

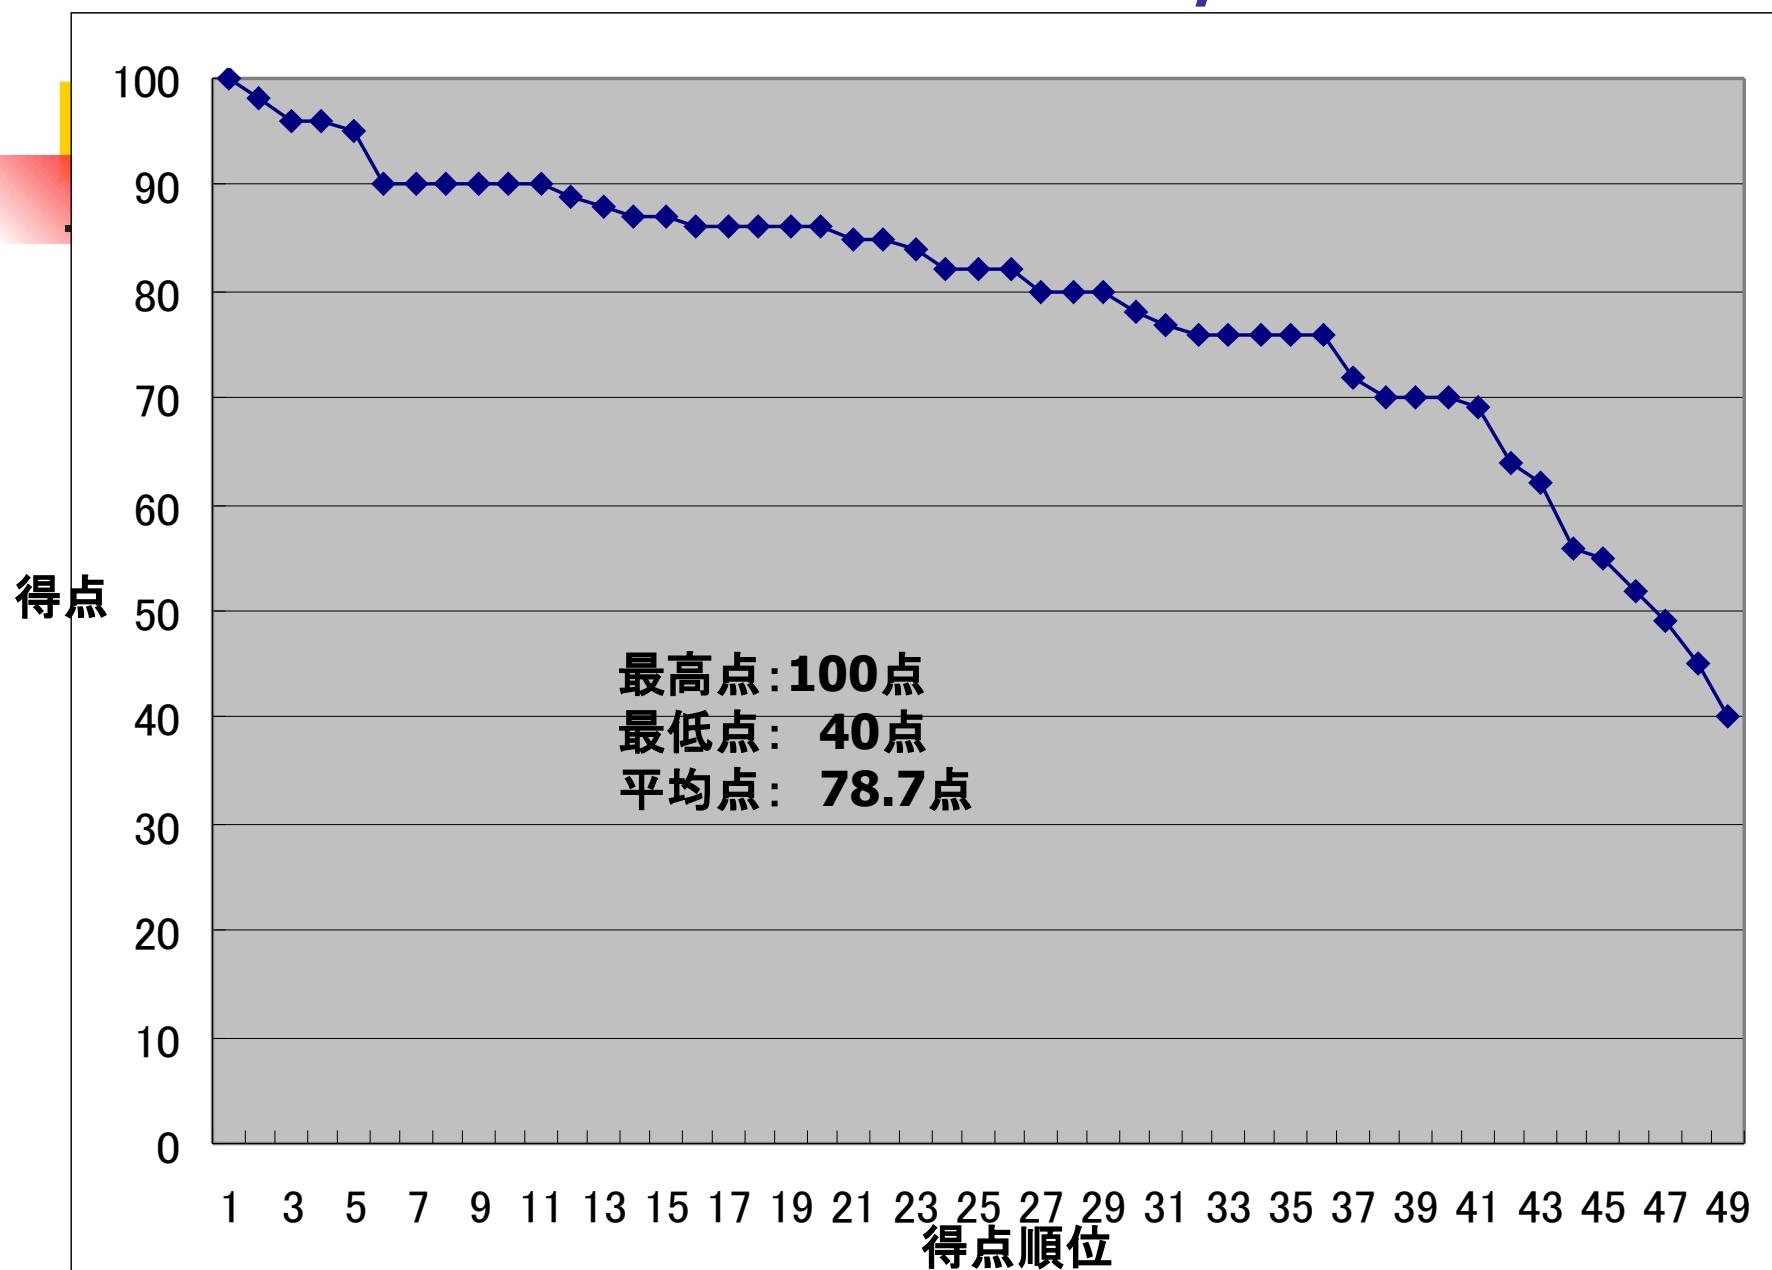
# アルゴリズムとデータ構造III

## 11回目：12月18日（木）

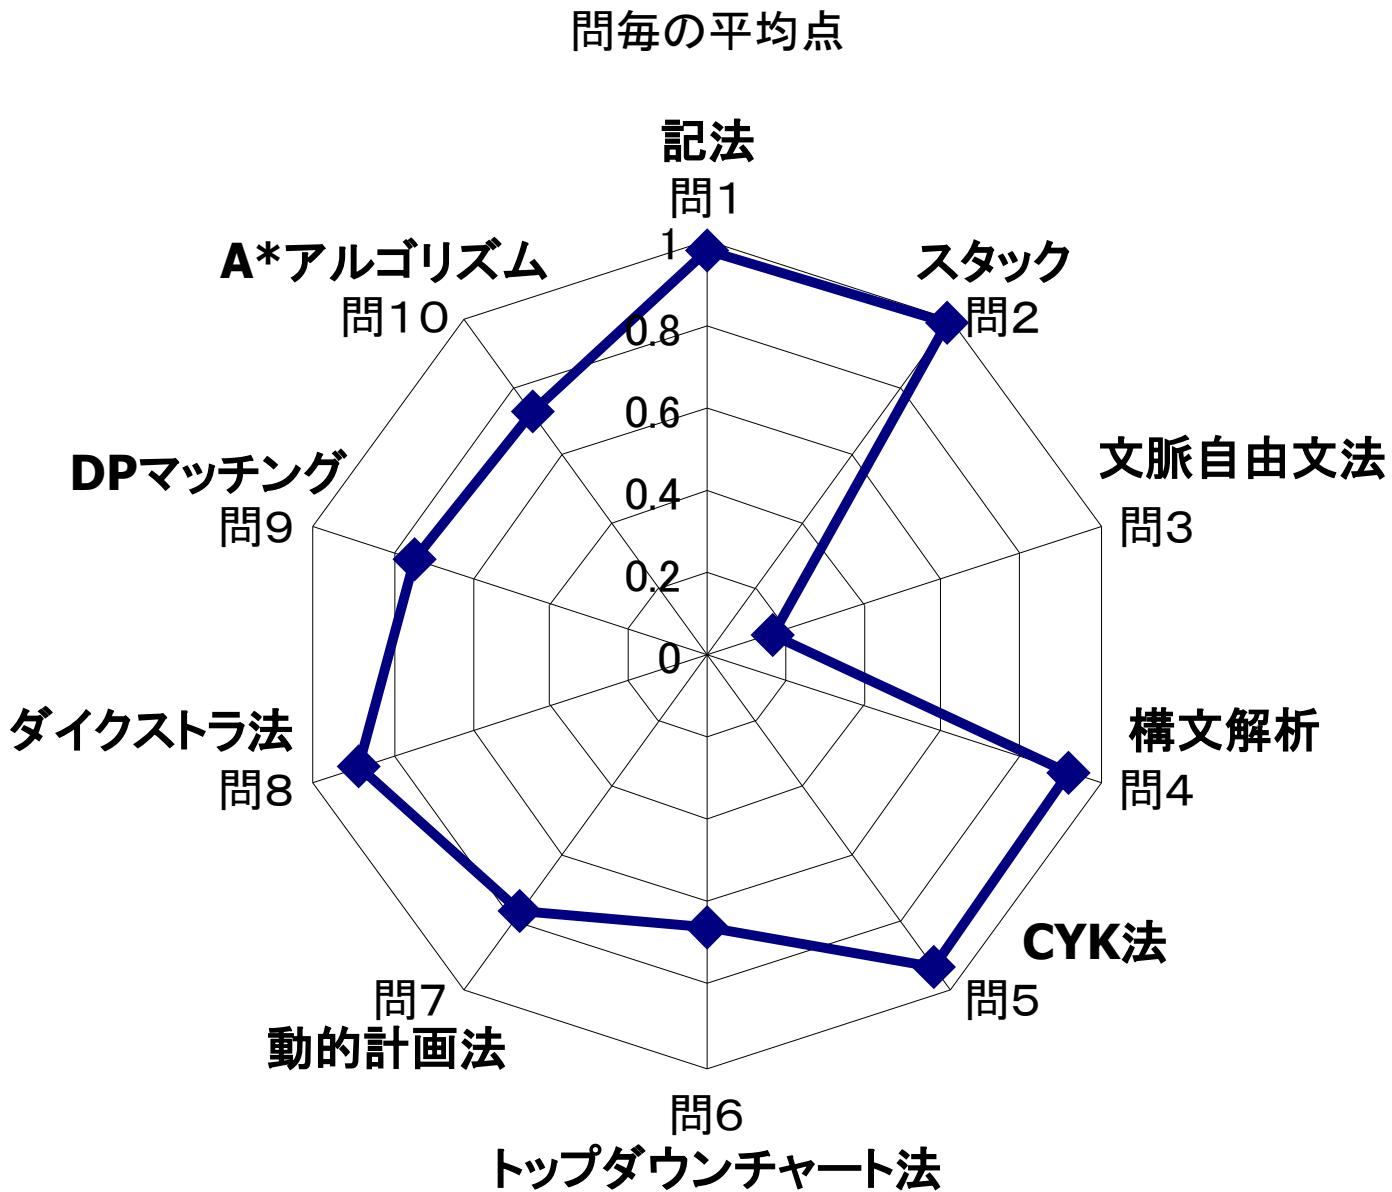
全文検索アルゴリズム  
(BM, Aho-Corasick)

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

# 中間試験の結果 1/2



# 中間試験の結果 2/2

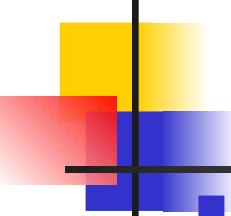


# 授業の予定(中間試験まで)

1	10/02	スタック（後置記法で書かれた式の計算）
2	10/09	チューリング機械, 文脈自由文法
3	10/16	構文解析 CYK法
4	10/23	構文解析 CYK法
5	10/30	構文解析(チャート法), グラフ(ダイクストラ法)
6	11/06	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	11/13	グラフ(DPマッチング, A*アルゴリズム)
8	11/20	グラフ(A * アルゴリズム), 前半のまとめ
9	11/27	中間試験

# 授業の予定(中間試験以降)

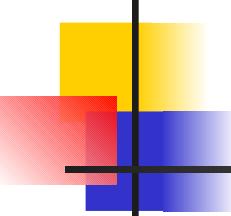
10	12/04	全文検索アルゴリズム(simple search, KMP)
11	12/18	全文検索アルゴリズム(BM, Aho-Corasick)
12	01/08	全文検索アルゴリズム(Aho-Corasick), データ圧縮
13	01/15	暗号(黄金虫, 踊る人形) 符号化(モールス信号, Zipfの法則, ハフマン符号)テキスト圧縮
14	01/29	テキスト圧縮(zip), 音声圧縮(ADPCM, MP3, CELP), 画像圧縮(JPEG)
15	02/05	期末試験



# 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

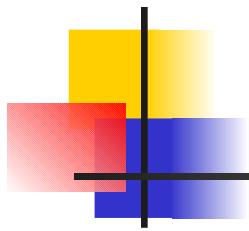
- テキスト処理には不可欠
- テキスト文字列からキーワードとその出現位置を見つける
- 例
  - テキスト文字列 : aabcdabdabbababcabacade
  - キーワード : abcaba

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											
									a	b	c	a	b	a					

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

- テキスト文字列の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

2文字目からの照合→1回目の照合で失敗

3文字目からの照合→1回目の照合で失敗

4文字目からの照合→照合成功！！

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

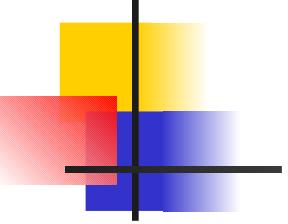


は文字列照合に成功

# 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	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

                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;

        1:

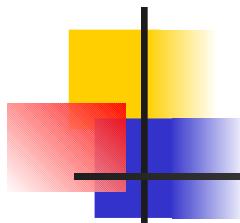
    end

end

# Simple Search 最も効率の悪い場合

- key = aaa 文字照合回数  $(7-3+1)*3=15$
- text = aaaaaaaaa  $(m-n+1)*n$ 回  
一般に  $m \gg n$  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



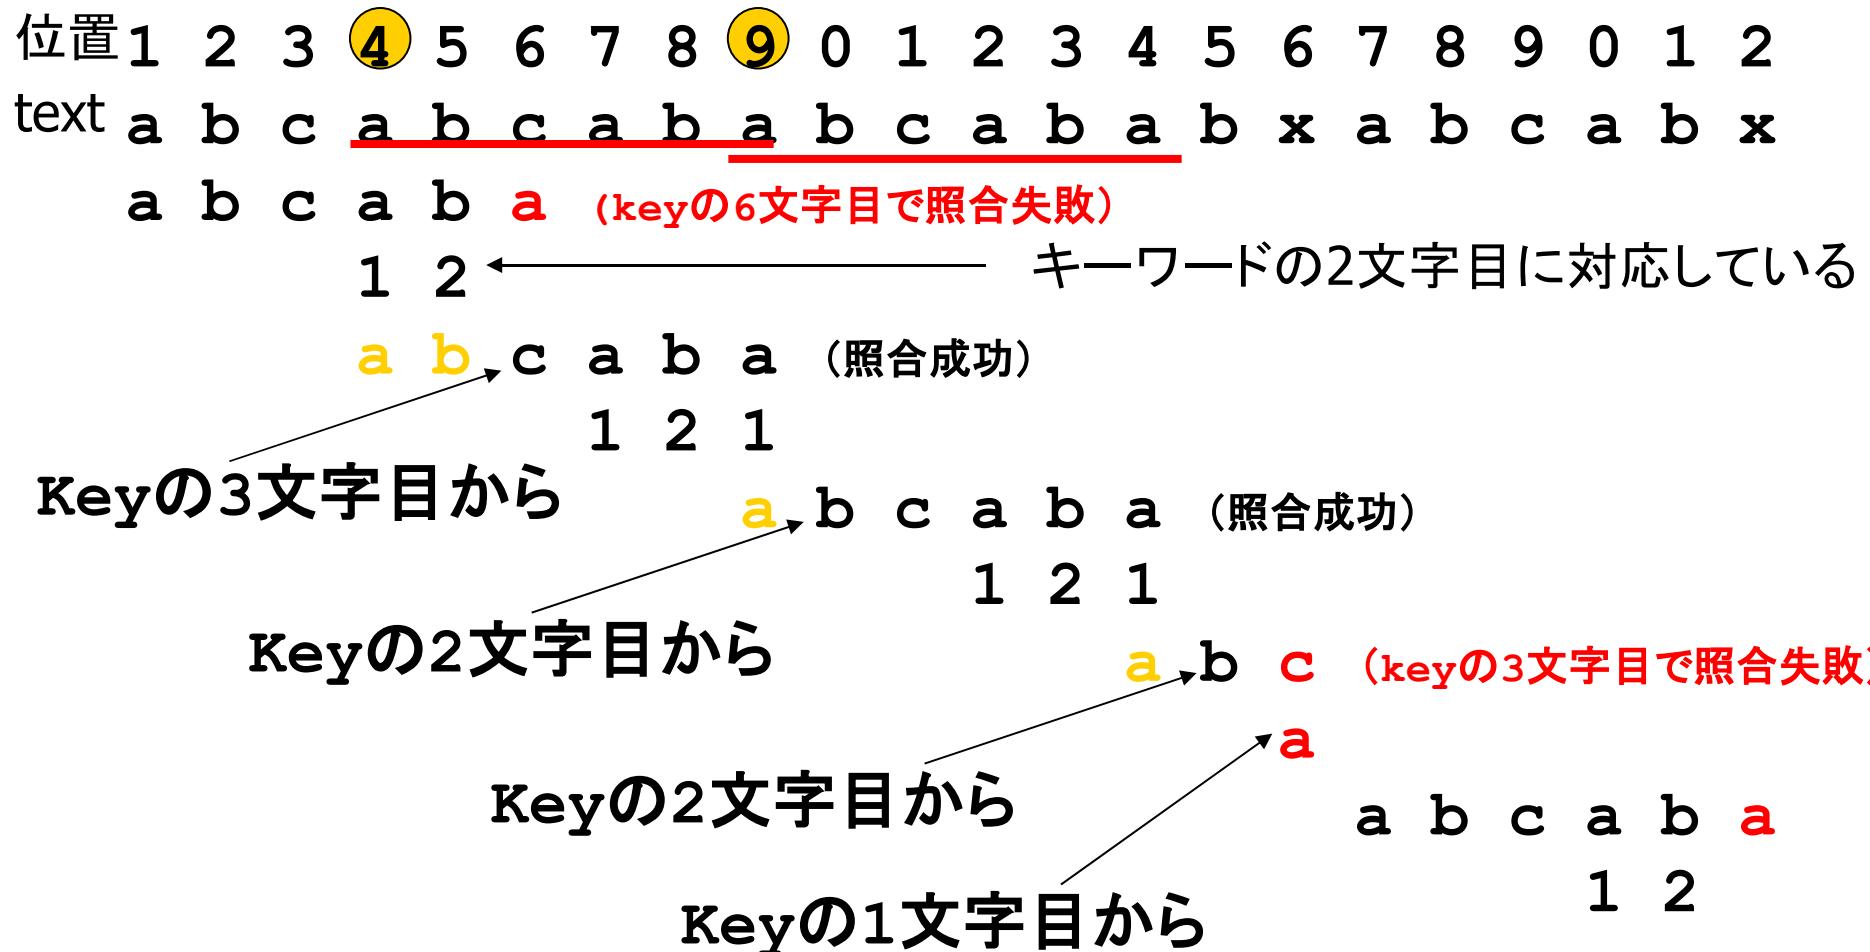
# Knuth-Morris-Pratt法（KMP法）

- 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  
next 0 1 1 0 1 3 2

次にキーワードの何文字目から照合すればよいか → next



# 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

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	b	c	a	b	a	
	a	b	c	a	b	a	<b>a</b>	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abb)

→ 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abcc)

→ 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 →  
 $\text{next}(4)=0$

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 →  $\text{next}(5)=1$

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 →  $\text{next}(6)=3$

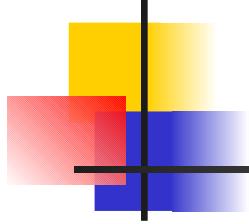
6文字目のaで照合成功 (直前の文字がabcaba)

→ 照合失敗箇所(照合成功末尾の右隣)とb:2を照合 →  
 $\text{next}(7)=2$

# KMP法 アルゴリズム next関数

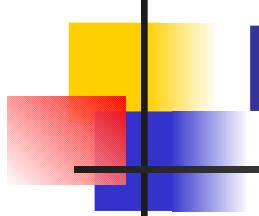
入力:キーワード key, 出力:next関数

```
Method next
begin
    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
                next(j+1):=next(t);  keyの
                else
                    next(j+1):=t;   j+1文字目の
                                next関数値を
                                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

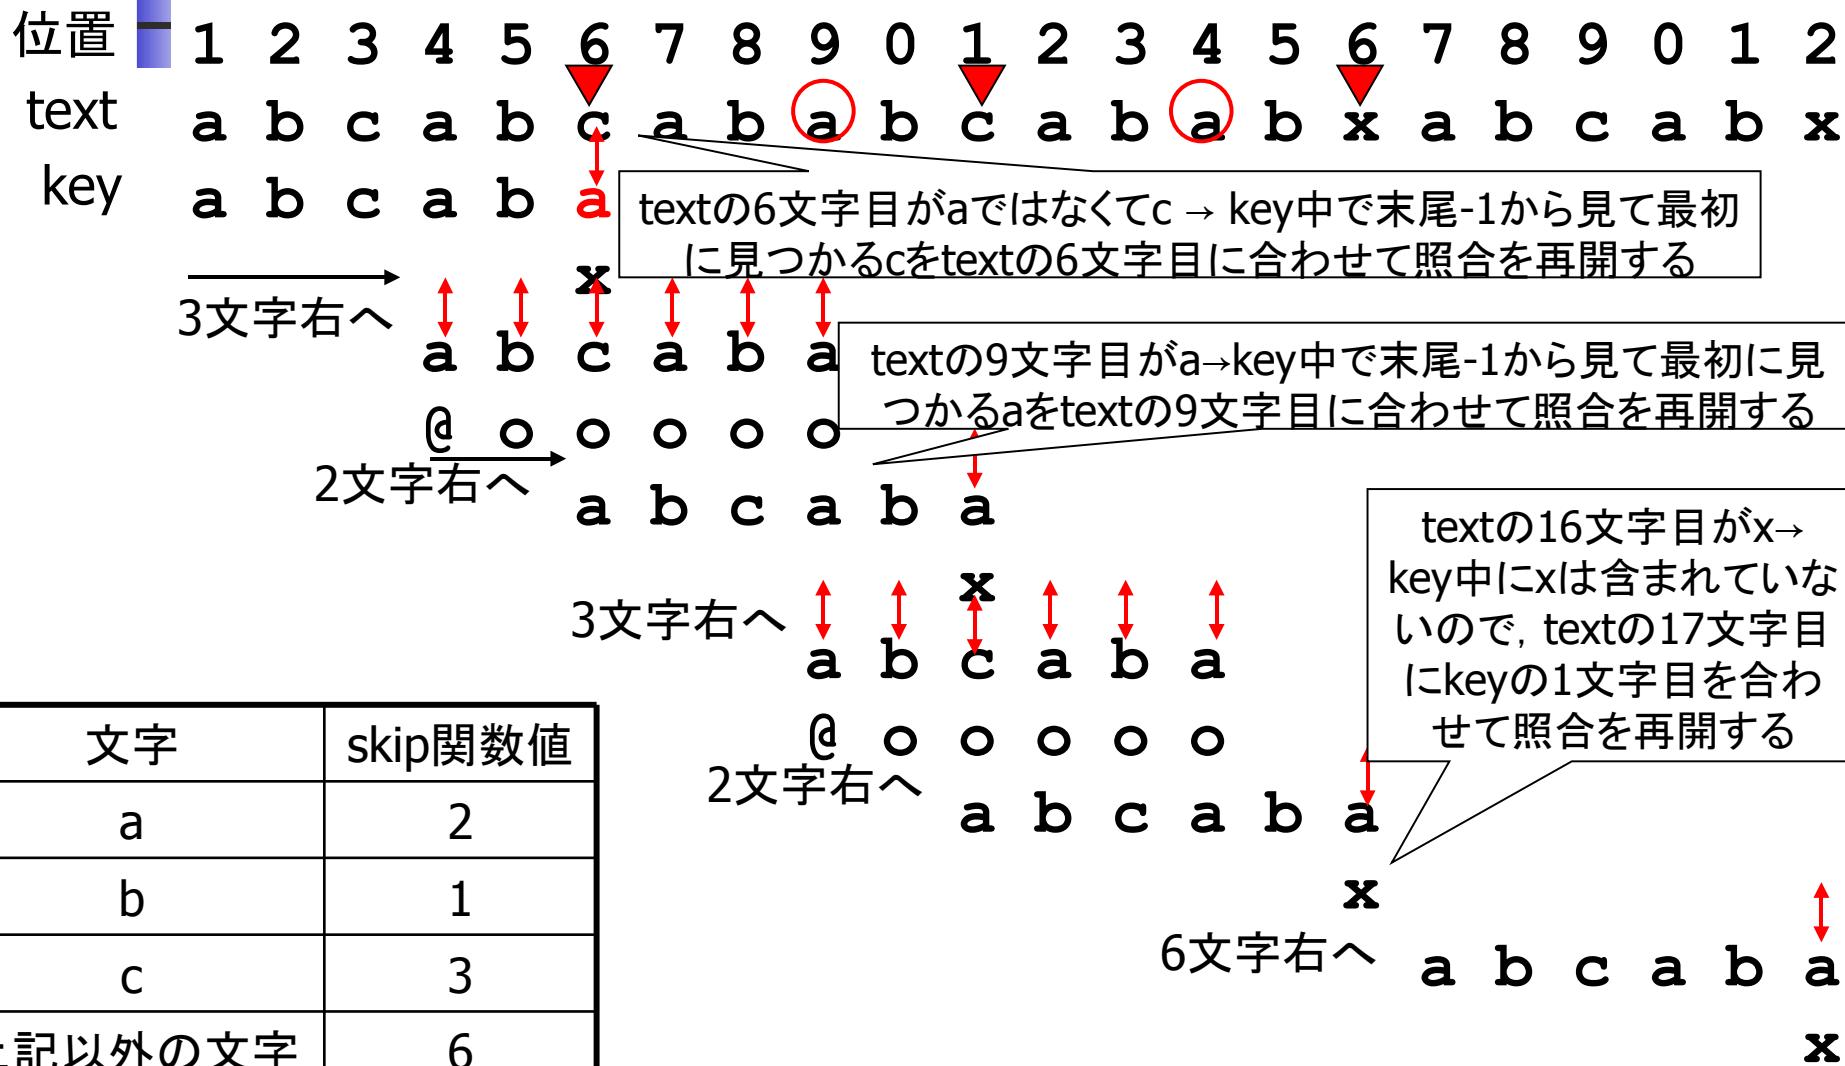


# Boyer-Moore法

- 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

Key: a b c a b a



# 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

キーワード”a b c a b a”に対するskip関数

? ? ? ? ? c

abcaba  
6543210

3文字スキップ

? ? ? ? ? x

abcaba  
6543210

6文字スキップ

文字	skip関数值
a	2
b	1
c	3
上記以外の文字	6

# BM法による文字列照合

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
```

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

# 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;
```

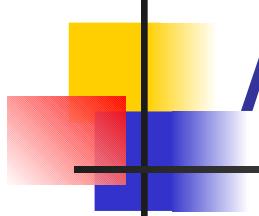
end

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

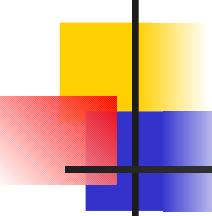
# BM法の評価

- 最良の場合  $m/n$ 回の文字照合  
textの文字  $\cap$  keyの文字 =  $\emptyset$  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



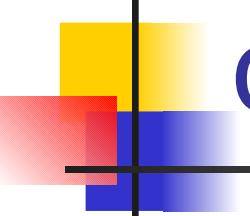
# Aho-Corasick法

- 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

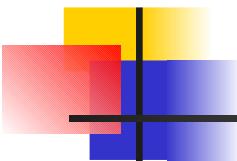


# goto関数, failure関数, output関数

- 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

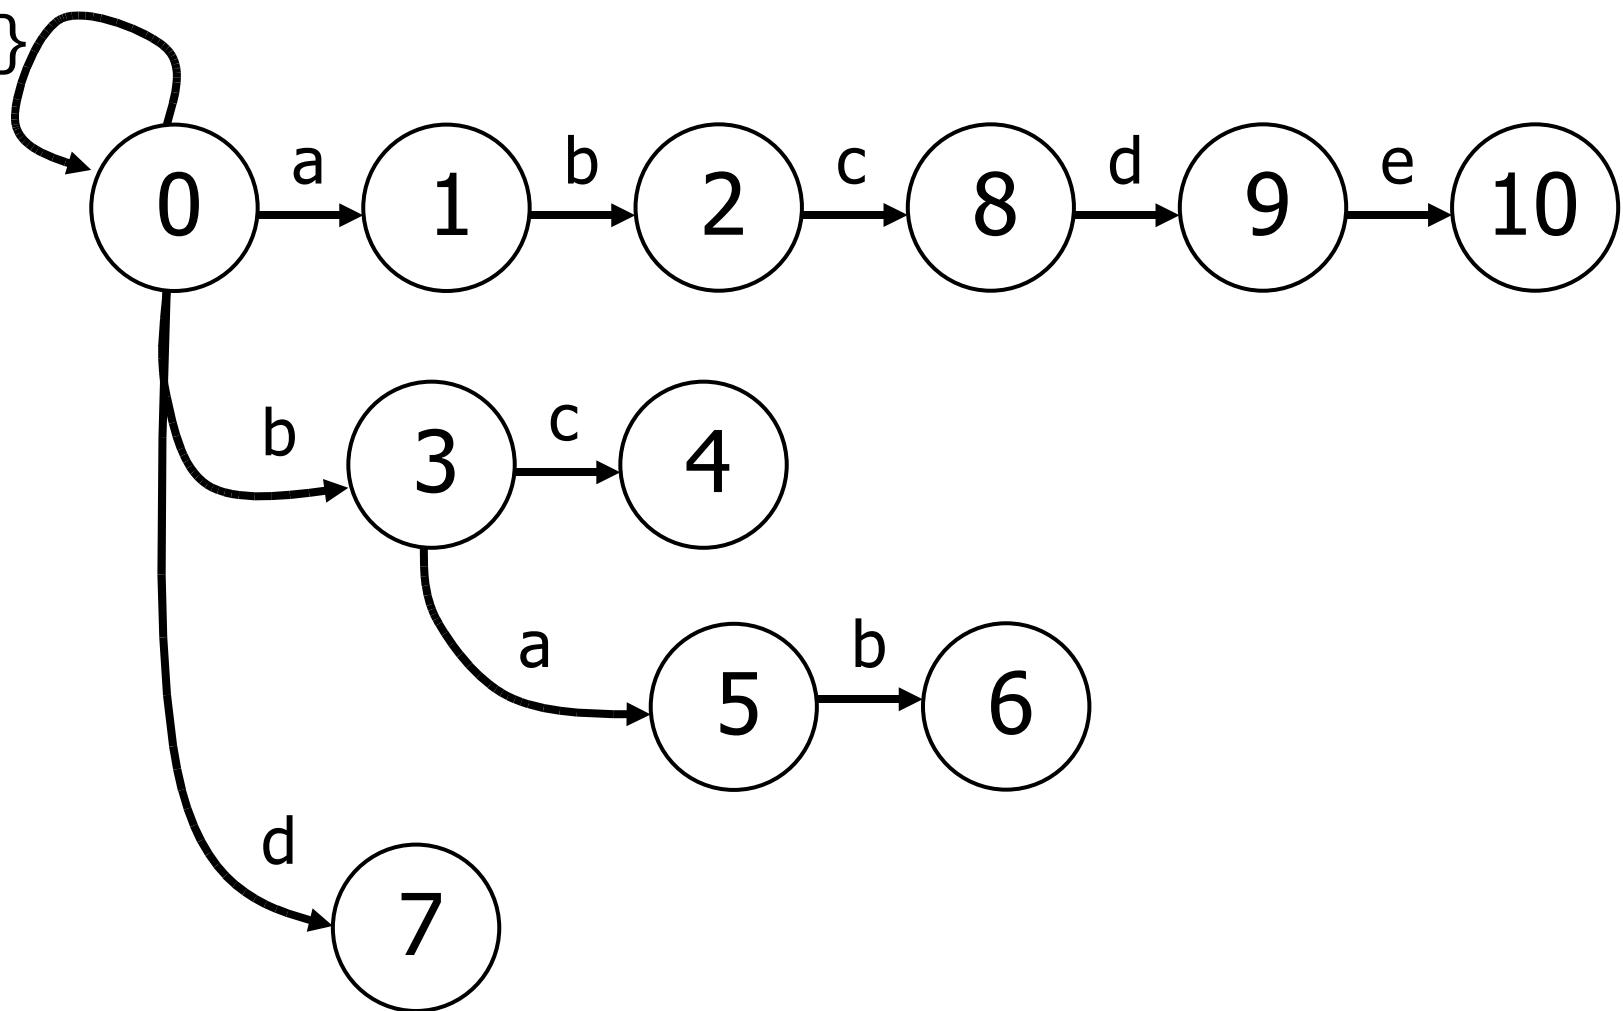
# キーワード

{"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

$\neg\{a,b,d\}$



# 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"}