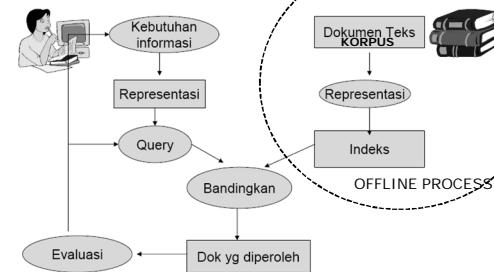


## KOM341 Temu Kembali Informasi

KULIAH #2  
 • Pemrosesan Teks  
 • Pengantar bahasa PERL

### Proses Perolehan Informasi Sederhana



JULIO ADISANTOSO - ILKOM IPB

### Pengertian TEKS

- Teks ≈ Korpus ≈ Koleksi dokumen yang bisa dibaca oleh mesin
- Contoh:
  - Kumpulan artikel surat kabar yang diperoleh dari Internet
  - Kumpulan skripsi mahasiswa yang telah dikumpulkan secara digital oleh perpustakaan

JULIO ADISANTOSO - ILKOM IPB

### Korpus

- Korpus adalah teks alami yang dipilih dengan cara tertentu.
- Masalah pada perancangan korpus
  - Ukuran
  - Jenis
  - Bahasa
- Media: teks, audio, video (multimedia)
- Isu pada korpus:
  - Tokenisasi pada korpus
  - Anotasi pada korpus

JULIO ADISANTOSO - ILKOM IPB

### Contoh Korpus Free text

Sekurangnya 17 ribu ayam ras milik peternak di wilayah kabupaten Kotawaringin Timur (Kotim) , Kalimantan Tengah mati dan kuat dugaan akibat terserang virus avian influenza (AI) atau yang lagi ramai disebut penyakit flu burung. Kasubdin Produksi Peternakan Dinas Pertanian Kotim Drh. Mawardi di Sampit, Selasa mengatakan sebanyak 17 ribu ekor ayam ras yang mati diduga terserang flu burung itu sejak Desember 2003.

Dari hasil diagnosis Balai Penyelidikan dan Pengujian Veteriner (BPPV) regional V Banjar Baru Kalimantan Selatan yang diterima Dinasn Kotim, Senin (26/1) menyebutkan ayam yang mati terserang panyakit itu hanya ada dua kemungkinan yaitu terserang virus AI dan VVND atau tetelo. "Namun kasus kematian masal ayas ras di Kotim kemungkinan besar akibat akibat serangan virus avian influenza yang bisa menular kepada manusia namanya menjadi flu burung," ucapnya.

JULIO ADISANTOSO - ILKOM IPB

### Contoh Korpus XML Format

```

<DOC>
<DOCNO>DOC01</DOCNO>
<TITLE>Flu Burung Menyerang Kalimantan Tengah</TITLE>
<AUTHOR>Ark. Ari</AUTHOR>
<DATE>7 Februari 2003 </DATE>
<TEXT>
<p>Sekurangnya 17 ribu ayam ras milik peternak di wilayah kabupaten Kotawaringin Timur (Kotim) , Kalimantan Tengah mati dan kuat dugaan akibat terserang virus avian influenza (AI) atau yang lagi ramai disebut penyakit flu burung. Kasubdin Produksi Peternakan Dinas Pertanian Kotim Drh. Mawardi di Sampit, Selasa mengatakan sebanyak 17 ribu ekor ayam ras yang mati diduga terserang flu burung itu sejak Desember 2003. </p>
</TEXT>
</DOC>
    
```

P-Dari hasil diagnosis Balai Penyelidikan dan Pengujian Veteriner (BPPV) regional V Banjar Baru Kalimantan Selatan yang diterima Dinasn Kotim, Senin (26/1) menyebutkan ayam yang mati terserang panyakit itu hanya ada dua kemungkinan yaitu terserang virus AI dan VVND atau tetelo. "Namun kasus kematian masal ayas ras di Kotim kemungkinan besar akibat akibat serangan virus avian influenza yang bisa menular kepada manusia namanya menjadi flu burung," ucapnya.

JULIO ADISANTOSO - ILKOM IPB

## Melacak Teks

- Operasi dasar dalam string matching
- Contoh:
  - Dapatkan semua baris yang dimulai dengan kata Flu.
  - Dapatkan semua baris yang dimulai dengan kata Huruf Besar.
  - Dapatkan semua baris yang memiliki kata terdiri dari huruf besar semua.
  - Hitung banyaknya kata Flu pada dokumen tersebut.
  - dsb.

JULIO ADISANTOSO - ILKOM IPB

## Statistik Teks

- Jumlah Kata
  - Seberapa besar korpus yang ada (N)
- Jenis Kata
  - Berapa jumlah kata yang unik?
  - Berapa besar perbedahan kata pada korpus?
- Token kata
  - Berapa jumlah kata pada korpus?
  - Berapa frekuensi dari setiap jenis kata?
  - Kata apa yang paling sering muncul pada korpus?

JULIO ADISANTOSO - ILKOM IPB

## Prosedur Menghitung Frekuensi Kata

- Tokenisasi : mendapatkan kata
- Ubah menjadi huruf kecil
- Urutkan menurut abjad
- Hitung frekuensi kemunculan kata
- Urutkan menurut frekuensinya
- Hitung frekuensi dari frekuensi kemunculan kata

JULIO ADISANTOSO - ILKOM IPB

## Fenomena Frekuensi Kata

- Sejumlah kata merupakan kata yang sangat umum (frekuensi sangat besar), misalnya "the", "of"
- Kebanyakan kata sangat jarang muncul (frekuensi sangat kecil).
- Setengah dari kata-kata pada korpus hanya muncul sekali.

JULIO ADISANTOSO - ILKOM IPB

## Contoh

Kata	Frekuensi Kata (f)	Peringkat (r)	$f * r$
name	21	400	8400
comes	16	500	8000
group	13	600	7800
science	11	700	7700
family	10	800	8000
begin	9	900	8100
broke	4	2000	8000
seems	2	3000	6000
could	2	4000	8000

JULIO ADISANTOSO - ILKOM IPB

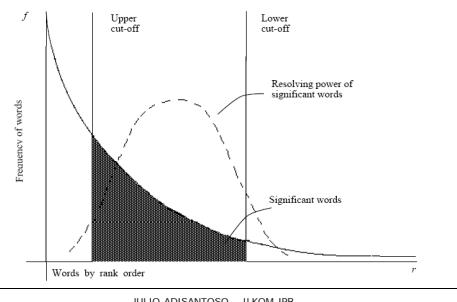
## Hukum Zipf

- Menjelaskan adanya hubungan antara frekuensi dan urutan/rank (George Kingsley Zipf).
- Urutan/Rank:
  - hitung berapa kali kata muncul pada semua teks di dalam korpus (f).
  - urutkan sesuai dengan frekuensi kemunculan kata membentuk rank (r).
- Terdapat konstanta c sehingga  $f * r = c$

JULIO ADISANTOSO - ILKOM IPB

## Luhn's Ideas

kata-kata yang paling umum dan paling tidak umum adalah tidak signifikan untuk indexing



JULIO ADISANTOSO - ILKOM IPB

## Stopwords

### STOPWORDS:

- Terdapat kata yang merupakan bagian terbesar dari teks yang tidak perlu digunakan sebagai penciri dokumen.
- Terdapat banyak ragam kata yang hanya muncul sedikit sekali di dalam suatu teks.
- Contoh: to, in, form, yang, dan
- Kata-kata dengan frekuensi cukup (di bagian tengah) adalah yang paling baik digunakan sebagai penciri dokumen.

JULIO ADISANTOSO - ILKOM IPB

## Tokenisasi

- Pengertian : suatu tahap pemrosesan di mana teks input dibagi menjadi unit-unit kecil yang disebut token, yang dapat berupa suatu kata, suatu angka, atau suatu tanda baca.
- Konsekuensinya:
  - Perlu mengenali unit secara otomatis
  - Apakah suatu kata itu?
  - Kalimat?
  - Paragraf?

JULIO ADISANTOSO - ILKOM IPB

## Kata

- Karakter alfanumerik yang saling terhubung yang dipisahkan oleh whitespace.
- Whitespace: spasi, tab, newline
- Masalah:
  - B2B, amazon.com, Micro\$oft
  - isn't, Jum'at
  - pro-aktif, out-of-date
  - tanda sambung pada akhir baris

JULIO ADISANTOSO - ILKOM IPB

## Segmentasi kata

- Proses tokenisasi sederhana, tetapi tidak terlepas dari kesalahan.
- Contoh:
  - Kata majemuk: Jurusan Surabaya-Jakarta
  - Frase: tusuk jarum, keras kepala, sistem informasi
  - Nomor telpon (0251) 8356653 +62 251 8625584
- Menjadi topik dari ekstraksi informasi

JULIO ADISANTOSO - ILKOM IPB

## Kalimat

- Satu atau lebih string kata yang diakhiri dengan suatu tanda berhenti sepenuhnya, tanda tanya atau tanda seru.
- Contoh:
  - Akhir dari baris.
  - Akhir dari suatu cerita!
  - Apakah kamu sudah punya pacar?
  - Ia sering mengunjungi friendster.com.
  - Dr. Iwan pergi ke Surabaya.
  - Dia mengatakan "Bohong!".

JULIO ADISANTOSO - ILKOM IPB

## Batas kalimat

- Hipotesakan bahwa batas kalimat sesudah . ? !
- Pindahkan batas kalimat sesudah tanda petik, bukan setelah titik.
  - "Jangan ambil buku itu. Buku itu milik pak Budi.", kata ibu kepada Ani.
- Jangan gunakan titik jika:
  - Sebelumnya adalah singkatan yg umum yg biasanya bukan akhir kalimat, tp biasanya diikuti oleh nama dengan huruf besar: Prof.
  - Didahului oleh singkatan yang umum dan tidak diikuti oleh kata dengan huruf besar: Jr.
- Jangan kenali sebagai batas jika ada ! atau ? yang diikuti oleh huruf kecil

JULIO ADISANTOSO - ILKOM IPB

## Pemrosesan Teks Otomatis

- Menghitung kata pada teks
- Mengurutkan kata
- Menghitung berbagai nilai statistik kata
  - Input : berkas teks (bisa berupa korpus)
  - Output : daftar kata beserta frekuensinya
- Pertanyaannya:
  - Bagaimana program komputernya?
  - Bahasa pemrograman apa yang digunakan?

JULIO ADISANTOSO - ILKOM IPB

## PERL

<http://www.activestate.com/activeperl/downloads>

- Practical Extraction and Report Language
- Dikembangkan oleh Larry Wall pada tahun 1987
- Mengembangkan suatu bahasa script yang lebih baik daripada Unix shell tetapi tidak serumit C.
- Berguna untuk memanipulasi teks yang tidak dapat dilakukan oleh instruksi baris unix

JULIO ADISANTOSO - ILKOM IPB

## PERL

```
#!/usr/local/bin/perl
#Program untuk menulis kata 'hello'
print "Hello\n";
```

- Tulis pada suatu file, misalnya bernama 'halo.p' (Unix), atau 'halo.pl' (Windows).
- Untuk me-run pada Unix/Linux:  
 > perl halo.p
- Untuk me-run pada Windows:  
 > perl halo.pl

JULIO ADISANTOSO - ILKOM IPB

## PERL di web

```
#!/C:/apache/xampp/perl/bin/perl.exe"

print "Content-type: text/html\n\n";
print '<html>';
print '<head>';
print '<meta name="author" content="Kay Vogelgesang">';
print '<link href="/xampp/xampp.css" rel="stylesheet"
type="text/css">';
print '</head>';
print "<body>&nbsp;<p><h1>GCI with MiniPerl</h1></p>
<h2>CGI with MiniPerl is ready ...</h2></body></html>";
```

Tulis pada suatu file, misalnya bernama 'test.cgi' dan simpan di folder cgi-bin.

JULIO ADISANTOSO - ILKOM IPB

## PERL Jenis data

- Tiga jenis data dalam PERL:
  - Skalar
  - Array
  - Associative array atau hash
- Nama variabel
  - Nama variabel skalar dimulai dengan \$ (mis. \$dok)
  - Nama variabel array dimulai dengan @ (mis. @kata)
  - Nama variabel hash dimulai dengan % (mis. %tabel)
  - Nama variabel adalah case sensitive (\$kelas ≠ \$KELAS)

JULIO ADISANTOSO - ILKOM IPB

## PERL Skalar

- Angka
  - digits, desimal, eksponensial dll.
  - \$nilai = 350;
  - \$nilai = 3.50
- Strings
  - Diapit oleh tanda petik single / double;
  - Escape character dengan backslash
    - \n (newline) ; \t (tab) ;
    - \U (Uppercase) ; \L (Lower case)
  - print "\Uhalo\n"; → HALO
  - print "ha\Ulo\n"; → haLO

JULIO ADISANTOSO - ILKOM IPB

## PERL Operator

- Bilangan
  - Aritmatika : +, -, /, \*, %
  - Assignment : =, +=, -=, +=, -=
- String :
  - Concatenation: .
  - Repetition: x

JULIO ADISANTOSO - ILKOM IPB

## PERL Array

- Suatu array adalah suatu variabel yang berisi list
- Suatu array berisi nol atau lebih elemen. Tidak perlu ditentukan panjangnya seperti pemrograman lainnya.
- Contoh:
 

```
(1, 2, 3)
("yang", "dan", "untuk")
()
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Array

```
@kata = ("yang", "dan", "untuk");
@x = (1, 2, 3);
@y = @x;      # assign nilai x ke y
@y = (@x 4 5);      # @y=(1 2 3 4 5)
$z = @y;      # $z bernilai 5 (panjang @y)
($z) = @y;      # $z = 1 (elemen pertama @y)
@prefix = $kata[0,1];  # ("yang", "dan")
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Array

```
@array = ("aa", "bb", "cc", "dd");
$length = @array; #4
print $#array; #3
print $array[$#array]; #dd"
print scalar(@array); #4
($a, $b) = ("satu", "dua");
($satu, @b) = (1,2,3,4,5,6);
# $satu = 1, @b=(2 3 4 5 6)
($a, $b) = ($b, $a); #tukar nilainya
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Mengubah isi array

**Push**  
menambahkan list pada bagian akhir dari array

```
@a1 = ("aa", "bb", "cc", "dd");
@a2 = ("ee", "ff");
push @a1, @a2;
#@a1=("aa","bb","cc","dd","ee","ff")
push @a2, "gg";
#@a2=("ee","ff","gg")
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Mengubah isi array

### Pop

Membuang elemen terakhir dari list

```
@array = ("aa", "bb", "cc", "dd");
$elemen = pop @array;
# $elemen= "dd"
# @array = ( "aa", "bb", "cc" )
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Associative Arrays

- Array yang memiliki indeks bukan berupa bilangan 0 sampai dengan n-1, melainkan string.
  - Contoh:
- ```
%nilai=();
$nilai{ "dan"}=200;
$nilai{ "yang"}=150;
@kata=keys(%nilai); #@kata=( "dan", "yang")
@freq=values(%nilai); #@freq=(200, 150)
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Control Structures

- IF

```
if ($nilai > 60)
    { print "Lulus\n"; }
else
    { print "Tidak lulus\n"; }
```
- UNLESS

```
unless ($nilai > 60)
    { print "Tidak lulus\n"; }
```
- ELSIF

```
if ($nilai >= 80)
    { print "A\n"; }
elsif ($nilai >= 60)
    { print "B\n"; }
else
    { print "Tidak lulus\n"; }
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Control Structures

- WHILE

```
$i = 10;
while ($i > 5) {
    $x = $i*$i;
    print "Kuadrat dari $i adalah $x\n";
    $i--;
```
- UNTIL

```
$i = 10;
until ($i <= 5) {
    $x = $i*$i;
    print "Kuadrat dari $i adalah $x\n";
    $i--;
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Control Structures

- FOR

```
for ($i = 1; $i<=10; $i++)
{ print "$i\n"; }

@kata=( "dan", "yang", "untuk" );
for ($i=0 ; $i<=$#kata; $i++) {
    $prefix = $kata[$i];
    print "$prefix\n";
}
```
- FOREACH

```
foreach $prefix(@kata) {
    print "$prefix\n";
}
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Associative Arrays

```
%nilai=();
$nilai{ "dan"}=200;
$nilai{ "yang"}=150;
foreach $i (keys %nilai)
    { print "$nilai{$i}\n"; }
while (( $kata, $freq) = each (%nilai))
    { print "$kata : $freq\n"; }
foreach $i (sort keys %nilai)
    { print "$nilai{$i}\n"; }
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Sorting

```
@kata = ("dan", "itu", "yang", "pada");
reverse(@nama);
@stopwords = sort(@kata);

 Sesuai alfabet: sort { $a cmp $b } @list;
 Sesuai numerik: sort { $a <= $b } @list;
 Descending: sort { $b <= $a } @list;
 Associative array
    sort { $tabel{$b} <= $tabel{$a} } @keys %tabel;
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Input/Output

- Membuka dan menutup file
 

```
open(IN, "koleksi.txt");
open(OUT, ">hasil.txt");
open(OUT ">>hasil.txt"); → append
close(OUT);
```
- Membuka dan menutup file
 

```
open(IN, "koleksi.txt");
open(OUT, ">hasil.txt");
while ($line = <IN>) {
    chop($line); # buang carriage return
    print OUT "$line\n";
}
close(IN);
close(OUT);
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Regular Expression

- Ekspresi yang digunakan untuk menggambarkan pola dari suatu obyek.
- Sering digunakan dalam pemrosesan teks.
- Bahasa yang banyak menggunakan RE adalah PERL.
- Pemrograman menjadi lebih singkat dan mudah.

JULIO ADISANTOSO - ILKOM IPB

## PERL Regular Expression

|    |                                    |
|----|------------------------------------|
| \b | batas kata                         |
| \d | digit = [0-9]                      |
| \n | newline                            |
| \r | carriage return                    |
| \s | karakter white space               |
| \t | tab                                |
| \w | karakter alfanumerik = [A-Za-z0-9] |
| ^  | awal dari string                   |
| \$ | akhir dari string                  |

JULIO ADISANTOSO - ILKOM IPB

## PERL Regular Expression

|         |                                                              |
|---------|--------------------------------------------------------------|
| .       | karakter apapun                                              |
| [bdkp]  | karakter b, d, k dan p                                       |
| [a-f]   | karakter a sampai f                                          |
| [^a-f]  | semua karakter kecuali a sampai f                            |
| abc def | string abc atau string def                                   |
| *       | nol atau beberapa kali                                       |
| +       | sekali atau beberapa kali                                    |
| ?       | nol atau satu kali                                           |
| qw()    | ("quote word") function<br>qw(aa bb cc) → ("aa", "bb", "cc") |

JULIO ADISANTOSO - ILKOM IPB

## PERL Regular Expression

```
/ab)*(de)+/
abde
abbde
bde
abadde
ababde

/a{5}b{1,4}c{2}/
aaaaabcc
aaaaabcccc
aaaaabc
aaaabccc
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Regular Expression

```
/c[ad]r/
car, cdr
cadrr, cadddr

/c[ad]*r/
car, cdr, caaaadr, caaadaaar

/[a-g][t-z][0-9]*/
aul25
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Pengolahan String

- Pola string → //  
 \$kata=~ /tan/;  
 \$kata=~ ^tan/;  
 \$kata=~ /tan\$/;
- Mengubah bagian string → s///  
 \$kalimat=~ s/minyak/BBM/;  
 \$kalimat=~ s/minyak/BBM/g;  
 \$kalimat=~ s/minyak/BBM/gi;
- Mengubah karakter → tr///  
 \$kata=~ tr/[A-Z]/[a-z]/;

JULIO ADISANTOSO - ILKOM IPB

## PERL Fungsi SPLIT

- Untuk tokenisasi, mendapatkan kata dari suatu kalimat dengan pemisah (delimiter) tertentu.
- split(//);
- Contoh
 

```
$kalimat= "Petani alami gagal panen";
@kata=split(/\s+/, $kalimat);
maka array
@kata= ("Petani", "alami", "gagal", "panen")
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Contoh Program

```
$kalimat="Harga minyak sekarang turun.
Sebelumnya harga minyak naik. Sekarang
harga minyak turun lagi";
$kalimat =~ tr/[A-Z]/[a-z]/;
@kata = split(/\s+/, $kalimat);
foreach $token(@kata) {
  print "$token\n";
}
```

JULIO ADISANTOSO - ILKOM IPB

## PERL Contoh Program

```
open (IN, "dokumen.txt") || die;
while($line = <IN>)
{
  chomp($line); #buang carriage return
  $line =~ s/\s*//; #buang whitespace
  $line =~ s/\s+$//;
  reset @arraykata;
  @arraykata=split /\s+/, $line;
  #untuk siap kata
  foreach $kata(@arraykata) {
    $kata =~ tr/[A-Z]/[a-z];
    $kata =~ s/[!.,()]*|[^\w]/g;
    $freq{$kata}++;
  }
  # Mencetak daftar kata, sort by frekuensi
  foreach $key (sort{$freq{$b}<>$freq{$a}}keys %freq){
    print "$key - $freq{$key}\n";
  }
}
close(IN);
```

JULIO ADISANTOSO - ILKOM IPB