

**DETEKSI DAN PERBAIKAN PENULISAN KATA BAKU BAHASA
INDONESIA PADA BERITA DARING DENGAN ALGORITMA
LEVENSHTEIN DISTANCE**



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh
Gelar Sarjana Komputer (S.Kom.)

**Jezreel Kosasih
00000043909**

**PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK DAN INFORMATIKA
UNIVERSITAS MULTIMEDIA NUSANTARA
TANGERANG
2024**

**DETEKSI DAN PERBAIKAN PENULISAN KATA BAKU BAHASA
INDONESIA PADA BERITA DARING DENGAN ALGORITMA
LEVENSHTEIN DISTANCE**



Diajukan sebagai salah satu syarat untuk memperoleh
Gelar Sarjana Komputer (S.Kom.)

Jezreel Kosasih
00000043909
UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA
PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK DAN INFORMATIKA
UNIVERSITAS MULTIMEDIA NUSANTARA
TANGERANG
2024

HALAMAN PERNYATAAN TIDAK PLAGIAT

Dengan ini saya,

Nama : Jezreel Kosasih

NIM : 00000043909

Program Studi : Informatika

Menyatakan dengan sesungguhnya bahwa Tesis/Skripsi/Tugas Akhir/Laporan Magang/MBKM saya yang berjudul:

Deteksi dan Perbaikan Penulisan Kata Baku Bahasa Indonesia pada Berita Daring dengan Algoritma Levenshtein Distance

merupakan hasil karya saya sendiri, bukan merupakan hasil plagiat, dan tidak pula dituliskan oleh orang lain; Semua sumber, baik yang dikutip maupun dirujuk, telah saya cantumkan dan nyatakan dengan benar pada bagian Daftar Pustaka.

Jika di kemudian hari terbukti ditemukan kecurangan/penyimpangan, baik dalam pelaksanaan skripsi maupun dalam penulisan laporan karya ilmiah, saya bersedia menerima konsekuensi untuk dinyatakan TIDAK LULUS. Saya juga bersedia menanggung segala konsekuensi hukum yang berkaitan dengan tindak plagiarisme ini sebagai kesalahan saya pribadi dan bukan tanggung jawab Universitas Multimedia Nusantara.

Tangerang, 13 Mei 2024



(Jezreel Kosasih)

UNIVERSITAS
MULTIMEDIA
NUSANTARA

HALAMAN PENGESAHAN

Skripsi dengan judul

DETEKSI DAN PERBAIKAN PENULISAN KATA BAKU BAHASA INDONESIA PADA BERITA DARING DENGAN ALGORITMA LEVENSHTEIN DISTANCE

oleh

Nama : Jezreel Kosasih
NIM : 00000043909
Program Studi : Informatika
Fakultas : Fakultas Teknik dan Informatika

Telah diujikan pada hari Kamis, 30 Mei 2024

Pukul 13.00 s/s 15.00 dan dinyatakan

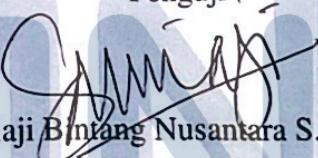
LULUS

Dengan susunan penguji sebagai berikut

Ketua Sidang


(David Agustriawan, S.Kom., M.Sc.,
Ph.D.)
NIDN: 0525088601

Penguji


(Samiaji Bintang Nusantara S.T., M.A.)
NIDN: 0324037702

Pembimbing


(Marlinda Vasty Overbeek, S.Kom, M.Kom)

NIDN: 0818038501

B. Ketua Program Studi Informatika,


(Dr. Eng. Niki Prastomo, S.T., M.Sc.)

NIDN: 0419128203

HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH MAHASISWA

Yang bertanda tangan di bawah ini:

Nama	:	Jezreel Kosasih
NIM	:	00000043909
Program Studi	:	Informatika
Jenjang	:	S1
Judul Karya Ilmiah	:	Deteksi dan Perbaikan Penulisan Kata Baku Bahasa Indonesia pada Berita Daring dengan Algoritma Levenshtein Distance

Menyatakan dengan sesungguhnya bahwa saya bersedia:

- Saya bersedia memberikan izin sepenuhnya kepada Universitas Multimedia Nusantara untuk mempublikasikan hasil karya ilmiah saya ke dalam repositori Knowledge Center sehingga dapat diakses oleh Sivitas Akademika UMN/Publik. Saya menyatakan bahwa karya ilmiah yang saya buat tidak mengandung data yang bersifat konfidensial. Saya tidak akan mencabut kembali izin yang telah saya berikan dengan alasan apapun.

Tangerang, 09 Juni 2024



(_____)

* Jika tidak bisa membuktikan LoA jurnal/HKI, saya bersedia mengizinkan penuh karya ilmiah saya untuk dipublikasikan ke KC UMN dan menjadi hak institusi UMN.

Halaman Persembahan / Motto

”A good name is to be more desired than great wealth, Favor is better than silver and gold.”

Proverbs 22:1 (NASB)

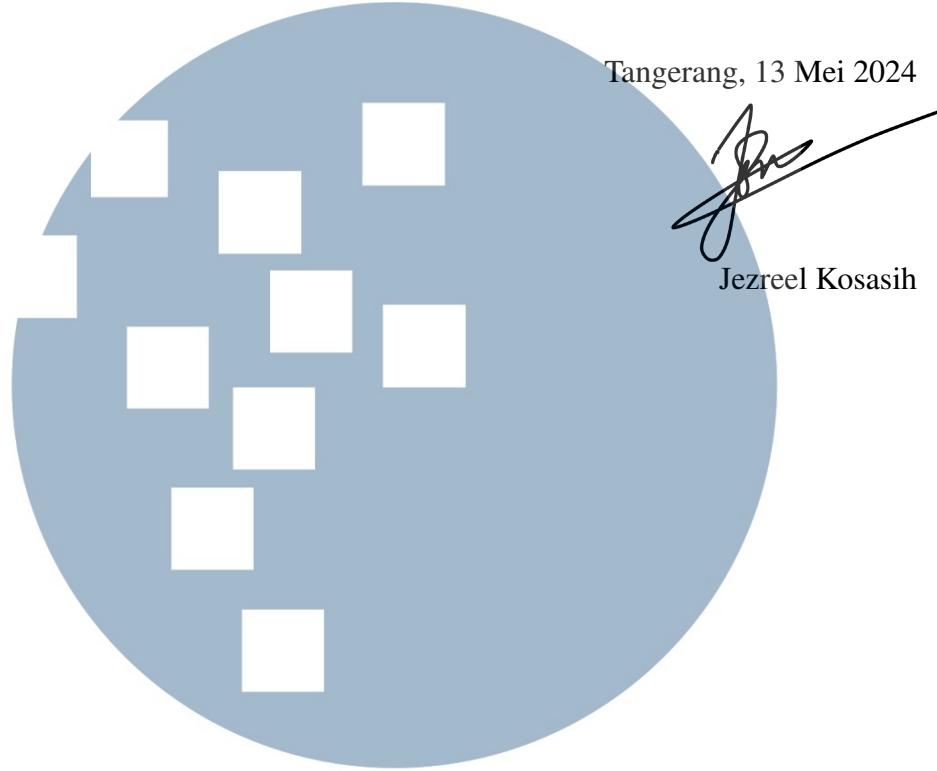


KATA PENGANTAR

Puji Syukur atas berkat dan rahmat kepada Tuhan Yang Maha Esa, atas selesainya penulisan laporan Skripsi ini dengan judul: Deteksi dan Perbaikan Penulisan Kata Baku Bahasa Indonesia pada Berita Daring dengan Algoritma Levenshtein Distance dilakukan untuk memenuhi salah satu syarat untuk mencapai gelar Sarjana Komputer Jurusan Informatika Pada Fakultas Teknik dan Informatika Universitas Multimedia Nusantara. Saya menyadari bahwa, tanpa bantuan dan bimbingan dari berbagai pihak, dari masa perkuliahan sampai pada penyusunan skripsi ini, sangatlah sulit bagi saya untuk menyelesaikan skripsi ini. Oleh karena itu, saya mengucapkan terima kasih kepada:

1. Bapak Dr. Ninok Leksono, selaku Rektor Universitas Multimedia Nusantara.
2. Bapak Dr. Eng. Niki Prastomo, S.T., M.Sc., selaku Dekan Fakultas Teknik dan Informatika Universitas Multimedia Nusantara.
3. Bapak Dr. Eng. Niki Prastomo, S.T., M.Sc., selaku Ketua Program Studi Informatika Universitas Multimedia Nusantara.
4. Bapak Marlinda Vasty Overbeek, S.Kom, M.Kom, sebagai Pembimbing pertama yang telah banyak meluangkan waktu untuk memberikan bimbingan, arahan dan motivasi atas terselesainya tesis ini.
5. Ibu Dr. Niknik Mediyawati,S.Pd,M.Hum, Bapak Bintang Samiaji Nusantara,S.T,M.A. sebagai Dosen yang telah banyak membantu dan memberikan bimbingan atas terselesainya Skripsi ini.
6. Orang Tua dan keluarga saya yang telah memberikan bantuan dukungan material dan moral, sehingga penulis dapat menyelesaikan Skripsi ini.
7. Teman-teman saya Brigitta Nissya, Jessica Sheridan, Reyhan Phillipies Wijaya, Indiana Jane, Cristophrous Tritama, Claudia Nicola, Charina Eliani, Clarissa Liani, Delicia Karen, dan Farion Wang yang telah mendukung dan menemani saya selama proses penyelesaian Skripsi ini
8. Teman-teman seperjuangan U-Tapis yaitu Vallencius Gavriel, Antonius Kevin B. S., Kevin Gleneagles, dan Jonathan Octavien yang telah belajar dan berjuang bersama selama proses penyelesaian Skripsi ini.

Semoga skripsi ini bermanfaat, baik sebagai sumber informasi maupun sumber inspirasi, bagi para pembaca.



Tangerang, 13 Mei 2024



Jezreel Kosasih

UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

**DETEKSI DAN PERBAIKAN PENULISAN KATA BAKU BAHASA
INDONESIA PADA BERITA DARING DENGAN ALGORITMA
LEVENSHTEIN DISTANCE**

Jezreel Kosasih

ABSTRAK

Penelitian deteksi dan perbaikan kesalahan kata baku didasari oleh kemajuan teknologi dan *artificial intelligence* serta masalah kesalahan yang umum terjadi dalam penulisan artikel jurnalistik akibat keterbatasan waktu dan banyaknya tuntutan kerja. Penelitian deteksi dan perbaikan kesalahan kata baku turut didasari oleh penelitian sebelumnya yaitu penelitian U-Tapis. Penelitian merupakan pengembangan penelitian U-Tapis untuk menciptakan sebuah aplikasi berbasis *machine learning* untuk melakukan deteksi dan perbaikan kesalahan kata atau tata kalimat dalam bahasa Indonesia. Penelitian menggunakan algoritma Levenshtein Distance sebagai algoritma utama untuk memproses *input* artikel. Algoritma ini akan mencocokan tiap karakter pada sebuah kata dan menghasilkan nilai *ratio* atau *similarity*. Penelitian menunjukkan keberhasilan dengan akurasi deteksi kata tidak baku hingga 100% dan F1 score mencapai 1.0. Penelitian terbukti efektif dalam mendeteksi kata tidak baku pada artikel berita dan mampu menggantikan kata tersebut dengan kata yang baku.

Kata kunci: Levenshtein Distance, *ratio*, U-Tapis, jurnalistik



DETECTION AND IMPROVEMENT OF INDONESIAN STANDARDIZED WORD WRITING IN ONLINE NEWS DRAFT WITH LEVENSHTEIN DISTANCE ALGORITHM

Jezreel Kosasih

ABSTRACT

The research on standardized word error detection and correction is based on technological advances and artificial intelligence as well as the problem of errors that are common in writing journalistic articles due to time constraints and work demands. The research on standardized word error detection and correction is also based on previous research, namely U-Tapis research. The research is a development of U-Tapis research to create a text-based application machine learning to detect and correct word or sentence errors in Indonesian. The research uses the Levenshtein Distance algorithm as the main algorithm for processing input articles. This algorithm will match each character in a word and produce a ratio or similarity value. The research shows success with the accuracy of nonstandard word detection up to 100% and F1 score reaching 1.0. The research proved to be effective in detecting nonstandard words in news articles and was able to replace the word with a standard word.

Kata kunci: *Levenshtein Distance, ratio, U-Tapis, journalistic*



DAFTAR ISI

HALAMAN JUDUL	i
PERNYATAAN TIDAK MELAKUKAN PLAGIAT	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iii
HALAMAN PERSETUJUAN PUBLIKASI ILMIAH	iv
HALAMAN PERSEMBAHAN/MOTO	v
KATA PENGANTAR	vi
ABSTRAK	viii
ABSTRACT	ix
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
DAFTAR KODE	xiv
DAFTAR LAMPIRAN	xv
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	4
1.6 Sistematika Penulisan	4
1.6.1 BAB 1 PENDAHULUAN	4
1.6.2 BAB 2 LANDASAN TEORI	4
1.6.3 BAB 3 METODOLOGI PENELITIAN	5
1.6.4 BAB 4 HASIL DAN DISKUSI	5
1.6.5 BAB 5 SIMPULAN DAN SARAN	5
BAB 2 LANDASAN TEORI	6
2.1 Bahasa Indonesia	6
2.2 Kata Baku	6
2.3 Natural Language Processing	7
2.4 Text Preprocessing	7
2.5 Levenshtein Distance	9
2.6 Pustaka FuzzyWuzzy	10
BAB 3 METODOLOGI PENELITIAN	15
3.1 Studi Literatur	17
3.2 Pengumpulan Data	17
3.3 <i>Pre-processing</i> Teks Berita Daring	18
3.4 Algoritma Levenshtein Distance	18
3.5 Implementasi Algoritma	21
3.6 Pengembangan Situs Web	21
3.7 Uji Coba dan Evaluasi	23
BAB 4 HASIL DAN DISKUSI	25
4.1 Spesifikasi Sistem	25
4.2 Dataset	25
4.2.1 Split Dataset	26
4.3 Pre-processing	27
4.4 Permodelan	28

4.4.1	Pencocokan string dengan algoritma Levenshtein Distance dari pustaka fuzzywuzzy	28
4.4.2	Proses menampilkan <i>output</i> program	30
4.4.3	Fitur tambahan	32
4.5	Aplikasi Web	32
4.6	Diagram Alir Aplikasi Web	35
4.7	Berkas Penyusun Aplikasi Web	38
4.7.1	Berkas program.py	38
4.7.2	Berkas template.html	41
4.8	Evaluasi Program	43
4.8.1	Akurasi	48
4.8.2	F1 Score	49
4.8.3	Mean Squared Error Score	50
BAB 5	SIMPULAN DAN SARAN	52
5.1	Simpulan	52
5.2	Saran	52
DAFTAR PUSTAKA	54



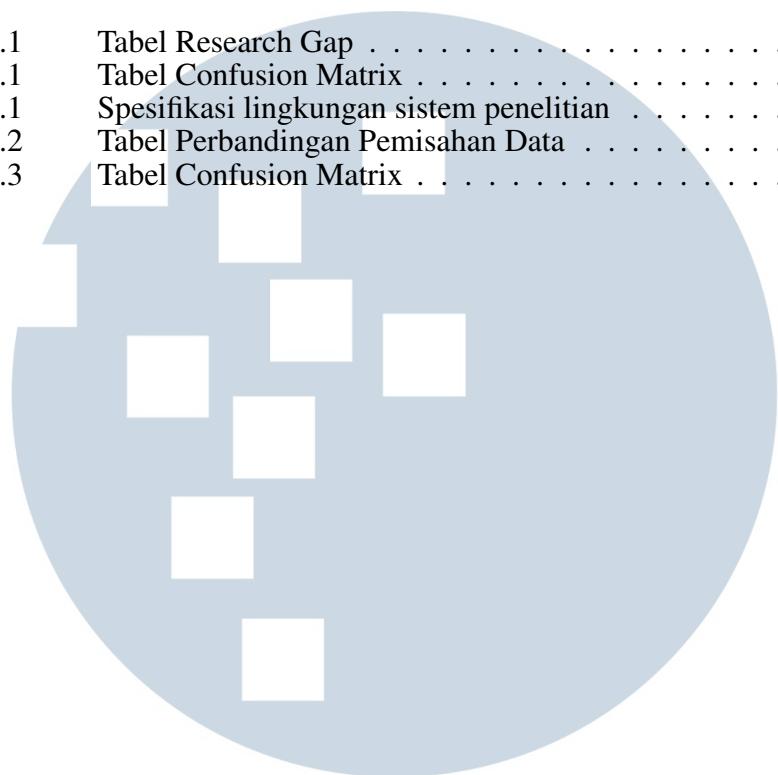
DAFTAR GAMBAR

Gambar 2.1	Hasil deteksi pada halaman situs penelitian U-Tapis kata baku	12
Gambar 2.2	Hasil deteksi pada halaman situs ejaan.id	12
Gambar 2.3	Hasil deteksi pada halaman situs typoonline	13
Gambar 2.4	Hasil deteksi pada halaman situs Gramatika	13
Gambar 2.5	Hasil deteksi pada halaman situs cek-ejaan.com	14
Gambar 3.1	Diagram metode penelitian	16
Gambar 3.2	Diagram End to End Process	17
Gambar 3.3	Proses <i>pre-processing</i> input teks berita	18
Gambar 3.4	Diagram alir Algoritma Levenshtein Distance	20
Gambar 3.5	Rancangan tampak halaman web untuk <i>input</i> teks	22
Gambar 3.6	Rancangan tampak halaman web untuk unggah berkas	22
Gambar 4.1	Tampak halaman web <i>input</i> teks	33
Gambar 4.2	Tampak halaman web unggah berkas	33
Gambar 4.3	<i>Output</i> dari <i>input</i> teks	34
Gambar 4.4	<i>Output</i> dari <i>input</i> berkas txt bagian 1	34
Gambar 4.5	<i>Output</i> dari <i>input</i> berkas txt bagian 2	34
Gambar 4.6	Diagram alir utama aplikasi web	35
Gambar 4.7	Diagram alir fungsi replaced_words_in_sentences	36
Gambar 4.8	Diagram alir fungsi suggest_correct_words	37
Gambar 4.9	Hasil evaluasi program menggunakan pustaka sklearn python	44
Gambar 4.10	Hasil 1 <i>false detection</i> pada program	44
Gambar 4.11	Hasil 2 <i>false detection</i> pada program	45
Gambar 4.12	Hasil 3 <i>false detection</i> pada program	45
Gambar 4.13	Hasil 4 <i>false detection</i> pada program	45
Gambar 4.14	Hasil benar 1 deteksi kata tidak baku pada program	46
Gambar 4.15	Hasil benar 2 deteksi kata tidak baku pada program	46
Gambar 4.16	Hasil benar 3 deteksi kata tidak baku pada program	46
Gambar 4.17	Hasil benar 4 deteksi kata tidak baku pada program	47
Gambar 4.18	Hasil benar 5 deteksi kata tidak baku pada program	47
Gambar 4.19	Hasil benar 6 deteksi kata tidak baku pada program	47
Gambar 4.20	Grafik Learning Curves Model	48
Gambar 4.21	Mean Squared Error dari Model Deteksi dan Koreksi Kata Baku	51

**UNIVERSITAS
MULTIMEDIA
NUSANTARA**

DAFTAR TABEL

Tabel 2.1	Tabel Research Gap	11
Tabel 3.1	Tabel Confusion Matrix	23
Tabel 4.1	Spesifikasi lingkungan sistem penelitian	25
Tabel 4.2	Tabel Perbandingan Pemisahan Data	26
Tabel 4.3	Tabel Confusion Matrix	48



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA

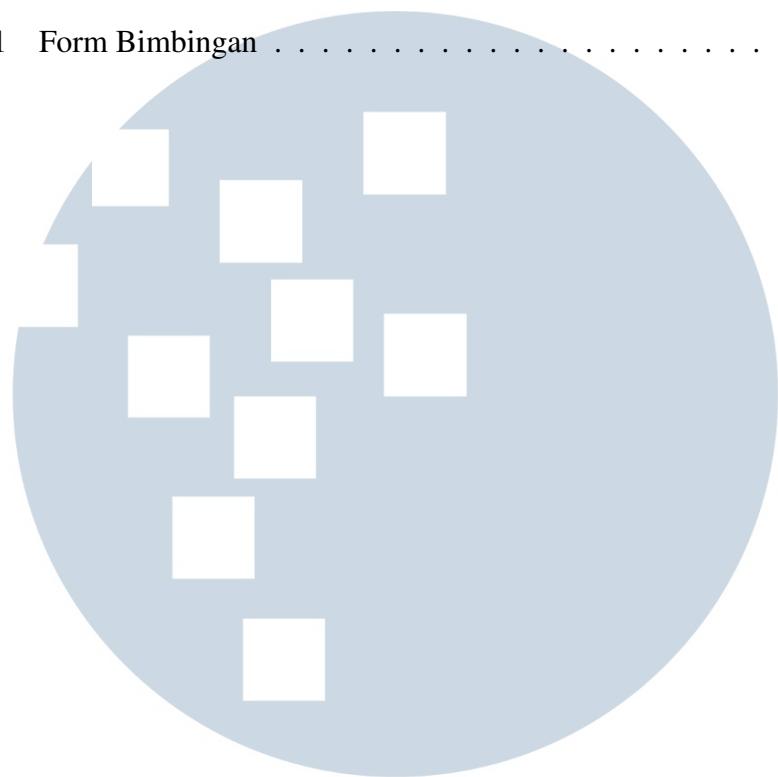
DAFTAR KODE

4.1	Proses <i>pre-processing</i> data <i>input</i> dari <i>user</i>	27
4.2	Fungsi ratio pada pustaka fuzzywuzzy	28
4.3	Fungsi ratio pada objek SequenceMatcher	29
4.4	Implementasi metode ratio pada program U-Tapis kata baku	30
4.5	Proses menampilkan output	30
4.6	Pendeteksian kutipan langsung	32
4.7	Fungsi replace_words_in_sentence	38
4.8	Fungsi suggest_correct_words	39
4.9	Potongan kode fungsi main untuk mengirimkan <i>output</i> ke tampilan web	40
4.10	potongan kode JavaScript pada berkas template.html	41



DAFTAR LAMPIRAN

Lampiran 1 Form Bimbingan	57
-------------------------------------	----



UMN
UNIVERSITAS
MULTIMEDIA
NUSANTARA