# アルゴリズムとデータ構造III
# 10回目：12月16日

全文検索アルゴリズム
（Simple Search, KMP）

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）<br>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），<br>音声圧縮　（ADPCM，MP3，CELP），<br>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

## 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

| 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

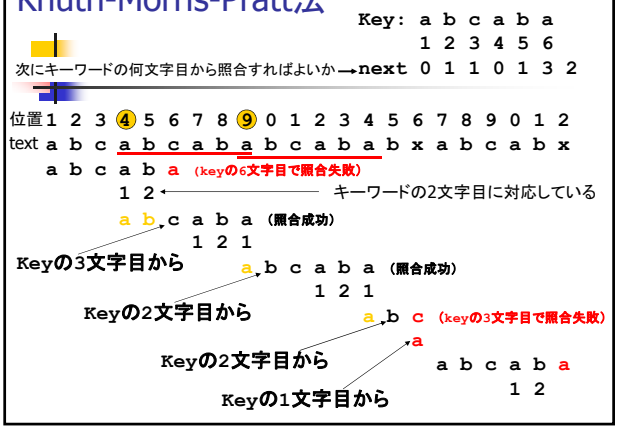


## KMP法 アルゴリズム

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
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
            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
```

## 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