

Pembobotan Kata pada Query Expansion dengan Tesaurus dalam Pencarian Dokumen Bahasa Indonesia

Fatra Nonggala Putra^{#1}, Ari Effendi^{#2}, Agus Zainal Arifin^{#3}

[#]Jurusan Teknik Informatika Institut Teknologi Sepuluh Nopember
Kampus ITS Keputih, Sukolilo, Surabaya, 60111, Jawa Timur, Indonesia

¹putra.fatra08@gmail.com

²arieffendi@gmail.com

³agusza@cs.its.ac.id

Abstract— In this paper we aim to expand the search results in the retrieval system by expanding words in queries using synonyms of words in a synonymous thesaurus, which then queries are weighted based on word combinations in queries based on the main query and the number of document frequency of expansion terms. Our contribution in this paper is: first, query expansion using thesaurus word synonym Indonesian. Second, new term weighting of query for ranking the retrieval documents. From the experiment result, we can be concluded, firstly, result of comparison of precision and recall between using query expansion and without query expansion each up by 2.05% and 54.24%. The value of precision and recall without query expansion 80% and 43.54%. While the query expansion has the value of precision and recall 82.05% and 97.78%. Second, new term weighting of query our proposed on query expansion is able to place the retrieval result from the top query in the top ranking compared to query expansion.

Keywords- term weighting, query expansion, thesaurus, tf-idf

Abstrak— Dalam paper ini kami bertujuan untuk memperluas hasil pencarian dalam sistem temu kembali dengan melakukan ekspansi kata dalam *query* menggunakan sinonim kata dalam tesaurus sinonim, yang kemudian *query* diberi bobot berdasarkan kombinasi kata dalam *query* berdasarkan *query* utama dan banyaknya *df* dari term hasil ekspansi. Kontribusi kami dalam paper ini adalah: pertama, *query* expansion menggunakan tesaurus sinonim kata bahasa Indonesia. Kedua, pembobotan kata dalam *query* untuk perankingan dokumen hasil temu kembali. Dari hasil uji coba dapat disimpulkan, pertama, mendapatkan hasil perbandingan *precision* dan *recall* antara menggunakan *query* expand dan tanpa *query* expand masing-masing naik sebesar 2.05% dan 54.24%. Nilai *precision* dan *recall* tanpa *query* expansion 80% dan 43.54%. Sedangkan dengan *query* expansion memiliki nilai *precision* dan *recall* 82.05% dan 97.78%. Kedua, pembobotan kata dalam *query* expansion yang kami usulkan mampu menempatkan hasil temu kembali dari *query* utama pada peringkat teratas dibandingkan hasil temu kembali *query* expansion.

Kata kunci - pembobotan kata, query expansion, tesaurus, tf-idf

I. PENDAHULUAN

Dengan terus bertambahnya jumlah dokumen yang tersedia secara daring. Layanan mesin pencari satu persatu bermunculan guna membantu pengguna menemukan dokumen yang dibutuhkan. Secara umum mesin pencari melakukan pencarian dokumen berdasarkan masukan kata kunci yang diberikan. Pada kondisi tertentu, mesin pencari tidak mengembalikan dokumen apapun dikarenakan ketidaksesuaian kata kunci dengan dokumen yang tersedia[4].

Tesaurus merupakan sebuah rujukan yang berisi kata-kata yang memiliki pertalian makna berupa kesamaan, perlawanan, hubungan superordinat dan subordinat, atau hubungan antarbagian. Kesamaan makna (sinonim) dapat digunakan untuk memperkaya *query* pada proses Temu Kembali Informasi. Diharapkan dengan pemanfaatan sinonim untuk memperkaya *query* dapat menemukan dokumen yang lebih banyak dibanding sebelum menggunakan pengayaan *query*.

Penelitian dengan memanfaatkan tesaurus persamaan kata (sinonim) juga pernah dilakukan oleh Hazra Imrandan[1] dan Percy Nohama et.al[2]. Berbeda dengan penelitian[3] yang menggunakan selektif *query expansion* (QE) untuk melakukan prediksi terhadap kata yang akan di-*expan*, metode yang kami gunakan adalah dengan mencari sinonim *term* dari tesaurus dan melakukan perankingan terhadap kandidat *term* k QE, yaitu hanya mengambil lima sinonim dari setiap kata yang memiliki nilai *document frequency*(*df*) tertinggi.

Dalam penelitian ini kami mengusulkan, pertama, QE menggunakan tesaurus sinonim kata bahasa Indonesia. Kedua, pembobotan kata dalam *query* untuk perankingan dokumen hasil temu kembali.

II. METODOLOGI

Dalam Sistem temu kembali informasi pengguna menggunakan keyword untuk melakukan pencarian di dalam sistem. Keyword yang diinputkan oleh pengguna dikenali sebagai query oleh sistem dan nantinya akan di-expand oleh sistem berdasarkan tesaurus sinonim yang ada.

Pada penelitian ini, tesaurus sinonim yang kami buat berupa kumpulan sinonim yang merupakan sinonim dari kata hasil ekstraksi dari dokumen berbahasa Indonesia. Tesaurus sinonim ini yang dijadikan sumber ekspansi kata dari keyword yang dimasukkan oleh user.

A. Pengumpulan Data


Data yang digunakan sebagai corpus dalam penelitian ini berupa dokumen berita dari berbagai media daring nasional berbahasa Indonesia dengan topik politik pada tahun 2016. Jumlah dokumen berita yang dikumpulkan sebanyak 400 dokumen. Dokumen berita memiliki metadata yang terdiri dari: <id>, <judul>, <tanggal>, <kata_kunci>, <isi>, dan <link>. Kemudian dokumen disimpan di database sistem.

B. Preprocessing

Sebelum data diolah lebih lanjut perlu dilakukan tahap preprocessing agar data siap untuk diproses. Tahapan preprocessing ini terdiri dari 4 (empat) tahap yaitu casefolding, tokenizer, stopwords removal, dan stemming.

1) *Casefolding*: Casefolding adalah proses penyeragaman huruf menjadi huruf kecil (lowercase) agar tidak terjadi kesalahan sistem dalam mengenali dua kata atau lebih yang sama namun berbeda dalam penulisannya, misalnya kata ‘KPK’ dengan ‘kpk’.

2) *Tokenizing*: Tokenizer adalah proses pemecahan kumpulan kata dalam dokumen atau kalimat yang dipisahkan oleh tanda baca spasi menjadi kumpulan token yang biasanya berupa kata [5]. Gambar.1 merupakan contoh tokenizing pada sebuah kalimat.



Gambar. 1 Contoh Tokenizer pada sebuah kalimat

3) *Stopwords Removal*: tahap ini adalah proses penghapusan kata yang dianggap tidak penting (*stopword*) hasil proses *tokenizing* apakah termasuk dalam daftar kata tidak penting (*stop list*) [5]. Contoh *stopword* tertera pada Tabel I.

TABEL I
CONTOH STOPWORD

ada	pada
adalah	di
akan	yang
mungkin	oleh
jika	dll


4) *Stemming*: Stemming adalah proses pengubahan kata berimbuhan menjadi kata dasar sesuai dengan kamus kata yang digunakan. Dalam penelitian ini kami menggunakan algoritma dan kamus kata *stemming* milik sastrawi. Contoh dari proses stemming ditunjukkan pada Tabel II.

TABEL II
CONTOH STEMMING KATA

Sebelum Stemming	Setelah Stemming
mencari	cari
melihat	lihat
pembobotan	bobot
pencalonan	calon

C. Pembentukan Tesaurus Sinonim kata

Pada tahap ini dilakukan pembentukan tesaurus sinonim yang memuat semua sinonim kata dari kata yang terkandung di dalam korpus. Semua kata yang dihasilkan dari tahapan *preprocessing* digunakan untuk melakukan proses scraping dari laman sinonimkata.com untuk mendapatkan sinonim kata dari semua kata/token yang dihasilkan pada tahapan preprocessing dan hasilnya berupa kumpulan sinonim kata disimpan di database sistem. Alur tahap ini ditunjukkan pada Gambar. 2




Gambar. 2 Proses pembentukan tesaurus

D. Perhitungan pembobotan TF-IDF

Pada tahap ini setiap kata (*term*) hasil *pre-processing* dari seluruh dokumen yang akan digunakan untuk perhitungan *cosine similarity* untuk dilakukan perhitungan bobot setiap dalam tiap dokumen. Perhitungan bobot yang digunakan adalah *term frequency* (tf), *inverse document frequency* (idf), dan tf-idf.

Gambar.3 adalah alur proses pemberian bobot kata dengan metode tf-idf. Metode pembobotan tf-idf ini digunakan untuk menilai bobot relevansi term dari sebuah dokumen terhadap seluruh dokumen dalam korpus[6].



Gambar. 3 Proses perhitungan bobot kata dengan metode TFIDF

E. Query Expansion

Tesaurus sinonim kata berbahasa indonesia yang telah dibuat digunakan untuk memperluas pencarian dengan memperbanyak query asli menjadi beberapa QE.

TABEL III

CONTOH SINONIM KATA BERDASARKAN TESAUROS YANG DIBANGUN

Query	Kata	Sinonim
Kasus korupsi	Kasus	kejadian, masalah, peristiwa, perkara, persoalan, skandal, urusan
	Korupsi	kecurangan, manipulasi, penggelapan, penyelewengan,

F. Perhitungan Cosine Similarity

Dalam proses perhitungan *cosine similarity*, *input* yang digunakan adalah bobot dari term setiap dokumen, bobot *term* yang digunakan adalah bobot tf-idf yang sudah

dihitung pada proses sebelumnya. Persamaan *cosine similarity* yang digunakan sebagai berikut:

$$CosSim(d_i, q_i) = \frac{q_i \cdot d_i}{|q_i| |d_i|} = \frac{\sum_{j=1}^t (q_{ij} \cdot d_{ij})}{\sqrt{\sum_{j=1}^t (q_{ij})^2 \cdot \sum_{j=1}^t (d_{ij})^2}} \quad (1)$$

Keterangan:

q_{ij} = bobot istilah j pada dokumen i = $tf_{ij} \cdot idf_j$

d_{ij} = bobot istilah j pada dokumen i = $tf_{ij} \cdot idf_j$

G. Pembobotan Kata pada Query

Pembobotan kata pada query yang kami usulkan ini untuk memberikan bobot pada kata(*term*) yang digunakan untuk pencarian dokumen. Dalam pembobotan yang diusulkan, bobot kata yang merupakan bagian dari query asal diberikan bobot lebih dibandingkan kata hasil ekspansi dari tesaurus sinonim yaitu 1 untuk term dari query asli dan $1 - 1/\log(df_{term})$, sehingga hasil pencarian temu kembali oleh sistem akan menepatkan dokumen hasil dari *query* asli pada posisi teratas dibandingkan dokumen hasil temu kembali oleh *QE*.

Persamaan yang diusulkan untuk pembobotan terbaru kata pada *query* tercantum pada Persamaan. 2 dan contoh pemberian bobot pada Tabel IV. Sedangkan untuk alur temu kembali informasi ditunjukkan pada Gambar. 5.

$$Bobot\ Baru = \sum_{k=0}^n (WT_{qa}) + \sum_{k=0}^n (WT_{qe}) + CosSim \quad (2)$$

Keterangan:

WT_{qa} = bobot kata jika kata termasuk anggota kata dari query asli = 1


WT_{qe} = bobot kata untuk kata hasil ekspansi (sinonim) = $1 - 1/\log(df_{term})$

*jika *document frequency* (df) kata ekspansi (sinonim) ≤ 10 maka $WT_{qe} = 0$

TABEL IV

CONTOH PERHITUNGAN BOBOT KATA DALAM QUERY

No	Query	Bobot	Total Bobot Baru
1	Kasus Uang Suap	$1 + 1 + 1 + Cosim$	$3 + Cosim$
2	Skandal Uang Suap	$WT_{qe} + 1 + 1 + Cosim$	$TW_{qe} + 2 + Cosim$
3	Skandal Duit Suap	$WT_{qe} + WT_{qe} + 1 + Cosim$	$2WT_{qe} + 1 + Cosim$
4	Skandal Duit Korupsi	$WT_{qe} + WT_{qe} + WT_{qe} + Cosim$	$3WT_{qe} + Cosim$



Gambar.5 Metodologi Temu Kembali Informasi

III. HASIL UJI COBA

Uji coba dilakukan menggunakan 400 dokumen berita dengan topik politik digunakan sebagai dataset. Dokumen berita memiliki keunikan dalam penyajian penulisan berita antar tiap penulis atau antar media. Keunikan yang paling mencolok adalah perbedaan pemilihan kata yang digunakan untuk menyampaikan topik berita yang sama. Hal ini menyebabkan pencarian dengan kata kunci tertentu akan hanya mengembalikan dokumen berita yang memiliki kata kunci sama dengan kata kunci yang digunakan oleh pengguna sistem dan tidak dapat menemukan dokumen dengan kata kunci berbeda meskipun dengan topik dan isi berita yang sama. Gambar.7 menunjukkan hasil pencarian dengan kata kunci utama yaitu “demokrat pecat ruhut”, sedangkan Gambar.8 menunjukkan hasil pencarian dari kata kunci utama yang telah diekspan menjadi “demokrat henti ruhut” dan “demokrat lepas ruhut”.

Untuk menguji performa sistem dari metode yang diusulkan, perhitungan *recall* dan *precision* digunakan untuk mengukur kemampuan sistem pencarian dalam menemukan dokumen yang relevan (*recall*) dan mengukur kemampuan sistem untuk tidak memberikan peringkat pada dokumen yang tidak relevan (*precision*)[7]

Berdasarkan hasil ujicoba dengan metodologi pencarian pada gambar.5 menggunakan lima *query*, kami membandingkan antara pencarian biasa (tanpa *QE*) dengan pencarian menggunakan *QE*. Dari tabel V dan VI, terlihat perbandingan hasil temu kembali dari pencarian dengan *query* asli dan hasil pencarian *QE*. Pada kata kunci ‘demokrat pecat ruhut’, hasil temu kembali dari *query* asli hanya mampu mengembalikan 17 dokumen berita dengan nilai *precision* 100 % dan *recall* 65,38%. Dengan kata lain hasil pencarian dengan kata kunci asli tidak mampu mengembalikan 34,62% dokumen berita yang mempunya topik sama. Sedangkan hasil temu kembali oleh *QE*

mampu mengembalikan 30 dokumen dengan nilai *precision* 86,67% dan *recall* 100%.

Penurunan *precision* atau dengan kata lain ada beberapa dokumen yang tdk relevan dikembalikan oleh sistem pada hasil temu kembali oleh *QE* dapat diatasi dengan pembobotan baru kata dalam *query* yang kami usulkan. Dari gambar.7 dan gambar.8, terlihat bahwa hasil temu kembali dengan kata kunci asli yaitu ‘demokrat pecat ruhut’ mempunyai bobot 3,6 dan 3,5 sedangkan dokumen hasil *QE* dengan kata kunci ‘demokrat lepas ruhut’ dan ‘demokrat henti ruhut’ masing-masing 2,6 dan 2,5. Pembobotan baru kata dalam *query* yang kami usulkan memberikan bobot pada kata dalam *query* asli lebih besar daripada kata hasil ekspansi. Bobot query asli ‘demokrat pecat ruhut’ mempunyai bobot 3,5 hasil dari penjumlahan (3 + 0.5), 3 merupakan bobot tambahan karena terdapat tiga kata *query* yang masing-masing kata bernilai 1 dan 0,5 merupakan hasil perhitungan *cosine similarity*. Sedangkan query hasil ekspansi ‘demokrat lepas ruhut’ mempunyai bobot 2,6 hasil dari penjumlahan (2 + 0.6), 2 merupakan bobot tambahan karena terdapat 2 unsur kata query asli dan 0.6 merupakan hasil perhitungan *cosine similarity*.


Pembobotan kata dalam query yang kami usulkan memeberikan bobot lebih besar kepada term yang bersal dari query asli daripada term dari hasil ekspansi. Sehingga dokumen hasil temu kembali dari query asli akan mempunya peringkat yang lebih tinggi daripada dokumen hasil *QE* yang membuat dokumen temu kembali dari query asli akan selalu berada pada peringkat teratas.

TABEL V
HASIL PERCOBAAN TEMU KEMBALI SISTEM

No	Keyword	Hasil Temu Kembali			
		Query Asli	Relevan	Query Ekspansi	Relevan
1	Demokrat pecat ruhut	17	17	30	26
2	Penistaan agama oleh Ahok	10	8	10	8
3	Agus maju gubernur DKI	4	4	8	8
4	Kasus suap partai Golkar	1	1	17	12
5	Kasus suap E-ktp	0	0	4	3

TABEL VI
NILAI PRECISION DAN RECALL HASIL UJICoba SISTEM

No	Keyword	Tanpa QE		QE	
		Precission (%)	Recall (%)	Precission (%)	Recall (%)
1	Demokrat pecat ruhut	100	65,38	86.67	100
2	Penistaan agama oleh ahok	100	100	80	100
3	Agus maju gubernur dki	100	44.45	100	88.9
4	Kasus suap partai golkar	100	8.33	70.5	100
5	Kasus suap E-ktp	0	0	75	100
Rata-rata		80	43.54	82.05	97.78



Gambar.6 Grafik nilai precision dan recall antara query asli dan QE

Keputusan Dewan Kehormatan Demokrat: Ruhut Sitompul Dipecat dari Partai [morelikethis](#)

Score: 3.6460315970831827
Query: demokrat pecat ruhut

Pantaskah Demokrat Pecat Ruhut dan Hayono? [morelikethis](#)

Score: 3.5705754090155075
Query: demokrat pecat ruhut

Gambar. 7 Hasil temu kembali dengan query asli “demokrat pecat ruhut”

Komisi Pengawas Demokrat Segera Beri Sanksi pada Ruhut [morelikethis](#)

Score: 2.636941393844879
Query: demokrat lepas ruhut

Demokrat Tutup Rapat Alasan Pemberhentian Ruhut dari Jubir [morelikethis](#)

Score: 2.5918871265065198
Query: demokrat henti ruhut

Gambar. 8 Hasil temu kembali dengan QE

IV. ANALISA DAN PEMBAHASAN

Pada proses ekspansi kata dalam query tidak dilakukan tahapan *stemming* sebelum kata itu telah di-ekspansi atau dicari persamaan kayanya, namun *stemming* dilakukan setelah proses QE. Hal ini dilakukan karena berdasarkan pembacaan terhadap sinonim kata, kata berimbuhan dan kata dasar memiliki beberapa sinonim yang berbeda yang dapat menyebabkan tidak relevannya antara kata kunci pencarian dengan dokumen hasil temu kembali.

Pada hasil ujicoba dengan menggunakan QE terjadi kenaikan recall yang signifikan yaitu 54.24% dibanding tanpa menggunakan QE. Sedangkan nilai precision cenderung stabil meskipun ada kenaikan sebesar 2.05%. Kenaikan recall yang cukup tinggi dikarenakan data yang kami pakai adalah dokumen berita yang kebanyakan dari redaksi media banyak menggunakan kata ganti sinonim ataupun majas untuk menggantikan topik pada umumnya. Contoh pada pencarian dengan kata kunci ‘suap e-ktp’ dokumen yang dikembalikan sistem sebanyak nol atau dengan kata lain sistem tidak dapat menemukan dokumen dengan topik ‘suap e-ktp’. Namun, dengan diterapkannya QE dokumen yang dikembalikan oleh sistem sebanyak empat dokumen dikarenakan kata ‘suap’ telah dicari persamaan katanya (sinonim) menjadi ‘korupsi’, sehingga kata kunci pencarian hasil QE menjadi ‘korupsi e-ktp’.

V. KESIMPULAN

Dalam penelitian ini telah diusulkan metode baru untuk melakukan pembobotan query. Serangkaian percobaan telah dilakukan untuk menguji kinerja dari metode yang diusulkan. Dari hasil pengujian didapatkan perbandingan *precision* dan *recall* antara penggunaan *query expand* dan tanpa *query expand* masing-masing naik sebesar 2.05% dan 54.24%. Nilai *precision* dan *recall* tanpa QE 80% dan 43.54%. Sedangkan dengan QE memiliki nilai *precision* dan *recall* 82.05% dan 97.78%. Pembobotan kata dalam penelitian yang diusulkan mampu menempatkan hasil temu kembali dari query utama pada peringkat teratas dibandingkan hasil temu kembali QE.

Penelitian lebih lanjut dapat dilakukan untuk menyelidiki syarat perluasan query agar tidak merubah makna dari query asal. Sehingga perluasan relevansi dokumen yang ditampilkan dari hasil pencarian tetap terjaga.

REFERENSI

- [1] H. Imran, & A. Sharan. "Thesaurus and query expansion," *International journal of computer science & information Technology (IJCSIT)*, 1(2), 89-97, 2009
- [2] P. Nohama., Pacheco, E.J., Andrade, R.L de, Bitencourt, J.L., Markó, K., Schulz, S., "Quality issues in thesaurus building: a case study from the medical Domain," *Brazilian Journal of Biomedical Engineering* Volume 28, Número 1, p. 11-22, 2012.
- [3] Amati G., Carpineto C., Romano G. "Query Difficulty, Robustness, and Selective Application of Query Expansion", McDonald S., Tait J. (eds) *Advances in Information Retrieval. ECIR 2004. Lecture Notes in Computer Science*, vol 2997, 2004.
- [4] Hang Cui, Ji-Rong Wen, Jian-Yun Nie and Wei-Ying Ma, "Query expansion by mining user logs," *IEEE Transactions on Knowledge and Data Engineering*, vol. 15, no. 4, pp. 829-839, July-Aug. 2003.
- [5] Arifin AZ , SA Novan. "Klasifikasi dokumen berita kejadian berbahasa Indonesia dengan algoritma single pass clustering", *Proceeding of seminar on intelligent Technology and Its Applications (SITIA)*, Teknik Elektro, Institut Teknologi Sepuluh, 2002.
- [6] Munjiah NS, Atmagi RW, Rahayu DS, dan Arifin AZ, "Sistem Temu Kembali Dokumen Teks Dengan Pembobotan Tf-Idf Dan Lcs", *JUTI*, vol. 11, pp. 17-20, 2013.
- [7] Carterette B. Precision and Recall. In: LIU L., ÖZSU M.T. (eds) *Encyclopedia of Database Systems*. Springer, Boston, MA, 2009.