

**PERBANDINGAN EKSTRAKSI FITUR *TF-IDF* DAN  
*WORD2VEC* PADA ANALISIS SENTIMEN KUISIONER  
EVALUASI DOSEN MENGGUNAKAN *LOGISTIC  
REGRESSION***

**TUGAS AKHIR**

**Oleh:**

**ARYO PRATAMA GINANTAKA**

**NIM.1910817310012**



**PROGRAM STUDI TEKNOLOGI INFORMASI**

**FAKULTAS TEKNIK**

**UNIVERSITAS LAMBUNG MANGKURAT**

**BANJARMASIN**

**2024**

**PERBANDINGAN EKSTRAKSI FITUR *TF-IDF* DAN  
*WORD2VEC* PADA ANALISIS SENTIMEN KUISIONER  
EVALUASI DOSEN MENGGUNAKAN *LOGISTIC  
REGRESSION***

**TUGAS AKHIR**

Diajukan untuk Memenuhi Salah Salah Satu Syarat  
Sarjana Strata-1 Teknologi Informasi

**Oleh:**

**ARYO PRATAMA GINANTAKA**

**NIM.1910817310012**



**PROGRAM STUDI TEKNOLOGI INFORMASI**

**FAKULTAS TEKNIK**

**UNIVERSITAS LAMBUNG MANGKURAT**

**BANJARMASIN**

**2024**

## **LEMBAR PERNYATAAN**

Saya yang bertanda tangan di bawah ini,

Nama : Aryo Pratama Ginantaka  
NIM : 1910817310012  
Fakultas : Teknik  
Program Studi : Teknologi Informasi  
Judul Tugas Akhir : Perbandingan Ekstraksi Fitur TF-IDF dan Word2Vec Pada Analisis Sentimen Kuisioner Evaluasi Dosen Menggunakan Logistic Regression  
Dosen Pembimbing : Nurul Fathanah Mustamin, S.Pd., M.T

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar akademik di suatu perguruan tinggi, dan sepanjang pengetahuan saya, juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar rujukan.

Banjarmasin, Desember 2023

Aryo Pratama Ginantaka  
NIM.1910817310012

# LEMBAR PENGESAHAN

## LEMBAR PENGESAHAN SKRIPSI PROGRAM STUDI S-1 TEKNOLOGI INFORMASI

Perbandingan Ekstraksi Fitur *TF-IDF* dan

*Word2Vec* Pada Analisis Sentimen Kuisisioner

Evaluasi Dosen Menggunakan *Logistic Regression*

oleh

Aryo Pratama Ginantaka (1910817310012)

Telah dipertahankan di depan Tim Penguji pada 3 Januari 2024 dan  
dinyatakan

LULUS

**Komite Penguji :**

**Ketua** : Muti'a Maulida, S.Kom., M.T.I  
NIP 198810272019032013

**Anggota 1** : Andreyan Rizky Baskara, S.Kom., M.Kom  
NIP 199307032019031011

**Anggota 2** : Dr. Ir. Yuslena Sari, S.Kom., M.Kom  
NIP 198411202015042002

**Pembimbing** : Nurul Fathanah Mustamin, S.Pd., MT  
**Utama** NIP 199110252019032018

12 JAN 2024

Banjarbaru,

diketahui dan disahkan oleh:

**Wakil Dekan Bidang**



**Koordinator Program Studi**  
**S-1 Teknologi Informasi.**

**Andreyan Rizky Baskara, S.Kom., M.Kom**  
NIP 199307032019031011

## **PERSETUJUAN TUGAS AKHIR**

### **PERSETUJUAN TUGAS AKHIR**

**PERBANDINGAN EKSTRAKSI FITUR TF-IDF DAN WORD2VEC PADA  
ANALISIS SENTIMEN KUISIONER EVALUASI DOSEN MENGGUNAKAN  
LOGISTIC REGRESSION**

**OLEH**  
**ARYO PRATAMA GINANTAKA**  
**NIM. 1910817310012**

Telah diperiksa dan terpenuhi semua persyaratan akademik, administrasi dan disetujui  
untuk dipertahankan di hadapan dewan pengaji

Banjarmasin, 15 Desember 2023

Pembimbing utama,  
  
Nurul Fathanah Mustamin, S.Pd., M.T.  
NIP. 199110252019032018

## **ABSTRAK**

Dosen memegang peranan krusial dalam membentuk lingkungan belajar. Oleh karena itu, evaluasi dosen menjadi aspek penting dalam upaya meningkatkan kualitas kampus. Data dari kolom kritik dan saran pada kuisioner evaluasi dosen dapat dilakukan analisis sentimen untuk mengetahui teks tersebut memiliki nilai positif atau negatif. Analisis sentimen adalah teknik dalam pemrosesan bahasa alami yang bertujuan untuk mengidentifikasi dan mengekstrak sentimen atau opini dari teks. Sentimen termasuk jenis data teks tidak terstruktur, sehingga untuk dapat diproses, teks tersebut harus diubah men-jadi data terstruktur dengan proses ekstraksi fitur. Ekstraksi fitur yang umum digunakan adalah TF-IDF dan Word2Vec. Penelitian ini bertujuan untuk membandingkan metode ekstraksi fitur, yaitu TF-IDF dan Word2Vec menggunakan metode Logistic Regression. Dataset yang digunakan adalah kolom kritik dan saran dari kuisioner evaluasi dosen sebanyak 2000 data yang terbagi menjadi kelas positif dan negatif. Penelitian ini melakukan uji coba dengan rasio pembagian data 70%, 80%, 90%, 100% sebagai data latih dan 30%, 20%, 10%, 20 data uji. Pada data latih diterapkan SMOTE untuk menangani ketidakseimbangan kelas. Kemudian dilakukan klasifikasi dengan metode Logistic Regression. Hasil dari penelitian ini yaitu ekstraksi fitur TF-IDF tanpa menggunakan stopword menunjukkan kinerja yang sangat baik dengan accuracy 98%, 99%, 98% dan 90%. Sedangkan ekstraksi fitur Word2Vec tanpa stopword mendapatkan nilai akurasi yang lebih rendah yaitu 87%, 89%, 90%, dan 90%.

**Kata Kunci :** Analisis Sentimen, Evaluasi Dosen, TF-IDF, Word2Vec, *Logistic Regression*

## ***ABSTRACT***

*Lecturers play a crucial role in shaping the learning environment. Therefore, evaluating lecturers is an essential aspect of efforts to improve campus quality. Data from the critique and suggestion columns in lecturer evaluation questionnaires can undergo sentiment analysis to determine whether the text has a positive or negative value. Sentiment analysis is a natural language processing technique aimed at identifying and extracting sentiment or opinions from text. Sentiment is a type of unstructured text data, so to process it, the text must be transformed into structured data through the feature extraction process. Commonly used feature extraction methods include TF-IDF and Word2Vec. This study aims to compare feature extraction methods, namely TF-IDF and Word2Vec, using the Logistic Regression method. The dataset used consists of 2000 data points from the critique and suggestion columns in lecturer evaluation questionnaires, divided into positive and negative classes. The study conducts experiments with data splitting ratios of 70%, 80%, 90%, 100% for training data and 30%, 20%, 10%, 20 data points for testing. The training data is subjected to SMOTE to address class imbalance. Classification is then performed using the Logistic Regression method. The results of this study show that TF-IDF feature extraction without using stop words exhibits excellent performance with accuracies of 98%, 99%, 98%, and 90%. In contrast, Word2Vec feature extraction without stop words yields lower accuracy values of 87%, 89%, 90%, and 90%.*

***Keywords:*** *Sentiment Analysis, Lecturer Evaluation, TF-IDF, Word2Vec, Logistic Regression*

## **KATA PENGANTAR**

Dengan mengucapkan puji dan syukur atas kehadirat Tuhan Yang Maha Esa. Yang telah melimpahkan anugerah-Nya sehingga penulis dapat menyelesaikan Tugas Akhir ini dengan judul “Perbandingan Ekstraksi Fitur TF-IDF dan Word2Vec Pada Analisis Sentimen Kuisioner Evaluasi Dosen Menggunakan Logistic Regression” dengan baik. Tugas akhir ini merupakan salah satu syarat kelulusan untuk memperoleh gelar Sarjana Strata-1 pada Program Studi Teknologi Informasi Fakultas Teknik Universitas Lambung Mangkurat (ULM) Banjarmasin.

Selama berlangsungnya penulisan ini, penulis mendapatkan banyak arahan bantuan, binaan, saran dan kritik sehingga penyusunan laporan ini telah sampai ke tahap penyelesaian. Penulis sangat bersyukur dan mengucapkan banyak terima kasih kepada semua pihak yang telah membantu, terutama kepada:

1. Orang tua dan keluarga di rumah yang telah memberikan motivasi dan turut membantu demi kelancaran penyelesaian Tugas Akhir ini.
2. Dosen Pembimbing Utama, Nurul Fathanah Mustamin, S.Pd., M.T,yang telah memberikan waktu, bimbingan dan arahan dalam proses penyelesaian dan penulisan laporan Tugas Akhir ini.
3. Dosen-dosen beserta staf di program Studi Teknologi Informasi yang telah mengarahkan dan teman-teman yang membantu dalam proses penyelesaian Tugas Akhir ini.
4. Teman seperjuangan dari masa perkuliahan sampai Tugas Akhir ini dan seluruh teman-teman angkatan 2019 Program Studi Teknologi Informasi.

Akhir kata, penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah turut serta membantu dalam penyelesaian program dan penulisan laporan ini yang tidak bisa disebutkan satu per satu. Harapan yang paling besar dari penyusunan laporan ini adalah agar bermanfaat untuk banyak orang, baik untuk pribadi, teman-teman, serta pembaca. Penulis juga mengharapkan

saran dan kritik demi perbaikan dan penyempurnaan laporan ini. Semoga laporan ini dapat bermanfaat bagi para pembaca dan semua pihak yang membutuhkan.

Banjarmasin, Desember 2023  
Penulis,

Aryo Pratama Ginantaka

## DAFTAR ISI

HALAMAN SAMPUL LUAR.....	i
HALAMAN SAMPUL DALAM.....	ii
LEMBAR PERNYATAAN .....	iii
LEMBAR PENGESAHAN .....	iv
PERSETUJUAN TUGAS AKHIR .....	v
ABSTRAK.....	vi
<i>ABSTRACT</i> .....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI .....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR .....	xiv
DAFTAR LAMPIRAN .....	xv
DAFTAR RIWAYAT HIDUP .....	xvi
BAB I PENDAHULUAN .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
BAB II TINJAUAN PUSTAKA .....	5
2.1 Landasan Teori .....	5
2.1.1 Kuisioner Evaluasi Dosen .....	5
2.1.2 Analisis Sentimen.....	5
2.1.3 Data Mining.....	6
2.1.4 Text Preprocessing.....	6
2.1.5 TF-IDF .....	7
2.1.6 Word2Vec .....	8
2.1.7 <i>Synthetic Minority Over-sampling Technique</i> (SMOTE).....	9
2.1.8 Logistic Regression .....	10
2.1.9 Confusion Matrix .....	12

2.2 Penelitian Terkait.....	14
2.2.1 Analisis Perbandingan Pembobotan TF-IDF Dan TF-RF Pada Trending Topic Di Twitter Dengan Menggunakan Klasifikasi K-Nearest Neighbor .....	14
2.2.2 Analisis Sentimen Twitter Bahasa Indonesia dengan Word2Vec .....	14
2.2.3 Perbandingan Model Pembobotan TF-IDF Dan Word2Vec Pada Klasifikasi Analisis Sentimen Perpindahan Ibukota Indonesia Dengan Metode <i>Xtreme Gradient Boosting</i> .....	15
2.2.4 Analisis Sentimen Pengguna Twitter Terhadap Kenaikan Harga Bahan Bakar Minyak (BBM) Menggunakan Metode <i>Logistic Regression</i> .....	15
2.2.5 Analisis Sentimen Evaluasi Pembelajaran Tatap Muka 100 Persen pada Pengguna Twitter menggunakan Metode Logistic Regression .....	16
2.3 Kerangka Pemikiran .....	18
BAB III METODOLOGI PENELITIAN.....	19
3.1 Alat dan Bahan .....	19
3.2 Alur Penelitian .....	20
3.2.1 Identifikasi Masalah .....	20
3.2.2 Studi Literatur.....	20
3.2.3 Pengumpulan Data .....	20
3.2.4 Melakukan Eksperimen .....	21
3.2.5 Evaluasi .....	29
3.2.6 Implementasi .....	29
BAB IV HASIL DAN PEMBAHASAN.....	30
4.1 Hasil.....	30
4.1.1 Pengumpulan Data .....	30
4.1.2 Pelabelan Data.....	30
4.1.3 Preprocessing Data .....	33
4.1.4 Pembagian Data.....	36
4.1.5 TF-IDF.....	36
4.1.6 Word2Vec .....	38
4.1.7 <i>Synthetic Minority Over-sampling Technique</i> (SMOTE) .....	39
4.1.8 Logistic Regression .....	41
4.1.9 Evaluasi .....	46
4.1.10 Implementasi Sistem .....	53
4.2 Pembahasan .....	54

BAB V KESIMPULAN .....	56
5.1 Kesimpulan.....	56
5.2 Saran .....	56
DAFTAR PUSTAKA .....	57

## DAFTAR TABEL

Tabel 1.1 Penelitian Poornima dan Sathiya.....	3
Tabel 1.2 Penelitian Aloysius.....	3
Tabel 2.1 Penelitian Terkait.....	17
Tabel 3.1 Contoh Komentar .....	22
Tabel 3.2 Hasil Cleaning .....	23
Tabel 3.3 Hasil Case Folding .....	24
Tabel 3.4 Hasil Tokenization.....	24
Tabel 3.5 Hasil Stopword.....	25
Tabel 3.6 Hasil Stemming.....	25
Tabel 3.7 Contoh Pengujian Confusion Matrix.....	27
Tabel 4.1 Acuan Pelabelan .....	32
Tabel 4.2 Hasil Cleaning .....	33
Tabel 4.3 Hasil Case Folding .....	34
Tabel 4.4 Hasil Tokenization.....	34
Tabel 4.5 Hasil Stopword.....	35
Tabel 4.6 Hasil Stemming.....	36
Tabel 4.7 Hasil TF-IDF .....	37
Tabel 4.8 Hasil SMOTE.....	40
Tabel 4.9 Parameter Logistic Regression.....	41
Tabel 4.10 Hasil Prediksi Logistic Regression dengan TF-IDF DS.....	42
Tabel 4.11 Hasil Prediksi Logistic Regression + TF-IDF TS .....	43
Tabel 4.12 Hasil Prediksi Logistic Regression + W2V DS.....	44
Tabel 4.13 Hasil Prediksi Logistic Regression + W2V TS .....	45
Tabel 4.14 Confusion Matix TF-IDF dengan Stopword .....	46
Tabel 4.15 Classification Report TF-IDF dengan Stopword.....	47
Tabel 4.16 Confusion Matrix TF-IDF tanpa Stopword.....	48
Tabel 4.17 Classification Report TF-IDF tanpa Stopword .....	48
Tabel 4.18 Confusion Matrix W2V dengan Stopword.....	49
Tabel 4.19 Classification Report W2V dengan Stopword .....	50
Tabel 4.20 Confusion Matrix W2V tanpa Stopword.....	50
Tabel 4.21 Classification Report W2V tanpa Stopword .....	51

## **DAFTAR GAMBAR**

Gambar 2.1 Arsitektur CBOW.....	8
Gambar 2.2 Arsitektur Skip Gram .....	9
Gambar 2.3 Fungsi Logistik .....	12
Gambar 2.4 Confusion Matrix [18].....	12
Gambar 2.5 Kerangka Pemikiran.....	18
Gambar 3.1 Alur Penelitian.....	20
Gambar 3.2 Tahap Penelitian .....	21
Gambar 4.1 Data Kuisisioner Evaluasi Dosen .....	30
Gambar 4.2 Implementasi Pelabelan Otomatis.....	31
Gambar 4.3 Hasil Pelabelan Data Otomatis.....	31
Gambar 4.4 Hasil Pemilihan Data.....	32
Gambar 4.5 Jumlah Data Perkelas .....	32
Gambar 4.6 Hasil Prediksi Logistic Regression + TF-IDF DS.....	42
Gambar 4.7 Hasil Prediksi Logistic Regression + TF-IDF TS .....	43
Gambar 4.8 Hasil Prediksi Logistic Regression + W2V DS.....	44
Gambar 4.9 Hasil Prediksi Logistic Regression + W2V TS .....	45
Gambar 4.10 Halaman Input Teks .....	53
Gambar 4.11 Halaman Hasil Prediksi.....	53
Gambar 4.12 Perbandingan Akurasi Model.....	54

## **DAFTAR LAMPIRAN**

Lampiran 1. Source Code Google Collaboratory.....	60
Lampiran 2. Source Code Implementasi Sistem.....	63
Lampiran 3. Hasil Prediksi Logistic Regression.....	68
Lampiran 4. Lembar Konsultasi.....	74
Lampiran 5. Surat Permohonan Data.....	75