

PENERAPAN ALGORITMA EDIT DISTANCE UNTUK PENGUKURAN KEMIRIPAN ANTAR DOKUMEN BERBAHASA INDONESIA

Iyan Mulyana, Aries Maesya, Andi Chairunnas

Program Studi Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Pakuan, Bogor
Iyandelon@yahoo.com

Abstrak

Salah satu pencegahan tindakan plagiarisme adalah pengukuran kemiripan dokumen dengan tingkat kecepatan dan nilai akurasi yang tinggi. Tujuan dari penelitian ini adalah membuat aplikasi untuk mengukur kemiripan dokumen berbahasa Indonesia menggunakan edit distance. Algoritma edit distance yaitu algoritma yang berfungsi untuk mengukur nilai kemiripan atau kesamaan antar kata (string) berdasarkan total biaya terkecil dari transformasi salah satu kata menjadi kata yang lain dengan menggunakan edit-rules, yaitu penambahan karakter (insertion), penggantian karakter (substitution) dan penghapusan karakter (deletion). Cara kerja algoritma edit distance dalam mencocokkan string yaitu mengukur kesamaan karakter pada urutan yang sama bukan berdasarkan kata yang sama. Hasil penelitian menunjukkan bahwa pengukuran kemiripan dengan tahap preprocessing menghasilkan nilai lebih baik dari pada tanpa preprocessing. Tahap Preprocessing dapat mengoptimalkan kerja algoritma edit distance sehingga meningkatkan nilai akurasi pengukuran kemiripan.

1 PENDAHULUAN

Karya ilmiah merupakan suatu tulisan yang memaparkan hasil penelitian yang telah dilakukan oleh seseorang atau sekelompok masyarakat ilmuwan. Karya ilmiah yang telah ditulis itu diharapkan menjadi wahana transformasi pengetahuan antara sekolah dengan masyarakat, atau orang-orang yang berminat membacanya. Bila karya ilmiah dimuat di media online akan semakin memudahkan banyak orang untuk mengakses karya ilmiah. Kewajiban publikasi karya ilmiah juga akan mendorong seseorang untuk bertindak jujur karena tulisannya dibaca oleh banyak orang dan dapat mengurangi tingkat plagiarisme.

Salah satu pencegahan tindakan plagiarisme adalah pengukuran kemiripan dokumen dengan tingkat kecepatan dan nilai akurasi yang tinggi sangat dibutuhkan. Salah satu cara untuk mengetahui seberapa besar kemiripan suatu dokumen dengan dokumen lainnya dapat dengan menggunakan pendekatan string metric yaitu melakukan perbandingan string dengan memasukkannya ke dalam fungsi matematis tertentu. Pada penelitian yang telah dilakukan Goenawan, et al (2005), menyatakan bahwa salah satu

algoritma yang dapat digunakan untuk perbandingan string atau pencocokkan string dalam pengukuran kemiripan antar dokumen adalah algoritma edit distance. Adapun, kompleksitas waktu dari algoritma edit distance ini adalah kuadratik $O(n^2)$ yang jauh lebih baik daripada algoritma brute force dengan kompleksitas waktu eksponensial $O(2^n)$.

Pada Penelitian ini digunakan algoritma edit distance dalam pengukuran kemiripan antar dokumennya. Algoritma edit distance berfungsi untuk mengukur nilai kemiripan atau kesamaan antar kata (string) berdasarkan total biaya terkecil dari transformasi salah satu kata menjadi kata yang lain dengan menggunakan edit-rules, yaitu penambahan karakter, penggantian karakter dan penghapusan karakter.

Penerapan algoritma edit distance diharapkan mampu mendapatkan nilai kemiripan dengan akurasi yang tinggi dan memenuhi kebutuhan efisiensi pengukuran kemiripan antar dokumen.

1.1 ALGORITMA EDIT DISTANCE

Edit distance atau levenshtein-distance adalah algoritma yang ditemukan oleh Vladimir Levenshtein, seorang ilmuwan Rusia, pada tahun 1965. Algoritma ini berguna untuk memeriksa kemiripan dari dua buah string yang umumnya ditemukan pada aplikasi-aplikasi pengecekan suatu ejaan. Perhitungan edit distance didapatkan dari matriks yang digunakan untuk menghitung jumlah perbedaan string antara dua string. Perhitungan jarak antara dua string ini ditentukan dari jumlah minimum operasi perubahan untuk membuat string A menjadi string B Secara umum, operasi mengubah yang diperbolehkan untuk keperluan ini adalah: (Dani, 2006)

- Memasukkan karakter ke dalam string,
- Menghapus sebuah karakter dari suatu string,
- Mengganti karakter string dengan karakter lain.

Persamaan algoritma edit distance :

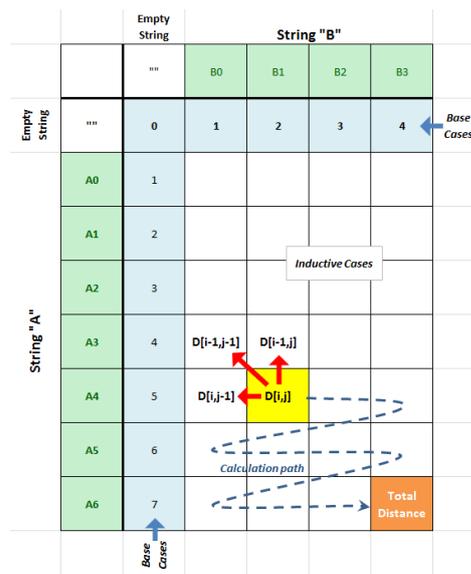
$$\text{lev}_{a,b}(i,j) = \begin{cases} 0 & , i = j = 0 \\ i & , j = 0 \text{ and } i > 0 \\ j & , i = 0 \text{ and } j > 0 \\ \min \begin{cases} \text{lev}_{a,b}(i-1,j) + 1 \\ \text{lev}_{a,b}(i,j-1) + 1 \\ \text{lev}_{a,b}(i-1,j-1) + [a_i \neq b_j] \end{cases} & , \text{ else} \end{cases}$$

Gambar 1: Persamaan algoritma edit distance

Tabel 1 Penentuan nilai matriks edit distance

Baris dan kolom pada tabel dua dimensi (matriks) di atas diisi dengan langkah-langkah sebagai berikut:

1. Elemen matriks $[0,0]$ akan diisi dengan nilai 0



Gambar 2:

2. Elemen matriks $[i,0]$ akan diisi dengan nilai matriks $[i-1,0]+1$
3. Elemen matriks $[0,j]$ akan diisikan nilai matriks $[0,j-1]+1$
4. Elemen lainnya (matriks $[i,j]$) diisi dengan urutan langkah di bawah ini:
 - (a) Jika karakter ke-I pada string ke-1 memiliki kesamaan dengan karakter ke-J pada string ke-2 maka nilai matriks $[i-1,j-1]$ akan dianggap ditambahkan 1 dari nilai sebelumnya.
 - (b) Bandingkan 3 elemen matriks pada posisi matriks $[i-1,j-1]$, matriks $[i,j-1]$, dan matriks $[i-1,j]$ untuk pencarian nilai minimum di antara ketiganya. Elemen dengan nilai terkecil akan dimasukkan nilainya ke dalam matriks $[i,j]$
 - (c) ulangi langkah 1 dan 2 sampai semua elemen tabel terisi.

1.2 MENGHITUNG KEMIRIPAN (SIMILARITY) DENGAN EDIT DISTANCE

Pengukuran ini dilakukan untuk mengetahui seberapa besar kemiripan teks antara dokumen asli dan dokumen pembanding. Langkah-langkah dalam menentukan similarity adalah: (Winoto, 2012)

Jika dimisalkan

S1 = Source string

S2 = Target string

Setelah dilakukan perhitungan dari kedua string tersebut menggunakan edit distance, maka algoritma ini akan memberikan angka sebagai perbedaan dari kedua string.

Setelah didapatkan distance dari kedua string tersebut maka dapat ditentukan formula untuk menghitung derajat similarity kedua string. Formula tersebut adalah

$$\text{Nilai Kemiripan} = 1 - \frac{\text{Distance}}{\text{Max}(S1,S2)} \times 100 \quad (1)$$

Gambar 3:

Keterangan:

Max(S1,S2) merupakan nilai yang paling panjang yang diberikan dari perbandingan S1 dan S2.

2 PERANCANGAN SISTEM

Penerapan algoritma edit distance pada pengukuran kemiripan dokumen ini mempunyai cara kerja yaitu pertama user memasukkan dokumen teks, kemudian dokumen teks akan diproses pada tahap preprocessing. Tahapan ini menghasilkan kumpulan kata-kata penting (kata dasar) yang selanjutnya diukur kemiripannya dengan menerapkan algoritma edit distance, yaitu dengan melakukan pencocokan string dari antar dokumen terhadap kumpulan kata-kata. Hasil pengukurannya berupa presentase kemiripan antar dokumen. Cara kerja sistem ditunjukkan pada Gambar 4.

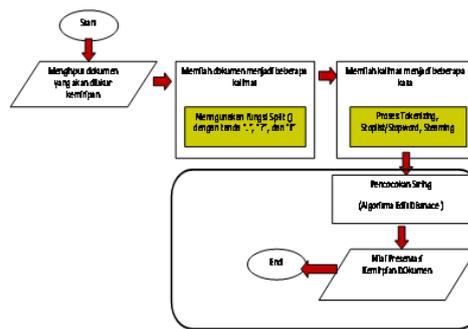


Gambar 4: Alur kerja system

Secara garis besar sistem pengukuran kemiripan dokumen teks ini dibangun oleh dua tahapan utama yaitu tahap preprocessing (text preprocessing) dan tahap pencocokan string (algoritma edit distance). Seperti ditunjukkan pada Gambar 5.

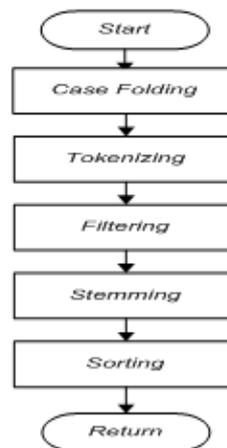
2.1 TAHAP PREPROCESSING

Tahap preprocessing merupakan tahapan dimana dilakukan proses untuk mengurangi noise yang terdapat dalam dokumen. Tahapan preprocessing yang dilakukan dalam sistem ini adalah case folding (mengubah ukuran huruf dan penghilangan simbol-simbol), tokenizing (pemotongan kata), filtering (penghilangan kata-kata yang tidak



Gambar 5: Tahapan Proses Pengukuran Kemiripan Dokumen

penting), stemming (penghilangan imbuhan) dan sorting (pengurutan), seperti yang ditunjukkan pada Gambar 3. Hasil dari tahapan preprocessing yaitu kumpulan kata dasar yang akan digunakan sebagai pencocokan string atau perbandingan dokumen.



Gambar 6: Tahapan Preprocessing

2.2 TAHAP PENCOCOKAN STRING (ALGORITMA EDIT DISTANCE)

Setelah proses preprocessing langkah selanjutnya adalah pencocokan string dari dokumen uji dengan dokumen pembandingan menggunakan algoritma edit distance. Berikut ini flowchart algoritma edit distance pada Gambar 7.

3 HASIL DAN PEMBAHASAN

Hasil dari implementasi penerapan algoritma edit distance, terdiri dari dua macam pengukuran yaitu pengukuran kemiripan antar dua dokumen ditunjukkan pada Gambar 5, dan pengukuran kemiripan satu dokumen dengan dokumen yang berada dalam database ditunjukkan pada Gambar 6. File yang dapat diukur kemiripannya hanya



Gambar 7: Flowchart algoritma edit distance

file dengan ekstensi .txt.

Pada aplikasi pengukuran kemiripan Dokumen ini File .txt sebagai dokumen inputan diproses melalui tahap preprocessing antara lain : Pertama case folding yang berfungsi untuk mengubah semua huruf menjadi huruf kecil dan selain karakter angka dan huruf dihilangkan (dianggap delimiter/pembatas). Kedua adalah proses tokenisasi yang berfungsi untuk memecah sekumpulan karakter dalam suatu teks ke dalam satuan kata. Tahap ketiga adalah proses filtering yang berfungsi untuk mengurangi ukuran dimensi dengan menghapus kata-kata yang tidak penting atau disebut sebagai stopword/stoplist dan menyimpan kata penting(wordlist), stopword ini disimpan pada database. Setelah melalui proses filtering kemudian ke proses stemming, stemming ini berfungsi untuk menghapus kata imbuhan menjadi kata dasar.

Proses terakhir pada preprocessing adalah sorting yang berfungsi untuk mengurutkan string. Hasil text preprocessing kemudian dihitung jumlah karakter dan nilai edit distance untuk mendapatkan nilai persentase kemiripan antar dokumen.

4 EVALUASI SISTEM

Evaluasi sistem dilakukan untuk mengetahui tingkat akurasi dari Metode yang digunakan. Evaluasi dilakukan dengan cara membandingkan hasil perhitungan manual dengan hasil sistem.

4.1 PENGUKURAN KEMIRIPAN MELALUI PERHITUNGAN MANUAL

Proses penentuan nilai edit distance diperoleh dengan mencocokkan antar dua string dalam bentuk matriks yang digunakan untuk menghitung jumlah perbedaan antar string. Perhitungan manual untuk memperoleh nilai persentase kemiripan antar dokumen adalah sebagai berikut :

1. Input teks dokumen: S1 = algoritma edit distance
S2 = algoritma edit distance



Gambar 8: Halaman Pengukuran (One to One)



Gambar 9: Halaman Pengukuran dengan Database (One To Many)

2. Setelah isi dokumen melalui text preprocessing (case folding, tokenizing, filtering, stemming, dan sorting)

S1 = algoritmadistanceedit

S2 = algoritmdistanceedit

3. Menentukan nilai edit distance dengan menggunakan matriks dalam tabel:

(a) Isi nilai matriks $m[i,0] = i$

(b) Isi nilai matriks $m[0,j] = j$

- (c) Jika karakter $S1[i] = S2[j]$ maka isi nilai $m[i,j] = m[i-1,j-1]$
 (d) Jika karakter $S1[i] \neq S2[j]$ maka isi nilai $m[i,j] = \max(m[i-1,j]+1, m[i,j-1]+1, m[i-1,j-1]+1)$

	a	l	g	o	r	i	t	m	d	i	s	t	a	n	c	e	d	i	t
0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
a	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
l	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
g	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
o	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14
r	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	10	11	12	13
t	6	5	4	3	2	1	2	1	2	3	4	5	6	7	8	9	10	11	12
m	7	6	5	4	3	2	3	2	1	2	3	4	5	6	7	8	9	10	11
a	8	7	6	5	4	3	4	3	2	3	4	5	6	5	6	7	8	9	10
d	9	8	7	6	5	4	5	4	3	2	3	4	5	6	7	8	9	8	9
i	10	9	8	7	6	5	4	5	4	3	2	3	4	5	6	7	8	9	8
s	11	10	9	8	7	6	5	6	5	4	3	2	3	4	5	6	7	8	9
t	12	11	10	9	8	7	6	5	6	5	4	3	2	3	4	5	6	7	8
a	13	12	11	10	9	8	7	6	7	6	5	4	3	2	3	4	5	6	7
n	14	13	12	11	10	9	8	7	8	7	6	5	4	3	2	3	4	5	6
c	15	14	13	12	11	10	9	8	9	8	7	6	5	4	3	2	3	4	5
e	16	15	14	13	12	11	10	9	10	9	8	7	6	5	4	3	2	3	4
e	17	16	15	14	13	12	11	10	11	10	9	8	7	6	5	4	3	4	5
d	18	17	16	15	14	13	12	11	12	11	10	9	8	7	6	5	4	3	4
i	19	18	17	16	15	14	13	12	13	12	11	10	9	8	7	6	5	4	3
t	20	19	18	17	16	15	14	13	14	13	12	11	10	9	8	7	6	5	4

Gambar 10: matriks menentukan nilai edit distance pada percobaan 1A

Algoritma edit distance digambarkan dalam tabel matriks $n+1 \times m+1$, dimana n dan m adalah panjang karakter dari dua string tersebut. Nilai edit distance diperoleh dari tabel matriks di atas, terletak pada pojok kanan bawah yaitu bernilai 3.

$$\text{Distance} = 3$$

$$\text{Max}(S1,S2) = 20(\text{panjang dari S1})$$

$$\text{Nilai Kemiripan} = 1 - \frac{3}{20} = 85$$

$$\text{Persentase Nilai Kemiripan} = 1 - \frac{3}{20} \times 100 = 85\%$$

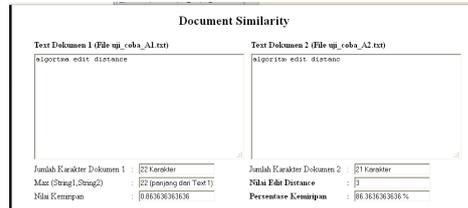
Gambar 11:

Persentase nilai kemiripan yang diperoleh dari perhitungan manual di atas dari perbandingan string `algotmadistanceedit` dan `algotm distancedit` adalah 85%. Memiliki nilai edit distance sama dengan 3, yang berarti mempunyai perbedaan 3 karakter.

4.2 PENGUKURAN KEMIRIPAN MENGGUNAKAN APLIKASI

1. Input teks dokumen: $S1 = \text{algotma edit distance}$
 $S2 = \text{algotm edit distanc}$

2. Hasil uji coba pada Gambar 8 diperoleh sebesar 86,36%, karena pada beberapa kata memiliki karakter yang berbeda.



Gambar 12: gukuran kemiripan melalui Aplikasi

Setelah beberapa kali dilakukan percobaan terdapat perbedaan hasil persentase pengukuran kemiripan secara manual dengan yang dihasilkan melalui aplikasi sekitar 1% - 3% . Hal ini disebabkan Algoritma edit distance dalam pencocokkan string mengukur kesamaan karakter pada urutan yang sama bukan berdasarkan kata yang sama, Kondisi ini yang sering membedakan antar perhitungan manual dan aplikasi.

5 SIMPULAN

Dari hasil penelitian dapat disimpulkan sebagai berikut :

1. Aplikasi pengukuran kemiripan dokumen dengan algoritma edit distance dapat digunakan untuk identifikasi plagiarise dengan nilai akurasi sistem sebesar 95 %.
2. Algoritma edit distance melakukan pencocokkan string berdasarkan kesamaan karakter pada urutan yang sama bukan berdasarkan kata yang sama. Sehingga Hal ini mengurangi tingkat akurasi proses pengukuran kemiripan antar dua dokumen.
3. Tingkat akurasi Aplikasi pengukuran kemiripan dokumen menggunakan Algoritma edit distance sangat dipengaruhi oleh tahap Preprocessing . Hal ini disebabkan melalui Preprocessing menghasilkan string yang urut.

Daftar Pustaka

1. Dani, T.G. Limandra & L.R.E Adiseputra. 2006. *Deteksi Kemiripan Kode Program dengan Metode Preprocessing dan Perhitungan Levenshtein Distance*, ISSN : 1411-6286. Prosiding Seminar Ilmiah Nasional Komputer dan Sistem Intelijen (KOMMIT 2006). Universitas Gunadarma, Depok.
2. Firdaus, H.D. 2008. *Deteksi Plagiat Dokumen Menggunakan Algoritma Rabin-Karp*. Makalah IF2251 Strategi Algoritmik. Institut Teknologi Bandung, Bandung.
3. Goenawan, W., R. Augustinus & K. Sembiring. 2005. *Penerapan Algoritma Edit Distance Pada Pendeteksian Praktik Plagiat*. Makalah STMIK. Institut Teknologi Bandung, Bandung.
4. Khusnaini, W. 2012. *Penentuan Kemiripan Data Karya Ilmiah IPB Menggunakan Algoritma Levenshtein*. Skripsi. Institut Pertanian Bogor, Bogor.
5. Kurniawati, A., K. A. Sekarwati & I.W.S. Wicaksana. 2012. *Arsitektur untuk aplikasi Deteksi Kesamaan Dokumen Bahasa Indonesia*. Makalah dalam Konferensi Nasional Sistem Informasi 2012. Universitas Gunadarma, Depok.
6. Thalib, K & R. Kusumawati. 2004. *Pembuatan Program Aplikasi untuk Pendeteksi Kemiripan Dokumen Teks dengan Algoritma Smith-Waterman*. Makalah. Universitas Gunadarma, Depok.
7. Winoto, H. 2012. *Deteksi Kemiripan Isi Dokumen Teks Menggunakan Algoritma Levenshtein Distance*. Skripsi. Universitas Islam Negeri Maulana Malik Ibrahim, Malang.