

**PERBANDINGAN PONTE-CROFT DAN JELINEK-MERCER
SMOOTHING DALAM QUERY LIKELIHOOD MODEL**

TUGAS AKHIR



Disusun oleh :

**Martin Eric Gunawan
22074206**



**Program Studi Teknik Informatika Fakultas Teknologi Informasi
Universitas Kristen Duta Wacana
Tahun 2011**

**PERBANDINGAN PONTE-CROFT DAN JELINEK-MERCER
SMOOTHING DALAM QUERY LIKELIHOOD MODEL**

TUGAS AKHIR



Diajukan kepada Fakultas Teknologi Informasi
Universitas Kristen Duta Wacana

Sebagai salah satu syarat dalam memperoleh gelar
Sarjana Komputer



Disusun oleh :

Martin Eric Gunawan

22074206

**Program Studi Teknik Informatika
Universitas Kristen Duta Wacana
Tahun 2011**

PERNYATAAN KEASLIAN TUGAS AKHIR

Saya menyatakan dengan sesungguhnya bahwa tugas akhir dengan judul :

Penambahan Jelinek-Mercer Smoothing Dalam Query Likelihood Model Untuk Peningkatan Akurasi Sistem Temu Kembali Informasi

yang saya kerjakan untuk melengkapi sebagian persyaratan menjadi Sarjana Komputer pada pendidikan sarjana Program Studi Teknik Informatika, Fakultas Teknologi Informasi Universitas Kristen Duta Wacana, bukan merupakan tiruan atau duplikasi dari skripsi kesarjanaan di lingkungan Universitas Kristen Duta Wacana maupun di Perguruan Tinggi atau instansi manapun, kecuali bagian yang sumber informasinya dicantumkan sebagaimana mestinya.

Jika dikemudian hari didapati bahwa hasil skripsi ini adalah plagiasi atau tiruandari skripsi lain, saya bersedia dikenai sanksi yakni pencabutan gelar kesarjanaan saya.

Yogyakarta, Juli 2011


(Martin Eric Gunawan)

22074206



HALAMAN PENGESAHAN

SKRIPSI

PERBANDINGAN PONTE-CROFT DAN JELINEK-MERCER SMOOTHING DALAM QUERY LIKELIHOOD MODEL

Oleh : Martin Eric Gunawan / 22 07 4206

Dipertahankan di depan dewan Pengaji Tugas Akhir
Program Studi Teknik Informatika Fakultas Teknologi Informasi
Universitas Kristen Duta Wacana Yogyakarta
Dan dinyatakan diterima untuk memenuhi salah satu

Syarat memperoleh gelar

Sarjana Komputer

Pada tanggal

26 Juli 2011

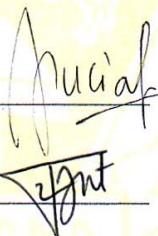
11/8/2011

Yogyakarta,

Mengesahkan,

Dewan Pengaji:

1. Lucia Dwi Krisnawati, S.S., M.A.
2. Budi Susanto, S. Kom., M.T.
3. Antonius R, S. Kom, M. Cs
4. Yuan Lukito, S.Kom


Lucia
Dwi
Krisnawati


Budi
Susanto



Dekan

(Drs. Wiminie Handiwidjojo, MIT)

Ketua Program Studi


Nugroho
Agus
Haryono

(Nugroho Agus Haryono S.Si.,MSi.)

HALAMAN PERSETUJUAN

Judul : Penambahan Jelinek-Mercer Smoothing dalam Query Likelihood Model untuk Peningkatan Akurasi Sistem Temu Kembali Informasi

Nama : Martin Eric Gunawan

NIM : 22074206

Mata Kuliah : Tugas Akhir

Kode : TI 2126

Semester : Genap

Tahun Akademik : 2010/2011

Telah diperiksa dan disetujui

Di Yogyakarta,

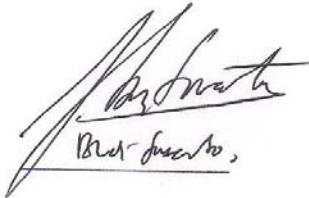
Pada tanggal 13 Juli 2011

Dosen Pembimbing 1

Dosen Pembimbing 2



Lucia D. Kristyawati



M. Martin
Martin
Martins

UCAPAN TERIMA KASIH

Puji dan Syukur saya haturkan kepada Tuhan yang selalu membimbing saya dalam mengerjakan Tugas Akhir ini. Saya juga tidak lupa mengucapkan terima kasih kepada Papah, Mamah, dan Oh Henry yang sudah mendukung saya dalam doa sehingga saya dapat menyelesaikan Tugas Akhir ini. Saya juga tidak lupa mengucapkan terima kasih kepada Rudy yang telah menjadi sahabat dan teman untuk diskusi dalam mengerjakan Tugas Akhir ini. Terima kasih juga saya sampaikan kepada Ko Dddy yang telah membimbing dan memberikan masukan untuk pembangunan sistem yang saya buat.

Tidak Lupa saya juga berterima kasih kepada Andhri yang telah membantu saya dalam memberikan informasi dan trik-trik untuk optimalisasi *database* dan *code*. Saya tidak lupa mengucapkan terima kasih kepada Aka yang telah menemani dan menyemangati saya dalam mengerjakan Tugas Akhir ini. Saya juga mengucapkan banyak terima kasih kepada Ibu Lucia Dwi Krisnawati dan Bapak Budi Susanto yang telah menjadi dosen pembimbing saya. Beliau-beliau inilah yang telah membantu saya dengan cara member masukan-masukan, kritik maupun saran terhadap Tugas Akhir saya.

Saya juga ingin mengucapkan terima kasih kepada keluarga kedua saya yaitu keluarga PSPP (Pusat Studi dan Pengembangan Perdamaian) dan Duta Voice. Semua rekan-rekan yang ada di 2 unit tersebut sangat mendukung saya dalam penggerjaan Tugas Akhir ini. Saya juga mendapat pengalaman yang sangat berharga dari setiap kegiatan yang saya ikuti selama bergabung dalam kedua unit tersebut. Satu lagi yang perlu saya ucapkan terima kasih yaitu para sahabat-sahabatku KC (Kebo Ceria) dan Hexa. Terima kasih semuanya, semoga kita semua sukses ^_^

Yogyakarta, Juli 2011

Penulis

INTISARI

Informasi merupakan hal yang sangat penting bagi semua orang. Informasi tersebut sebagian besar digunakan untuk menunjang pekerjaannya ataupun untuk menambah pengetahuan umum seseorang. Jumlah informasi yang sangat besar dan banyak merupakan suatu latar belakang untuk membuat suatu mesin pencarian informasi. Dewasa ini, mesin pencarian informasi tersebut makin lama makin canggih dan menghasilkan informasi yang sangat relevan bagi penggunanya. Mesin pencari informasi yang biasa dikenal dengan sistem temu kembali informasi (*Information Retrieval*) dapat menggunakan metode-metode tertentu. Tidak semua metode dapat menjawab kebutuhan dari pengguna.

Pada penelitian ini penulis membandingkan 2 (dua) metode *smoothing* pada *Query Likelihood Model* yang biasa digunakan untuk membangun *Information Retrieval* (IR) antara lain *Ponte Croft experience* dan *Jelinek Mercer*. Kedua metode tersebut memiliki kegunaan memberi bobot pada setiap token di tiap dokumen, sehingga sistem dapat menyajikan dokumen-dokumen yang kira-kira sesuai dengan kebutuhan pengguna.

Dari penelitian yang dibuat penulis ini terlihat bahwa performa dari kedua metode tersebut hampir sama. Kedua metode tersebut memiliki perbedaan hanya diposisi peringkat dokumen yang dianggap sistem paling relevan, sementara untuk jumlah dokumen yang ditemukan kembali sama.

DAFTAR ISI

PERNYATAAN KEASLIAN TUGAS AKHIR.....	i
HALAMAN PERSETUJUAN.....	ii
UCAPAN TERIMA KASIH.....	iii
INTISARI.....	iv
DAFTAR ISI.....	v
DAFTAR TABEL.....	viii
DAFTAR GAMBAR	x
Bab 1 PENDAHULUAN	1
1.1 Latar Belakang Masalah.....	1
1.2 Perumusan Masalah.....	2
1.3 Batasan Masalah.....	2
1.4 Tujuan Penelitian.....	2
1.5 Hipotesis.....	2
1.6 Metode/Pendekatan	3
1.7 Sistematika Penulisan.....	3
Bab 2 LANDASAN TEORI.....	4
2.1 Tinjauan Pustaka	4
2.2 Landasan Teori.....	6
<i>1. Information Retrieval</i>	6

2. Language Model.....	9
2.1. Query Likelihood	9
2.2. Ponte-Croft experience.....	10
2.3. Jelinek-Mercer Smoothing Method	11
3. Precision dan Recall.....	17
4. Interpolated Precision dan Recall.....	18
Bab 3 ANALISIS DAN PERANCANGAN SISTEM	20
3.1 Alat	20
3.2 Bahan.....	20
3.3 Use Case.....	21
3.4 Perancangan Masukan.....	24
3.5 Prancangan Keluaran.....	24
3.6 Perancangan Proses	25
3.7 Perancangan Antar Muka	29
3.8.1 Form Manipulasi Dokumen.....	30
3.8.2 Form Manipulasi Stopword.....	31
3.8.3 Form Pencarian Informasi.....	32
3.8 Perancangan Basis Data	32
3.9 Perancangan Evaluasi.....	33
Bab 4 IMPLEMENTASI DAN ANALISIS SISTEM	37
4.1 Implementasi Sistem	37

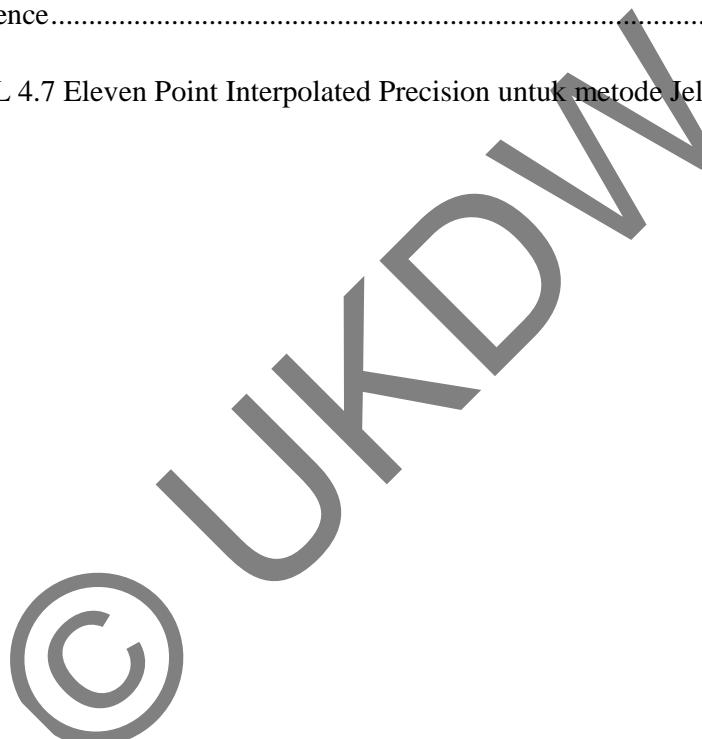
4.1.1 Korpus	37
4.1.2 Manipulasi Stopword	37
4.1.3 Manipulasi Dokumen	38
4.1.4 <i>Indexing</i>	38
4.1.4 Pencarian	44
4.2 Pengujian dan Evaluasi Sistem.....	46
Bab 5 KESIMPULAN DAN SARAN	58
5.1 Kesimpulan.....	58
5.2 Saran	58
DAFTAR PUSTAKA	59



DAFTAR TABEL

TABEL 2.1 Jumlah Dokumen tiap <i>term</i> (dl_d)	12
TABEL 2.2 Frekuensi Dokumen setiap <i>term</i> (df_t)	12
TABEL 2.3 Jumlah token di korpus (cf_t)	12
TABEL 2.4 Jumlah <i>term</i> tiap dokumen $tf(t,D)$	13
TABEL 2.5 Probabilitas <i>Maximum Likelihood</i> tiap <i>term</i>	13
TABEL 2.6 Probabilitas rata-rata setiap <i>term</i> (P_{avg}).....	14
TABEL 2.7 Rata-rata frekuensi setiap <i>term</i> (\bar{f}_t).....	14
TABEL 2.8 Nilai <i>risk</i> setiap <i>term</i>	14
TABEL 2.9 Pembobotan <i>term</i> menggunakan <i>Ponte-Croft experience</i>	15
TABEL 2.10 Hasil perankingan menggunakan <i>Ponte-Croft experience</i>	16
TABEL 2.11 Probabilitas setiap <i>term</i> dalam korpus $P(t C)$	16
TABEL 2.12 Pembobotan <i>term</i> menggunakan metode <i>smoothing Jelinek-Mercer</i>	17
TABEL 2.13 Perangkingan menggunakan metode <i>smoothing Jelinek-Mercer</i>	17
TABEL 3.1 <i>Use case text</i> manipulasi <i>stopword</i>	21
TABEL 3.2 <i>Use case text</i> manipulasi dokumen	22
TABEL 3.3 <i>Use case text</i> pencarian informasi	23
TABEL 3.4 <i>Use case text</i> menampilkan hasil pencarian	23
TABEL 3.5 Daftar query dan dokumen yang relevan	34

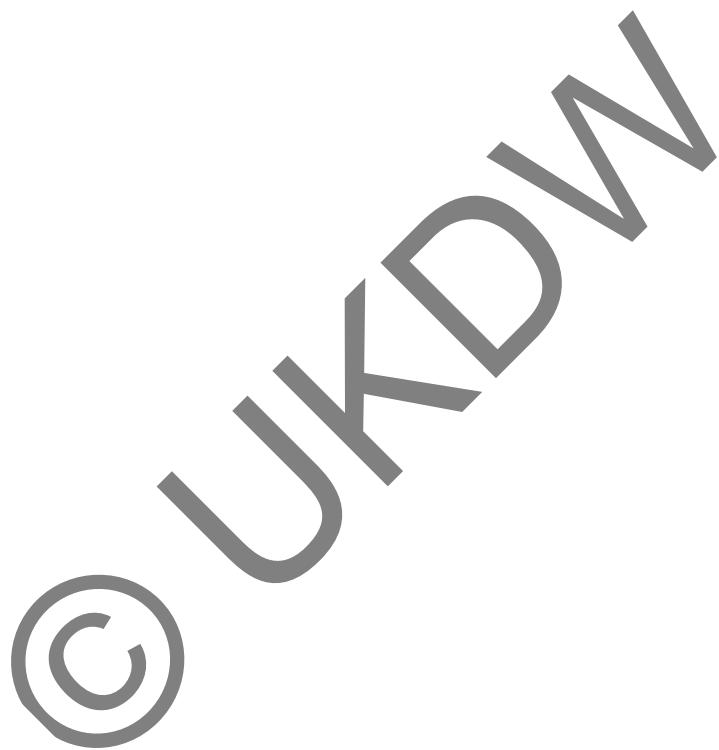
TABEL 4.1 Hasil Pengujian 15 <i>Query</i>	46
TABEL 4.2 Hasil Pengujian menggunakan Ponte Croft Experience	47
TABEL 4.3 Hasil Pengujian menggunakan Jelinek Mercer	48
TABEL 4.4 Eleven Point Precision untuk metode Ponte Croft Experience	51
TABEL 4.5 Eleven Point Precision untuk metode Jelinek Mercer.....	52
TABEL 4.6 Eleven Point Interpolated Precision untuk metode Ponte Croft Experience.....	54
TABEL 4.7 Eleven Point Interpolated Precision untuk metode Jelinek Mercer ...	55



DAFTAR GAMBAR

GAMBAR 2.1 <i>Information Retrieval Processes</i>	7
GAMBAR 2.2 Grafik <i>Interpolated average precision</i>	18
GAMBAR 3.1 <i>Use case diagram</i> sistem temu kembali informasi	21
GAMBAR 3.2 Flowchart Temu Kembali Informasi	25
GAMBAR 3.3 <i>Flowchart</i> Pra Pemrosesan Dokumen dan Query	26
GAMBAR 3.4 <i>Flowchart</i> Proses Pembobotan <i>term</i> menggunakan <i>Ponte Croft Experience</i>	27
GAMBAR 3.5 <i>Flowchart</i> Proses Pembobotan <i>term</i> menggunakan metode <i>smoothing Jelinek Mercer</i>	27
GAMBAR 3.6 <i>Flowchart</i> perhitungan <i>similarity coefisien</i>	28
GAMBAR 3.7 <i>Sitemap</i> sistem temu kembali informasi	29
GAMBAR 3.8 Rancangan Antar Muka Halaman Utama.....	30
GAMBAR 3.9 Rancangan Antar Muka Form Penambahan Dokumen	31
GAMBAR 3.10 Rancangan Antar Muka Form Manipulasi <i>Stopword</i>	31
GAMBAR 3.11 Rancangan Antar Muka Halaman Pencarian.....	32
GAMBAR 3.12 Diagram E-R untuk Sistem Temu Kembali Informasi	33
GAMBAR 4.1 <i>Pseudocode</i> Penambahan <i>Stopword</i>	37
GAMBAR 4.2 <i>Pseudocode</i> Pra Pemrosesan	38
GAMBAR 4.3 <i>Pseudocode</i> salin isi token ke semua dokumen.....	39
GAMBAR 4.4 <i>Pseudocode</i> salin isi token menggunakan <i>Bulk Insert</i>	41

GAMBAR 4.5 <i>Pseudocode</i> pemberian bobot tiap <i>term</i>	42
GAMBAR 4.6 <i>Pseudocode</i> Pencarian	44
GAMBAR 4.7 Grafik Interpolated Precision Recall	56



BAB 1

PENDAHULUAN

1.1 Latar Belakang

Pencarian informasi yang sulit menjadi pokok masalah pada saat *user* mencari suatu informasi dari suatu dokumen yang sangat besar dan banyak. Sistem pencarian informasi terus berkembang seiring berjalannya waktu, dengan penerapan suatu metode tertentu membuat sistem pencarian informasi tersebut menjadi otomatis dan mempermudah *user* untuk mencari informasi.

Information Retrieval (IR) merupakan suatu sistem pencari otomatis yang dapat menyelesaikan permasalahan pencarian yang lambat tersebut. Sistem ini biasanya berbasis *web* yang memiliki korpus yang sangat besar. Penerapan langkah – langkah *IR* antara lain pemotongan kata (tokenisasi), penghapusan *stopword*, pemberian bobot pada setiap kata hingga proses evaluasi dengan memperhitungkan *precision* dan *recall*.

Pada penelitian ini, penulis akan menggunakan metode *Query Likelihood Model* yang merupakan salah satu metode *IR* yang dapat memecahkan masalah pencarian informasi yang lambat tersebut. Pada penelitian ini pula, penulis akan menambahkan metode *Jelinek Mercer Smoothing* agar mendapatkan hasil yang lebih optimal.

Penulis berharap bahwa dengan penambahan *Jelinek – Mercer Smoothing* pada *Query Likelihood Model*, *user* mendapatkan hasil yang lebih cepat dan lebih relevan.

1.2 Rumusan Masalah

1. Bagaimana perbandingan kinerja metode smoothing *Ponte-Croft experience* dan *Jelinek-Mercer Smoothing Method*?

1.3 Batasan Masalah

Dalam tugas akhir ini, penulis membatasi penelitian dengan beberapa batasan yang didefinisikan di bawah ini:

1. Dokumen teks yang menjadi korpus data adalah *file plain text* yang berekstensi .txt.
2. Jumlah maksimal *file .txt* yang diteliti adalah 110 *file*.
3. Kamus data yang akan dipakai akan diambil dari <http://internasional.kompas.com/> dengan topik
4. *Query* yang diberikan tidak memperhitungkan operator boolean.
5. Tidak dilakukan proses *stemming* untuk setiap *token*.
6. Dalam pencarian, sistem bersifat contextual
7. Panjang *query* dibatasi maksimal 5 kata.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini yaitu dapat membandingkan performa dari metode *Ponte-Croft experience* dan metode *smoothing Jelinek-Mercer*.

1.5 Hipotesis

Dengan penelitian ini, penulis menduga dengan penggunaan metode *Query Ponte-Croft experience* nilai presisinya akan lebih baik daripada menggunakan metode *smoothing Jelinek-Mercer*.

1.6 Metode / Pendekatan

Tahap pertama yang dilakukan penulis yaitu mengumpulkan kamus data dengan cara menyalin dari situs – situs *web* dan kemudian akan disimpan kedalam *plain text* dengan format .txt. Proses kedua yang dilakukan yaitu menerapkan metode *Query Likelihood Model* pada program yang akan dibuat kemudian kamus data dimasukkan dan dilakukan proses evaluasi dengan memperhitungkan *precision* dan *recall*.

Proses ketiga yang dilakukan setelah metode *Query Likelihood Model* diterapkan adalah penulis akan menambahkan metode *Jelinek – Mercer Smoothing* pada program yang diteliti. Penulis akan menggunakan kamus data yang sama ketika melakukan penelitian dan evaluasi terhadap metode *Query Likelihood Model*. Hasil evaluasi dari *Query Likelihood Model* dan dengan penambahan *Smoothing* akan dibandingkan dan akan diperoleh hasilnya.

1.7 Sistematika Penulisan

Laporan yang akan dibuat oleh penulis terdiri dari 5 bab. Bab 1 PENDAHULUAN berisi tentang gambaran umum dari penelitian yang akan dilakukan oleh penulis. Bab 2 LANDASAN TEORI yang berisi tentang dasar teori dan hasil penelitian yang ditulis dalam jurnal – jurnal mengenai topik penelitian yang sama yang diambil oleh penulis. Bab 3 RANCANGAN SISTEM yang berisi tentang cara kerja sistem yang akan dibuat oleh penulis. Bab 4 IMPLEMENTASI DAN ANALISIS SISTEM yang berisi tentang hasil penelitian yang dilakukan dan yang telah diterapkan kedalam *program*. Bab 5 KESIMPULAN DAN SARAN yang berisi tentang jawaban dari hipotesis yang telah dibuat pada bab 1 dan saran – saran yang diberikan oleh penulis agar penerapan metode ini dapat menjadi lebih baik.

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Setelah melakukan penelitian mengenai penerapan metode *Ponte-Croft experience* dan metode *smoothing Jelinek-Mercer* dengan korpus dari <http://internasional.kompas.com>, kedua metode tersebut memiliki hasil temu kembali yang hampir sama. Hasil temu kembali dari kedua metode tersebut sangat dipengaruhi oleh probabilitas suatu token yang muncul. Jika token *query* jarang muncul dalam korpus, maka nilai probabilitasnya akan menjadi semakin kecil juga.

Pembobotan token untuk metode *Ponte-Croft experience* sangat dipengaruhi oleh probabilitas munculnya suatu token. Sedangkan metode *Jelinek-Mercer* dipengaruhi oleh perubahan nilai konstanta λ . Dari rentang nilai konstanta λ yang diuji ($0,1 \leq \lambda \leq 1$) maka dapat disimpulkan bahwa nilai konstanta λ semakin besar maka hasilnya akan mendekati sama dengan perhitungan bobot yang menggunakan *Ponte-Croft experience*. Hasil temu kembali informasi untuk kedua metode tersebut tidak terpengaruh dengan adanya *query* yang berupa kata-kata berulang.

Kedua metode ini lebih cocok diterapkan pada sistem yang jarang melakukan *update* data sebab waktu yang diperlukan untuk update data cukup lama. Waktu pengindeksan akan terus meningkat sesuai dengan dokumen yang dimasukkan ke dalam korpus sistem.

5.2 Saran

Untuk pengembangan sistem selanjutnya yang lebih baik, penulis memiliki beberapa saran diantaranya adalah pada metode *Jelinek Mercer* dapat diubah untuk

menguji nilai konstanta. Berdasarkan jurnal yang ditulis oleh Zhou dan Lafferty, semakin kecil nilai λ maka semakin cocok untuk *query* yang lebih panjang, tetapi jika nilai λ semakin besar maka semakin cocok untuk *query* yang pendek.

Penerapan kedua metode ini lebih baik tidak menggunakan basis data untuk media penyimpanan, sebab jika disimpan dalam basis data maka waktu yang diperlukan untuk melakukan *indexing* dan perhitungan akan sangat lama dan kurang efisien. Proses *indexing* untuk kedua metode tersebut menjadi sangat lama sebab setiap dokumen memiliki semua token yang tidak berada pada dokumen itu sendiri. Saran dari penulis adalah penyimpanan informasi token pada saat proses *indexing* dan perhitungan bobot token lebih baik disimpan pada suatu *file* teks sehingga ketika *user* akan melakukan *indexing* hanya memanggil *file* tersebut.

Penulis juga memiliki saran untuk masukkan kata kunci dapat menggunakan *operator boolean* sehingga dapat menggabungkan beberapa *query* sekaligus. Kemudian untuk panjang *query* dapat dibuat lebih dari 5 kata sehingga hasil temu kembalinya akan lebih mencerminkan *information need* dari *user*.

DAFTAR PUSTAKA

Grossman, David. A.,& Frieder, O.(2004). *Information Retrieval, Algorithms and Heuristic*. 2nd Edition. Springer.

Manning, Christopher D.(2008). *Introduction to Information Retrieval*. Cambridge University Press, New York.

Zhou, Croft.(2005). *Document Quality Model for Web Ad Hoc Retrieval*. University of Massachusetts, Amherst.

Zhai, Lafferty. *The Dual Role of Smoothing in the Language Modeling Approach*. Carnegie Mellon University.

Ponte, Croft. (1998). *A Language Model Approach to Information Retrieval*.

University of Massachusetts, Amherst.

