

Implementasi Metode Document Oriented Index Pruning pada Information Retrieval System

Hendri Priyambowo¹, Yanuar Firdaus A.W. S.T, M.T², Siti Sa'adah S.T. M.T³

^{1,2,3}Program Studi S1 Teknik Informatika, Fakultas Informatika, Universitas Telkom

Abstrak - Perkembangan Informasi yang sangat pesat mengakibatkan jumlah informasi yang tersedia secara online mengalami peningkatan yang sangat pesat, sehingga sangat sulit apabila pencarian dilakukan secara satu-persatu, karenanya dibutuhkan *Information Retrieval System* untuk menemukan suatu informasi.

Permasalahan yang muncul pada *Information Retrieval* adalah semakin besar *data collection* yang dimiliki maka semakin besar pula biaya yang dibutuhkan untuk menyediakan layanan komputasi, *storage*, dan *network resource*. Oleh karena itu suatu metode diperlukan untuk mengatasi permasalahan tersebut yaitu dengan kompresi *index*. Metode kompresi *index* yang akan digunakan adalah metode *Document Oriented Index Pruning*.

Berdasarkan penelitian yang telah dilakukan sampai dengan persentase *index* sebesar 80% metode *Document Oriented Index Pruning* mampu memberikan hasil relevansi pencarian yang lebih baik dibandingkan hasil relevansi pencarian tanpa menggunakan metode *Document Oriented Index Pruning* sehingga performansi sistem yang dihasilkan lebih baik dibandingkan dengan tanpa menggunakan metode *Document Oriented Index Pruning*.

Kata kunci:*information retrieval* , *document oriented index pruning*, *indexing*

1. Pendahuluan

Perkembangan Informasi yang sangat pesat mengakibatkan jumlah informasi yang tersedia secara online mengalami peningkatan yang sangat pesat, sehingga sangat sulit apabila pencarian dilakukan secara satu-persatu, karenanya dibutuhkan *Information Retrieval System* untuk menemukan suatu informasi. *Information Retrieval* bisa dikatakan sebagai teknik untuk mencari sesuatu(informasi) yang berada pada *data collection* yang berukuran besar dan sesuai dengan apa yang kita inginkan [1].

Secara umum proses yang terjadi di *Information Retrieval* adalah *indexing* dan *searching*. Pada *indexing* dibentuk struktur data yang akan digunakan untuk menemukan informasi, sementara pada *searching* dilakukan pencocokan *query* masukan *user* dengan data yang ada pada struktur data(*index*).

Permasalahan yang muncul pada *Information Retrieval* adalah semakin besar *data collection* yang dimiliki maka semakin besar pula biaya yang dibutuhkan untuk menyediakan layanan komputasi, *storage*, dan *network resource* [2]. Salah satu solusi atas permasalahan diatas adalah dengan mengurangi ukuran *inverted index*. *Inverted index* adalah struktur data yang digunakan pada *Information Retrieval* (IR). Ada beberapa metode yang dapat digunakan yaitu *posting oriented pruning*, *term oriented pruning*, dan *document oriented index pruning*.

Metode yang akan digunakan pada tugas akhir ini adalah metode *Document Oriented Index Pruning*. Metode ini dipilih karena metode ini mampu menjaga relevansi hasil pencarian lebih baik daripada metode lainnya. Ide dasar dari metode ini adalah dengan mengeliminasi seluruh kolom dari *index table*, berdasarkan asumsi tidak semua *document* yang ada di *collection document* itu penting. Pemilihan *document* yang akan dieliminasi berdasarkan *importance Score* dari masing-masing *document* [2].

Tugas akhir ini akan berfokus pada kompresi *index* pada *Information Retrieval* dan kemudian dilakukan analisa performansi sistem pada beberapa persentase ukuran *index* setelah dilakukan pemotongan *index*. Analisa performansi sistem akan dilakukan pada tahap *indexing* dan *searching*. Parameter performansi yang akan digunakan pada proses *indexing* adalah *index size* dan *index construction time*(waktu pembangunan *index*), sementara pada proses *searching* parameter yang akan digunakan adalah *precision*, *recall*, dan *query time*.

2. Landasan Teori

Document Oriented Index Pruning

Document Oriented Index Pruning adalah metode kompresi *Index* dengan cara menghilangkan sebagian *document* yang tidak diperlukan. Ide dasar dari metode ini adalah dengan menghilangkan kolom yang ada pada *index table*. Pemilihan *document* mana yang akan dihilangkan dilakukan berdasarkan *importance score*-nya.

Pada metode ini diasumsikan bahwa *document* yang mengandung *term* yang sering muncul tidak lebih penting dibandingkan dengan *document* yang mengandung *term* yang jarang muncul [2].

persamaan untuk menentukan importance score :

$$\text{tf} = \frac{1}{|d|} \sum_{i \in d} t_i \cdot N_{ti}$$

$$tf = \frac{1}{|d|} \sum_{i \in d} t_i \cdot \log\left(\frac{N - N_{ti} + 0,5}{N_{ti} + 0,5}\right)$$

Keterangan :

t_i = nilai term frequency term i dari dokumen d


N = jumlah keseluruhan dokumen

N_{ti} = jumlah kemunculan term i di seluruh dokumen

$|d|$ = denominator berupa panjang dokumen

3. Perancangan Sistem

Sistem yang akan dibangun adalah sistem *Information Retrieval* yang menggunakan metode *Document Oriented Index Pruning* sebagai metode untuk pemangkasan index.



Berdasarkan Gambaran Umum Sistem yang dibangun proses yang akan dilakukan adalah

- a. Sistem menerima inputan berupa file koleksi dokumen dengan format txt. Dari file koleksi dokumen tersebut dilakukan pemisahan berdasarkan token-token yang ada di dalam masing masing dokumen berdasarkan id dokumen.
- b. Dari koleksi dokumen yang dimiliki dilakukan *scoring document* menggunakan metode *Document Oriented Index Pruning*, untuk mendapatkan nilai *importance score* dari tiap-tiap dokumen.
- c. Setelah itu dokumen diurutkan berdasarkan *importance score* dari tiap-tiap dokumen.
- d. Kemudian dilakukan pemangkasan dokumen berdasarkan persentase *index* yang akan digunakan pada sistem. Pemangkasan dokumen dilakukan berdasarkan nilai *importance score* dari dokumen.
- e. Setelah itu dilakukan *indexing* untuk membentuk struktur data dari sistem, kemudian dilakukan analisis hasil performansi.
- f. Kemudian dilakukan proses *searching* dari *index* yang telah terbentuk, *searching* dilakukan berdasarkan *query* yang telah ditentukan.
- g. Hasilnya kemudian di analisis.

4. Pengujian dan Analisis

Skenario Pengujian

Pengujian sistem yang telah dibangun dilakukan dengan menggunakan *query* yang telah ditentukan, *query* tersebut diperoleh dari http://ir.dcs.gla.ac.uk/resources/test_collections/ yang terdiri dari 40 *query*. *Query* yang digunakan adalah *query* yang memiliki daftar *relevant judgement* yang lebih besar dari 10 buah untuk mendapatkan kemungkinan nilai *precision* dan *recall* yang tidak terlalu berbanding jauh untuk setiap persentase *index* yang digunakan. Pengujian akan dilakukan dengan membandingkan hasil pengujian berdasarkan ukuran *index*. Ukuran *index* yang akan digunakan adalah 100%, 95%, 90%, 85%, 80%, 75%, 70%, 65%, 60%, 55%, 50%, 45%, 40%, 35%, 30% dari ukuran *index* awal. Pengujian dilakukan untuk mendapatkan nilai *indexsize*, *querytime*, *precision* dan *recall*. Nilai-nilai tersebut akan dibuat grafik kemudian dilakukan analisis.

Pada tahapan *Searching* akan digunakan *query* sebanyak 40 *query* dan untuk menentukan nilai parameter performansi sistem dari total keseluruhan *query* akan diambil nilai rata-rata untuk setiap persentase *index*.

Hasil Pengujian

A. Hasil pengujian tahapan indexing

Tabel 1 Hasil performansi tahap Indexing

Ukuran Index	Index Size(KB)	Index Construction Time(detik)
100%	10828,32	11,24
95%	10426,096	10,161
90%	9975,592	10,375
85%	9501,408	9,555
80%	9008,472	8,957
75%	8521,16	8,25
70%	8021,016	7,264
65%	7500,208	6,71
60%	6940,432	5,966
55%	6375,968	5,29
50%	5782,024	4,524
45%	5173,336	4,19
40%	4554,432	3,536
35%	3909,232	2,983
30%	3293,296	2,705

Dari hasil yang diperoleh pada Tabel 1 terlihat bahwa untuk setiap persentase pemotongan *index* didapatkan nilai *index construction time* serta nilai *index size* yang berbeda-beda. Nilai *index size* serta *index construction time* terbesar diperoleh pada persentase *index* 100%, sementara nilai *index size* serta *index construction time* terkecil diperoleh pada persentase *index* 30%.

B. Hasil pengujian tahapan searching

Tabel 2 Hasil performansi tahapan Searching

Ukuran Index	Query Time(s)	Recall	Precision
100%	0,074	0,76	0,037
95%	0,07	0,71	0,037
90%	0,066	0,68	0,037
85%	0,062	0,63	0,037
80%	0,059	0,59	0,037
75%	0,0551	0,55	0,036
70%	0,051	0,5	0,036
65%	0,048	0,47	0,037
60%	0,044	0,43	0,037
55%	0,041	0,38	0,034
50%	0,037	0,33	0,032
45%	0,034	0,29	0,032
40%	0,03	0,25	0,032
35%	0,026	0,21	0,031
30%	0,023	0,17	0,03

Dari hasil yang diperoleh pada Tabel 2 terlihat bahwa untuk nilai *recall* serta nilai *query time* yang dihasilkan untuk setiap persentase *index* yang digunakan diperoleh nilai yang berbeda-beda. Nilai *query time* serta nilai *recall* tertinggi diperoleh pada persentase *index* 100% sementara nilai *query time* serta nilai *recall* terendah diperoleh pada persentase *index* 30%. Untuk nilai *precision* untuk beberapa persentase *index* diperoleh nilai yang sama, misalnya dapat dilihat pada tabel 2 untuk persentase *index* 100% sampai dengan 80% diperoleh nilai *precision* yang sama.

5. Kesimpulan dan Saran

Berdasarkan hasil pengujian dan analisis yang dihasilkan selama pengerjaan tugas akhir ini, dapat disimpulkan bahwa :

1. Proses penerapan metode *Document Oriented Index Pruning* dapat dilakukan dengan melakukan proses *scoring document* kemudian hasil *scoring* diurutkan berdasarkan *importance score* tiap-tiap dokumen dan penentuan dokumen yang dihilangkan dilakukan berdasarkan *importance score*.
2. Pada proses *indexing* untuk setiap pemangkasan 5% index terjadi pengurangan 400 – 500 KB *index size* dan 0.2 sampai 1 detik *index construction time* sehingga semakin kecil persentase *index* yang digunakan maka semakin kecil pula nilai *index size* serta nilai *index construction time* atau waktu yang dibutuhkan untuk membentuk *index* yang dihasilkan.
3. Pada proses *searching* metode *Document Oriented Index Pruning* dapat meningkatkan performansi pada persentase *index* sampai dengan 80%. Kesimpulan ini didasarkan dari semakin rendahnya nilai *query time* yaitu terjadi penurunan nilai *query time* sebesar 0.003 – 0.005 detik untuk setiap 5% pemangkasan index yang dihasilkan dengan tetap menghasilkan nilai *precision* yang sama baiknya dengan persentase *index* 100% atau ukuran *index* asli.

Adapun saran yang dapat digunakan, jika ingin melanjutkan penelitian ini :

1. Menggunakan varian pembobotan yang lainnya seperti *augmented*, *boolean*, *pivoted unique weighting* atau varian lainnya,
2. Membandingkan performansi antara metode-metode *pruning index* yang ada pada *Information Retrieval* seperti metode *posting oriented pruning* atau *term oriented pruning* atau mencoba mengkombinasikan algoritma-algoritma tersebut.

Referensi

- [1] C. D. Manning, R. Prabhakar and H. Schütze, *An Introduction to Information Retrieval*, Cambridge: Cambridge University Press, 2009.
- [2] L. Zheng and C. I. J, "Document Oriented Pruning of The Inverted Index in Information Retrieval Systems," *International Conference on Advanced Information Networking and Applications Workshop*, pp. 697-702, 2009.
- [3] C. J. v. RIJSBERGEN, *Information Retrieval*, Glasgow: Information Retrieval Group , 1979.
- [4] A. Silberschatz, H. F. Korth and S. Sudarshan, *Database System Concept*, McGraw-Hill , 2005.
- [5] Bernardi, "Department of Information Engineering and Computer Science University of Toronto," [Online]. Available: http://disi.unitn.it/~bernardi/Courses/DL/Slides_11_12/measures.pdf. [Accessed 19 March 2015].
- [6] A. Z. Broder, N. Eiron, M. Fontoura, M. Herscovici, R. Lempel, J. McPherson, R. Qi and E. Shekita, "Indexing Shared Content in Information".
- [7] J. Prasetyo, "IMPLEMENTASI DAN ANALISIS METODE STATIC INDEX PRUNING PADA INFORMATION RETRIEVAL SYSTEM UNTUK MENINGKATKAN PERFORMANSI SEARCH ENGINE," Telkom University, Bandung, 2011.
- [8] Mausam, "Document Similarity in Information Retrieval," [Online]. Available: <https://courses.cs.washington.edu/courses/cse573/12sp/lectures/17-ir.pdf>. [Accessed 17 March 2015].
- [9] "UCI Donald Bren School of Information & Computer Science," [Online]. Available: http://www.ics.uci.edu/~djp3/classes/2008_09_26_CS221/Lectures/Lecture26.pdf. [Accessed 17 March 2015].
- [10] B. Zhou and Y. Yao, "Evaluating Information Retrieval System Performance".
- [11] R. B. González, *Index Compression for Information Retrieval Systems*, 2008.
- [12] A. Singhal, C. Buckley and M. Mitra, "Pivoted Document Length Normalization".
- [13] "Clemson University," 2002. [Online]. Available: <http://people.cs.clemson.edu/~juan/CPSC862/Concept-50/IR-Basics-of-Inverted-Index.pdf>. [Accessed 18 March 2015].
- [14] J. D. Anderson, "Guidelines for Indexes and Related Information Retrieval Devices," *The National Information Standards Organization*, 1997.

[15] "Database Index," [Online]. Available:
https://en.wikipedia.org/wiki/Database_index. [Accessed 3 March 2016].

[16] "Search Engine Indexing," [Online]. Available:
https://en.wikipedia.org/wiki/Search_engine_indexing. [Accessed 3 March 2016].

