



IN244 – Strategi Algoritmik

11 – String Matching

Overview

1. Definisi String Matching/ Pattern Matching ?
2. Algoritma Brute Force
3. Algoritma Boyer-Moore
4. Algoritma Knuth-Morris-Pratt

Diadaptasi dari Pattern Matching


Dr. Andrew Davison, WiG Lab (teachers room), CoE, ad@fivedots.coe.psu.ac.th

String Matching?

- Definisi :
 - diberikan string teks T dengan panjang n karakter
 - string pola P dengan panjang m karakter,
 - Temukan lokasi pertama di dalam teks T, dimana pola P ditemukan dalam teks T
 - Contoh:
 - T: “the rain in spain stays **mainly** on the plain”
 - P: “main”
- Aplikasi :
 - Pencarian dalam text editors, Web search engines (mis. Google), image analysis


Konsep String

- S : string dengan panjang m.
 - *substring* $S[i \dots j]$: substring di antara index i dan j.
 - *prefix* dari S : substring $S[0 \dots i]$
 - *suffix* dari S : substring $S[i \dots m-1]$
- Contoh string S
 - Substring $S[1..3] == \text{"ndr"}$
 - prefix dari S:
 - "andrew", "andre", "andr", "and", "an", "a"
 - suffix dari S:
 - "andrew", "ndrew", "drew", "rew", "ew", "w"



Algoritma Brute Force

- Periksa setiap posisi dalam text T, mulai dari awal string untuk memastikan pola P ada dalam T dimulai pada posisi ke j



Pemeriksaan maju 1 char untuk mencari P dalam T

Contoh pencocokan dengan Brute Force

- *Pattern*: NOT
- Teks: NOBODY NOTICED HIM
- Proses Pencocokan :

NOBODY **NOT**ICED HIM
1NOT
2 NOT
3 NOT
4 NOT
5 NOT
6 NOT
7 NOT
8 **NOT**

- *Pattern*: 001011
- Teks: 10010101**001011**110101010001
- Proses Pencocokan :

10010101**001011**110101010001
1 001011
2 001011
3 001011
4 001011
5 001011
6 001011
7 001011
8 001011
9 **001011**

Fungsi Search secara Brute Force

```
#Kamus data
#T : text
#P : pola yang akan dicari dalam text T
#jika P ada dalam T, nilai posisi awal P dikirimkan
#jika P tidak ada, fungsi mengirimkan -1
def searchBruteF(T,P):
    n = len(T)
    m = len(P)
    for i in range (0,n-m+1,1):
        j = 0
        while (j < m) and (P[j] == T [i + j]):
            j = j + 1;
        if (j == m):
            return (i) #P ditemukan pada posisi ke i
    return (-1) #P tidak ditemukan
```

Pemanggilan Fungsi String Matching

```
#text : string sumber
#pola : pola yang akan dicari dalam text T
#pos : posisi awal pola dalam text
def main():
    text = str(input("text:"))
    pola = str(input("pola:"))
    pos = searchBruteF(text, pola)
    if (pos >= 0):
        print("Pola ", pola, " ditemukan dalam text
        pada posisi ",pos)
    else:
        print("Pola ", pola, " tidak ditemukan dalam
        text")
if __name__ == '__main__':
    main()
```

Analisis Brute Force

- Brute force untuk string matching mempunyai $O(mn)$ untuk kasus terburuk
- Pada umumnya search dalam ordinary text mempunyai $O(m+n)$ -> sangat cepat.
- Algoritma brute force berjalan cepat bila alphabet dari text berukuran besar
 - Mis. A..Z, a..z, 1..9, dll
- Algoritma brute force melambat bila alphabet berukuran kecil
 - Mis. 0, 1 (dalam binary files, image files, dll.)

Analisis Brute Force

- Contoh best case:
 - T: "string ini berakhir dengan zzz"
 - P: "zzz"
- Contoh worst case:
 - T: "aaaaaaaaaaaaaaaaaaaaaaaaaaaaah"
 - P: "aaah"
- Contoh average case:
 - T: "a string searching example is standard"
 - P: "store"

Algoritma Boyer-Moore

- Didasarkan pada 2 teknik :

1. The *looking-glass* technique

- Cari P dalam T dengan bergerak mundur dalam P, mulai dari karakter terakhir dalam P


2. The *character-jump* technique

- Bila ada ketidakcocokan pada $T[i] \neq P[j]$, dilakukan character jump

- Terdapat 3 kemungkinan kasus


Kasus 1

- Jika P mengandung x , maka geser P ke kanan untuk menempatkan kemunculan x dalam P dengan T[i].




Kasus 2

- Jika P mengandung x, tapi langkah pada kasus 1 tidak mungkin, maka geser P ke kanan 1 karakter pada $T[i+1]$.




Kasus 3

- Jika bukan kasus 1 dan 2 (x tidak ada dalam P), maka geser P untuk menempatkan $P[0]$ dengan $T[i+1]$.



Contoh Boyer-Moore



1. Kasus-1
2. Kasus-3
3. Kasus-3
4. Kasus-3
5. Kasus-3
6. Kasus-1

Fungsi Last Occurrence

- Algoritma Boyer-Moore melakukan preprocessing terhadap P dan alfabet A untuk membangun fungsi last occurrence $L()$
 - $L()$ memetakan semua huruf dalam A menjadi integer
- $L(x)$ didefinisikan sbg:
 - index terbesar i sehingga $P[i] == x$, atau
 - -1 jika x tidak muncul dalam P
 - x : huruf dalam alfabet A

Contoh L()

- $A = \{a, b, c, d\}$
- $P: \text{"abacab"}$

P

a	b	a	c	a	b
0	1	2	3	4	5



x	a	b	c	d
$L(x)$	4	5	3	-1


Contoh Boyer-Moore

T:

a	b	a	c	a	a	b	a	d	c	a	b	a	c	a	b	a	a	b	b
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

P:

a	b	a	c	a	b
---	---	---	---	---	---



1. Kasus-1
2. Kasus-1
3. Kasus-1
4. Kasus-3
5. Kasus-1

<i>x</i>	<i>a</i>	<i>b</i>	<i>c</i>	<i>d</i>
<i>L(x)</i>	4	5	3	-1

Boyer-Moore (Python)

```
def searchBM(T,P):  
    last = lastO(P)  
    n = len(T)  
    m = len(P)  
    i = m-1  
    if (i > n-1):  
        #pola > text  
        hasil = -1  
    else:  
        j = m-1  
        Found = False  
        # while ...
```

```
        while (i < n) and (not Found):  
            if (P[j] == T[i]):  
                if (j == 0):  
                    Found = True  
                else:  
                    j = j - 1;  
                    i = i - 1;  
            else: #character jump  
                lo = last[ord(T[i])]   
                i = i + m - min(j,1+lo)  
                j = m-1  
        if (Found):  
            hasil = i  
        else:  
            hasil = -1  
    return (hasil)
```

Fungsi Last Occurrence

```
# array last menyimpan kemunculan terakhir
# darisetiap karakter dalam pola
# jika karakter tidak muncul diberi nilai -1


def lastO(pola):
    last = [None]*128
    for i in range(0,128,1):
        last[i] = -1
    for i in range(0, len(pola), 1):
        last[ord(pola[i])] = i;
    return last;
```

Analisis Boyer Moore

- Boyer-Moore worst case running time : $O(nm + A)$
- Boyer-Moore :
 - berjalan dengan cepat jika alfabet (A) berukuran besar,
 - Berjalan lambat jika alfabet (A) berukuran kecil,
 - Mis. Baik untuk English text, kurang baik untuk binary
- Boyer-Moore *lebih cepat dari brute force* untuk searching English text.

Contoh Worst Case untuk Boyer Moore


- T: "aaaaa...a"
- P: "baaaaa"



Algoritma KMP

- Algoritma Knuth-Morris-Pratt (KMP) mencari pola dalam teks secara *left-to-right* order
- KMP menggeser pola lebih cerdas dibandingkan algoritma brute force
- Jika ada ketidakcocokan antara text dan pola P pada posisi P[j], bagaimana pergeseran pola utk menghindari pencocokan yang tidak diperlukan?
- *Jawab:*
 - the largest prefix of $P[0 \dots j-1]$ that is a suffix of $P[1 \dots j-1]$

Contoh



$j = 5$

$j_{\text{new}} = 2$

Teknik KMP

- Temukan largest prefix (start) of:

"a b a a b" ($P[0..j-1]$)

yang merupakan suffix (end) of:

"b a a b" ($p[1 .. j-1]$)

$j == 5$

- Jawaban : "a b"
- Set $j = 2$ // the new j value
- Pergeseran = $\text{len}(\text{"abaab"}) - \text{len}(\text{"ab"}) = 5 - 2 = 3$

Fungsi KMP Failure

- KMP melakukan preprosesing pola untuk mencocokkan prefix dari pola dengan polanya sendiri.
- j = posisi mismatch dalam $P[]$
- k = posisi sebelum mismatch ($k = j-1$).
- *failure function* $F(k)$ didefinisikan sbg
 - Ukuran dari largest prefix of $P[0..k]$ yang merupakan suffix of $P[1..k]$.

Contoh Failure Function

POLA

a	b	a	a	b	a
0	1	2	3	4	5

j	0	1	2	3	4
$F(j)$	0	0	1	1	2

Failure
Function

$F(j)$: ukuran dari
the largest prefix.

$J=4$

a	b	a	a	b
0	1	2	3	4

$J=3$

a	b	a	a
0	1	2	3

$J=2$

a	b	a
0	1	2

Mengapa $F(4) = 2$?

P: "abaaba"

- $F(4)$ berarti
 - Temukan ukuran dari largest prefix $P[0..4]$ yang merupakan suffix $P[1..4]$
= temukan ukuran largest prefix "abaab" yang juga suffix dari "baab"
= ukuran dari "ab"
= **2**

Pemakaian Failure Function

- Modifikasi algoritma Knuth-Morris-Pratt's :
 - if a mismatch occurs at $P[j]$ ($P[j] \neq T[i]$),
 - then
 - $k = j-1;$
 - $j = F(k);$ // obtain the new j

Fungsi Search KMP

```
def searchKMP(T,P):
```

```
    fail = cfail(P)
```

```
    n = len(T)
```

```
    m = len(P)
```

```
    i = 0
```

```
    j = 0
```

```
    Found = False
```

```
    #while .....
```

```
        while (i < n) and (not Found):
```

```
            if (P[j] == T[i]):
```

```
                if (j == m-1):
```

```
                    Found = True
```

```
                    hasil = i-m+1
```

```
                else:
```

```
                    j = j + 1;
```

```
                    i = i + 1;
```

```
            elif (j > 0):
```

```
                j = fail[j-1]
```

```
            else:
```

```
                i = i + 1
```

```
        if (not Found):
```

```
            hasil = -1
```


```
        return (hasil)
```

```
:
```

Failure Function

```
def cfail(pola):  
    fail = [None] * len(pola)  
  
    fail[0]=0  
  
    m = len(pola)  
  
    j = 0  
  
    i = 1  
  
    #while . . .  
        while (i < m):  
            if (pola[j] == pola[i]) :  
                #j+1 chars match  
                fail[i] = j + 1;  
                i= i+1;  
                j= j+1;  
            elif (j > 0):  
                # j follows matching prefix  
                j = fail[j-1];  
            else: # no match  
                fail[i] = 0;  
                i= i+1;  
        return fail
```

Contoh KMP



k	0	1	2	3	4
F(k)	0	0	1	0	1

Keuntungan KMP

- KMP mempunyai waktu optimal : $O(m+n) \Rightarrow$ sangat cepat
- Algoritma tidak perlu mundur dalam memeriksa teks input T
 - Algoritma KMP baik untuk pemrosesan files yg sangat besar yg berasal dari external devices atau dikirim melalui network

Kerugian KMP

- KMP bekerja kurang baik jika ukuran alfabet meningkat
 - Ketidakcocokan akan meningkat
 - mismatch cenderung terjadi di awal pola, sedangkan KMP berjalan cepat jika mismatch terjadi di akhir pola

LATIHAN

- Diberikan P dan T sbb :
 - P = badbaaa
 - T = badbacabcbadbbaacb
- Tunjukkan pemakaian algoritma KMP dan algoritma BM untuk pencarian pola P dalam teks T di atas.

Referensi

- Anany Levitin, Introduction to The Design and Analysis of Algorithms, Pearson, 2012.
- S.Dasgupta, et al. Algorithms, 2006.
- Cormen, et al. Algorithms, MGH, 2009.
- Strategi Algoritma – Rinaldi Munir (ITB) :
 - <https://informatika.stei.itb.ac.id/~rinaldi.munir/Stmik/stmik.htm>
- Khan Academy, Computer Science: Algorithm,
<https://www.khanacademy.org/computing/computer-science/algorithms>