

**PERBANDINGAN PERFORMA LABELING LEXICON INSET DAN
LEXICON VADER PADA ANALISA SENTIMEN ROHINGYA DI
APLIKASI X DENGAN SUPPORT VECTOR MACHINE**

SKRIPSI



Oleh :

MUHAMMAD FERNANDA NAUFAL FATHONI

20081010257

**PROGRAM STUDI INFORMATIKA
FAKULTAS ILMU KOMPUTER
UNIVERSITAS PEMBANGUNAN NASIONAL “VETERAN” JAWA
TIMUR
2024**

LEMBAR PENGESAHAN

SKRIPSI

Judul : PERBANDINGAN PERFORMA LABELING LEXICON INSET DAN LEXICON VADER PADA ANALISA SENTIMEN ROHINGYA DI APLIKASI X DENGAN SUPPORT VECTOR MACHINE

Oleh : MUHAMMAD FERNANDA NAUFAL FATHONI

NPM : 20081010257

Telah Diseminarkan Dalam Ujian Skripsi Pada:

Hari Selasa, Tanggal 22 Mei 2024

Mengetahui

Dosen Pembimbing

1.

Eva Yulia Puspaningrum, S.Kom, M.Kom.
NIP. 19890705 2021212 002

2.

Andreas Nugroho Sihananto, S.Kom, M.Kom.
NPT. 211199 00 412271

Dosen Pengaji

1.

Dr. Rr. Ani Dijah Rahajoe, ST., M.Cs.
NIP. 19730512 200501 2003

2.

Afina Lina Nurlaili, S.Kom, M.Kom.
NIP.1993121 3202203 2010

Menyetujui



Prof. Dr. Ir. Novirina Hendrasarie, MT.
NIP. 19681126 199403 2 001

Koordinator Program Studi

Informatika

Fetty Tri Anggraeny, S.Kom, M.Kom.
NIP. 19820211 2021212 005

SURAT PERNYATAAN BEBAS DARI PLAGIASI

Saya, mahasiswa Program Studi Sarjana Informatika Universitas Pembangunan Nasional “Veteran” Jawa Timur, yang bertanda tangan di bawah ini:

Nama : Muhammad Fernanda Naufal Fathoni

NPM : 20081010257

Menyatakan dengan sesungguhnya bahwa Skripsi/Tugas Akhir yang saya kerjakan berjudul:

“Perbandingan Performa Labeling *Lexicon* Inset dan *Lexicon* Vader pada Analisa Sentimen
Rohingya di Aplikasi X dengan *Support Vector Machine*”

bukan merupakan plagiasi sebagian atau keseluruhan dari Skripsi/Tugas Akhir/Penelitian orang lain dari juga bukan merupakan produk dan software yang saya beli dari pihak lain. Saya juga menyatakan bahwa Skripsi/Tugas Akhir ini secara keseluruhan adalah pekerjaan Saya sendiri, kecuali yang dinyatakan dalam Daftar Pustaka dan tidak pernah diajukan untuk syarat memperoleh gelar di Universitas Pembangunan Nasional “Veteran” Jawa Timur maupun di Institut Pendidikan lain. Bukti hasil pengecekan plagiasi dokumen ini dapat ditelusuri melalui QR Code di bawah.

Apabila di kemudian hari terbukti bahwa dokumen ini merupakan plagiasi karya orang lain, saya sanggup menerima sanksi sesuai aturan yang berlaku.

Demikian atas perhatiannya disampaikan terima kasih.

QR



Surabaya, 2 Juni 2024

Hormat saya,



Muhammad Fernanda Naufal Fathoni

NPM. 20081010257

PERBANDINGAN PERFORMA LABELING LEXICON INSET DAN LEXICON VADER PADA ANALISA SENTIMEN ROHINGYA DI APLIKASI X DENGAN SUPPORT VECTOR MACHINE

Nama Mahasiswa : Muhammad Fernanda Naufal Fathoni
NPM : 20081010257
Program Studi : Teknik Informatika
Dosen Pembimbing : 1. Eva Yulia Puspaningrum, S.Kom, M.Kom
2. Andreas Nugroho Sihananto, S.Kom., M.Kom.

Abstrak

Masuknya Rohingya di Indonesia menjadi bahan perbincangan di sosial media. Salah satu cara untuk melihat bagaimana respon masyarakat terhadap hal tersebut dibutuhkan analisa sentimen. Banyaknya data menjadikan masalah efisiensi waktu dalam proses pelabelan, maka dari itu dibutuhkannya kamus *lexicon* untuk proses pelabelan tersebut. Kamus *lexicon* merupakan adalah suatu kamus yang berisikan data kata dengan nilai atau bobot kata yang kemudian dikalkulasikan untuk menentukan suatu sentimen sebuah kalimat. Adanya *lexicon* membuat proses pelabelan data training jadi lebih cepat sehingga mempermudah proses pengolahan data. Di era saat ini data yang berkembang dan beredar sangat pesat sehingga dibutuhkan waktu yang cepat dan efisien. Meskipun cepat dan mempermudah dalam penyelesaian masalah masih perlu dipertanyakan akurasi yang dihasilkan apabila menggunakan pelabelan *lexicon* tersebut.

Dilakukan perbandingan proses pelabelan antara *lexicon* InSet dan *lexicon* VADER untuk mengetahui akurasi dari pelabelan tersebut. Hal itu dilakukan kombinasi *lexicon* dengan machine learning metode support vector machine dan pembobotan TF-IDF. Hasil yang didapatkan akan dievaluasi kinerjanya dengan menggunakan confusion matrix dan dilakukan perhitungan akurasi dari hasil tersebut.

Data yang didapatkan dari sosial media X sebanyak 9117 baris dan pada saat dilabeli dengan *lexicon* InSet menghasilkan 5241 sentimen negatif, 1369 sentimen positif, dan 521 sentimen netral. Lalu hasil pelabelan dengan *lexicon* VADER menghasilkan 2749 sentimen positif, 2523 sentimen negatif, dan 1881 sentimen netral. Setelah diberikan label dilakukan

pembobotan lalu diproses dengan SVM dan dihitung *confusion* matrixnya dengan hasil akurasi InSet *lexicon* memiliki rata rata sebesar 85,8% sedangkan lexicon VADER SVM memiliki rata rata 82,65%

Kata Kunci : Lexicon, InSet, VADER, TF-IDF, SVM

KATA PENGANTAR

Alhamdulillahirobilalamin, Segala puji Bagi Allah Tuhan yang Maha Esa, Maha Pengasih dan Penyayang yang telah memberikan rahmat serta petunjuk sehingga skripsi ini dapat terselesaikan. Skripsi yang berjudul “PERBANDINGAN PERFORMA LABELING LEXICON INSET DAN LEXICON VADER PADA ANALISA SENTIMEN ROHINGYA DI APLIKASI X DENGAN SUPPORT VECTOR MACHINE” adalah skripsi yang ditulis berdasarkan ketertarikan penulis sejak belajar mengenai pengolahan data sehingga penulis tertarik mengambil judul yang berkaitan terkait data mining. Pada waktu itu berita mengenai pengungsi rohingya yang tiba di aceh dan sempat menjadi trending topik di sosial media X menjadikan penulis tertarik mengambil data tersebut untuk diteliti.

Ucapan terima kasih tak terhingga saya haturkan kepada Dosen Pembimbing 1 ibu Eva Yulia Puspaningrum yang telah membantu serta meluangkan waktu dalam mengarahkan serta memberikan nasihat kepada penulis dalam penyusunan hingga skripsi ini dapat terselesaikan dengan baik. Ucapan terima kasih juga dihaturkan kepada dosen Pembimbing 2 bapak Andreas Nugroho Sihananto yang sudah meluangkan waktunya untuk diskusi terkait penelitian tersebut sehingga penulis tidak tersesat dijalan.

Dalam prosesnya penulis juga mengucapkan terima kasih atas bantuan dari berbagai pihak lainnya. Maka dari itu penulis mengucapkan terima kasih kepada berbagai pihak sebagai berikut :

1. Kedua orang tua yang telah membantu dalam proses belajar selama ini
2. Bapak Ibu dosen prodi Informatika Fakultas Ilmu Komputer Universitas Pembangunan Nasional Veteran Jawa Timur
3. Para jajaran staff Universitas Pembangunan Nasional Veteran Jawa Timur yang turut membantu dalam proses belajar selama ini
4. Universitas Pembangunan Nasional Veteran Jawa Timur sebagai kampus yang memberikan wadah untuk belajar
5. Teman teman angkatan 20 informatika universitas pembangunan nasional veteran jawa timur
6. Freedive malang sebagai wadah dalam menyalurkan stress selama pengajaran berlangsung
7. Galuh Alfisyah mahasiswa matematika universitas negeri surabaya telah membantu dan mensupport penuh dalam penulisan ini.

8. Lintang sebagai teman selama perkuliahan dan diskusi selama penelitian berlangsung.
9. Saudara yang telah membantu support dan doa
10. Semua pihak yang belum disebutkan membantu dalam penggerjaan dan proses penggerjaan selama ini.

Sebagai penutup, penulis mengharapkan tulisan ini menjadi nilai manfaat dan pahala jariyah bagi penulis dan menambah wawasan serta pengetahuan bagi pembacanya. Penulis menyadari bahwa tulisan ini masih jauh dari kata sempurna sehingga penulis terbuka menerima kritik dan saran sebagai sarana evaluasi penulis kedepannya.

Surabaya,

Penulis

Muhammad Fernanda Naufal Fathoni

NPM. 20081010257

DAFTAR ISI

LEMBAR PENGESAHAN	ii
KATA PENGANTAR.....	v
DAFTAR ISI.....	vii
DAFTAR TABEL	x
DAFTAR GAMBAR.....	xii
DAFTAR KODE PROGRAM.....	xiii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	3
1.3. Tujuan.....	3
1.4. Manfaat.....	3
1.5. Batasan Masalah.....	4
BAB II TINJAUAN PUSTAKA	5
2.1 Penelitian Sebelumnya	5
2.2 Rohingya	5
2.3 Aplikasi X	6
2.4 Analisa Sentimen.....	7
2.3.1 Lexicon Based.....	8
2.3.2 Lexicon InSet.....	9
2.3.3 <i>Lexicon VADER</i>	10
2.5 Machine Learning	11
2.6 Text Preprocessing	11
2.7 TF-IDF (Term Frequency Inverse Document Frequency)	12
2.8 SVM (Support Vector Machine)	13
2.9 Data Latih dan Uji	15
2.10 Confusion Matrix	15
BAB III METODOLOGI PENELITIAN	17
3.1 Metode Penelitian.....	17
3.2 Pengumpulan Data	17
3.3 Preprocessing	18

3.3.1	Penggabungan Data	19
3.3.2	Cleaning Data.....	19
3.3.3	Tokenizing	20
3.3.4	Normalisasi	21
3.3.5	Translate Data	22
3.3.6	Filtering / Stopword Removal.....	23
3.3.7	Stemming	25
3.4	Lexicon Based.....	26
3.4.1	InSet Lexicon.....	26
3.4.2	VADER Lexicon.....	28
3.5	Split Data Uji dan Data Latih.....	29
3.6	TF-IDF.....	29
3.7	Support Vector Machine	33
3.8	Skenario Pengujian.....	38
3.9	Confusion Matrix	39
BAB IV PEMBAHASAN	40
4.1	Proses Penelitian	40
4.1.1	Perangkat Keras.....	40
4.1.2	Perangkat Lunak.....	40
4.2	Pengumpulan Data	41
4.3	Data Preprocessing.....	41
4.2.1	Penggabungan Data	42
4.2.2	Cleaning Data	43
4.2.3	Tokenizing	47
4.2.4	Normalisasi	48
4.2.5	Translate Data.....	50
4.2.6	Filtering / Stopword Removal	51
4.2.7	Stemming	55
4.4	Lexicon Based.....	59
4.3.1	InSet Lexicon.....	59
4.3.2	VADER Lexicon	62
4.5	Split Data Uji dan Data Latih.....	64
4.6	TF-IDF	66

4.7	TF-IDF Standarisasi	67
4.8	Support Vector Machine	68
4.9	Confusion Matrix	69
BAB V PENUTUP	75
5.1	Kesimpulan.....	75
5.2	Saran.....	76
DAFTAR PUSTAKA	77

DAFTAR TABEL

Tabel 2. 1 Daftar Bobot Kata pada Lexicon InSet.....	9
Tabel 2.2 Daftar Bobot Kata Lexicon Vader.....	10
Tabel 2.3 Confusion Matrix	15
Tabel 3.1 Data Cleaning	20
Tabel 3.2 Tokenizing.....	21
Tabel 3.3 Normalisasi	22
Tabel 3.4 Kamus Normalisasi	22
Tabel 3.5 Tabel Normalisasi.....	23
Tabel 3.6 Filtering Bahasa Indonesia.....	24
Tabel 3.7 Filtering Bahasa Inggris	25
Tabel 3. 8 Stemming	25
Tabel 3.9 Perhitungan Bobot Lexicon InSet.....	27
Tabel 3.10 Perhitungan Bobot VADER Lexicon	28
Tabel 3.11 Kalimat Pada Setiap Dokumen.....	30
Tabel 3.12 Perhitungan Term Frequency.....	31
Tabel 3.13 Perhitungan Kemunculan Kata	31
Tabel 3.14 Hasil Perhitungan TF-IDF	32
Tabel 3.15 Hasil Perhitungan Kernel.....	34
Tabel 3.16 Skenario Pengujian	38
Tabel 4.1 Tabel Perangkat Lunak.....	40
Tabel 4.2 Hasil Data Cleaning	45
Tabel 4.3 Hasil Tokenize	47
Tabel 4.4 Hasil Normalisasi Data	49
Tabel 4.5 Hasil Translate Data	50
Tabel 4.6 Hasil Filtering Data Bahasa Indonesia.....	53
Tabel 4.7 Hasil Filtering Data Bahasa Inggris	54
Tabel 4.8 Hasil Stemming Data Bahasa Indonesia	56
Tabel 4.9 Hasil Stemming Bahasa Inggris.....	58
Tabel 4.10 Hasil Labeling InSet Lexicon	61
Tabel 4.11 Tabel Jumlah Labeling Lexicon InSet	61
Tabel 4.12 Hasil Labeling VADER Lexicon	63

Tabel 4.13 Jumlah Labeling Lexicon VADER	64
Tabel 4.14 Hasil Split Data Latih dan Uji.....	66
Tabel 4.15 Hasil Confusion Matrix	69
Tabel 4.16 Hasil Akurasi Model	72

DAFTAR GAMBAR

Gambar 2.1 Migrasi Rohingya	6
Gambar 2.2 Penggunaan Analisa Sentimen	7
Gambar 2.3 Pendekatan Analisa Sentimen	8
Gambar 2.4 Ilustrasi Support Vector Machine	14
Gambar 3.1 Diagram Metodologi Penelitian.....	17
Gambar 3.2 Pengumpulan Data	17
Gambar 3.3 Flowchart Preprocessing.....	18
Gambar 3.4 Proses Penggabungan Data	19
Gambar 3.5 Proses Normalisasi Data	21
Gambar 3.6 Flowchart Stopword Removal.....	23
Gambar 3.7 Proses Labeling.....	26
Gambar 3.8 Flowchart Perhitungan TF-IDF	29
Gambar 3.9 Flowchart Support Vector Machine	332
Gambar 4.1 Kumpulan Dataset.....	42
Gambar 4.2 Hasil Penggabungan Data.....	43
Gambar 4.3 Hasil Pengambilan Kolom yang Digunakan	44
Gambar 4.4 Hasil Labeling InSet Lexicon	62
Gambar 4.5 Gambar Hasil Labeling VADER	64
Gambar 4.6 Hasil Hapus Netral VADER Lexicon	65
Gambar 4.7 Hasil Hapus Netral InSet Lexicon.....	65
Gambar 4.8 Hasil TF-IDF.....	67

DAFTAR KODE PROGRAM

Kode Program 3.1 Kode Program Daftar Stopwords Bahasa Indonesia	24
Kode Program 4.1 Penggabungan Data.....	42
Kode Program 4.2 Explorasi Data	43
Kode Program 4.3 Penghapusan Data yang Tidak Digunakan.....	44
Kode Program 4.4 Data Cleaning.....	45
Kode Program 4.5 Tokenizing Data.....	47
Kode Program 4.6 Normalisasi Data	48
Kode Program 4.7 Translate Bahasa	50
Kode Program 4.8 Filtering Data Bahasa Indonesia.....	52
Kode Program 4.9 Filtering Data Bahasa Inggris	54
Kode Program 4.10 Stemming Bahasa Indonesia.....	56
Kode Program 4.11 Stemming Bahasa Inggris	58
Kode Program 4.12 Membaca Kamus Lexicon	60
Kode Program 4.13 Fungsi Menghitung Bobot Nilai InSet Lexicon.....	60
Kode Program 4.14 Menerapkan Fungsi dan Menyimpan Hasil InSet Lexicon	61
Kode Program 4.15 Labeling VADER Lexicon	63
Kode Program 4.16 Hapus Data Sentimen Netral.....	65
Kode Program 4.17 Split Data Uji dan Latih.....	66
Kode Program 4.18 TF-IDF.....	67
Kode Program 4.19 Support Vector Machine.....	68
Kode Program 4.20 Confusion Matrix.....	69