ 时串称为**空串**，表示为 $\emptyset$
- 串中**任意多个连续的**字符组成的**子序列**称为串的**子串**，包含子串的串称为**主串**
- 字符在串中的序号称为字符的**位置**
- 子串在主串中的**位置**等于子串**第一个字符**在主串中的**位置**
- 一个或多个空格组成串称为**空格串**，空格串不是空串
- 两个串**长度相等**，且**每个对应位置**的字符**都相等**时，两个串**相等**

字符串的基本概念

字符串的抽象数据类型

ADT String{

数据对象: $D = \{a_i \mid a_i \in \text{CharacterSet}, i = 1, 2, 3, \dots, n, n \geq 0\}$

数据关系: $R = \{ \langle a_{i-1}, a_i \rangle \mid a_{i-1}, a_i \in D, i = 1, 2, 3, \dots, n \}$

基本操作:

StrAssign (&T, chars) : 赋值, 将串T赋值为chars

StrCompare (S, T) : 比较两个串S和T是否相等

StrLength (S) : 求串T的长度, 返回元素个数

Index(S, T, p): 求主串S中串T的位置

Concat(&T, S1, S2): 将串S1和S2合并为新串T

SubString(&Sub, S, pos, len): 返回串S中起始位置为pos, 长度为len的子串

StrCopy(&T, S): 由串S复制得到串T

}ADT String

字符串的基本概念

字符串的存储结构

顺序存储结构



定长
固定空间

```
#define MaxLen 255 // 1. 定义字符串的最大长度
typedef struct SString { // 2. 定义顺序串
    char ch[MaxLen]; // 2.1 定义字符串序列
    int length; // 2.2 定义串内字符长度变量
}SString;
```

堆(顺序存储)




动态
分配空间

```
#typedef struct HString { // 1. 定义动态存储的堆字符串
    char *ch; // 2. 按串长分配存储区
    int length; // 3. 定义串内字符长度变量
}HString;
```

块(链式储存)



以多字符存
串结点



字符串的基本概念

串的前缀、后缀和部分匹配值


前缀：除最后一个字符以外，字符串的所有头部子串

后缀：除第一个字符以外，字符串的所有尾部子串

部分匹配：字符串的前缀和后缀的最长相等长度

部分匹配值：由每个子串构成的部分匹配值序列

例1：字符串 ababa			
子串	前缀	后缀	最长相等值
a	null	null	0
ab	a	b	0
aba	a,ab	a,ba	1
abab	a,ab,aba	b,ab,bab	2
ababa	a,ab,aba,abab	a,ba,aba,baba	3
部分匹配值：00123			




BF暴力匹配算法 (朴素模式匹配)

/ BF算法的基本思想

BF暴力匹配算法 (朴素模式匹配)

BF算法的基本思想

模式匹配是指从**主串**中查找与**模式串**完全相同的部分。其中最简单的方法是**逐元素匹配**，即**朴素模式匹配 (Brute-Force, BF)** 算法。



时间复杂度为 $O(m * n)$

平均时间复杂度近似于 $O(m + n)$


BF暴力匹配算法 (朴素模式匹配)

BF算法的基本思想


- 1 执行循环，将主串的第*i*个字符与子串的第1个字符比较。
 - ✓ 若相等，则继续逐个比较后续字符
 - ✓ 若不相等，回溯到主串的下一个字符 ($i = i - j + 2$)，重新与子串第1个字符比较
- 2 若S中**存在**与T匹配的子序列，则返回子序列的第1个字符序号；若不存在，则返回0


BF算法的基本流程

```
int Index (SString S, SString T) { // S主串, T子串
    int i = 1, j = 1;                // 初始化串的指针
    while (i <= S.length && j <= T.length) {
        if (S.ch[i] == T.ch[j]) {    // 相等, 则继续比较
            i++; j++;
        }
        else {                        // 不相等, 则回溯
            i = i - j + 2; j = 1;
        }
    }
    if (j > T.length)
        return i - T.length;
    else
        return 0;
}
```



课堂互动 9.1






KMP匹配算法

- / KMP算法的动机
- / KMP算法的基本思想
- / KMP算法的代码实现
- / next[] 数组的计算方法
- / nextval[] 数组的计算方法

KMP匹配算法



克鲁特Knuth
《计算机程序设计艺术》




莫里斯Morris



普拉特Pratt

KMP匹配算法


KMP算法的动机



是否能利用已获得的信息来避免暴力算法中“回退 (backup)”的步骤?

KMP匹配算法

KMP算法的基本思想



KMP匹配算法

KMP算法的代码实现

- 1 定义两个指针，分别指向主串和子串的工作元素
- 2 若主串和子串未完，则持续对比
 - ✓ 若单个字符匹配，则指针后移1位
 - ✓ 若单个字符失配，则子串根据next数组跳过前面的一些字符
 - ✓ 若子串第一个字符失配，则将主串指针向前移动1位
- 3 若匹配成功，返回子串的起始位置

KMP算法主程序

```
Status KMP_Search (SString string, SString patt, int next[])
{
    int i = 1, j = 1;
    while (i <= string.length && j <= patt.length) {
        if (string.ch[i] == patt.ch[j]) {
            i++; j++;
        }
        else if (j > 1)
            j = next[j];
        else
            i++;
    }
    if (j > patt.length)
        return i - patt.length;
}
```

主串中的
指针 i 永不回退
时间复杂度 $O(n)$

KMP匹配算法

模式串 next[j] 的计算方式

- ① $next[1] = 0$, $next[2] = 1$
- ② 若存在 n 个前缀 = n 个后缀, 则 $next[j] = n + 1$
- ③ 不存在 前缀 = 后缀, 则 $next[j] = 1$

例2:

j	1	2	3	4	5	6	7
模式串	a	b	c	a	a	b	b
Next[j]	0	1	1	1	2	2	3

不存在相等子串

a

a

ab

KMP匹配算法

模式串 next[j] 的计算方式

例3: 已知字符串S为 ‘abaabaabcabaabc’ ， 模式串T为 ‘abaabc’ 。采用KMP算法进行匹配，第一次出现 “失配” ($S[i] \neq T[j]$) 时, $i=j=5$ ，则下次开始匹配时, i 和 j 的值分别是 (**C**) :

A. $i=1, j=0$ B. $i=5, j=0$ C. $i=5, j=2$ D. $i=6, j=2$

【解析】

1. 在KMP算法中，主串指针 i **永不回退**，因此 $i = 5$
2. 当 $j=5$ 时，新的 j 值等于 $next[5]$

j	1	2	3	4	5	6
模式串	a	b	a	a	b	c
部分匹配字符	-	-	-	a	a	ab
next[j]	0	1	1	2	2	3

KMP匹配算法

next[] 数组的优化

当模式串中有多个连续相同的值，则可能出现多次重复匹配。

例如，主串 $s=aaabaaaab$ ，模式串 $p=aaaab$

主串	a	a	a	b	a	a	a	a	b
j	1	2	3	4	5				
模式串	a	a	a	a	b				
Next[j]	0	1	2	3	4				

当发生失配时，需要多次连续回退。因为 $p_{next[4]=3}=p_4=a$, $p_{next[3]=2}=p_3=a$, $p_{next[2]=1}=p_2=a$ 。

解决办法：

对next[j]进行再次递归，将next[j]修正为next[next[j]]

KMP匹配算法

next[] 数组的优化 -> nextval[] 数组

- ① $\text{nextval}[1] = 0$
- ② 若第2位与第1位相同，则为0；若不相同，则为1
- ③ 从第3位开始，根据next值指路。
若元素值相同，则等于目标元素nextval值；不相同，则等于当前next值

j	1	2	3	4	5
模式串	a	a	a	a	b
next[j]	0	1	2	3	4
nextval[j]	0	0	0	0	4

直接退回到起点

KMP匹配算法


next[] 数组的优化 -> nextval[] 数组

例4: 串 'ababaaababaa' 的nextval数组为 (**C**) :


A. 010112010102 B. 010114110102 C. 010104210104 D. 011102110104

【解析】

j	1	2	3	4	5	6	7	8	9	10	11	12
模式串	a	b	a	b	a	a	a	b	a	b	a	a
next[j]	0	1	1	2	3	4	2	2	3	4	5	6
nextval[j]	0	1	0	1	0	4	2	1	0	1	0	4



课堂互动 9.2



第09讲 串

小 结

- 串是内容受限的线性表，它限定表中的元素为字符。
- 常见的模式匹配，包括BF匹配算法和KMP匹配算法
- BF暴力模式匹配算法时间复杂度 $O(m*n)$ ，KMP匹配算法时间复杂度 $O(m+n)$
- BF暴力模式匹配算法失配时，主串 i 回溯到 $i-j+2$ ，模式串 j 回溯到 $j=1$
- KMP匹配算法失配时，主串 i 不需要回溯，模式串 j 回溯与模式串有关，使用 $next[j]/nextval[j]$ 表示
- $nextval[]$ 数组时对 $next[]$ 数组的优化，可以有效解决连续字符重复对比的问题

读万卷书 行万里路 只为最好的修炼



QQ: 14777591 (宇宙骑士)

Email: ouxinyu@alumni.hust.edu.cn

Website: <http://ouxinyu.cn>

Tel: 18687840023

地址: 安宁校区 诚远楼201

南院 智能应用研究院A306-2