アルゴリズムとデータ構造III
11回目：12月22日

全文検索アルゴリズム
（BM, Aho-Corasick）

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

授業の予定（中間試験まで）

1	10/06	スタック（後置記法で書かれた式の計算）
2	10/13	チューリング機械，文脈自由文法
3	10/20	構文解析　CYK法
4	11/10	構文解析　CYK法
5	11/17	構文解析（チャート法），グラフ（ダイクストラ法）
6	12/01	構文解析（チャート法），グラフ（ダイクストラ法，DPマッチング）
7	12/08	グラフ（DPマッチング，A*アルゴリズム）
8	12/09	グラフ（A*アルゴリズム），前半のまとめ
9	12/15	中間試験

12/09: 1時限 B2-31，　12/16: 4時限 B2-41

授業の予定（中間試験以降）

10	12/16	全文検索アルゴリズム（simple search, KMP）
11	12/22	全文検索アルゴリズム（BM, Aho-Corasick）
12	01/05	全文検索アルゴリズム（Aho-Corasick），データ圧縮
13	01/12	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
14	01/19	テキスト圧縮　（zip）， 音声圧縮　（ADPCM，MP3，CELP）， 画像圧縮（JPEG）
15	01/26	**期末試験**

12/09: 1時限 B2-31，　12/16: 4時限 B2-41

中間試験の結果

	今年11年度	10年度	09年度	08年度	07年度
受験者	35人	44人	33人	49人	48人
平均点	92点	85点	86点	79点	75点
満点獲得者	16人	3人	4人	1人	0人

中間試験の結果

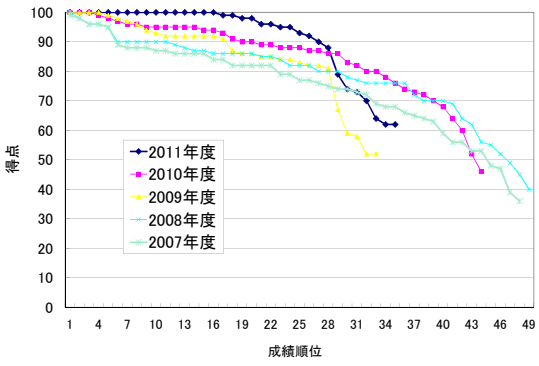

問題別得点結果

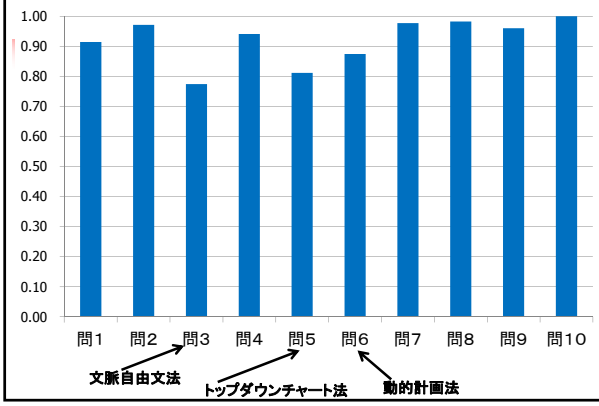

中間試験の解答例

http://ir.cs.yamanashi.ac.jp/~ysuzuki/public/algorithm3/
の12月15日の授業資料に掲載予定

本日のメニュー

- 全文検索アルゴリズム
  - 全文検索とは
  - simple search
    - 動作の説明
    - アルゴリズム
  - KMP
    - 動作の説明
    - アルゴリズム
  - BM
    - 動作の説明
    - アルゴリズム
  - Aho-Corasick
    - 動作の説明

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

- テキストに
  - キーワードが含まれているか？
  - その出現位置は？
- テキスト処理には不可欠
- タスク例　テキストTからキーワードKを見つける
  - テキストT：abcabcababcababxabca
  - キーワードK：abcaba

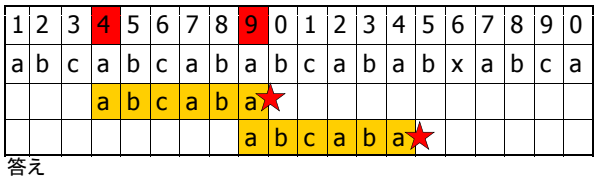

答え
キーワードは含まれているか：YES
出現位置：4文字目から始まる文字列と9文字目から始まる文字列

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．（n:キーワードの文字数）

1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9	0	
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															1文字目からの照合→6回目の照合で失敗
	a	b	c	a	b	a														2文字目からの照合→1回目の照合で失敗
		a	b	c	a	b	a													3文字目からの照合→1回目の照合で失敗
			a	b	c	a	b	a												4文字目からの照合→照合成功！！
				a	b	c	a	b	a											5文字目からの照合→1回目の照合で失敗

は照合失敗箇所　は文字照合に成功　は文字列照合に成功

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																
							a	b	c													
								a														
									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								

文字照合失敗

文字照合成功

Simple Searchのアルゴリズム

- 入力：テキスト（text），キーワード（key）
- 出力：テキスト中のキーワードの位置
- m: テキストの長さ
- 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
                        if text[i+j-1]≠key[j] then   キーワードと1字ずつ照合
                                goto 1;              照合に失敗したらループを抜ける
                print i;                             出現位置を表示
                1:
        end
end
```

Simple Search 最も効率の悪い場合

- key = aaa
- text = aaaaaaa

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

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

Knuth-Morris-Pratt法 （KMP法）

- Simple Search
  - テキスト文字列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，バックトラックの必要がない

Knuth-Morris-Pratt法

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

次にキーワードの何文字目から照合すればよいか → `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   (keyの6文字目で照合失敗)
           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   (照合成功)
             1 2 1
Keyの3文字目から
               a b c a b a   (照合成功)
               1 2 1
Keyの2文字目から
                 a b c   (keyの3文字目で照合失敗)
                 a
Keyの2文字目から
                   a b c a b a
                     1 2
Keyの1文字目から
```

KMP法　アルゴリズム

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

```
Method KMP
begin
      j:=1;
      for i:=1 to m do
      begin
            while j>0 and key[j] ≠text[i] do   照合
                  j:=next(j);   次の照合位置
            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
テキスト文字列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

キーワード	a	b	c	a	b	a					
						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　a:1：keywordの一文字目のa
123456　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　a:1：keywordの一文字目のa
123456　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
            t:=t+1;             接頭辞と一致しているか調べる
            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
```

前回はここまで

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: テキストの文字数
n: キーワードの文字数

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文字列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

- 応用情報技術者試験 平成21年度秋期午後問2

Boyer-Moore法

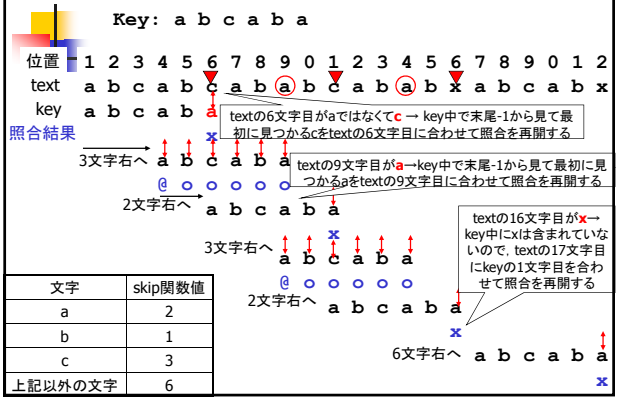

文字	skip関数値
a	2
b	1
c	3
上記以外の文字	6

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

```
?????a
  abcaba
 6543210   2文字スキップ

?????b
 abcaba
6543210   1文字スキップ

?????c
   abcaba
  65432103文字スキップ

?????x
      abcaba
     6543210
     6文字スキップ
```

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

m: textの文字数
n: keyの文字数

- 最良の場合 m/n回の文字照合
  textの文字 ∩ keyの文字 = ϕの場合
- 最悪の場合 m*n回の文字照合
  textの文字 = keyの文字 = {a}の場合
- 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

- マシンAC
- AC法の文字列照合手順
- AC法の文字列照合アルゴリズム
- AC法の評価
- 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
キーワード {“ab”,”bc”,”bab”,”d”,”abcde”}

ある状態で文字xが入力されたときに遷移する状態

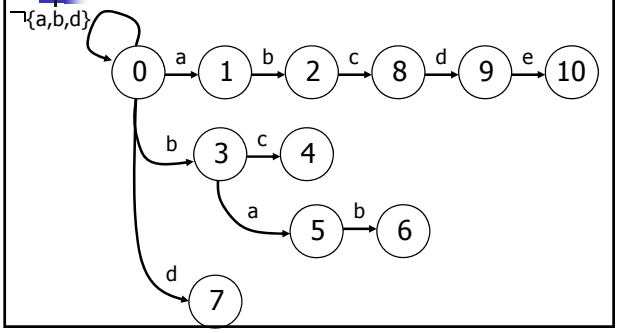

マシンAC　failure関数

goto関数からfailが返された際の照合ポインタの移動先

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

マシンAC　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

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”

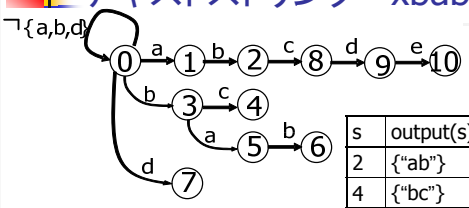

keyword
“ab”, ”bc”, ”bab”, ”d”, ”abcde”

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”

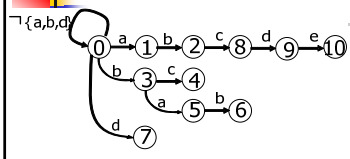

keyword
“ab”, ”bc”, ”bab”, ”d”, ”abcde”

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

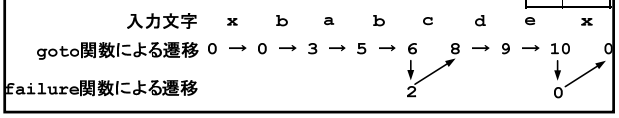

練習問題　照合ポインタの遷移
テキストストリング ”abcdbcba”

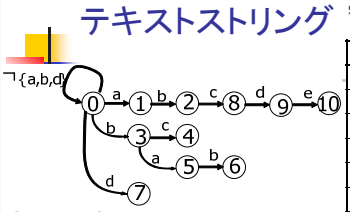

keyword
“ab”, ”bc”, ”bab”, ”d”, ”abcde”

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

練習問題　照合ポインタの遷移
テキストストリング ”abcdbcba”

今回はここまで

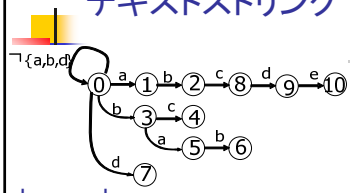

keyword
“ab”, ”bc”, ”bab”, ”d”, ”abcde”

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

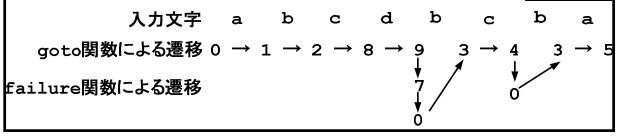

マシンACの構成方法

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

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)

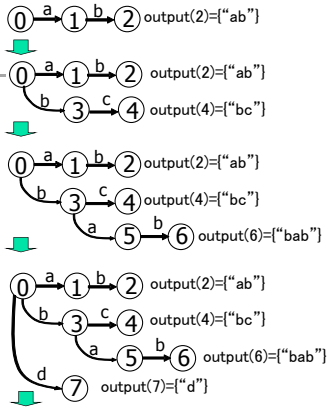

goto関数とoutput関数の構成方法 2/2

keyword
“ab”
”bc”
”bab”
”d”
”abcde”

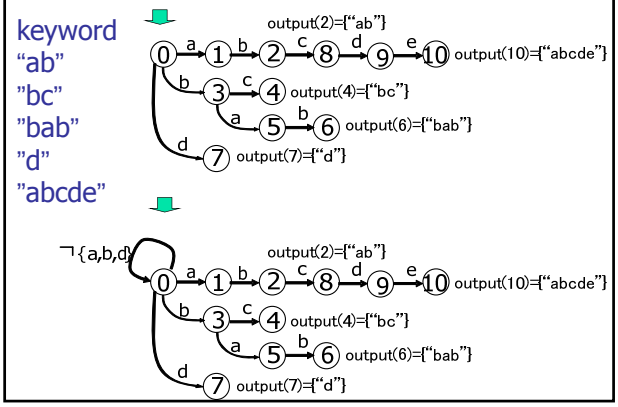

failure関数の構成方法

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

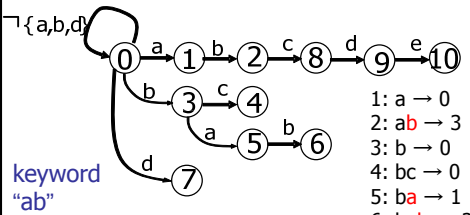

keyword
“ab”
”bc”
”bab”
”d”
”abcde”

babの最長の接尾辞

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