

**IMPLEMENTASI MODUL INDEXING PADA SEARCH ENGINE
TELUSURI DENGAN INTEGRASI INVERTED INDEX DAN
GENERALIZED SUFFIX TREE UNTUK MEREDUKSI WAKTU
PENCARIAN**

Skripsi

**Disusun untuk memenuhi salah satu syarat
memperoleh gelar Sarjana Komputer**



*Mencerdaskan dan
Memartabatkan Bangsa*

Oleh:
Mochammad Hanif Ramadhan
1313619025

**PROGRAM STUDI ILMU KOMPUTER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI JAKARTA**

2023

ABSTRAK

MOCHAMMAD HANIF RAMADHAN. Implementasi Modul Indexing Pada Search Engine Telusuri Dengan Integrasi Inverted Index Dan Generalized Suffix Tree Untuk Mereduksi Waktu Pencarian. Skripsi. Program Studi Ilmu Komputer. Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta. Agustus 2023. Di bawah bimbingan Muhammad Eka Suryana, M.Kom dan Med Irzal, M.Kom.

Mesin pencari atau *search engine* adalah program komputer yang digunakan untuk melakukan pencarian situs web. Pencarian dapat dilakukan dengan mengumpulkan informasi tentang halaman web terlebih dahulu. Karena ukuran data yang besar sebagai sumber informasi utama bagi mesin pencari, penggunaan *index* bisa dimanfaatkan untuk mereduksi waktu pencarian. Penelitian ini merupakan bagian dari rangkaian penelitian mesin pencari *Telusuri*, dan bertujuan untuk membuat implementasi *index* berdasarkan struktur *inverted index*, yaitu struktur *index* yang digunakan oleh mesin pencari *Google*, dan melakukan integrasi dengan struktur *Generalized Suffix Tree*. Tujuan utamanya adalah untuk mereduksi waktu pencarian suatu *keyword* dan memberikan peringkat terhadap dokumen berdasarkan kesesuaian antara informasi dalam dokumen dengan teks yang dimasukkan oleh pengguna. Hasil akhir dari implementasi modul menunjukkan reduksi waktu yang signifikan, berkisar antara 89 - 98%.

Kata kunci: *mesin pencari, indeks, basis data, teori informasi*

ABSTRACT

MOCHAMMAD HANIF RAMADHAN. Implementasi Modul Indexing Pada Search Engine Telusuri Dengan Integrasi Inverted Index Dan Generalized Suffix Tree Untuk Mereduksi Waktu Pencarian. Mini Thesis. Computer Science. Faculty of Mathematics and Natural Sciences, Universitas Negeri Jakarta. August 2023. Under guidance from Muhammad Eka Suryana, M.Kom and Med Irzal, M.Kom.

Search engine is a computer program that is used to search for a webpage. Before searching can be done, it is required to gather information about the webpage first. Due to the large collection of data needed for a search engine to be usable, indexes can be used to reduce time to retrieve information. This research is a part of a longer research for *Telusuri* search engine, and aims to implement an index structure based on inverted index form, which are used by *Google*, and integrates it with the *Generalized Suffix Tree*. The goal is to reduce the time taken to get informations from a given keyword and ranks the result based on the relevancy between the webpage and the input keyword. The index implementations are shown to be able to reduce the time taken significantly, ranging from 89 to 98%.

Kata kunci: *search engine, indexing, database, information retrieval, tree*

LEMBAR PERSETUJUAN HASIL SIDANG SKRIPSI

IMPLEMENTASI MODUL INDEXING PADA SEARCH ENGINE TELUSURI DENGAN INTEGRASI INVERTED INDEX DAN GENERALIZED SUFFIX TREE UNTUK MEREDUKSI WAKTU PENCARIAN

Nama : Mochammad Hanif Ramadhan

No. Registrasi : 1313619025

Penanggung Jawab

Dekan : Prof. Dr. Muktiningsih N. M.Si.
NIP. 196405111989032001



1-09-2023

Wakil Penanggung Jawab

Wakil Dekan I : Dr. Esmar Budi, S.Si., MT.
NIP. 197207281999031002

1-09-2023

Ketua : Drs. Mulyono, M.Kom.
NIP. 19660517 199403 1 003

23-08-2023

Sekretaris : Ari Hendarno, S.Pd., M.Kom.
NIP. 19881102 202203 1 002

23-08-2023

Pengaji : Dr. Ria Arafiah, M.Si.
NIP. 19751121 200501 2 004

23-08-2023

Pembimbing I : Muhammad Eka Suryana, M.Kom.
NIP. 19851223 201212 1 002

22-08-2023

Pembimbing II : Med Irvan, M.Kom.
NIP. 19770615 200312 1 001

23-08-2023

Dinyatakan lulus UJIAN SKRIPSI tanggal: 21 Agustus 2023

LEMBAR PERNYATAAN

Saya menyatakan dengan sesungguhnya bahwa skripsi dengan judul "**Implementasi Modul Indexing Pada Search Engine Telusuri Dengan Integrasi Inverted Index Dan Generalized Suffix Tree Untuk Mereduksi Waktu Pencarian**" yang disusun sebagai syarat untuk memperoleh gelar Sarjana Komputer dari Program Studi Ilmu Komputer Universitas Negeri Jakarta adalah karya ilmiah saya dengan arahan dari dosen pembimbing.

Sumber informasi yang diperoleh dari peneliti lain yang telah dipublikasikan yang disebutkan dalam teks Skripsi ini, telah dicantumkan dalam Daftar Pustaka sesuai dengan norma, kaidan dan etika penulisan ilmiah.

Jika dikemudian hari ditemukan sebagian besar skripsi ini bukan hasil karya saya sendiri dalam bagian-bagian tertentu, saya bersedia menerima sanksi pencabutan gelar akademik yang saya sanding dan sanksi-sanksi lainnya sesuai dengan peraturan perundang-undangan yang berlaku.

Jakarta - 21 Agustus 2023



Mochammad Hanit Ramadhan



KEMENTERIAN PENDIDIKAN DAN KEBUDAYAAN
UNIVERSITAS NEGERI JAKARTA
UPT PERPUSTAKAAN

Jalan Rawamangun Muka Jakarta 13220
Telepon/Faksimili: 021-4894221
Laman: lib.unj.ac.id

**LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademika Universitas Negeri Jakarta, yang bertanda tangan di bawah ini, saya:

Nama : MOCHAMMAD HANIF RAMADHAN
NIM : 1313619025
Fakultas/Prodi : FMIPA / ILMU COMPUTER
Alamat email : eternal70@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada UPT Perpustakaan Universitas Negeri Jakarta, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah:

Skripsi Tesis Disertasi Lain-lain (.....)

yang berjudul :

IMPLEMENTASI MODUL INDEXING PADA SEARCH ENGINE TELUSURI DENGAN

INTEGRASI INVERTED INDEX DAN GENERALIZED SUFFIX TREE UNTUK MEREDUKSI

WAKTU PENCARIAN

Dengan Hak Bebas Royalti Non-Ekslusif ini UPT Perpustakaan Universitas Negeri Jakarta berhak menyimpan, mengalihmediakan, mengelolanya dalam bentuk pangkalan data (*database*), mendistribusikannya, dan menampilkan/mempublikasikannya di internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan Universitas Negeri Jakarta, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini saya buat dengan sebenarnya.

Jakarta, 2 September 2023

Penulis

(MOCHAMMAD HANIF R)
nama dan tanda tangan

KATA PENGANTAR

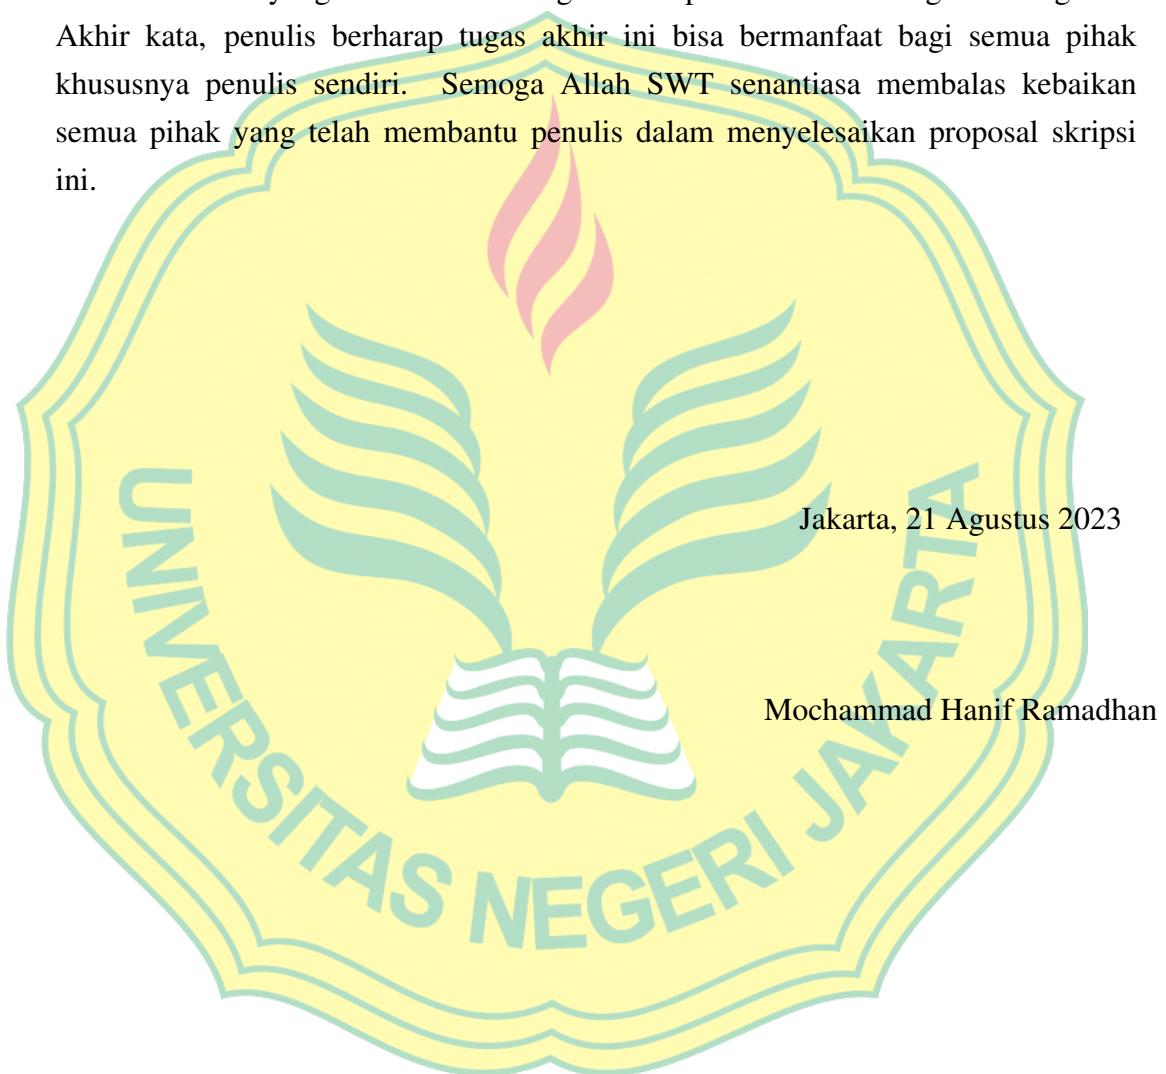
Puji syukur penulis panjatkan ke hadirat Allah SWT, karena dengan rahmat dan karunia-Nya, penulis dapat menyelesaikan proposal skripsi yang berjudul *Implementasi Modul Indexing Pada Search Engine Telusuri Dengan Integrasi Inverted Index Dan Generalized Suffix Tree Untuk Mereduksi Waktu Pencarian*.

Keberhasilan dalam penyusunan proposal skripsi ini tidak lepas dari bantuan berbagai pihak yang mana dengan tulus dan ikhlas memberikan masukan guna sempurnanya proposal skripsi ini. Oleh karena itu dalam kesempatan ini, dengan kerendahan hati penulis mengucapkan banyak terima kasih kepada:

1. Yth. Para petinggi di lingkungan FMIPA Universitas Negeri Jakarta.
2. Yth. Ibu Dr. Ria Arafiyah, M.Si selaku Koordinator Program Studi Ilmu Komputer.
3. Yth. Bapak Muhammad Eka Suryana, M.Kom selaku Dosen Pembimbing I yang telah membimbing, mengarahkan, serta memberikan saran dan koreksi terhadap proposal skripsi ini.
4. Yth. Bapak Med Irzal, M.Kom selaku Dosen Pembimbing II yang telah membimbing, mengarahkan, serta memberikan saran dan koreksi terhadap proposal skripsi ini.
5. Kedua orang tua dan kakak penulis yang telah mendukung dan memberikan semangat serta doa untuk penulis.
6. Wulan sebagai seseorang yang mau mendengarkan keluh kesah dan mendukung penulis.
7. Teman-teman Warung Tegang yang walau dengan segala keanehananya selalu memberikan semangat dan motivasi bagi penulis
8. Teman-teman SMAN 68 yang seringkali menemani penulis bertukar pikiran ketika beristirahat sejenak selama penulisan
9. Teman-teman Program Studi Ilmu Komputer 2019 yang telah memberikan dukungan dan memiliki andil dalam penulisan proposal skripsi ini.

10. Kedua kucing milik Pak Eka yang seringkali menghibur penulis selama melaksanakan bimbingan di Jasinga

Penulis menyadari bahwa penyusunan proposal skripsi ini masih jauh dari sempurna karena keterbatasan ilmu dan pengalaman yang dimiliki. Oleh karenanya, kritik dan saran yang bersifat membangun akan penulis terima dengan senang hati. Akhir kata, penulis berharap tugas akhir ini bisa bermanfaat bagi semua pihak khususnya penulis sendiri. Semoga Allah SWT senantiasa membalas kebaikan semua pihak yang telah membantu penulis dalam menyelesaikan proposal skripsi ini.



DAFTAR ISI

KATA PENGANTAR	iv
ABSTRAK	v
ABSTRACT	vi
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
DAFTAR TABEL	1
II KAJIAN PUSTAKA	6
2.1 Proses <i>Indexing</i>	6
2.2 <i>Repository</i>	7
2.3 Daftar URL	7
2.4 <i>Document Index</i>	7
2.5 Daftar Kosakata	8
2.6 <i>docID</i> dan <i>wordID</i>	8
2.7 <i>Inverted Index</i>	8
2.7.1 Struktur Index	9
2.7.2 Skema Penyimpanan Index	11
2.7.3 Pemeringkatan Query	11
2.7.4 <i>Similarity Scoring</i>	12
2.8 Proses Pembuatan Index	12
2.8.1 Pengolahan Query	14
2.9 <i>Jaccard Distance</i>	15
2.10 Komunikasi antar proses	16
2.11 Modul <i>typing</i> pada Python	17
2.12 Perbandingan Metode <i>Indexing</i>	17
2.12.1 <i>Signature File Index</i>	17
2.12.2 <i>Bitmap Index</i>	18
2.12.3 <i>WordNet</i>	18

III METODOLOGI PENELITIAN	19
3.1 Tahapan Penelitian	19
3.2 Konstruksi Index	20
3.3 Daftar kata umum	22
3.4 Metode Pemeringkatan	23
3.4.1 <i>Word distance (γ)</i>	23
3.4.2 <i>Word similarity (β)</i>	24
3.5 Modifikasi Arsitektur <i>Telusuri</i>	25
3.6 Skema Pencarian	26
3.7 Alat dan Bahan Penelitian	30
3.8 Tahapan Pengembangan	30
3.8.1 Meningkatkan kemampuan modul <i>indexing</i> saat ini	30
3.8.2 Rancangan Eksperimen	31
IV HASIL DAN PEMBAHASAN	33
4.1 Implementasi	33
4.1.1 Pengolahan <i>Dataset</i>	34
4.1.2 Pembentukan <i>Inverted Index</i>	35
4.1.3 Pengolahan <i>User Query</i>	38
4.1.4 Proses Penggabungan <i>Hitlist</i> dan Pemeringkatan Hasil	41
4.1.5 Integrasi dengan <i>Generalized Suffix Tree (GST)</i>	45
4.1.6 Modifikasi kode <i>TF-IDF</i>	49
4.1.7 Struktur Direktori Kode	54
4.2 Pengujian	54
4.2.1 Statistik Pengujian	54
4.2.2 Pengujian Relevansi	56
4.2.3 Pengujian Performa	64
4.3 Analisis Hasil	64
V KESIMPULAN DAN SARAN	66
5.1 Kesimpulan	66
5.2 Saran	66
DAFTAR PUSTAKA	68
LAMPIRAN	69
A Dokumentasi Pengujian Metode <i>Inverted Index</i>	69
B Dokumentasi Pengujian Metode <i>Inverted Index</i> dan Integrasi <i>GST</i>	71