



SKRIPSI

PENGARUH RFE TERHADAP *LOGISTIC REGRESSION* DAN *SUPPORT VECTOR MACHINE* PADA ANALISIS SENTIMEN HOTEL SHANGRI-LA SURABAYA

FAKHRI MAULANA HERZA

NPM 20081010039

DOSEN PEMBIMBING

Dr. Basuki Rahmat, S. Si. MT.

M. Muhamrom AL Haromainy, S.Kom., M.Kom.

KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN TEKNOLOGI

UNIVERSITAS PEMBANGUNAN NASIONAL VETERAN JAWA TIMUR

FAKULTAS ILMU KOMPUTER

PROGRAM STUDI INFORMATIKA

SURABAYA

2024



SKRIPSI

PENGARUH RFE TERHADAP *LOGISTIC REGRESSION* DAN *SUPPORT VECTOR MACHINE* PADA ANALISIS SENTIMEN HOTEL SHANGRI-LA SURABAYA

FAKHRI MAULANA HERZA

NPM 20081010039

DOSEN PEMBIMBING

Dr. Basuki Rahmat, S. Si. MT.

M. Muhamrom AL Haromainy, S.Kom., M.Kom.

KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN TEKNOLOGI

UNIVERSITAS PEMBANGUNAN NASIONAL VETERAN JAWA TIMUR

FAKULTAS ILMU KOMPUTER

PROGRAM STUDI INFORMATIKA

SURABAYA

2024

Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

PENGARUH RFE TERHADAP *LOGISTIC REGRESSION DAN SUPPORT VECTOR MACHINE* PADA ANALISIS SENTIMEN HOTEL SHANGRI-LA SURABAYA

Oleh:

FAKHRI MAULANA HERZA
NPM. 20081010039

Telah dipertahankan dihadapan dan diterima oleh Tim Pengaji Skripsi Prodi Informatika Fakultas Ilmu Komputer Universitas Pembangunan Nasional Veteran Jawa Timur Pada tanggal 2 September 2024

Menyetujui

Dr. Basuki Rahmat, S. Si. MT.
NIP. 19690723 2021211 002

..... (Pembimbing I)

M. Muhamrom AL Haromainy, S.Kom., M.Kom.
NIP. 19950601 202203 1 006

..... (Pembimbing II)

Dr. I Gede Susrama Mas Divasa, ST., MT. IPU.
NIP. 19700619 2021211 009

..... (Ketua Pengaji)

Retno Mumpuni, S.Kom., M.Sc.
NPT. 172198 70 716054

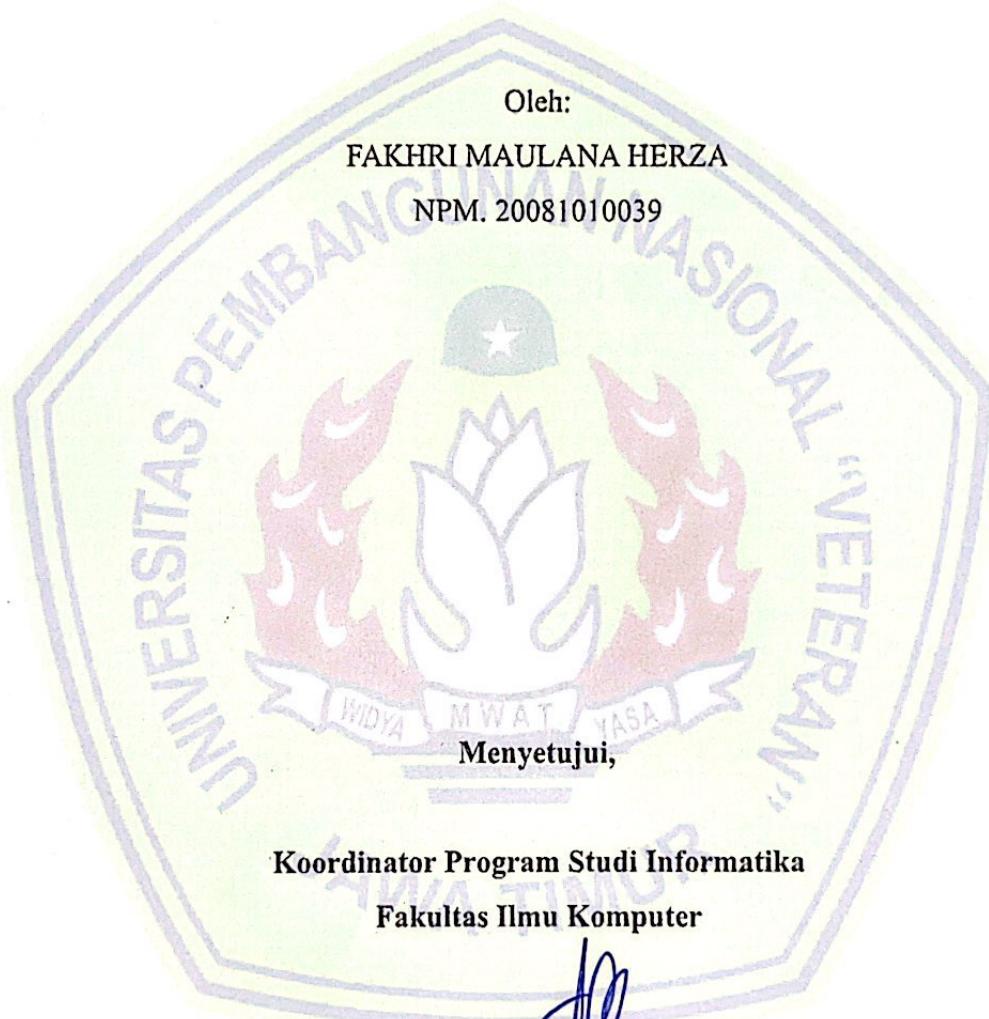
..... (Anggota Pengaji)

Mengetahui,
Dekan Fakultas Ilmu Komputer

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

LEMBAR PERSETUJUAN

PENGARUH RFE TERHADAP *LOGISTIC REGRESSION DAN SUPPORT VECTOR MACHINE* PADA ANALISIS SENTIMEN HOTEL SHANGRI-LA
SURABAYA



Koordinator Program Studi Informatika
Fakultas Ilmu Komputer

A handwritten signature in black ink, appearing to read "Fetty Tri Anggraeny".

Fetty Tri Anggraeny, S.Kom., M.Kom.

NIP. 19820211 2021212 005

Halaman ini sengaja dikosongkan

SURAT PERNYATAAN ORISINALITAS

Yang bertandatangan di bawah ini:

Nama Mahasiswa : Fakhri Maulana Herza

Program Studi : Informatika

Dosen Pembimbing : Dr. Basuki Rahmat, S.Si. MT.

dengan ini menyatakan bahwa isi sebagian maupun keseluruhan disertasi dengan judul:

PENGARUH RFE TERHADAP *LOGISTIC REGRESSION DAN SUPPORT VECTOR MACHINE* PADA ANALISIS SENTIMEN HOTEL SHANGRI-LA SURABAYA

adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diizinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri. Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, 2 September 2024

Yang Membuat Pernyataan,



FAKHRI MAULANA HERZA

NPM. 20081010039

Halaman ini sengaja dikosongkan

ABSTRAK

Nama Mahasiswa / NPM	: Fakhri Maulana Herza / 20081010039
Judul Skripsi	: Pengaruh RFE Terhadap <i>Logistic Regression</i> Dan <i>Support Vector Machine</i> Pada Analisis Sentimen Hotel Shangri-La Surabaya
Dosen Pembimbing	: 1. Dr. Basuki Rahmat, S.Si. MT. 2. M. Muhamrom AL Haromainy, S.Kom., M.Kom

Analisis sentimen adalah salah satu sarana penting dalam industri pariwisata untuk memahami respon dan pengalaman tamu terhadap layanan hotel. Ulasan para tamu sebelumnya berperan krusial dalam membentuk persepsi calon tamu terhadap kualitas fasilitas dan daya tarik hotel yang akan dikunjungi. Namun, salah satu tantangan utama dalam analisis sentimen adalah memilih fitur yang paling relevan untuk meningkatkan kinerja model prediksi. Banyak ulasan mengandung informasi yang beragam, dan tidak semua kata atau fitur memiliki kontribusi yang signifikan dalam membedakan antara sentimen positif dan negatif.

Dalam konteks ini, metode *Recursive Feature Elimination* (RFE) berpotensi untuk mengoptimalkan pemilihan fitur dengan mengeliminasi fitur yang kurang informatif, sehingga diharapkan mampu meningkatkan akurasi model *Logistic Regression* dan *Support Vector Machine* (SVM) dalam analisis sentimen. Oleh karena itu, penelitian ini fokus pada pengaruh penerapan RFE terhadap kinerja kedua model tersebut, khususnya dalam analisis sentimen ulasan tamu di Hotel Shangri-La Surabaya. Data yang digunakan dalam penelitian ini berjumlah 3719 ulasan.

Hasil pengujian menunjukkan bahwa pada model *Logistic Regression* yang menggunakan RFE, terdapat peningkatan performa yang signifikan dalam nilai presisi, sensitivitas, *F1 Score*, dan akurasi, dengan rata-rata peningkatan sebesar 9%. Bahkan, untuk model *Support Vector Machine* yang menggunakan RFE, peningkatan performa lebih signifikan, dengan rata-rata peningkatan sebesar 14%. Temuan ini menunjukkan bahwa penerapan RFE secara efektif dapat meningkatkan kualitas prediksi pada kedua model dalam konteks analisis sentimen ulasan hotel.

Kata kunci : Analisis Sentimen, Sektor Pariwisata, *Google Maps*, *Recursive Feature Elimination*, *Support Vector Machine*, *Logistic Regression*.

Halaman ini sengaja dikosongkan

ABSTRACT

Student Name / NPM	: Fakhri Maulana Herza / 20081010039
Thesis Title	: The Influence Of RFE On Logistic Regression And Support Vector Machine In Sentiment Analysis Of The Shangri-La Hotel Surabaya
Advisor	: 1. Dr. Basuki Rahmat, S.Si. MT. 2. M. Muhamrom AL Haromainy, S.Kom., M.Kom

Sentiment analysis is one of the essential tools in the tourism industry for understanding guest responses and experiences regarding hotel services. Previous guest reviews play a crucial role in shaping the perceptions of potential guests about the quality of facilities and the attractiveness of the hotel they plan to visit. However, one of the main challenges in sentiment analysis is selecting the most relevant features to improve model prediction performance. Many reviews contain diverse information, and not all words or features significantly contribute to distinguishing between positive and negative sentiment.

In this context, the Recursive Feature Elimination (RFE) method has the potential to optimize feature selection by eliminating less informative features, thus expected to improve the accuracy of Logistic Regression and Support Vector Machine (SVM) models in sentiment analysis. Therefore, this study focuses on the impact of RFE application on the performance of both models, particularly in analyzing guest reviews at the Shangri-La Hotel Surabaya. The data used in this study consists of 3719 reviews.

The test results show that in the Logistic Regression model using RFE, there was a significant improvement in performance in terms of precision, sensitivity, F1 Score, and accuracy, with an average increase of 9%. Moreover, for the Support Vector Machine model using RFE, the performance improvement was even more significant, with an average increase of 14%. These findings indicate that the application of RFE can effectively enhance the predictive quality of both models in the context of hotel review sentiment analysis.

Kata kunci : *Sentiment Analysis, Tourism Sector, Google Maps, Recursive Feature Elimination, Support Vector Machine, Logistic Regression.*

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur kehadirat Allah SWT atas segala rahmat, hidayah dan karunia-Nya kepada penulis sehingga skripsi dengan judul “**Pengaruh RFE Terhadap Logistic Regression Dan Support Vector Machine Pada Analisis Sentimen Hotel Shangri-La Surabaya**” dapat terselesaikan dengan baik.

Oleh karena itu, saya ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada semua pihak yang telah berkontribusi.

1. Prof. Dr. Ir. Akhmad Fauzi, M.MT selaku Rektor Universitas Pembangunan Nasional “Veteran” Jawa Timur.
2. Prof. Dr. Novirina Hendrasarie, S.T, M.T. Selaku Dekan Fakultas Ilmu Komputer Universitas Pembangunan Nasional “Veteran” Jawa Timur.
3. Ibu Fetty Tri Anggraeny, S.Kom, M.Kom selaku Ketua Program Studi Teknik Informatika Universitas Pembangunan Nasional “Veteran” Jawa Timur.
4. Bapak Dr. Basuki Rahmat, S.Si. MT selaku dosen pembimbing 1 dan bapak M. Muhamrom Al Haromainy, S.Kom., M.Kom selaku dosen pembimbing 2 yang telah membimbing serta memberikan arahan dalam menyusun pengerjaan tugas akhir ini.
5. Orang Tua tercinta saya yang telah memberikan doa, dukungan, dan motivasi yang diberikan kepada penulis.

Saya menyadari bahwa laporan ini masih memiliki beberapa kekurangan. Oleh karena itu, saya sangat mengharapkan saran dan kritik yang konstruktif demi penyempurnaan laporan ini. Akhir kata, dengan penuh harap akan Ridho dari Allah SWT, semoga laporan tugas akhir ini dapat bermanfaat bagi kita semua. Aamiin.

Surabaya, 2 September 2024

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN	iii
SURAT PERNYATAAN ORISINALITAS	v
ABSTRAK	vii
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
DAFTAR NOTASI	xix
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan	4
1.4 Manfaat	4
1.5 Batasan Masalah	5
BAB II TINJAUAN PUSTAKA	7
2.1 Penelitian Sebelumnya	7
2.2 Shangri-La	8
2.3 Analisis Sentimen	9
2.4 Preprocessing	9
2.4.1 Case-folding	10
2.4.2 Cleaning	10
2.4.3 Tokenizing	10
2.4.4 Stopword Removal	10
2.4.5 Stemming	10
2.5 TF-IDF	10
2.6 Recursive Feature Elimination (RFE)	12
2.7 Support Vector Machine (SVM)	12
2.8 Logistic Regression	14
2.9 Confusion Matrix	16
BAB III METODOLOGI	19
3.1 Tahapan Penelitian	19
3.2 Studi Literatur	19
3.3 Analisa Dan Desain	20

3.4	Pengambilan Dan <i>Labeling</i> Data	21
3.5	Preprocessing Data.....	23
3.5.1	Case Folding	24
3.5.2	Cleaning	24
3.5.3	Tokenizing	24
3.5.4	Stopword Removal.....	26
3.5.5	Stemming	27
3.6	TF-IDF	28
3.7	Recursive Feature Elimination (RFE).....	29
3.8	Support Vector Machine (SVM).....	31
3.9	Logistic Regression.....	38
3.10	Skenario Pengujian	41
BAB IV HASIL DAN PEMBAHASAN.....		43
4.1	Akusisi dan <i>Labeling</i> Data.....	43
4.2	Preprocessing data.....	45
4.2.1	Case Folding	47
4.2.2	Cleaning	48
4.2.3	Tokenizing	49
4.2.4	Stopword Removal.....	50
4.2.5	Stemming	51
4.3	TF-IDF	52
4.4	Splitting Data	54
4.5	Recursive Feature Elimination (RFE).....	55
4.6	Support Vector Machine (SVM).....	57
4.6.1	SVM menggunakan RFE	58
4.6.2	SVM tidak menggunakan RFE	64
4.7	Logistic Regression.....	70
4.7.1	<i>Logistic Regression</i> menggunakan RFE	71
4.7.2	<i>Logistic Regression</i> tidak menggunakan RFE	77
4.8	Hasil Evaluasi Model	83
4.9	Analisis Sentimen Aspek	88
BAB IV KESIMPULAN DAN SARAN.....		91
5.1	Kesimpulan	91
5.2	Saran.....	92
DAFTAR PUSTAKA.....		93

DAFTAR GAMBAR

Gambar 2. 1 Garis <i>Hyperlane SVM</i>	13
Gambar 2. 2 Klasifikasi SVM	13
Gambar 2. 3 Contoh Rumus <i>Logistic Regression</i>	15
Gambar 2. 4 Contoh Bentuk <i>Logistic Regression</i>	15
Gambar 3. 1 Flowchart Tahapan Penelitian	19
Gambar 3. 2 Flowchart Rancangan Sistem	20
Gambar 3. 3 Flowchart Pengambilan Dan <i>Labeling Data</i>	21
Gambar 3. 4 <i>Scrapping Dataset</i>	22
Gambar 3. 5 Contoh <i>Labelling Dataset</i>	23
Gambar 3. 6 Flowchart <i>Preprocessing Data</i>	23
Gambar 3. 7 Flowchart RFE	29
Gambar 3. 8 Flowchart SVM.....	32
Gambar 3. 9 Flowchart <i>Logistic Regression</i>	38
Gambar 4. 1 Hasil <i>Scrapping data</i>	43
Gambar 4. 2 Hasil Pelabelan Sentimen Positif dan Negatif.....	44
Gambar 4. 3 Hasil Upload <i>File Dataset Pada Google Collab</i>	46
Gambar 4. 4 Dataset Hasil <i>Upload</i>	47
Gambar 4. 5 Hasil Proses <i>Case-folding</i>	48
Gambar 4. 6 Hasil Proses <i>Cleaning</i>	49
Gambar 4. 7 Hasil Proses <i>Tokenizing</i>	50
Gambar 4. 8 Hasil Proses <i>Stopword Removal</i>	51
Gambar 4. 9 Hasil Proses <i>Stemming</i>	52
Gambar 4. 10 Hasil Array <i>Label Encoding</i>	53
Gambar 4. 11 Hasil Proses TF-IDF	54
Gambar 4. 12 Data Sebelum Diproses RFE.....	56
Gambar 4. 13 Data Setelah Diproses RFE.....	57
Gambar 4. 14 <i>Confusion Matrix 90% Data Train Dan 10% Data Test</i>	59
Gambar 4. 15 <i>Confusion Matrix 80% Data Train Dan 20% Data Test</i>	61
Gambar 4. 16 <i>Confusion Matrix 70% Data Train Dan 30% Data Test</i>	63
Gambar 4. 17 <i>Confusion Matrix 90% Data Train Dan 10% Data Test</i>	65
Gambar 4. 18 <i>Confusion Matrix 80% Data Train Dan 20% Data Test</i>	67
Gambar 4. 19 <i>Confusion Matrix 70% Data Train Dan 30% Data Test</i>	69
Gambar 4. 20 <i>Confusion Matrix 90% Data Train Dan 10% Data Test</i>	72
Gambar 4. 21 <i>Confusion Matrix 80% Data Train Dan 20% Data Test</i>	74
Gambar 4. 22 <i>Confusion Matrix 70% Data Train Dan 30% Data Test</i>	76
Gambar 4. 23 <i>Confusion Matrix 90% Data Train Dan 10% Data Test</i>	78
Gambar 4. 24 <i>Confusion Matrix 80% Data Train Dan 20% Data Test</i>	80
Gambar 4. 25 <i>Confusion Matrix 70% Data Train Dan 30% Data Test</i>	82
Gambar 4. 26 Diagram Batang Akurasi	85
Gambar 4. 27 Diagram Batang Presisi.....	86
Gambar 4. 28 Diagram Batang Sensitifitas	87
Gambar 4. 29 Diagram Batang <i>F1 Score</i>	88
Gambar 4. 30 Analisis Sentimen Aspek	89

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 3. 1 Contoh <i>Case Folding</i>	24
Tabel 3. 2 Contoh <i>Cleaning</i>	24
Tabel 3. 3 Contoh <i>Tokenizing</i>	24
Tabel 3. 4 Contoh <i>Stopword Removal</i>	26
Tabel 3. 5 Contoh <i>Stemming</i>	27
Tabel 3. 6 Contoh Bobot Setiap Fitur	30
Tabel 3. 7 Contoh Kelas Sentimen.....	32
Tabel 3. 8 Contoh Ekstraksi Fitur Pada Dataset	33
Tabel 3. 9 Contoh Pasangan Kernel	34
Tabel 3. 10 Contoh hasil Perhitungan Kernelisasi.....	34
Tabel 3. 11 Contoh Hasil Perhitungan Matriks Hessian	35
Tabel 3. 12 Data Kernel	35
Tabel 3. 13 Matriks Kernel	37
Tabel 3. 14 Contoh Dataset	38
Tabel 3. 15 Skenario Pengujian	41
Tabel 4. 1 Kode Program <i>Import Library Preprocessing Data</i>	45
Tabel 4. 2 Kode Program <i>Input File Dataset</i>	46
Tabel 4. 3 Kode Program <i>Case Folding</i>	47
Tabel 4. 4 Kode Program <i>Cleaning</i>	48
Tabel 4. 5 kode program <i>Tokenizing</i>	49
Tabel 4. 6 Kode Program <i>Stopword Removal</i>	50
Tabel 4. 7 Kode Program <i>Stemming</i>	51
Tabel 4. 8 Kode Program <i>Label Encoding</i>	52
Tabel 4. 9 Kode Program <i>TF-IDF</i>	53
Tabel 4. 10 Kode Program <i>Splitting Data</i>	54
Tabel 4. 11 Metode Optimasi RFE	55
Tabel 4. 12 Kode Program <i>Support Vector Machine</i>	57
Tabel 4. 13 Hasil Evaluasi Model	60
Tabel 4. 14 Hasil Evaluasi Model	62
Tabel 4. 15 Hasil Evaluasi Model	64
Tabel 4. 16 Hasil Evaluasi Model	66
Tabel 4. 17 Hasil Evaluasi Model	68
Tabel 4. 18 Hasil Evaluasi Model	70
Tabel 4. 19 Kode Program <i>Logistic Regression</i>	70
Tabel 4. 20 Hasil Evaluasi Model	73
Tabel 4. 21 Hasil Evaluasi Model	75
Tabel 4. 22 Hasil Evaluasi Model	77
Tabel 4. 23 Hasil Evaluasi Model	79
Tabel 4. 24 Hasil Evaluasi Model	81
Tabel 4. 25 Hasil Evaluasi Model	83
Tabel 4. 26 Hasil Evaluasi Seluruh Model.....	83

Halaman ini sengaja dikosongkan

DAFTAR NOTASI

TF	: Frekuensi kemunculan kata pada suatu dokumen d.
td	: Jumlah kemunculan kata t dalam dokumen d.
d	: Total jumlah kata dalam dokumen d.
lg	: logaritma natural
D	: jumlah semua dokumen.
df	: jumlah <i>term/kata</i> dari dokumen.
W	: bobot
TF	: Nilai TF
IDF	: Nilai IDF
D_{ij}	: Elemen matriks data ke – ij
y_i	: Kelas atau label data ke – i
y_j	: Kelas atau label data ke – j
λ^2	: Turunan batas teoritis
E_i	: Nilai error data ke – I
γ	: Tingkat pembelajaran
$Max_i D_{ij}$: Nilai maksimum diagonal matriks hessian
c	: 1 (Konstanta untuk perhitungan kernel)
λ	: 0.5
γ	: 0.001 (<i>learning rate</i>)
C	: 1 (<i>Variabel slack</i>)
ε	: 0.0001 (<i>epilson</i>)

Halaman ini sengaja dikosongkan