

アルゴリズムとデータ構造III

11回目：12月20日（木）

全文検索アルゴリズム
(BM, Aho-Corasick)

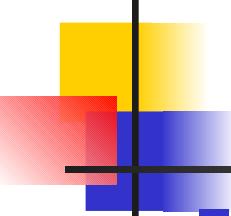
授業資料 <http://ir.cs.yamanashi.ac.jp/~ysuzuki/algorithm3/index.html>

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)

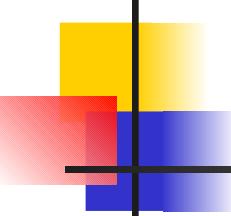
10	12/17	全文検索アルゴリズム(simple search, KMP)
11	12/20	全文検索アルゴリズム(BM, Aho-Corasick)
12	01/10	暗号(黄金虫, 踊る人形) 符号化(モールス信号, Zipfの法則, ハフマン 符号) テキスト圧縮(zip)
13	01/17	音声圧縮 ADPCM, MP3
14	01/24?	音声圧縮(CELP), 画像圧縮(JPEG)
15	02/07	期末試験



本日のメニュー

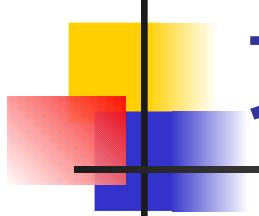
全文検索アルゴリズム

- 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



全文検索

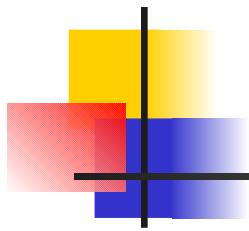
- 文書中から、与えられた文字列と完全に一致する部分を探し出す。
- 全文検索の種類
 - 文字列照合による全文検索
 - 索引を用いた全文検索



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

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					



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	c	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								
					a	b	c	a	b	a							
						a	b	c	a	b	a						
							a	b	c	a	b	a					
								a	b	c	a	b	a				

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							

照合失敗

文字列照合成功

Simple Searchのアルゴリズム

Method
begin

- 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

```
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
```

Simple Search 最も効率の悪い

場合

文字照合回数 $(7-3+1)*3=15$

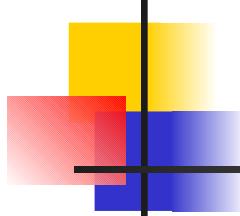
$(m-n+1)*n$ 回

一般に $m \gg n$ ので $O(mn)$

key = aaa

text = aaaaaaaaa

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

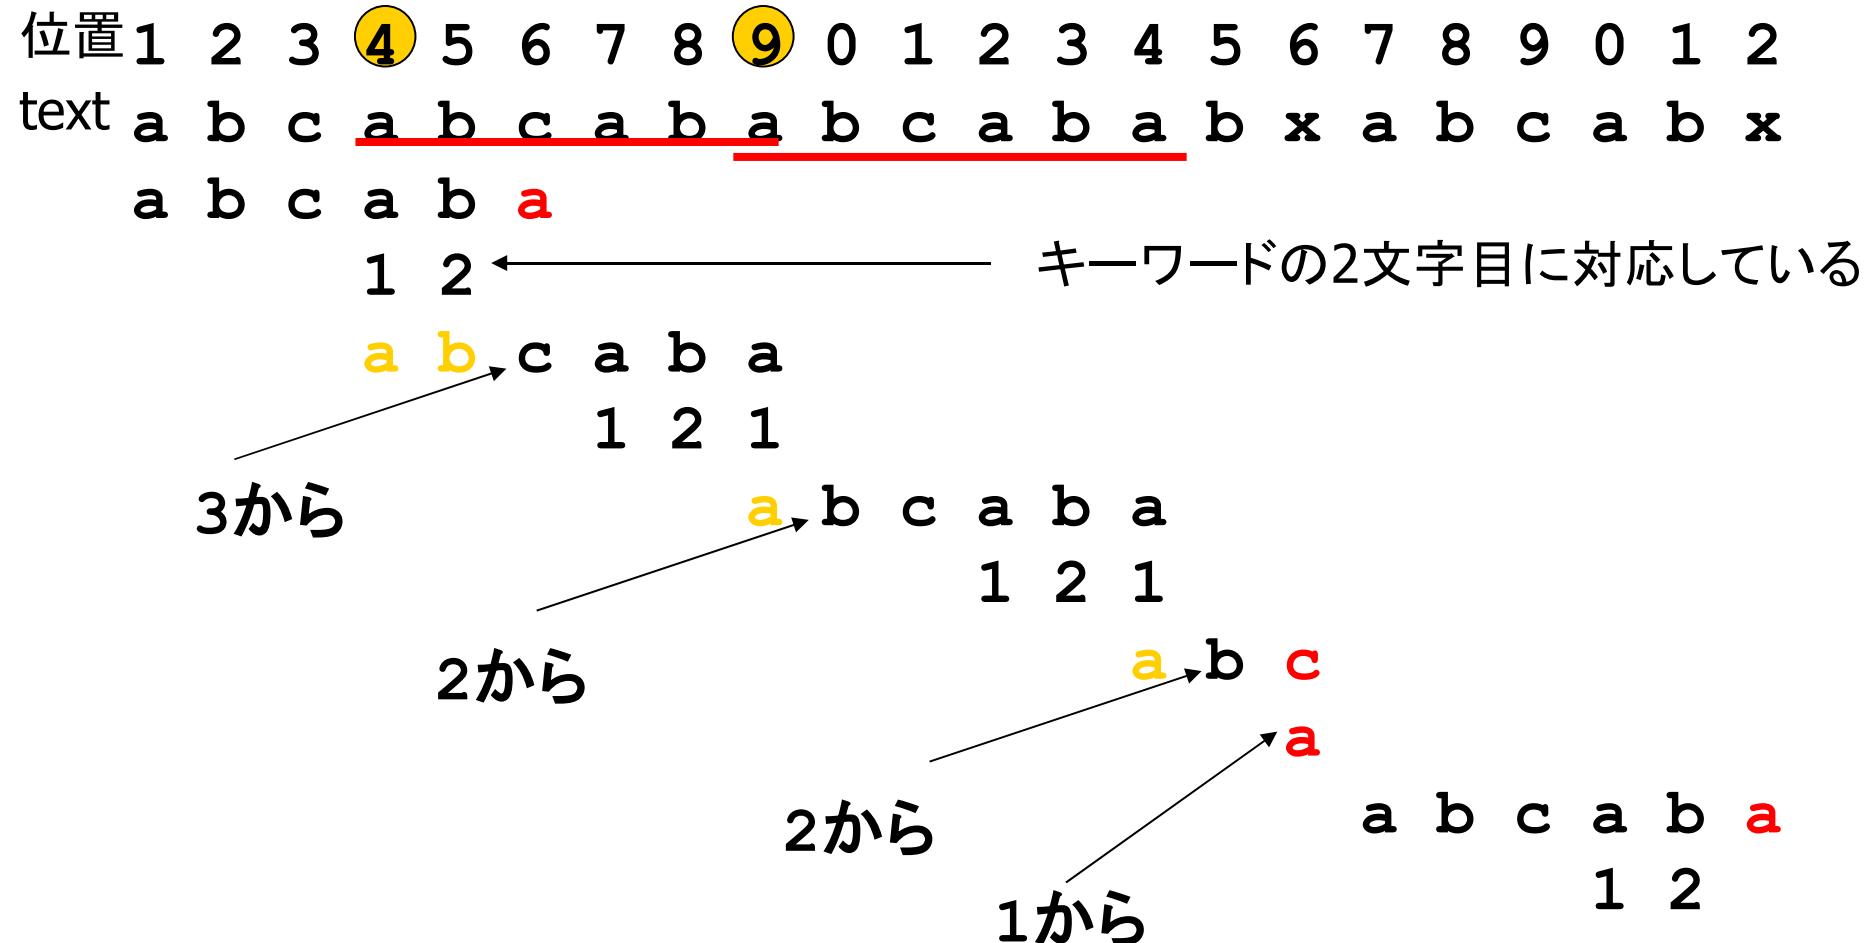
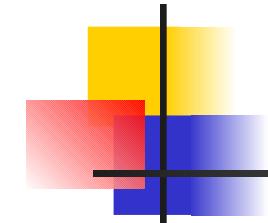


Knuth-Morris-Pratt法 (KMP法)

- 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

Knuth-Morris-Pratt法

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



KMP法 アルゴリズム



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); つぎの照合位置

 if j=n then

 print i-n+1:] 照合成功

 j:=j+1;

 end

end

m :textの長さ

n :keywordの長さ

i: textの照合位置

J: keywordの照合位置

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

The diagram shows a sequence of characters: a | b | c | a | b | a. A yellow box highlights the character at position 6, which is 'b'. A blue arrow points from this character to the character at position 3, which is 'a'. This indicates that the search window has shifted from position 6 back to position 3, starting the search again.

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 → $\text{next}(6)=3$

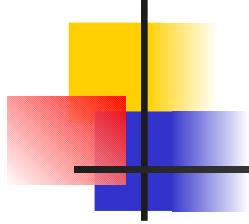
6文字目のaで照合成功 (直前の文字がabcaba)

→ 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

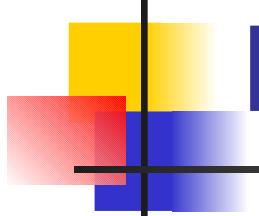
入力:キーワード key, 出力:next関数

```
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

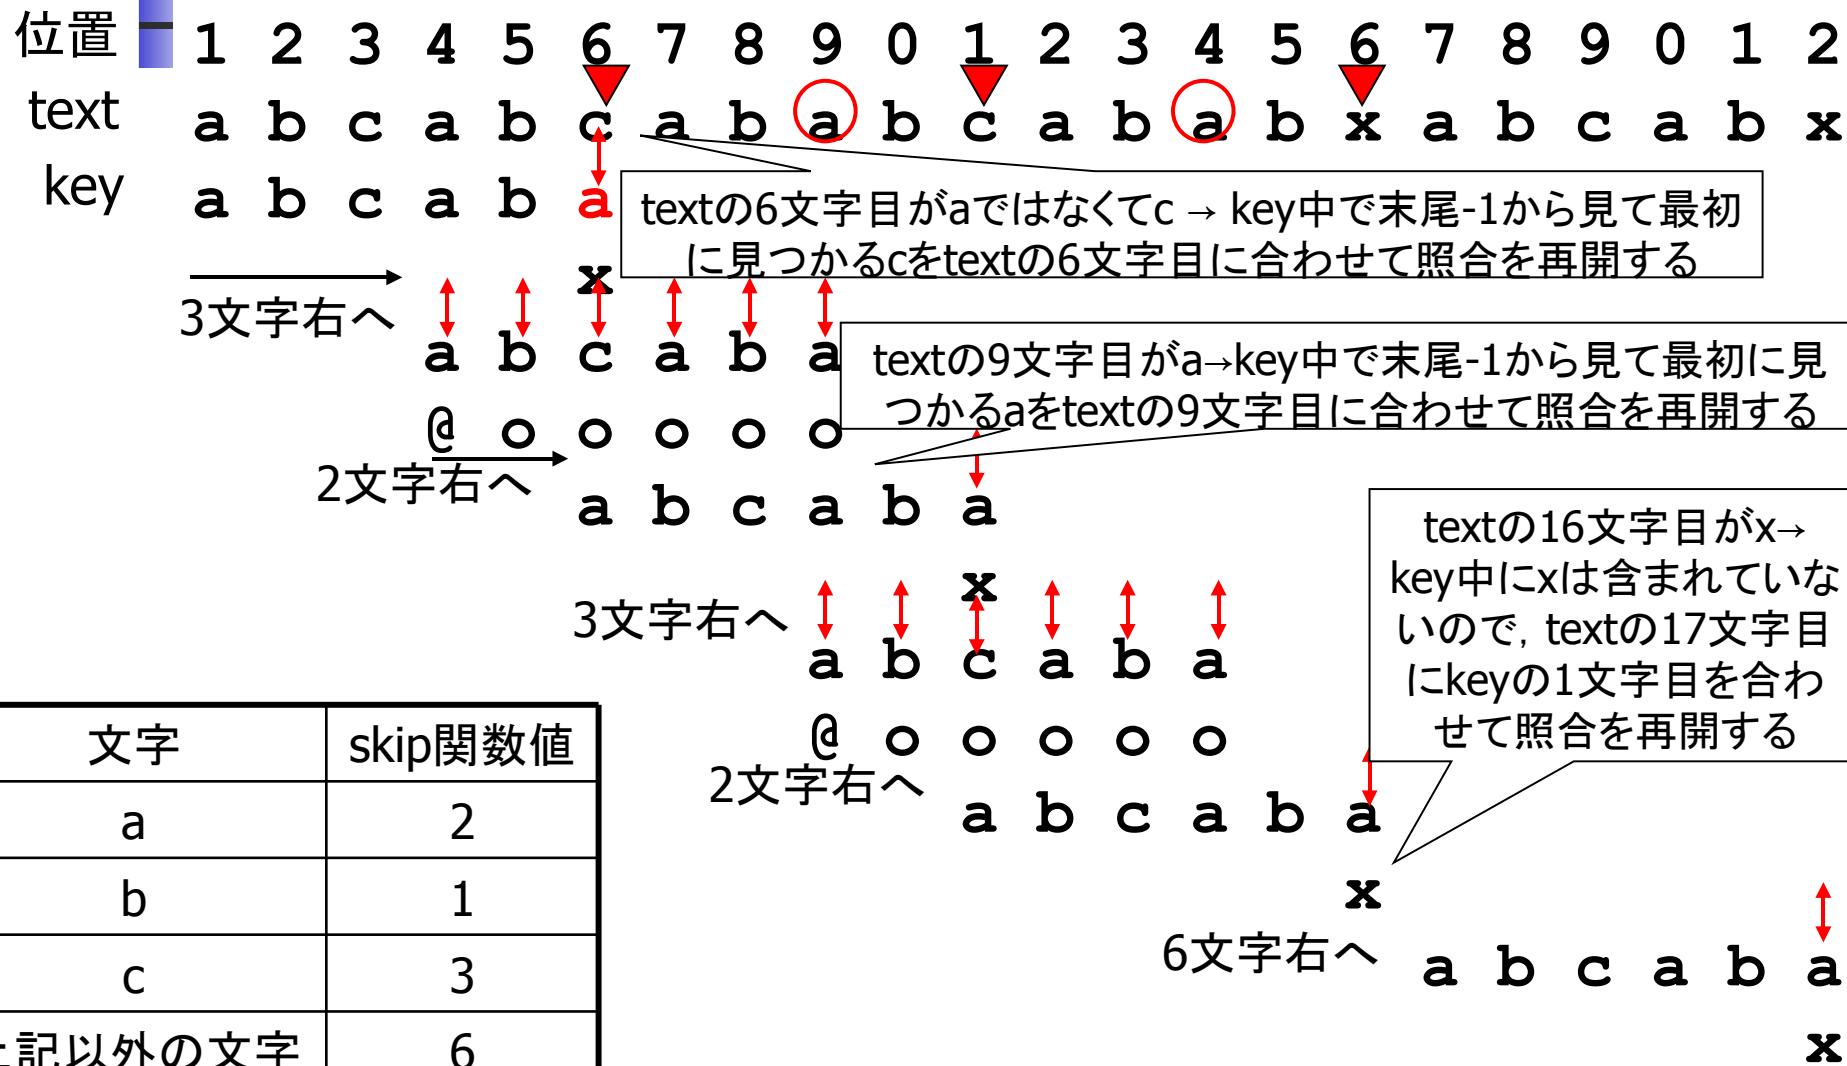


Boyer-Moore法

- 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

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

?????b
abcaba
6543210

?????c
abcaba
6543210

?????x
abcaba
6543210

キーワード”a b c a b a”に対するskip関数

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

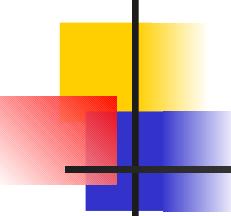
begin

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

end

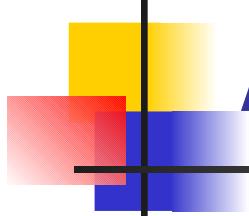
初期設定(全ての文字種で
keyの長さだけskip)

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



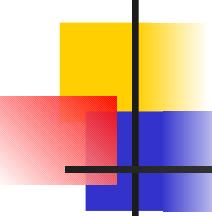
BM法の評価

- 最良の場合 m/n 回の文字照合
 $text\text{の文字} \cap key\text{の文字} = \emptyset$
- 最悪の場合 $m*n$ 回の文字照合
 $text\text{の文字} = key\text{の文字} = \{a\}$
- 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



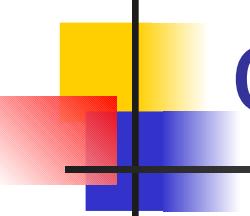
Aho-Corasick法

- 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

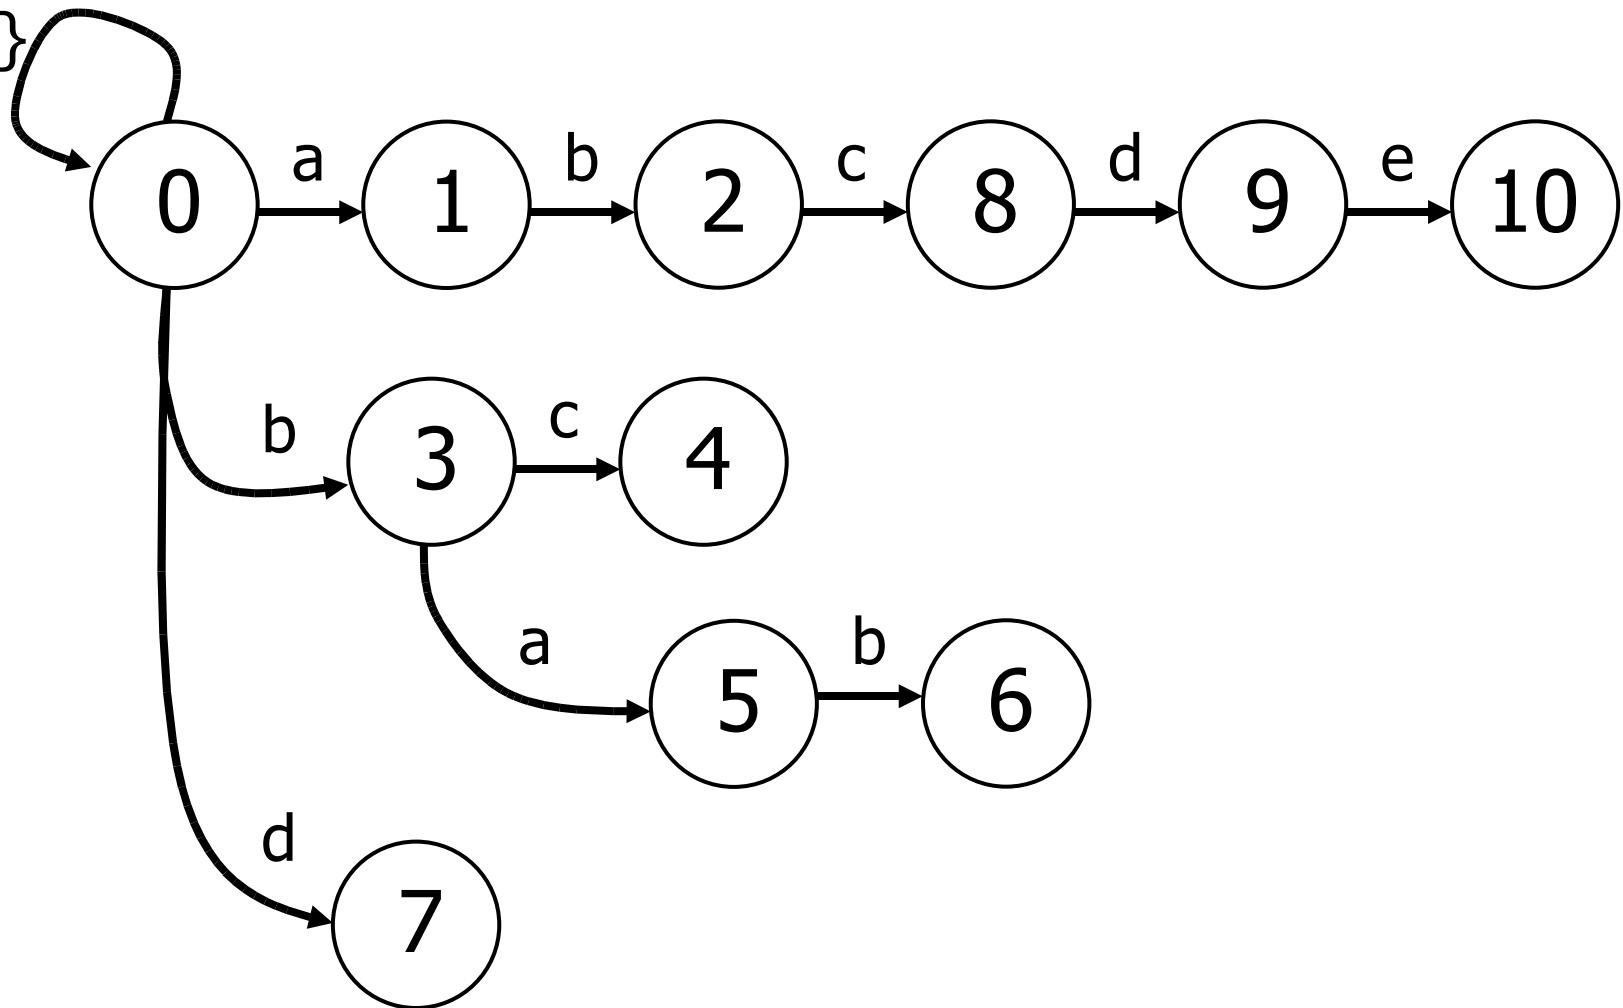


goto関数, failure関数, output関数

- 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'}