

**ANALISIS ULASAN HOTEL DI SITUS TRIPADVISOR
MENGGUNAKAN METODE *TERM FREQUENCY-INVERSE
DOCUMENT FREQUENCY* DAN *K-NEAREST NEIGHBOR***

**Tesis untuk Tesis S-2
Program Studi Magister Sistem Informasi**



**Khairul Huda
30000318410014**

**PROGRAM PASCASARJANA
UNIVERSITAS DIPONEGORO
SEMARANG
2022**

HALAMAN PENGESAHAN

TESIS

ANALISIS ULASAN HOTEL DI SITUS TRIPADVISOR MENGGUNAKAN METODE TERM FREQUENCY-INVERSE DOCUMENT FREQUENCY (TF-IDF) DAN K-NEAREST NEIGHBOR (KNN)

Oleh:
Khairul Huda
30000318410014

Telah diujikan dan dinyatakan lulus ujian tesis pada tanggal 15 Agustus 2022 oleh tim penguji Program Studi Magister Sistem Informasi Sekolah Pascasarjana Universitas Diponegoro.

Semarang, 15 Agustus 2022
Mengetahui,

Penguji I

Penguji II

Prof. Dr. Kusworo Adi, S.Si., M.T.
NIP: 197203171998021001

Drs. Bayu Surarso, M.Sc., Ph.D
NIP. 196311051988031001

Pembimbing I

Pembimbing II

Dr. Catur Edi Widodo, MT.
NIP: 196405181992031002

Vincencius Gunawan S.K., M.Si., Ph.D
NIP: 197105221997021001

Mengetahui :
Dekan Sekolah Pascasarjana
Universitas Diponegoro

Ketua Program Studi
Magister Sistem Informasi

Dr. R.B. Sularto, S.H., M.Hum
NIP. 196701011991031005

Drs. Bayu Surarso, M.Sc., Ph.D
NIP. 196311051988031001

**PERNYATAAN PERSETUJUAN
PUBLIKASI TESIS UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Diponegoro, saya yang bertanda tangan di bawah ini:

Nama	:	Khairul Huda
NIM	:	30000318410014
Program Studi	:	Magister Sistem Informasi
Program	:	Sekolah Pascasarjana
Jenis Karya	:	Tesis

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Diponegoro Hak Bebas Royalti Noneksklusif atas karya ilmiah saya yang berjudul:

**ANALISIS ULASAN HOTEL DI SITUS TRIPADVISOR
MENGGUNAKAN METODE TERM FREQUENCY-INVERSE DOCUMENT
FREQUENCY DAN K-NEAREST NEIGHBOR**

beserta perangkat yang ada. Dengan Hak bebas Royalti Noneksklusif ini Program Studi Magister Sistem Informasi Sekolah Pascasarjana Universitas Diponegoro berhak menyimpan, mengalihmedia/formatkan, mengelola dalam bentuk pangkalan data (*database*) merawat, dan mempublikasikan tesis saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik hak cipta.

Dibuat di: Semarang

Pada tanggal: 12 Juli 2022

Yang menyatakan

Khairul Huda
NIM. 30000318410014

PERNYATAAN

Dengan ini saya menyatakan bahwa dalam tesis 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 pustaka.

Semarang, 12 Juli 2022

Khairul Huda



KATA PENGANTAR

Puji syukur ke hadirat Allah SWT, atas limpahan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan penelitian tesis dengan judul “Analisis Ulasan Hotel Di Situs TripAdvisor Menggunakan Metode *Term Frequency-Inverse Document Frequency* (TF-IDF) Dan *K-Nearest Neighbor* (KNN)”. Penulis menyadari tidak dapat menyelesaikan Tesis ini tanpa bantuan dan dorongan dari berbagai pihak. Untuk itu pada kesempatan ini penulis ingin mengucapkan terima kasih kepada:

1. Bapak Dr. Catur Edi Widodo, MT selaku pembimbing pertama penulis yang telah memberikan wawasan, masukan, arahan dan nasehat dalam penulisan tesis.
2. **Bapak Vincencius Gunawan S.K., M.Si., Ph.D** selaku pembimbing kedua yang juga telah memberikan bimbingan, koreksi dan dukungan dalam penulisan tesis.
3. Bapak Drs. Bayu Surarso, M.Sc., Ph.D **Selaku Ketua Program Studi, Magister Sistem Informasi, Sekolah Pascasarjana, Universitas Diponegoro, Semarang.**
4. Bapak Dr. R.B. Sularto, S.H., M.Hum, **Selaku Dekan Sekolah Pascasarjana Universitas Diponegoro Semarang.**
5. Keluargaku tercinta, Bapak Drs. Pardi dan Ibu Sri Wahyuti, serta istri dan kakak-kakak saya.
6. Seluruh Dosen Magister Sistem Informasi, Universitas Diponegoro yang tidak dapat penulis sebutkan satu persatu, terimakasih atas ilmu yang diberikan selama perkuliahan.
7. Rekan-rekan Magister Sistem Informasi 2018 dan semua staf karyawan Pascasarjana, Universitas Diponegoro, terimakasih atas kerja sama yang telah terjalin selama ini, sehingga penulis menyelesaikan administrasi hingga menyelesaikan tesis ini.

Penulis menyadari bahwa tesis ini masih jauh dari sempurna, untuk itu saran dan kritik yang membangun sangat penulis harapkan. Semoga tesis ini dapat bermanfaat bagi pihak-pihak yang membutuhkan.

Semarang, Juni 2022
Penulis

DAFTAR ISI

	Halaman
Halaman Judul	i
Halaman Persetujuan	ii
Halaman Pernyataan Persetujuan Publikasi	iii
Halaman Pernyataan	iv
Kata Pengantar	v
Daftar Isi	vi
Daftar Gambar	viii
Daftar Tabel	ix
Daftar Lampiran	x
Daftar Arti Lambang dan Singkatan	xi
Abstrak	xii
<i>Abstract</i>	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Tujuan Penelitian	3
1.3 Manfaat Penelitian	3
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	4
2.1 Tinjauan Pustaka	4
2.2 Dasar Teori	5
2.2.1 <i>Data Mining</i>	5
2.2.2 Fungsi Penerapan <i>Data Mining</i>	6
2.2.3 Metode Pengembangan <i>Data Mining</i>	7
2.2.4 <i>Text Mining</i>	8
2.2.5 Analisis Sentimen	8
2.2.6 Prapengolahan Teks	9
2.2.7 Metode <i>Resampling</i>	10
2.2.8 Algoritma TF-IDF	11
2.2.9 Algortima KNN (<i>K-Nearest Neighbor</i>)	12
2.2.10 Pengukuran Kinerja Klasifikasi	14
BAB III METODE PENELITIAN	15
3.1 Bahan dan Alat Penelitian	15
3.2 Prosedur Penelitian	15
3.3 Perancangan Sistem	19
3.3.1 Kerangka Sistem	19
3.3.2 Diagram Alir Sistem	21
3.4 Desain Sistem	22
3.4.1 Perancangan Diagram Alir Data	22
3.4.2 Pemodelan Sistem	24

3.4.3 Perancangan Basis Data	26
3.4.4 Perancangan Antar Muka	27
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	29
4.1 Hasil Penelitian	29
4.1.1 Pemilihan Data	29
4.1.2 Prapengolahan Teks	30
4.1.3 Pelabelan Kelas Sentimen	30
4.1.4 Implementasi Algortima TF-IDF	31
4.1.5 Implementasi Algortima KNN	33
4.1.6 Implementasi Sistem	34
4.1.7 Pengujian <i>Black Box Testing</i>	37
4.2 Pembahasan	38
4.2.1 Analisis Data	38
4.2.2 Evaluasi Kinerja Sistem	39
 BAB V KESIMPULAN DAN SARAN	47
5.1 Kesimpulan	47
5.2 Saran	47
 DAFTAR PUSTAKA	48
LAMPIRAN	51

DAFTAR GAMBAR

Halaman

Gambar 3.1	SDLC dengan model <i>waterfall</i>	16
Gambar 3.2	Prosedur Penelitian.....	18
Gambar 3.3	Kerangka Sistem yang akan dibangun	20
Gambar 3.4	Diagram Alir Sistem.....	21
Gambar 3.5	DFD Level 0	22
Gambar 3.6	DFD Level 1.....	23
Gambar 3.7	<i>Use Case Diagram</i>	24
Gambar 3.8	<i>Sequence Diagram</i>	25
Gambar 3.9	<i>Activity Diagram</i>	26
Gambar 3.10	Desain <i>Mockup</i> Sistem	27
Gambar 3.11	Desain Tampilan Utama Sistem	28
Gambar 4.1	Tampilan Modul Masukan Data <i>Training</i>	35
Gambar 4.2	Tampilan Modul Masukan Data uji	35
Gambar 4.3	Tampilan Modul Proses	36
Gambar 4.4	Tampilan Keluaran Sistem	36
Gambar 4.5	Statistik Data masukan	38
Gambar 4.6	Statistik Hasil <i>Rebalance</i> Data.....	39
Gambar 4.7	Hasil Evaluasi Tanpa <i>Rebalance</i> Data	39
Gambar 4.8	Hasil Evaluasi Setelah <i>Rebalance</i> Data	41
Gambar 4.9	Distribusi Kelas Pengujian Pertama	42
Gambar 4.10	Distribusi Kelas Pengujian Kedua	43
Gambar 4.11	Distribusi Kelas Pengujian Ketiga	45

DAFTAR TABEL

	Halaman
Tabel 1.1 Penerapan Prapengolahan Teks	10
Tabel 4.1 Sampel data yang digunakan.....	29
Tabel 4.2 Hasil Prapengolahan Teks.....	30
Tabel 4.3 Hasil Pelabelan Data Masukan	31
Tabel 4.4 Data Masukan Untuk TF-IDF	32
Tabel 4.5 Hasil Perhitungan TF	32
Tabel 4.6 Hasil Perhitungan TF-IDF	33
Tabel 4.7 Tingkat Kemiripan Data.....	34
Tabel 4.8 Hasil Pengujian <i>Black Box Testing</i>	37
Tabel 4.9 Hasil Evaluasi Pengujian Pertama	42
Tabel 4.10 Hasil Evaluasi Pengujian Kedua.....	44
Tabel 4.11 Hasil Evaluasi Pengujian Ketiga.....	45

DAFTAR LAMPIRAN

Halaman

Lampiran 1. Tabel perhitungan TF	51
Lampiran 2. Tabel perhitungan TF-IDF.....	52



DAFTAR ARTI LAMBANG DAN SINGKATAN

DAFTAR ARTI LAMBANG

Lambang	Arti Lambang
D_{xy}	Jarak antara objek x dan y
Cos_{ij}	Nilai kemiripan data uji dengan data latih
d_{ik}	Panjang vektor data uji
d_{jk}	Panjang vektor data latih
x	Data uji yang akan diklasifikasi
y	Data latih
n	Jumlah data latih
i	Data ke- i
Tf	Banyaknya kata dalam dokumen
$Tf_{t,d}$	Banyaknya kata t pada dokumen d
d	Jumlah dokumen
df	Jumlah dokumen yang mengandung suatu <i>term</i>
$W_{t,d}$	Nilai bobot akhir kata
$tf_{t,d}$	Banyaknya kata dalam dokumen
idf_t	Pembobotan keseluruhan

DAFTAR SINGKATAN

Singkatan	Kepanjangan Singkatan
<i>SVM</i>	<i>Support Vector Machine</i>
<i>ANN</i>	<i>Artificial Neural Network</i>
<i>KNN</i>	<i>K-Nearest Neighbor</i>
<i>CNN</i>	<i>Convolutional Neural Network</i>
<i>SQL</i>	<i>Structured Query Language</i>
<i>TF-IDF</i>	<i>Term Frequency-Inverse Document Frequency</i>
<i>KDD</i>	<i>Knowledge Discovery in Database</i>
<i>NLTK</i>	<i>Natural Language Toolkit</i>
<i>API</i>	<i>Application Programming Interface</i>
<i>NLP</i>	<i>Natural Language Processing</i>
<i>UML</i>	<i>Unified Modelling Language</i>
<i>SDLC</i>	<i>Software Development Language Cycle</i>

**ANALISIS ULASAN HOTEL DI SITUS TRIPADVISOR
MENGGUNAKAN METODE TERM FREQUENCY-INVERSE DOCUMENT
FREQUENCY DAN K-NEAREST NEIGHBOR**

ABSTRAK

Penelitian ini dilatarbelakangi oleh evaluasi produk dan jasa menggunakan metode konvensional melalui wawancara, survei dan kuisioner yang berakibat pada hasil analisis menjadi tidak akurat dan tidak konsisten. Penelitian ini bertujuan untuk menerapkan algoritma *Term Frequency-Inverse Document Frequency* (TF-IDF) dan *K-Nearest Neighbor* serta mengevaluasi hasil dari sistem yang dibangun dengan tingkat akurasi yang paling optimal. Salah satu upaya untuk menanggulangi permasalahan tersebut yaitu membangun sistem untuk analisis ulasan pelanggan hotel di situs TripAdvisor yang bernilai positif, negatif dan netral menggunakan teknik *text mining*. Algoritma klasifikasi yang digunakan dalam penelitian adalah *K-Nearest Neighbor* karena memiliki kelebihan dalam hal komputasi berkinerja tinggi, tahan terhadap berbagai karakteristik data yang besar, dan memiliki kompleksitas algoritma yang relatif kecil. Hasil penelitian menunjukkan bahwa sistem dapat melakukan klasifikasi terhadap ulasan hotel di situs TripAdvisor yang bernilai positif, negatif dan netral dengan nilai performa paling baik pada $K=31$ dan memiliki tingkat akurasi mencapai 76% untuk data *training*, dan menghasilkan peningkatan akurasi mencapai 84% dengan menerapkan metode *random over-sampling* untuk *rebalance* data.

Kata kunci : *text mining*, *term frequency-inverse document frequency*, *k-nearest neighbor*, *random over-sampling*

**ANALYSIS OF HOTEL REVIEWS ON THE TRIPADVISOR SITE
USING THE TERM FREQUENCY-INVERSE DOCUMENT FREQUENCY
AND K-NEAREST NEIGHBOR METHODS**

ABSTRACT

This research is based on analysis using conventional methods through interviews, surveys and questionnaires which resulted in the analysis being inaccurate and inconsistent. This study aims to apply the Term Frequency-Inverse Document Frequency (TF-IDF) and K-Nearest Neighbor algorithms and evaluate the results of the system built with the most optimal level of accuracy. To solve these problems is to build a system for analyzing hotel customer reviews on the TripAdvisor site which have positive, negative and neutral values using text mining techniques. The classification algorithm used in the research is K-Nearest Neighbor because it has advantages in terms of high-performance computing, is resistant to various characteristics of large data, and has a relatively small algorithm complexity. The results show that the system can classify hotel reviews on the TripAdvisor site which are positive, negative and neutral with the best performance value at $K = 31$ and has an accuracy of 76% for training data and increase in accuracy of up to 84% by applying the random over-sampling method for data rebalance.

Keywords: text mining, term frequency-inverse document frequency, k-nearest neighbor, random over-sampling