アルゴリズムとデータ構造III
12回目：1月10日（木）

全文検索アルゴリズム
（Aho-Corasick）
暗号：符号化：テキスト圧縮

授業資料　http://ir.cs.yamanashi.ac.jp/~ysuzuki/algorithm3/index.html

中間試験　成績

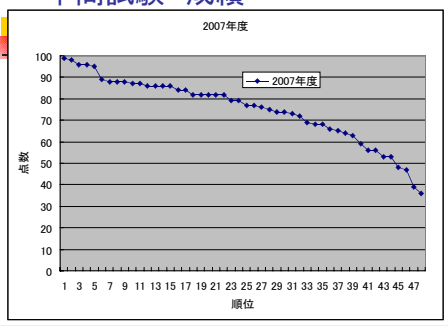

中間試験

	2007年度
受験者数	48名
平均点	75点
最高点	99点（1名）

問題別平均点

問題番号	満点	平均点
1	14	12.0
2	10	9.9
3	8	4.5
4	16	14.1
5	0	0
6	8	5.6
7	14	12.7
8	10	6.0
9	9	7.0
10	10	3.1

授業の予定（中間試験まで）

1	10/11	スタック（後置記法で書かれた式の計算）
2	10/18	文脈自由文法
3	10/25	構文解析　CKY法
4	11/01	構文解析　CKY法，チャート法
5	11/08	構文解析　CKY法，チャート法
6	11/15	構文解析　チャート法
7	11/29	グラフ（動的計画法，ダイクストラ法，DPマッチング）
8	12/06	グラフ（DPマッチング，ビームサーチ，A*アルゴリズム）
9	12/13	中間試験

授業の予定（中間試験以降）

10	12/17	全文検索アルゴリズム（simple search, KMP）
11	12/20	全文検索アルゴリズム（BM, Aho-Corasick）
12	01/10	全文検索アルゴリズム（Aho-Corasick），データ圧縮
13	01/17	暗号（黄金虫，踊る人形） 符号化（モールス信号，Zipfの法則，ハフマン符号）テキスト圧縮（zip） 音声圧縮　ADPCM，MP3
14	01/28（月）	音声圧縮（CELP），画像圧縮（JPEG）
15	02/07	期末試験

補講の実施日時候補

- ~~1月21日(月)5時限~~
- ~~1月24日(木)5時限 (1/24は月曜の時間割)~~
- 1月28日(月)5時限 ← 決定

本日のメニュー

- 全文検索アルゴリズム
  - Aho-Corasickの続き
- 暗号
  - 黄金虫(The gold bug)
  - 踊る人形(The Adventure of the Dancing Men)
- 符号化
- テキスト圧縮

全文検索

- 文書中から，与えられた文字列と完全に一致する部分を探し出す．
- 全文検索の種類
  - **文字列照合による全文検索**
  - 索引を用いた全文検索

文字列照合タスク

- テキスト処理には不可欠
- テキスト文字列からキーワードとその出現位置を見つける
- 例
  - テキスト文字列：aabcdabdabbabcdabacade
  - キーワード：abcaba

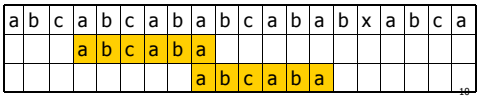

文字列照合アルゴリズム

- Simple Search
- Knuth-Morris-Pratt法
- Boyer-Moore法
- Aho-Corasick法

文字列照合問題の単純な解決法 Simple Search

- Simple Searchの文字列照合手順
- Simple Searchのアルゴリズム
- Simple Searchの評価

単純な文字列照合アルゴリズム Simple Search

- テキストストリングの1文字目からn文字目まで，2文字目からn+1文字目まで，・・・がキーワードと一致するかどうかをチェックする．

a	b	c	a	b	c	a	b	a	b	c	a	b	a	b	x	a	b	c	a
a	b	c	a	b	a														
	a	b	c	a	b	a													
		a	b	c	a	b	a												
			a	b	c	a	b	a											
				a	b	c	a	b	a										

13

Simple Search 同じ部分を何度も照合しなければならない

位置	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9	0	1	2
text	a	b	c	a	b	c	a	b	a	b	c	a	b	a	b	x	a	b	c	a	b	x
	a	b	c	a	b	a																
		a																				
			a																			
				a	b	c	a	b	a													
					a																	
						a												照合失敗				
							a	b	c													
								a										文字列照合成功				
									a	b	c	a	b	a								
											a											
												a										
													a	b	c							
照合回数	1	2	2	2	3	3	2	3	3	2	2	2	2	2								

Simple Searchのアルゴリズム

- 入力:テキストストリング text, キーワード key
- 出力:テキストストリング中のキーワードの位置
- m: テキストストリングの長さ
- n: キーワードの長さ

```
Method
begin
        for i:=1 to m-n+1 do                    起点を決めて
        begin
                for j:=1 to n do                キーワードと1字ずつ照合
                        if text[i+j-1]≠key[j] then
                                goto 1;
                print i;
                1:
        end
end
```

15

Simple Search 最も効率の悪い場合

文字照合回数 (7-3+1)*3=15
(m-n+1)*n回
一般にm≫nなので O(mn)

- key = aaa
- text = aaaaaaa

位置	1	2	3	4	5	6	7
text	a	a	a	a	a	a	a
	a	a	a				
		a	a	a			
			a	a	a		
				a	a	a	
					a	a	a
照合回数	1	2	3	3	3	2	1

16

Knuth-Morris-Pratt法 （KMP法）

- Simple Search
  - テキストストリング中の各文字がキーワードと複数回照合される → 冗長
- KMP法
  - 文字照合の実行中に次回の文字照合を考慮しつつ処理を進める
  - 文字照合中，バックトラックが必要ない

17

Knuth-Morris-Pratt法

```
Key: a b c a b a
     1 2 3 4 5 6
next 0 1 1 0 1 3 2
```

```
位置 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9 0 1 2
text a b c a b c a b a b c a b a b x a b c a b x
     a b c a b a
       1 2 ←―― キーワードの2文字目に対応している
       a b c a b a
         1 2 1
3から
           a b c a b a
             1 2 1
2から
               a b c
                 a
2から                  a b c a b a
                         1 2
1から
```

18

KMP法　アルゴリズム

```
Method kmp                                  m :textの長さ
begin                                       n :keywordの長さ
                                            i: textの照合位置
                                            J: keywordの照合位置
     j:=1;
     for i:=1 to m do
     begin
          while j>0 and key[j] ≠text[i] do      照合
               j:=next(j);   つぎの照合位置
          if j=n then
               print i-n+1:                     照合成功
          j:=j+1;
     end
end
```


キーワードの接頭辞文字列の出現位置

関数next：次回の照合でキーワードの何文字目を照合すべきか

テキストストリング中の照合に失敗した文字の直前の何文字がキーワードの接頭辞になっているかを調べる

位置	1	2	3	4	5	6	7				
キーワード	a	b	c	a	b	a					
				a	b	c	a	b	a		

6文字目で照合失敗した場合：直前文字列がabなので3文字目から照合開始

						a	b	c	a	b	a

照合に成功した場合：直前文字がaなので2文字目から照合開始

next関数値	0	1	1	0	1	3	2				

next関数

Keyword: abcabaのとき　123456

a:1：keywordの一文字目のa

a：a以外の文字

1文字目のaで照合失敗 （直前の文字がa）
→ 照合失敗箇所の右隣とa:1を照合
→ 照合失敗箇所はキーワードの0文字目と照合→ next(1)=0

2文字目のbで照合失敗 （直前の文字がab）
→ 照合失敗箇所とa:1を照合 → next(2)=1

3文字目のcで照合失敗 （直前の文字がabc）
→ 照合失敗箇所とa:1を照合 → next(3)=1

next関数

Keyword: abcabaのとき　123456

a:1：keywordの一文字目のa

a：a以外の文字

4文字目のaで照合失敗 （直前の文字がabca）
→ 照合失敗箇所の右隣とa:1を照合
→ 照合失敗箇所はキーワードの0文字目と照合→ next(4)=0

5文字目のbで照合失敗 （直前の文字がabcab）
→ 照合失敗箇所とa:1を照合 → next(5)=1

6文字目のaで照合失敗 （直前の文字がabcaba）
→ 照合失敗箇所とc:3を照合 → next(6)=3

6文字目のaで照合成功 （直前の文字がabcaba）
→ 照合失敗箇所（照合成功末尾の右隣）とb:2を照合 → next(7)=2

KMP法　アルゴリズム next関数

入力：キーワード key, 出力：next関数

```
Method next          n : keyの長さ
begin                j : keyの照合位置
                     t : keyのj文字目の直前の何文字がkeyの接頭辞になっているか
     t:=0;
     next(1):=0;
     for j:=1 to n do      keyの各文字に対してnext関数値を計算
     begin
          while t ≠ 0 and key[j] ≠ key[t] do
               t:=next(t);   keyのj文字目までの文字列がkeyの
                             接頭辞と一致しているか調べる
          t:=t+1;
          if key[j+1]=key[t] then    keyの
               next(j+1):=next(t);   j+1文字目の
          else                       next関数値を
               next(j+1):=t;         決定
     end
end
```


KMP法の評価

- KMP法
  - 漸近的時間計算量　$O(m)$
  - next関数が必要　テキスト文字列の各文字に対して1回照合
- Simple Search法
  - 漸近的時間計算量　$O(mn)$　テキスト文字列の各文字に対してキーワード文字数回照合

m: テキスト文字列数
n: キーワード文字列数

Boyer-Moore法

- キーワードの末尾から照合を行う.
- キーワードの末尾と照合したテキストストリングの文字を覚えておく
- その文字とキーワードの文字が一致するまでキーワードをずらす

Boyer-Moore法

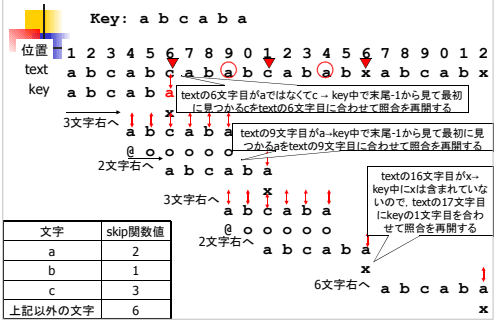

文字	skip関数値
a	2
b	1
c	3
上記以外の文字	6

skip関数

- テキスト文字列中の照合文字cが，キーワードの末尾から何文字目にあるか

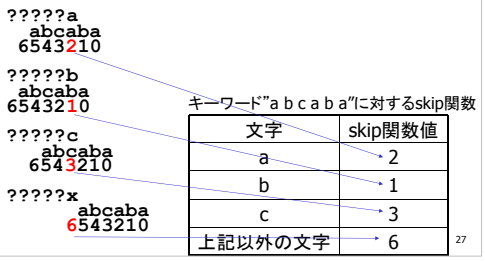

キーワード"a b c a b a"に対するskip関数

文字	skip関数値
a	2
b	1
c	3
上記以外の文字	6

BM法による文字列照合

m :textの長さ
n :keywordの長さ
J: keywordの照合位置
pos: text中の照合位置

```
Method BM
begin
      pos:=n;
      while pos<=m do
      begin
            if text[pos]=key[n] then
            begin
                  k:=pos-1;
                  j:=n-1;
                  while j>0 and text[k]=key[j] do
                  begin
                        k:=k-1;
                        j:=j-1;
                  end
                  if j=0 then
                        print k+1;
            end
            pos:=pos+skip(text[pos]);
      end
end
```

BM法による文字列照合
skip関数

入力:キーワード key
出力:skip関数

文字種:p~q
n: keyの長さ

```
Method skip
begin
      for i:=p to q do
            skip(i):=n;
      for i:=1 to n-1 do
            skip(key[i]):=n-i;
end
```

初期設定(全ての文字種でkeyの長さだけskip)

Keyに含まれる文字種の場合keyの先頭から末尾まで調べて最後に見つかった位置をkeyの長さから引いた数だけskipする

BM法の評価

- 最良の場合　m/n回の文字照合
  $\text{textの文字} \cap \text{keyの文字} = \phi$
- 最悪の場合　m*n回の文字照合
  $\text{textの文字} = \text{keyの文字} = \{a\}$
- キーワードが長いほど高速
  - keyに含まれない文字がtextに出現したときにkeyの長さだけスキップできる
- 文字種類数が少ないほど遅くなる
  - text中の文字がkey中に現れる確率が高くなる　→　遅くなる

Aho-Corasick法

- 5.5.1 マシンAC
- 5.5.2 AC法の文字列照合手順
- 5.5.3 AC法の文字列照合アルゴリズム
- 5.5.4 AC法の評価
- 5.5.5 マシンACの構成方法

Aho-Corasick法

- 文書中から複数のキーワードを検索するための手法
- テキストストリングをバックトラックすることなく1回走査するだけで，複数のキーワードを同時に検出することができる
- goto関数，failure関数，output関数により構成される

goto関数，failure関数，output関数

- goto関数
  - ある状態で文字xが入力されたときに遷移する状態
- failure関数
  - goto関数からfailが返された際の照合ポインタの移動先
- output関数
  - ある状態に遷移したときに検出できるキーワード

マシンAC　goto関数 {"ab","bc","bab","d","abcde"}

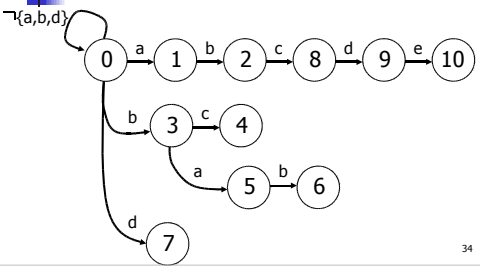

マシンAC failure関数，output関数

s	f(s)
1	0
2	3
3	0
4	0
5	1
6	2
7	0
8	4
9	7
10	0

s	output(s)
2	{"ab"}
4	{"bc"}
6	{"bab","ab"}
7	{"d"}
8	{"bc"}
9	{"d"}
10	{"abcde"}

照合ポインタの遷移 テキストストリング "xbabcdex"

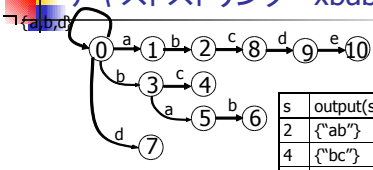

s	output(s)
2	{"ab"}
4	{"bc"}
6	{"bab","ab"
7	{"d"}
8	{"bc"}
9	{"d"}
10	{"abcde"}

s	f(s)
1	0
2	3
3	0
4	0
5	1
6	2
7	0
8	4
9	7
10	0

照合ポインタの遷移
テキストストリング ”xbabcdex”

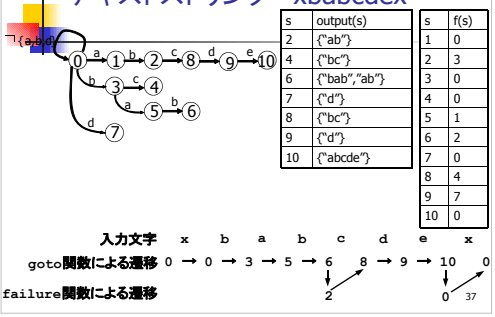

s	output(s)
2	{“ab”}
4	{“bc”}
6	{“bab”,”ab”}
7	{“d”}
8	{“bc”}
9	{“d”}
10	{“abcde”}

s	f(s)
1	0
2	3
3	0
4	0
5	1
6	2
7	0
8	4
9	7
10	0

入力文字 x b a b c d e x

goto関数による遷移 0 → 0 → 3 → 5 → 6 → 8 → 9 → 10 → 0

failure関数による遷移 2 0

37

練習問題　照合ポインタの遷移
テキストストリング ”abcdbcba”

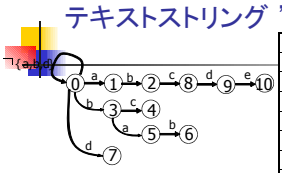

s	output(s)
2	{“ab”}
4	{“bc”}
6	{“bab”,”ab”}
7	{“d”}
8	{“bc”}
9	{“d”}
10	{“abcde”}

s	f(s)
1	0
2	3
3	0
4	0
5	1
6	2
7	0
8	4
9	7
10	0

入力文字 a b c d b c b a

goto関数による遷移

failure関数による遷移

38

練習問題　照合ポインタの遷移
テキストストリング ”abcdbcba”

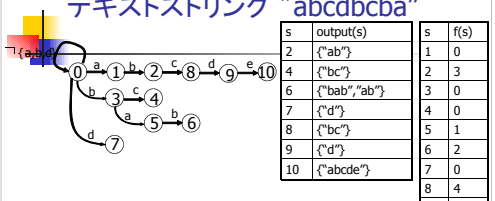

s	output(s)
2	{“ab”}
4	{“bc”}
6	{“bab”,”ab”}
7	{“d”}
8	{“bc”}
9	{“d”}
10	{“abcde”}

s	f(s)
1	0
2	3
3	0
4	0
5	1
6	2
7	0
8	4
9	7
10	0

入力文字 a b c d b c

goto関数による遷移 0 → 1 → 2 → 8 → 9 → 3 → 4 → 3 → 5

failure関数による遷移 7 0 0

39

マシンACの構成方法

- goto関数とoutput関数の構成方法
- failure関数の構成方法

40

goto関数とoutput関数の構成方法 1/2

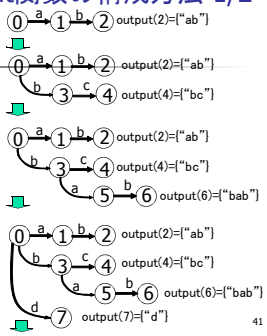

keyword
“ab” (2)
”bc” (4)
”bab” (6)
”d” (7)
”abcde” (10)

41

goto関数とoutput関数の構成方法 2/2

keyword
“ab”
”bc”
”bab”
”d”
”abcde”

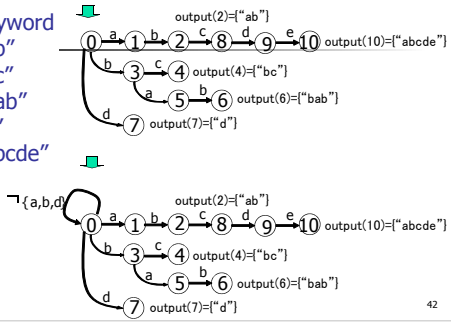

42

failure関数の構成方法

状態sのfailure関数

f(s)=q | ACstring[q]がACstring[s]の最長の接尾辞になる状態q

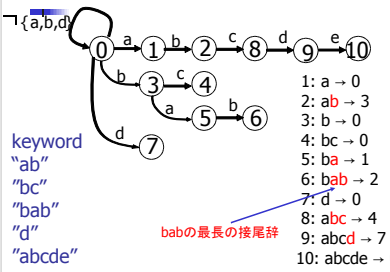

1: a → 0
2: ab → 3
3: b → 0
4: bc → 0
5: ba → 1
6: bab → 2
7: d → 0
8: abc → 4
9: abcd → 7
10: abcde → 0

s	f(s)
1	0
2	3
3	0
4	0
5	1
6	2
7	0
8	4
9	7
10	0

データ圧縮

- 対象データ
  - テキスト
  - 音声
    - 音楽
    - 話し声
  - 画像
  - 動画
- 圧縮方式
  - 可逆圧縮
  - 不可逆圧縮