

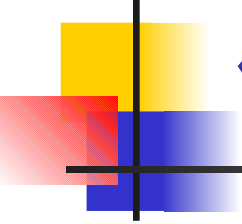


アルゴリズムとデータ構造III

10回目: 12月4日(月)

全文検索アルゴリズム
(Simple Search, KMP)

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



来週(12月11日) 出張のため 休講

- CNSでも連絡します.
- 補講日は後日相談します.

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	12/??	全文検索アルゴリズム (Aho-Corasick), データ圧縮
13	01/08?	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	01/15?	テキスト圧縮 (zip), 音声圧縮 (ADPCM, MP3, CELP), 画像圧縮 (JPEG)
15	01/29	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: aabcdabdabbabcdabacade
 - 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									
	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

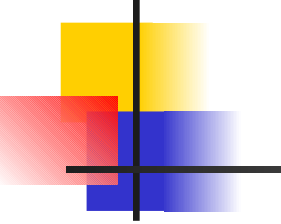
Simple Search 同じ部分を何度も照合しなければならない

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								

照合失敗

文字列照合成功

Simple Searchのアルゴリズム

- 
- 入力: テキスト文字列 text, キーワード key
 - 出力: テキスト文字列中のキーワードの位置
 - m: テキスト文字列の長さ
 - 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 = aaaaaaa

$(m-n+1)*n$ 回
一般に $m \gg n$ 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)

Keyの2文字目から

a

Keyの1文字目から

a b c a b a

1 2

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);

 if j=n then

 次の照合位置

 print i-n+1:

 j:=j+1;

 照合成功

 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	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abcabb）

→ 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

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

t:=t+1;

接頭辞と一致しているか調べる

if key[j+1]=key[t] then

next(j+1):=next(t);

keyの

j+1文字目の

else

next(j+1):=t;

next関数値を

決定

end

end

n : keyの長さ

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



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