

**PERBANDINGAN AKURASI *WORD EMBEDDING WORD2VEC*,
GLOVE, DAN *FASTTEXT* MENGGUNAKAN *SUPPORT VECTOR
MACHINE* UNTUK ANALISIS SENTIMEN ULASAN APLIKASI
*SPOTIFY***

SKRIPSI



MARGARETHA ANJANI

NIM. 1910511108

PROGRAM STUDI INFORMATIKA

FAKULTAS ILMU KOMPUTER

UNIVERSITAS PEMBANGUNAN NASIONAL VETERAN JAKARTA

2023

**PERBANDINGAN AKURASI *WORD EMBEDDING WORD2VEC*,
GLOVE, DAN *FASTTEXT* MENGGUNAKAN *SUPPORT VECTOR
MACHINE* UNTUK ANALISIS SENTIMEN ULASAN APLIKASI
*SPOTIFY***

SKRIPSI

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana Komputer



MARGARETHA ANJANI

NIM. 1910511108

PROGRAM STUDI INFORMATIKA

FAKULTAS ILMU KOMPUTER

UNIVERSITAS PEMBANGUNAN NASIONAL VETERAN JAKARTA

2023

LEMBAR PERSETUJUAN

Yang bertanda tangan di bawah ini:

Nama : Margaretha Anjani
NIM. : 1910511108
Program Studi : Informatika/Sistem Informasi Program Sarjana/Diploma 3 (*Coret yang tidak perlu)
Judul Skripsi/TA. : Perbandingan Akurasi Word Embedding Word2Vec, GloVe, dan FastText Menggunakan Support Vector Machine Untuk Analisis Sentimen Ulasan Aplikasi Spotify

Dinyatakan telah memenuhi syarat dan menyetujui untuk mengikuti ujian sidang skripsi.

Jakarta, 19 Mei 2023

Mengetahui,
Ketua Program Studi,

Dr. Widya Cholil, M.I.T.

Menyetujui,
Dosen Pembimbing,

Helena Nurramdhani Irminda, S.Pd., M.Kom.

PERNYATAAN ORISINALITAS

Tugas akhir ini adalah hasil karya sendiri, dan semua sumber yang dikutip maupun yang dirujuk telah saya nyatakan dengan benar.

Nama : Margaretha Anjani

NIM : 1910511108

Tanggal : 05 Juni 2023

Bilamana dikemudian hari ditemukan ketidaksesuaian dengan pernyataan saya, maka saya bersedia di tuntut dan diproses sesuai dengan ketentuan yang berlaku.

Jakarta, 05 Juni 2023

Yang menyatakan,



(Margaretha Anjani)

PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS

Sebagai civitas akademis Universitas Pembangunan Nasional Veteran Jakarta,
saya yang bertanda tangan di bawah ini:

Nama : Margaretha Anjani

NIM : 1910511108

Fakultas : Ilmu Komputer

Program Studi : S-1 Informatika

Demi pembangunan ilmu pengetahuan, menyetujui untuk memberikan pelayanan kepada Universitas Pembangunan Nasional Veteran Jakarta Hak Bebas Royalti Non-ekslusif (Non-exclusive Royalty Free Right) atas karya ilmiah saya yang berjudul :

Perbandingan Akurasi Word Embedding Word2Vec, GloVe, Dan FastText

Menggunakan Support Vector Machine Untuk Analisis Sentimen Ulasan

Aplikasi Spotify

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalty ini Universitas Pembangunan Nasional Veteran Jakarta berhak menyimpan, mengalih media/formatkan, mengelola dalam bentuk pangkalan data (database), merawat, dan mempublikasikan Tugas Akhir saya selama mencantumkan nama saya sebagai *penulis/pencipta dan sebagai pemilik Hak Cipta*.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat : Jakarta

Pada tanggal : 05 Juni 2023

Yang menyatakan



(Margaretha Anjani)

LEMBAR PENGESAHAN

Yang bertanda tangan di bawah ini:

Nama : Margaretha Anjani
NIM : 1910511108
Program Studi : S-1 Informatika
Judul Skripsi/TA : Perbandingan Akurasi Word Embedding Word2Vec, GloVe, Dan FastText Menggunakan Support Vector Machine Untuk Analisis Sentimen Ulasan Aplikasi Spotify

Telah berhasil dipertahankan dihadapan Tim Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Sarjana Komputer pada Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional Veteran Jakarta.



(Dr. Bambang Saraswati, S.T., M.Kom)

Penguji 1


(Ati Zaidiah, S.Kom., MTI.)

Penguji 2


(Helena Nurramdhani Irmarda,

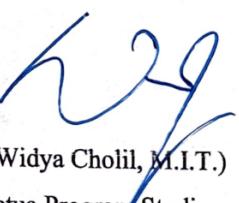
S.Pd., M.Kom.)

Pembimbing




(Dr. Ermatita, M.Kom.)

Dekan


(Dr. Widya Cholil, M.I.T.)

Ketua Program Studi

Ditetapkan di : Jakarta
Tanggal Ujian : 26 Mei 2023



Perbandingan Akurasi *Word Embedding Word2Vec, GloVe, dan FastText* Menggunakan
Support Vector Machine untuk Analisis Sentimen Ulasan Aplikasi Spotify

Margaretha Anjani

Program Studi Informatika, Fakultas Ilmu Komputer,
Universitas Pembangunan Nasional Veteran Jakarta

Email : margarethanjani@upnvj.ac.id

ABSTRAK

Spotify merupakan salah satu aplikasi yang digunakan sebagai platform layanan streaming audio digital yang menyajikan berbagai musik dan podcast dan dapat diunduh dengan gratis pada Google Play Store. Ulasan merupakan sebuah fitur Google Play Store yang dapat dimanfaatkan oleh pengguna untuk memberikan penilaian terhadap sebuah aplikasi. Ulasan yang dapat diterima oleh aplikasi dapat mempengaruhi pengguna yang akan mengunduh aplikasi tersebut. Karakteristik teks ulasan yang tidak terstruktur akan menjadi sebuah tantangan dalam proses pemrosesan teks. Untuk menghasilkan sentimen analisis yang valid dibutuhkan adanya penerapan *word embedding*. Data set yang dimiliki dibagi dengan perbandingan 80:20 untuk data training dan data testing. Metode yang digunakan untuk ekspansi fitur *Word2Vec, GloVe, dan FastText* dan metode yang digunakan dalam klasifikasi adalah *Support Vector Machine (SVM)*. Ketiga metode *word embedding* tersebut dipilih karena dapat menangkap makna yang semantik, sintatik, serta konteks pada sekitar kata bila dibandingkan *feature engineering* tradisional seperti *Bag of Word*. Hasil evaluasi performa terbaik menunjukkan model GloVe menghasilkan kinerja terbaik dibandingkan dengan word embedding lainnya dengan nilai akurasi sebesar 85%, nilai presisi sebesar 90%, nilai *recall* 79%, dan *f1-score* 85%.

Kata kunci: word2vec, glove, fasttext, support vector machine, klasifikasi, analisis sentimen.

Comparison Accuracy of Word Embedding Word2Vec, GloVe, dan FastText Using Support Vector Machine for Sentiment Analysis Spotify App Reviews

Margaretha Anjani

Program Studi Informatika, Fakultas Ilmu Komputer,
Universitas Pembangunan Nasional Veteran Jakarta

Email : margarethanjani@upnvj.ac.id

ABSTRACT

Spotify is an application that is used as a digital audio streaming service platform that presents a variety of music and podcasts and can be downloaded for free on the Google Play Store. Reviews are a feature of the Google Play Store that can be used by users to rate an application. The reviews that an app can receive may affect the users who will download the app. Characteristics of unstructured review texts will be a challenge in the text processing process. To produce a valid sentiment analysis, it is necessary to apply word embedding. The data set that is owned is divided by a ratio of 80:20 for training data and testing data. The method used for the expansion of the Word2Vec, GloVe, and FastText features and the method used in the classification is the Support Vector Machine (SVM). The three word embedding methods were chosen because they can capture the semantic, syntactic, and contextual meanings around words when compared to traditional engineering features such as Bag of Word. The best performance evaluation results show that the GloVe model produces the best performance compared to other word embeddings with an accuracy value of 85%, a precision value of 90%, a recall value of 79%, and an f1-score of 85%.

Keywords: word2vec, glove, fasttext, support vector machine, classification, sentiment analysis.

KATA PENGANTAR

Dengan mengucapkan syukur dan puji kehadirat Tuhan Yang Maha Esa yang telah memberikan rahmat, kesehatan, petunjuk, dan pertolongan, serta semua karunia-Nya, sehingga peneliti dapat menyelesaikan skripsi ini yang berjudul “Perbandingan Akurasi *Word Embedding Word2Vec, GloVe, FastText* Menggunakan *Support Vector Machine* Untuk Analisis Sentimen Ulasan Aplikasi Spotify”.

Skripsi ini disusun peneliti guna memenuhi salah satu syarat untuk memperoleh Gelar Sarjana pada Program Studi Informatika Fakultas Ilmu Komputer Universitas Pembangunan Nasional Veteran Jakarta. Pada penyusunan skripsi ini, peneliti memperoleh banyak dukungan serta bantuan dalam berbagai aspek baik spiritual, moral, dan material yang telah didapatkan peneliti selama proses skripsi sehingga akhirnya mampu menyelesaikan penelitian skripsi ini dengan baik dan lancar. Dengan rasa hormat, peneliti mengucapkan terima kasih kepada :

1. Ibu, Bapak, Kakak, dan seluruh keluarga peneliti yang telah senantiasa memberikan doa, dukungan, dan semangat sehingga peneliti dapat menyelesaikan penelitian dan skripsi.
2. Ibu Helena Nurramdhani Irmarda, S.Pd., M.Kom. sebagai dosen pembimbing yang telah senantiasa memberikan semangat dan membimbing serta memberi arahan untuk peneliti dalam proses menyusun skripsi.
3. Ibu Dr. Widya Cholil, M.I.T. sebagai Ketua Program Studi Informatika.
4. Ibu Dr. Ermatita, M.Kom. sebagai Dekan Fakultas Ilmu Komputer Universitas Pembangunan Nasional Veteran Jakarta.
5. Bapak/Ibu Dosen Fakultas Ilmu Komputer yang berdedikasi mengajar dan membagikan ilmu sehingga peneliti dapat memperluas wawasan serta ilmu pengetahuan selama berstatus menjadi mahasiswa di kawasan Fakultas Ilmu Komputer.
6. Sahabat-sahabat peneliti yang telah senantiasa mendukung, mengajak, dan mendoakan peneliti dalam melakukan penelitian dan penyusunan skripsi.
7. Teman-teman peneliti dan semua pihak lain yang tidak dapat disebutkan satu persatu atas semua kontribusi untuk peneliti dalam penelitian dan penyusunan skripsi baik secara langsung maupun tidak langsung.

Peneliti sangat menyadari masih terdapat banyak kekurangan dan kesalahan pada skripsi ini mengingat dengan keterbatasan pengetahuan dan kemampuan yang dimiliki oleh peneliti. Oleh karena itu, peneliti sangat mengharapkan skripsi ini dapat memberikan informasi dan pengetahuan yang berharga untuk pembaca.

Jakarta, 10 Mei 2023

Peneliti,

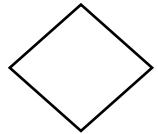
DAFTAR ISI

LEMBAR PERSETUJUAN	iii
PERNYATAAN ORISINALITAS	iv
PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK KEPENTINGAN AKADEMIS	v
LEMBAR PENGESAHAN	vi
ABSTRAK.....	vii
<i>ABSTRACT</i>	viii
KATA PENGANTAR	ix
DAFTAR ISI.....	xi
DAFTAR SIMBOL	xiv
DAFTAR GAMBAR	xv
DAFTAR TABEL.....	xvi
DAFTAR LAMPIRAN.....	xvii
BAB I	1
PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Ruang Lingkup Penelitian.....	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	6
1.6 Luaran yang Diharapkan.....	6
1.7 Sistematika Penelitian.....	6
BAB II.....	9
TINJAUAN PUSTAKA	9
2.1 Analisis Sentimen	9
2.2 Spotify.....	9
2.3 <i>Web Scraping</i>	10
2.4 <i>Text Mining</i>	10
2.5 <i>Text Preprocessing</i>	11
2.5.1 <i>Case Folding</i>	11
2.5.2 <i>Data Cleaning</i>	11
2.5.3 <i>Tokenizing</i>	11

2.5.4 <i>Normalization</i>	12
2.5.5 <i>Stopword Removal</i>	12
2.5.6 <i>Stemming</i>	12
2.6 <i>Word Embedding</i>	12
2.6.1 <i>Word2Vec</i>	13
2.6.2 <i>GloVe</i>	14
2.6.3 <i>FastText</i>	15
2.7 <i>Support Vector Machine</i>	16
2.7.1 SVM Linear	17
2.7.2 SVM Non-Linear	18
2.8 <i>Confusion Matrix</i>	19
2.9 Penelitian Terdahulu	21
BAB III	24
METODE PENELITIAN.....	24
3.1 Analisa dan Desain Tahapan Penelitian.....	24
3.2 Menentukan Topik.....	25
3.3 Identifikasi Masalah.....	26
3.4 Studi Pustaka.....	26
3.5 Pengumpulan Data dan <i>Labelling</i>	26
3.6 <i>Preprocessing</i>	27
3.6.1 <i>Case Folding</i>	28
3.6.2 <i>Data Cleaning</i>	29
3.6.3 <i>Tokenizing</i>	30
3.6.4 <i>Normalization</i>	32
3.6.5 <i>Stopword Removal</i>	33
3.6.6 <i>Stemming</i>	34
3.7 Ekstraksi Fitur.....	35
3.8 Klasifikasi Data.....	36
3.9 Pengujian Sistem.....	37
3.10 Perangkat yang Digunakan	37
3.11 Jadwal Penelitian	38
BAB IV	39
PEMBAHASAN	39
4.1 Pengumpulan Data dan <i>Labelling</i>	39
4.2 Preprocessing	41
4.2.1 <i>Case Folding</i>	42

4.2.2 <i>Data Cleaning</i>	43
4.2.3 <i>Tokenizing</i>	45
4.2.4 <i>Normalization</i>	46
4.2.5 <i>Stopword Removal</i>	48
4.2.6 <i>Stemming</i>	49
4.3 Pembagian Data	50
4.4 Ekstraksi Fitur.....	51
4.4.1 <i>Word2Vec</i>	52
4.4.2 <i>GloVe</i>	53
4.4.3 <i>FastText</i>	54
4.5 Klasifikasi	56
4.6 Evaluasi Klasifikasi Model	56
4.6.1 Evaluasi Klasifikasi Model Word2Vec.....	57
4.6.2 Evaluasi Klasifikasi Model GloVe	60
4.6.3 Evaluasi Klasifikasi Model FastText	62
4.6.4 Perbandingan Performa Klasifikasi Model Word Embedding.....	65
BAB V	70
PENUTUP	70
5.1 Kesimpulan	70
5.2 Saran	71
DAFTAR PUSTAKA	73
RIWAYAT HIDUP	76
LAMPIRAN.....	77

DAFTAR SIMBOL

No	Gambar	Nama	Keterangan
1		<i>Terminal (start, end)</i>	Menampilkan sebuah kegiatan dimulai atau kegiatan berakhir
2		<i>Flow direction</i>	Menampilkan alur dan arah sebuah proses
3		<i>Process</i>	Menampilkan sebuah proses yang dilakukan
4		<i>Data</i>	Menampilkan sebuah proses yang dilakukan memiliki data masukan (<i>input</i>) atau data keluaran (<i>output</i>)
5		<i>Decision</i>	Menampilkan sebuah proses yang memiliki kondisi yang harus memilih lebih dari satu proses

DAFTAR GAMBAR

Gambar 2.1 CBOW.....	13
Gambar 2.2 Skip-gram.....	14
Gambar 2.3 Arsitektur Model FastText	16
Gambar 2.4 Pemisah Hyperplane	17
Gambar 3.1 Tahapan Penelitian.....	24
Gambar 3.2 Pengumpulan Data & Labelling.....	26
Gambar 3.3 Tahapan Preprocessing	27
Gambar 3.4 Case Folding	28
Gambar 3.5 Data Cleaning.....	29
Gambar 3.6 Tokenizing	31
Gambar 3.7 Normalization.....	32
Gambar 3.8 Stopword Removal.....	33
Gambar 3.9 Stemming	35
Gambar 3.10 Tahapan Klasifikasi.....	36
Gambar 4.1 Hasil Scraping Data Ulasan Spotify	39
Gambar 4.2 Grafik Pelabelan Data Ulasan	41
Gambar 4.3 Hasil Case Folding	43
Gambar 4.4 Hasil Data Cleaning	45
Gambar 4.5 Hasil Tokenizing	46
Gambar 4.6 Hasil Normalization	47
Gambar 4.7 Hasil Stopword Removal	49
Gambar 4.8 Hasil Stemming	50
Gambar 4.9 Perbandingan Hasil Evaluasi Model dengan Data Testing.....	68
Gambar 4.10 Perbandingan Hasil Evaluasi Model dengan Data Training	69

DAFTAR TABEL

Tabel 2.1 Confusion Matrix	19
Tabel 2.2 Penelitian Terdahulu	21
Tabel 3.1 Perubahan Sebelum dan Sesudah Case Folding	28
Tabel 3.2 Perubahan Sebelum dan Sesudah Data Cleaning	30
Tabel 3.3 Perubahan Sebelum dan Sesudah Tokenizing	31
Tabel 3.4 Perubahan Sebelum dan Sesudah Normalization	32
Tabel 3.5 Perubahan Sebelum dan Sesudah Stopword Removal	34
Tabel 3.6 Perubahan Sebelum dan Sesudah Stemming	35
Tabel 3.7 Jadwal Penelitian	38
Tabel 4.1 Hasil Pelabelan Pada Sampel Data Ulasan	40
Tabel 4.2 Jumlah Pelabelan Pada Seluruh Data Ulasan	40
Tabel 4.3 Sebelum dan Sesudah Case Folding	42
Tabel 4.4 Sebelum dan Sesudah Data Cleaning	43
Tabel 4.5 Sebelum dan Sesudah Tokenizing	45
Tabel 4.6 Sebelum dan Sesudah Normalization	46
Tabel 4.7 Sebelum dan Sesudah Stopword Removal	48
Tabel 4.8 Sebelum dan Sesudah Stemming	49
Tabel 4.9 Pembagian Data Testing dan Data Training	51
Tabel 4.10 Nilai Vector Hasil Model Word2Vec	53
Tabel 4.11 Nilai Vector Hasil Model GloVe	54
Tabel 4.12 Nilai Vector Hasil Model FastText.....	55
Tabel 4.13 Hasil Nilai Akurasi	56
Tabel 4.14 Confusion Matrix Klasifikasi Model Word2Vec dengan Data Testing	57
Tabel 4.15 Confusion Matrix Klasifikasi Model Word2Vec dengan Data Training.....	58
Tabel 4.16 Confusion Matrix Klasifikasi Model GloVe dengan Data Testing	60
Tabel 4.17 Confusion Matrix Klasifikasi Model GloVe dengan Data Training.....	61
Tabel 4.18 Confusion Matrix Klasifikasi Model FastText dengan Data Testing	63
Tabel 4.19 Confusion Matrix Klasifikasi Model FastText dengan Data Training	64
Tabel 4.20 Perbandingan Performa Model Word Embedding.....	66

DAFTAR LAMPIRAN

Lampiran 1. Kamus Normalization.....	77
Lampiran 2. Daftar Stopword	85
Lampiran 3. Source Code	87
Lampiran 4. Uji Turnitin.....	94