

## ABSTRAK

Sistem pengecekan kemiripan dokumen tugas akhir pada Fakultas Teknologi Informasi Universitas Kristen Maranatha masih dilakukan secara manual sehingga mahasiswa dapat meniru dokumen tugas akhir orang lain. Untuk membantu para dosen mendeteksi peniruan dokumen tugas akhir, dibutuhkan sebuah sistem pendeteksian kemiripan judul dan isi dokumen. Sistem ini dibuat menggunakan konsep *data mining*, dimana pengecilan dimensi, penghilangan gangguan, dan perestrukturisasi masukan akan dilakukan. Sistem akan memroses masukan yang telah diekstrak untuk memperhitungkan nilai kemiripannya dengan masukan yang lain. Pertama-tama, sistem mengambil semua data dokumen tugas akhir dari basis data dan satu dokumen pilihan pengguna. Kemudian, sistem melakukan proses ekstraksi dokumen terhadap masukan berupa dokumen melalui *case folding* dan *tokenisasi*, *filtering*, dan *stemming* (menggunakan algoritma Nazief-Adriani) pada setiap dokumen. Setelah proses ekstraksi selesai, sistem dapat memroses dokumen untuk memperhitungkan nilai kemiripannya dengan dua cara, yaitu *cosine similarity* dan algoritma Smith-Waterman. Dengan *cosine similarity*, sistem menghitung jumlah kata-kata pada dokumen pilihan pengguna dan dokumen-dokumen lainnya, kemudian mengalkulasi nilai kemiripannya dengan hukum kosinus. Dengan algoritma Smith-Waterman, sistem membandingkan urutan kata-kata dari dokumen pilihan pengguna dan dokumen-dokumen lainnya, kemudian menghasilkan nilai kemiripannya. Pada akhirnya, sistem dapat menghasilkan angka dari 0% hingga 100% untuk setiap dokumen. Sistem menampilkan dokumen-dokumen yang terurut dari nilai kemiripan terbesar hingga terkecil.

Kata kunci: algoritma Smith-Waterman, algoritma Nazief-Adriani, *cosine similarity*, *data mining*, dokumen tugas akhir, nilai kemiripan

## **ABSTRACT**

The Information Technology of Maranatha Christian University's documents of final term paper checking system is still run manually so that students can copy others' document of final term paper. To help lecturers detecting document of final term paper copying, a similarity detecting documents of final term paper is needed. This system is made using data mining concept, where dimension reduction, noise removal, and input restructuring will be implemented. This system will process extracted input to count its similarity value compared to other inputs. First off, system fetches all documents of final term paper from database and one user-chosen document. Then, system does document extraction process toward the input in form of a document through case folding and tokenization, filtering, and stemming (using Nazief-Adriani algorithm) to every document. After the extraction process completed, system can process the user-chosen document to count its similarity value in two ways: cosine similarity and Smith-Waterman algorithm. With cosine similarity, system counts the number of words of user-chose document and other documents, and then calculates its similarity value with cosines law. Using Smith-Waterman algorithm, system compares words sequence from user-chose document and other documents, and then outputs its similarity value. In the end, system will produce percentage from 0% to 100% for every document. System shows sorted documents descendingly based on its similarity value.

Keywords: cosine similarity, data mining, document of final term, Nazief-Adriani algorithm, similarity value, Smith-Waterman algorithm

# DAFTAR ISI

LEMBAR PENGESAHAN .....	i
PERNYATAAN ORISINALITAS LAPORAN PENELITIAN .....	ii
PERNYATAAN PUBLIKASI LAPORAN PENELITIAN .....	iii
PRAKATA .....	iv
ABSTRAK .....	v
ABSTRACT .....	vi
DAFTAR ISI .....	vii
DAFTAR GAMBAR .....	x
DAFTAR TABEL .....	xi
DAFTAR LAMPIRAN .....	xii
BAB I PENDAHULUAN .....	1
1.1 Latar Belakang Masalah .....	1
1.2 Rumusan Masalah .....	1
1.3 Tujuan Pembahasan .....	2
1.4 Ruang Lingkup Kajian .....	2
1.5 Sumber Data .....	2
1.6 Sistematika Penyajian .....	3
BAB II KAJIAN TEORI .....	4
2.1 Kajian Teori Sistem Informasi .....	4
2.2 <i>Entity Relationship Diagram</i> (ERD) .....	5
2.3 <i>Unified Modelling Language</i> (UML) .....	9
2.3.1 <i>Use Case Diagram</i> .....	9
2.3.2 <i>Class Diagram</i> .....	9
2.3.3 <i>Activity Diagram</i> .....	10
2.4 Bagan Alir ( <i>Flowchart</i> ) .....	11
2.4.1 Bagan Alir Sistem .....	11
2.4.2 Bagan Alir Dokumen .....	14
2.4.3 Bagan Alir Skematik .....	14
2.4.4 Bagan Alir Program .....	14
2.4.5 Bagan Alir Proses .....	14
2.5 Basis Data .....	15
2.6 <i>Structured Query Language</i> (SQL) .....	15
2.7 PHP .....	16
2.8 Pemrograman Berorientasi Objek dalam PHP .....	17
2.9 MySQL .....	19
2.10 PHP Designer 2007 .....	20
2.11 XAMPP .....	20
2.12 Plagiarisme .....	20
2.13 <i>Text Mining</i> .....	21
2.13.1 <i>Information Retrieval</i> (IR) .....	21
2.13.2 <i>Natural Language Processing</i> (NLP) .....	22
2.13.3 Fungsi <i>Text Mining</i> .....	22
2.14 Vektor .....	23
2.14.1 Istilah-istilah Vektor .....	24
2.14.1.1 <i>Vector Length</i> (Panjang Vektor) .....	24
2.14.1.2 <i>Vector Addition</i> (Penambahan Vektor) .....	24
2.14.1.3 <i>Scalar Multiplication</i> (Perkalian Skalar) .....	25
2.14.1.4 <i>Inner Product</i> .....	25

2.14.1.5	<i>Orthogonality</i> (Ortogonalitas).....	25
2.14.1.6	<i>Normal Vector</i> (Vektor Normal).....	26
2.14.1.7	<i>Orthonormal Vector</i> (Vektor Ortonormal).....	26
2.14.1.8	Proses <i>Gram-Schmidt Orthonormalization</i> .....	27
2.15	Matriks .....	28
2.15.1	Notasi Matriks.....	29
2.15.2	Istilah Matriks.....	30
2.15.2.1	<i>Square Matrix</i> .....	30
2.15.2.2	<i>Transpose</i> .....	30
2.15.2.3	<i>Matrix Multiplication</i> (Perkalian Matriks).....	31
2.15.2.4	<i>Identity Matrix</i> (Matriks Identitas) .....	32
2.15.2.5	<i>Orthogonal Matrix</i> (Matriks Ortogonal).....	32
2.15.2.6	<i>Diagonal Matrix</i> (Matriks Diagonal) .....	33
2.15.2.7	<i>Determinant</i> (Determinan) .....	33
2.15.2.8	<i>Eigenvector</i> dan <i>Eigenvalues</i> .....	34
2.16	Ekstraksi Dokumen .....	36
2.16.1	<i>Case Folding</i> dan <i>Tokenizing</i> .....	37
2.16.2	<i>Filtering</i> .....	37
2.16.3	<i>Stemming</i> .....	38
2.17	Algoritma Nazief-Adriani.....	38
2.18	<i>Latent Semantic Indexing</i> (LSI) .....	42
2.18.1	<i>Singular Value Decomposition</i> (SVD) .....	43
2.18.1.1	Contoh SVD Penuh .....	43
2.18.1.2	SVD Tereduksi ( <i>Reduced SVD</i> ).....	49
2.18.1.3	Contoh SVD Tereduksi.....	50
2.19	Algoritma Smith-Waterman .....	52
BAB III ANALISIS DAN RANCANGAN SISTEM .....		55
3.1	Proses Bisnis .....	55
3.1.1	Pengecekan Judul Dokumen .....	55
3.1.2	Pengecekan Isi Dua Dokumen .....	56
3.1.3	Ekstraksi Dokumen.....	58
3.1.4	<i>Case Folding</i> .....	59
3.1.5	<i>Tokenizing</i> .....	60
3.1.6	<i>Filtering</i> .....	60
3.1.7	<i>Stemming</i> dengan Algoritma Nazief-Adriani .....	62
3.1.8	Cek Kamus.....	64
3.1.9	<i>Delete Inflection Suffixes</i> .....	65
3.1.10	Cek <i>Rule Precedence</i> .....	67
3.1.11	Cek <i>Prefix Disallowed Suffixes</i> .....	68
3.1.12	<i>Delete Derivation Suffixes</i> .....	69
3.1.13	<i>Delete Derivation Prefixes</i> .....	71
3.1.14	Proses Pemotongan Kata .....	73
3.2	<i>Entity Relational Diagram</i> (ERD) .....	75
3.2.1	Transformasi ERD .....	75
3.3	<i>Use Case Diagram</i> .....	78
3.3.1	Use Case Scenario.....	78
3.4	<i>Class Diagram</i> .....	80
3.5	<i>Activity Diagram</i> .....	80
3.6	Perancangan Sketsa <i>User Interface</i> .....	81
BAB IV HASIL PENELITIAN .....		86

4.1	Tampilan untuk Perhitungan Kemiripan Judul Dokumen .....	86
4.1.1	Halaman Beranda (Dosen) .....	86
4.1.2	Halaman Pengecekan Kelayakan Topik .....	87
4.1.3	Halaman Pengecekan Topik.....	88
4.2	Tampilan untuk Perhitungan Kemiripan Isi Dua Dokumen.....	89
4.2.1	Halaman Perbandingan Dua Dokumen.....	89
4.2.2	Halaman Hasil Perbandingan Dua Dokumen.....	90
4.3	Tampilan untuk Perhitungan Kemiripan Semua Judul .....	91
4.3.1	Halaman Perhitungan Kemiripan Semua Judul.....	91
4.3.2	Halaman Hasil Perhitungan Kemiripan Judul.....	92
BAB V PEMBAHASAN DAN UJI COBA HASIL PENELITIAN .....		93
BAB VI SIMPULAN DAN SARAN .....		95
6.1	Simpulan .....	95
6.2	Saran .....	95
DAFTAR PUSTAKA.....		xi
RIWAYAT HIDUP PENULIS .....		xiii

## DAFTAR GAMBAR

Gambar 1 Entitas Kuat.....	5
Gambar 2 Entitas Lemah .....	5
Gambar 3 Atribut Komposit.....	6
Gambar 4 Atribut Bernilai Banyak.....	6
Gambar 5 Atribut Turunan .....	6
Gambar 6 Relasi.....	7
Gambar 7 Aktor .....	9
Gambar 8 Tahap <i>Preprocessing</i> .....	37
Gambar 9 <i>Tokenizing</i> .....	37
Gambar 10 <i>Filtering</i> .....	38
Gambar 11 <i>Stemming</i> .....	38
Gambar 12 <i>Flowchart</i> Pengecekan Judul Dokumen .....	56
Gambar 13 <i>Flowchart</i> Pengecekan Isi Dua Dokumen.....	57
Gambar 14 <i>Flowchart</i> Ekstraksi Dokumen.....	58
Gambar 15 <i>Flowchart Case Folding</i> .....	59
Gambar 16 <i>Flowchart Tokenizing</i> .....	60
Gambar 17 <i>Flowchart Filtering</i> .....	61
Gambar 18 <i>Flowchart Stemming</i> dengan Algoritma Nazief-Adriani.....	63
Gambar 19 <i>Flowchart</i> Cek Kamus .....	64
Gambar 20 <i>Flowchart Delete Inflection Suffixes</i> .....	66
Gambar 21 <i>Flowchart</i> Cek <i>Rule Precedence</i> .....	67
Gambar 22 <i>Flowchart</i> Cek <i>Prefix Disallowed Suffixes</i> .....	68
Gambar 23 <i>Flowchart</i> <i>Delete Derivation Suffixes</i> .....	70
Gambar 24 <i>Flowchart</i> Proses Pemotongan Kata .....	74
Gambar 25 <i>Use Case Diagram</i> .....	78
Gambar 26 <i>Activity Diagram</i> Pengecekan Kemiripan Judul Dokumen .....	80
Gambar 27 <i>Activity Diagram</i> Pengecekan Kemiripan Isi Dua Dokumen.....	81
Gambar 28 Sketsa Halaman Beranda Dosen .....	82
Gambar 29 Sketsa Halaman Pengecekan Kelayakan Topik .....	82
Gambar 30 Sketsa Halaman Pengecekan Topik.....	83
Gambar 31 Sketsa Halaman Perbandingan Dua Dokumen .....	84
Gambar 32 Sketsa Halaman Hasil Perbandingan Dua Dokumen .....	84
Gambar 33 Sketsa Halaman Perhitungan Kemiripan Semua Judul .....	85
Gambar 34 Sketsa Halaman Hasil Perhitungan Kemiripan Semua Judul.....	85
Gambar 35 Halaman Beranda (Dosen).....	86
Gambar 36 Halaman Pengecekan Kelayakan Topik.....	87
Gambar 37 Halaman Pengecekan Topik .....	88
Gambar 38 Halaman Perbandingan Dua Dokumen .....	89
Gambar 39 Halaman Hasil Perbandingan Dua Dokumen .....	90
Gambar 40 Halaman Perhitungan Kemiripan Semua Judul .....	91
Gambar 41 Halaman Hasil Perhitungan Kemiripan Judul .....	92

## DAFTAR TABEL

Tabel I Simbol <i>Flowchart</i> .....	12
Tabel II 1997 <i>Fitness International Scorecard</i> . Source: Muscle & Fitness July 1997, p.139 .....	28
Tabel III Kata x Dokumen Terhadap Beberapa Dokumen Buatan.....	30
Tabel IV Kombinasi Prefiks dan Sufiks yang Tidak Diizinkan.....	40
Tabel V Contoh Tabel Kata x Dokumen.....	50
Tabel VI Tabel Pengguna .....	75
Tabel VII Tabel Mahasiswa.....	75
Tabel VIII Tabel Dosen .....	75
Tabel IX Tabel Jabatan.....	75
Tabel X Tabel Topik.....	76
Tabel XI Tabel Belum Lulus.....	76
Tabel XII Tabel Sudah Lulus.....	76
Tabel XIII Tabel Pengumpulan Topik .....	76
Tabel XIV Tabel Revisi .....	77
Tabel XV Tabel Semester .....	77
Tabel XVI Tabel Dosen Mengurus Topik .....	77
Tabel XVII Tabel Stoplist .....	77
Tabel XVIII Tabel Katadasar .....	77
Tabel XIX Uji Kasus Perhitungan Kemiripan Judul Dokumen.....	93
Tabel XX Uji Kasus Perhitungan Kemiripan Isi Dua Dokumen .....	93
Tabel XXI Uji Kasus Kemiripan Semua Judul Dokumen .....	94

## DAFTAR LAMPIRAN

LAMPIRAN A.....	A-1
LAMPIRAN B.....	B-1
LAMPIRAN C.....	C-1
LAMPIRAN D.....	D-1