DOI: 10.25126/jtiik.201861226 p-ISSN: 2355-7699 e-ISSN: 2528-6579

EVALUASI DAFTAR STOPWORD BAHASA INDONESIA

Faisal Rahutomo¹, Ariadi Retno Tri Hayati Ririd²

^{1,2}Politeknik Negeri Malang Email: ¹faisal@polinema.ac.id, ²ariadi.retno@polinema.ac.id

(Naskah masuk: 11 November 2018, diterima untuk diterbitkan: 18 Desember 2018)

Abstrak

Pada sistem temu kembali informasi berbentuk teks maupun *text mining*, terdapat proses pengindeksan. Teks diproses dengan tujuan mengintisarikan informasi berbentuk teks tersebut. Salah satu proses yang dilakukan adalah *stopword filtering*, beberapa kata yang tidak layak diindeks diabaikan berdasar sebuah daftar. Di dalam sistem berbahasa Indonesia, terdapat beberapa versi daftar *stopword* yang tersedia bebas. Penelitian ini bertujuan mengevaluasi daftar yang telah tersedia tersebut. Tujuan akhir dari penelitian ini adalah telaah daftar yang tersedia berdasarkan tata bahasa Indonesia, cara penyusunan, dan kebiasaan perambah internet. Dari hasil telaah diperoleh fakta bahwa daftar yang tersedia dibangun dengan analisis frekuensi kemunculan kata pada sebuah korpus (*corpus*) teks, tanpa memperhatikan jenis kata ataupun kebiasaan pengguna internet. Hasil lain penelitian ini adalah beberapa rekomendasi lebih lanjut bagi para peneliti di bidang ini ketika membutuhkan daftar *stopword* bahasa Indonesia, yaitu daftar yang memperhatikan jenis kata dan kebiasaan pengguna internet melalui mesin perambah yang tersedia.

Kata kunci: daftar stopword, bahasa Indonesia, temu kembali informasi, text mining, evaluasi

INDONESIAN STOPWORD LIST EVALUATION

Abstract

Most of text-based information retrieval system uses indexing process. The system processes the texts in order to obtain the information essence. One of the process is stopword filtering, several words are being ignored based on a stopword list. Several Indonesian stopword list are available openly. Therefore, this paper evaluates the available lists based on Indonesian formal grammar, its preparation technique, and internet surfer habit. The results show all of the list are developed by term frequency analysis based on a text corpus. This paper also provides several recommendations for researcher both in text mining and text-based information retrieval field, developing stoplist by the word type and internet surfer habit.

Keywords: stopword list, Indonesian, information retrieval, text mining, evaluation

1. PENDAHULUAN

Di dalam dokumen teks terdapat banyak jenis kata seperti kata depan, kata sambung, kata ganti, kata sifat dan lain sebagainya. Sebagian kata tersebut tidak berpotensi dijadikan indeks dokumen karena kemunculannya tidak unik untuk sebuah dokumen tertentu. Untuk itu dilakukan proses penyaringan kata-kata itu (G Salton, Wong, & Yang, 1975)(Gerard Salton & Buckley, 1988)(Baeza-Yates & Ribeiro-Neto, 2008)(Manning, Raghavan, & Schütze, 2008). Langkah ini adalah pembersihan teks dari kata-kata yang tidak relevan dijadikan indeks, disebut sebagai langkah stopword filtering.

Daftar kata tersebut diberi istilah daftar *stopword* atau *stoplist* (Luhn, 1959)(Flood, 1999). Daftar kata ini bersifat unik, tiap-tiap bahasa memiliki daftar katanya tersendiri. Di dalam bahasa

Indonesia terdapat beberapa versi daftar kata ini. Keragaman versi daftar kata yang dimaksud menjadi masalah tersendiri bagi peneliti di bidang sistem temu kembali informasi teks. Daftar kata mana yang lebih tepat digunakan sebagai *stoplist*. Idealnya, kata-kata yang sering digunakan di dalam perambahan internet tidak ikut masuk ke dalam daftar tersebut, dengan kata lain masih tercantum di dalam indeks dalam proses *stopword filtering*. Bila kata-kata tersebut dihapus dari indeks, maka dokumen yang mengandung kata terkait tidak lagi bisa ditemukan kembali oleh pencari.

Untuk itu di dalam penelitian ini dilakukan telaah daftar *stopword* bahasa Indonesia yang telah tersedia. Daftar yang dievaluasi di dalam penelitian ini adalah daftar yang disusun Fadillah Z. Tala (Z Tala, 2003), Damian Doyle (Doyle, n.d.), dan Wibisono (Wibisono, 2008). Validasi dilakukan

dengan telaah pendalaman struktur *stoplist* yang telah tersedia termasuk proses penyusunannya. Kemudian daftar *stopword* yang ada diperbandingkan dengan beberapa sumber yang lain, yaitu: hasil kuesioner, kata kunci pencarian dari Google Trends, dan istilah-istilah baku di dalam bahasa Indonesia.

Hasil penelitian ini berupa komentar proses penyusunan *stopword* yang telah ada. Dengan demikian diharapkan dapat dipilih daftar kata mana yang paling tepat digunakan oleh peneliti dan pengembang aplikasi di bidang ini. Penelitian ini juga memberikan rekomendasi daftar *stopword* yang sesuai dengan kebutuhan pengembang aplikasi ataupun peneliti di bidang ini berdasarkan kebutuhannya masing-masing.

2. STOPWORD FILTERING

Salah satu langkah pemrosesan teks di bidang sistem temu kembali informasi teks atau text mining adalah pembersihan teks dari kata-kata yang tidak relevan dijadikan indeks. Di dalam sebuah dokumen teks bisa jadi terdapat banyak jenis kata seperti kata depan, kata sambung, kata ganti, kata sifat, dan lain sebagainya. Sebagian kata tersebut bisa jadi tidak berpotensi dijadikan indeks dokumen karena kemunculannya tidak unik atau tidak pernah digunakan di dalam query pencarian. Untuk itu dilakukan proses penyaringan kata-kata tersebut (Luhn, 1959)(Flood, 1999). Penyaringan dilakukan dengan menyediakan sebuah daftar kata-kata yang tidak penting diindeks (stopword list). Hukum Zipf terkadang digunakan sebagai landasan pembentukan stoplist, utamanya pada analisis kemunculan kata (Zipf, 1949). Daftar stopword yang tersedia untuk Bahasa Indonesia diterangkan secara berturut-turut di Bagian 2.1, 2.2, dan 2.3.

2.1. Daftar Stopword Fadillah Z. Tala

Stoplist yang disusun Fadillah Z. Tala disusun bersamaan dengan penyusunan tesis master yang bersangkutan (Z Tala, 2003). Di appendix D. terdapat dua daftar yang diberikan: daftar yang disarankan (Tabel D.1.), dan daftar kata yang umum muncul di dalam korpus teks yang diteliti (Tabel D.2.). Daftar tersebut diturunkan dari analisis kemunculan kata yang dilakukan dengan menjalankan eksperimen korpus bahasa Indonesia. Eksperimen ini menggunakan koran Indonesia sebagai sumber teks. Satu tahun edisi dikumpulkan dari Kompas daring, http://www.kompas.com, sebagai salah satu koran yang banyak dibaca di Indonesia. Edisi ini diambil berurutan tiap hari selama setahun, dimulai dari Januari 2001 hingga Desember 2001 dengan total Dokumen-dokumen 3160 dokumen. tersebut hanyalah berita utama harian koran. Korpus untuk analisis ini berisi 50.000 kota-kata yang unik, setelah membuang nama-nama orang, kota, organisasi, negara, dll. Hasilnya adalah sebuah daftar *stopword*. Buku tesis Tala dapat diakses secara terbuka melalui tautan sebagai berikut: http://www.illc.uva.nl/Research/Reports/MoL-2003-02.text.pdf.

2.2. Daftar Stopword Damian Doyle

Daftar *Stopword* yang disediakan oleh Damian Doyle (Doyle, n.d.) dapat diakses terbuka di https://www.ranks.nl/stopwords. Selain *stoplist* Bahasa Indonesia, Doyle juga menyediakan *stoplist* untuk bahasa-bahasa lainnya. Ranks NL sendiri adalah sebuah perangkat pengembangan laman web yang ramah terhadap mesin perambah. Tidak terdapat informasi rinci di dalam website tersebut tentang bagaimana daftar stopword ini dibentuk. Begitu pula tidak ada naskah akademik yang memberikan informasi tahapan yang mendasarinya.

2.3. Daftar Stopword Yudi Wibisono


Yudi Wibisono membuat daftar *stopword* bahasa Indonesia untuk tugas salah satu matakuliah (Wibisono, 2008). Tujuannya waktu itu bukan untuk sistem temu kembali informasi, tetapi untuk klasifikasi *text mining*. Ia menggunakan langkah *stopword filtering* untuk mengurangi jumlah kata yang harus diproses algoritma klasifikasi.

Langkah yang dilakukan untuk membuat daftar stopword dengan cara mengumpulkan kata paling banyak muncul pada korpus (corpus). Ia menggunakan beberapa ratus artikel berita Kompas sebagai sumber data korpus. Setelah diurutkan kemudian diperiksa secara manual satu persatu. Karena, daftar itu dibuat secara manual dan untuk keperluan klasifikasi, ada beberapa kata yang mungkin dapat diperdebatkan apakah layak masuk ke dalam daftar stopword atau bukan, misalnya "utara", "senin", "gedung" dan sebagainya. Jadi, ia mempersilahkan daftar itu untuk diedit sesuai kebutuhan. Daftar tersebut sudah diurutkan dari kata yang frekuensinya paling tinggi. Stoplist yang disusun Yudi ini dapat diakses secara di: https://yudiwbs.wordpress.com/2008/07/23/stopwords-untuk-bahasa-indonesia/.

3. METODE EVALUASI

Metode penelitian yang digunakan di dalam makalah ini ditunjukkan pada Gambar 1. Beberapa sumber data disandingkan satu dengan lainnya untuk dapat dianalisis lebih lanjut. Data pertama adalah tiga daftar *stopword* sebagaimana telah dibahas sebelumnya. Ketiga daftar *stopword* tersebut diperbandingkan dengan kebiasaan pengguna mesin pencari di internet. Penelitian ini akan menggunakan dua pendekatan untuk mengetahui kebiasaan pengguna mesin pencari. Pendekatan pertama menggunakan kuesioner. Pendekatan kedua melakukan telaah tren kata pencarian di dalam mesin pencari komersial Google. Langkah ini dilakukan untuk melihat, apakah daftar *stopword* yang ada

melibatkan jenis kata yang sebenarnya digunakan oleh pengguna atau tidak. Bila daftar stopword melibatkan jenis kata tersebut, akan terjadi kesenjangan antara indeks yang ada dengan keinginan pencari. Dengan demikian pengaruh jenis kata tersebut dinafikan ketika dilakukan penelusuran dengan mesin pencari.



Gambar 1. Diagram penelitian

Pelengkap dalam langkah validasi yang dilakukan adalah tinjauan terhadap tata bahasa baku Bahasa Indonesia yang disusun di dalam aturan ejaan bahasa Indonesia (Alwi, Dardjowidjojo, Lapoliwa, & Moeliono, 2010)(Hamizan, 2015). Istilah-istilah yang digunakan di dalam pedoman ini dijadikan timbangan atas istilah yang digunakan di dalam kuesioner, analisis tren Google, dan istilah di stoplist yang ada. Timbangan yang digunakan adalah jenis kata di dalam bahasa Indonesia: kata benda, kata bilangan, kata depan, kata ganti, kata keadaan, kata kerja, kata keterangan, kata sandang, kata sambung, kata seru, kata sifat (adjektiva), partikel, dan pronomina (Bahasa, 2008).

3.1. Telaah Stoplist

Telaah mendalam stoplist yang dilakukan di dalam penelitian ini meliputi:

- · Menghitung jumlah kemunculan kata berdasar jenis katanya. Langkah ini dilakukan untuk mengetahui sebaran kata berdasar jenisnya di stoplist.
- Membandingkan satu stoplist dengan stoplist lainnya dari segi daftar katanya. Langkah ini untuk mengetahui di mana perbedaan jumlah dan kata vang ada.
- Melacak cara penyusunan stoplist.
- Mengurutkan tipe kata berdasar kemunculannya di stoplist. Langkah ini untuk mengetahui persentase kemunculan kata berdasar jenis kata.
- · Menghitung persentase kata yang muncul di stoplist dengan kata setara di Kamus Tesaurus Bahasa Indonesia untuk tiap jenis katanya.

3.2. Validasi dengan Kuesioner

untuk mengetahui Tujuan langkah ini kebiasaan pengguna ketika merambah internet dengan mesin pencari. Kuesioner dibagikan ke responden mahasiswa D4 Teknik Informatika tingkat 4 kelas 4A, 4B, 4C, 4D, dan 4E Jurusan Teknologi Informasi, Politeknik Negeri Malang. Setelah kuesioner terkumpul, langkah- langkah selanjutnya adalah sebagai berikut:

- Input data dari kertas kuesioner ke dalam komputer menggunakan aplikasi Excel. Untuk pertanyaan tertutup, skor untuk setiap jawaban dari pertanyaan.
- Hasil pengolahan data kuesioner ditampilkan dalam bentuk deskriptif.
- · Langkah selanjutnya adalah pengujian hipotesis berdasarkan data kuesioner yang ada.

3.3. Validasi dengan Tren Pencarian Google

Tujuan langkah ini sama dengan tujuan bagian sebelumnya, untuk mengetahui kebiasaan pengguna ketika merambah di internet dengan mesin pencari. Langkah yang dilakukan di dalam tahap ini meliputi:

- Dilakukan pencarian tren kata pencarian di Google dalam waktu satu bulan.
- Mengategorikan kata pencarian yang tren tersebut dengan jenis kata.
- Menghitung persentase penggunaan jenis kata dalam lingkup watu tertentu.

3.4. Hipotesis

Hipotesis penelitian ini adalah:

- Stoplist yang ada dibangun dengan memilih jenisjenis kata tertentu yang dianggap tidak penting.
- Stoplist mengandung kata-kata yang tidak pernah digunakan oleh perambah internet.
- Stoplist yang dibangun Fadillah Tala adalah stoplist yang paling bisa dipertanggung jawabkan secara ilmiah.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Telaah Stoplist

Tabel 1. Padanan istilah buku teks kamus tesaurus stonword kata benda nomina, tertulis n noun kata kerja verba, tertulis v verb kata sambung partikel, tertulis p particle kata depan partikel, tertulis p particle kata keadaan adjectiva, tertulis a adjective kata keterangan adverbia, tertulis adv adverbkata bilangan numeralia, tertulis num numeralia kata ganti pronomina, tertulis pron pronomina kata sandang partikel, tertulis p kata seru partikel, tertulis p

Telaah dilakukan setelah mengetahui padanan penggunaan istilah antara buku teks tata bahasa baku bahasa Indonesia, buku Kamus Tesaurus Bahasa Indonesia, dan istilah yang digunakan di dalam stoplist yang ada. Padanan tersebut ditunjukkan di Tabel 1. Tampak dari tabel tersebut, baik kata sambung, kata depan, kata sandang, dan kata seru disebut sebagai partikel di kamus tesaurus dan di


| Tabel 2. Kemunculan kata berdasar jenisnya | | | | | | | | | | |
|--|-----------------|-------|--------|-------|---------------|-------|------------|-------|--------|-------|
| tipe | tala (recom) | % | doyle | % | tala (add) | % | yudi wb | % | rerata | % |
| adverbia | 111 | 30,49 | 109,00 | 30,62 | 29,00 | 7,36 | 40,00 | 27,97 | 51,07 | 24,11 |
| verba | 22 | 6,04 | 21,00 | 5,90 | 231,00 | 58,63 | 10,00 | 6,99 | 50,65 | 19,39 |
| partikel | 107 | 29,40 | 108,00 | 30,34 | 11,00 | 2,79 | 43,00 | 30,07 | 47,36 | 23,15 |
| nomina | 28 | 7,69 | 26,00 | 7,30 | 71,00 | 18,02 | 12,00 | 8,39 | 24,29 | 10,35 |
| pronomina | 53 | 14,56 | 52,00 | 14,61 | 2,00 | 0,51 | 17,00 | 11,89 | 21,95 | 10,39 |
| Adjektiva | 32 | 8,79 | 29,00 | 8,15 | 40,00 | 10,15 | 16,00 | 11,19 | 20,58 | 9,57 |
| numeralia | 11 | 3,02 | 11,00 | 3,09 | 10,00 | 2,54 | 5,00 | 3,50 | 6,52 | 3,04 |
| jumlah | 364 | • | 356 | • | 394 | • | 143 | • | | |

stoplist. Setelah dilacak mendetail, stoplist tidak melibatkan kata sandang, baik itu yang disusun Tala, Doyle, dan Wibisono.

4.1.1. Jumlah Kemunculan Kata Berdasar Jenis Katanya

Untuk mengetahui sebaran kata berdasar jenisnya di stoplist, dilakukan langkah ini. Hasil telaah disarikan di dalam Tabel 2. Secara umum, kata keterangan adalah jenis kata yang paling banyak terlibat di stoplist. Disusul kata kerja, partikel, kata benda, kata ganti, kata keadaan, dan kata bilangan. Perlu ditinjau lebih detail bahwa sebenarnya partikel itu terdiri atas kata depan, kata sambung, dan kata seru. Hasil tersebut banyak berubah akibat data stoplist Tala tambahan yang jauh berbeda polanya dibandingkan tiga stoplist lainnya.

Tiga stoplist lainnya memiliki pola urutan pelibatan jenis kata yang sama. Berturut-turut dari yang paling banyak ke sedikit: kata keterangan, partikel, kata ganti, kata sifat, kata benda, kata kerja, dan kata bilangan. Pola data ini ditampilkan lebih jelas secara visual di dalam Gambar 2. Gambar 2 menunjukkan dengan jelas, penggunaan kata kerja yang amat banyak di stoplist tambahan Tala besar pengaruhnya ke dalam nilai rerata yang ada.



Gambar 2. Pola kemunculan kata berdasar stoplist

4.1.2. Perbandingan Daftar Kata

Perbedaan kata yang ada tidak terlalu banyak antara stoplist Tala yang disarankan dan stoplist Doyle. Malah bisa dikatakan kedua stoplist ini hampir identik, perbedaannya sangat tipis. Beberapa kata yang dihapus stoplist Doyle dari Tala yang disarankan: berkali-kali, bermacam-macam, bersama-sama, masing-masing, sama-sama, sekalikali, selama-lamanya, seolah-olah, dan setidaktidaknya. Selain menghapus beberapa kata ulang tersebut, Doyle menambahkan satu kata yang tidak ada di stoplist Tala yang disarankan: selagi.

Stoplist Wibisono sama sekali berbeda dengan stoplist Tala yang disarankan. Meskipun, sama-sama pendekatan menggunakan analisis kemunculan kata, Tala dan Wibisono menggunakan korpus yang berbeda.

4.1.3. Cara Penyusunan Stoplist

Tala (Z Tala, 2003) menyusun stoplist-nya dengan menggunakan analisis frekuensi kemunculan kata (Fox, 1992) yang diterapkan ke dalam Bahasa Indonesia. Hasilnya diperbandingakan dengan hasil stoplist di dalam bahasa lainnya. Frekuensi kemunculan kata dilakukan pada korpus Bahasa Indonesia. Tala menggunakan koran Indonesia daring sebagai sumber teksnya. Edisi satu tahun dikoleksi Kompas dari daring, http://www.kompas.com. Edisi ini diambil secara berurutan setiap harinya selama satu tahun (dimulai bulan January 2001 hingga December 2001) dengan total 3160 dokumen. Dokumen-dokumen tersebut adalah tajuk utama koran tersebut. Hasilnya berupa korpus yang memiliki 50.000 kata-kata yang unik, sesudah membuang nama orang, kota, organisasi, negara, dll. Dari hasil analisis ini, diperoleh stoplist, yang berasal dari kata-kata yang paling banyak muncul di dalam korpus tersebut (Z Tala, 2003).

Doyle (Doyle, n.d.) menyusun stoplist-nya memodifikasi stoplist Tala. menghilangkan 9 kata dari stoplist Tala yang berbentuk kata ulang, dan menambah satu kata sambung (partikel) di dalam *stoplist*-nya: selagi.

Wibisono (Wibisono, 2008) mengambil jalan yang sama dengan Tala, menggunakan analisis frekuensi kemunculan kata Bahasa Indonesia. Setelah diurutkan yang paling banyak muncul, diperiksa secara manual satu-persatu. Perbedaannya, Wibisono haya menggunakan beberapa ratus berita Kompas. Dari proses yang mirip, Wibisono hanya berisi 143 kata. Hanya sekitar 40% daftar Tala. Meskipun demikian, terdapat beberapa kata yang bisa diperdebatkan kelayakannya masuk stoplist: utara, senin, gedung, dlsb. Tala memproses penyusunan stoplist untuk

Tabel 3. Persentase kemunculan jenis kata di stoplist

| tipe | total di kamus tesaurus | tala (suggested) | % | doyle | % | tala (add) | % | yudi wb | % |
|-----------|-------------------------------|---------------------|-------|-------|-------|---------------|------|------------|-------|
| adverbia | 796 | 111 | 13,94 | 109 | 13,69 | 29 | 3,64 | 40 | 5,03 |
| verba | 15.465 | 22 | 0,14 | 21 | 0,14 | 231 | 1,49 | 10 | 0,06 |
| partikel | 388 | 107 | 27,58 | 108 | 27,84 | 11 | 2,84 | 43 | 11,08 |
| nomina | 18.702 | 28 | 0,15 | 26 | 0,14 | 71 | 0,38 | 12 | 0,06 |
| pronomina | 106 | 53 | 50,00 | 52 | 49,06 | 2 | 1,89 | 17 | 16,04 |
| adjektiva | 8.018 | 32 | 0,40 | 29 | 0,36 | 40 | 0,50 | 16 | 0,20 |
| numeralia | 150 | 11 | 7,33 | 11 | 7,33 | 10 | 6,67 | 5 | 3,33 |
| jumlah | 43.625 | 364 | | 356 | | 394 | | 143 | |
| rerata | | | 14,22 | | 14,08 | | 2,49 | | 5,12 |

meraih gelar master, sedangkan Wibisono sebagai tugas kuliahnya.

4.1.4. Perbandingan Kata Stoplist dengan Kamus Tesaurus Bahasa Indonesia

Tabel 3 menunjukkan persentase kemunculan jenis kata di *stoplist*. Kata-kata yang dijadikan acuan adalah kata-kata yang muncul di Kamus Tesaurus Bahasa Indonesia. Dari tabel tersebut tampak bahwa stoplist yang ada tidak melibatkan banyak kata yang tersedia di kamus. Hal tersebut sangat dimungkinkan karena sumber data yang digunakan dalam penyusunannya berupa artikel berita daring. Besar kemungkinan kosakata yang digunakan di dalamnya adalah kosakata bahasa sehari-hari yang tidak banyak menggunakan kosakata di dalam kamus. Rata-rata tidak lebih 15% kata-kata di dalam kamus untuk jenis yang ada yang digunakan. Jumlah terbanyak pelibatan kosakata di dalam stoplist ada pada daftar *stoplist* Tala yang melibatkan 50% jenis kata ganti.

4.2. Hasil Kuesioner

Tabel 4 Hasil Kuesioner

| jenis kata | jumlah | % penggunaan |
|-----------------|--------|--------------|
| kata benda | 120 | 89,55 |
| kata kerja | 104 | 77,61 |
| kata sambung | 96 | 71,64 |
| kata depan | 86 | 64,18 |
| kata keadaan | 74 | 55,22 |
| kata keterangan | 72 | 53,73 |
| kata bilangan | 64 | 47,76 |
| kata ganti | 40 | 29,85 |
| kata sandang | 27 | 20,15 |
| kata seru | 18 | 13,43 |

Tujuan langkah ini untuk mengetahui kebiasaan pengguna ketika merambah internet dengan mesin pencari. Kuesioner dibagikan ke responden mahasiswa tingkat 4 kelas 4A, 4B, 4C, 4D, dan 4E Jurusan Teknologi Informasi, Politeknik Negeri Malang. Total responden 134 orang. Hasil kuesioner ditampilkan pada Tabel 4. Tabel tersebut menunjukkan pengalaman natural perambah internet ketika menggunakan Bahas Indonesia. Setelah diurutkan dari frekuensi penggunaan kata yang

paling besar ke kecil, didapatkan hasil urutan berturut-turut: kata benda, kata kerja, kata sambung, kata depan, kata keterangan, kata bilangan, kata ganti, kata sandang, dan kata seru.

Nilai kemunculan minimum 18, median 73, dan maksimal 120. Tabel 4.4 menunjukkan kata seru adalah kata yang paling jarang digunakan dalam pencarian ketika merambah di internet. Dengan logika yang berkebalikan, jenis kata ini paling potensial masuk ke dalam stoplist. Demikian selanjutnya berturut-turut.

Hasil yang agak mengejutkan adalah seringnya responden menggunakan kata sambung ketika merambah internet. Pendalaman kuesioner dengan teknik dialog singkat menjelaskan responden memerlukan kata sambung ketika membandingkan sesuatu atau menyandingkan, sebagaimana fungsi kata sambung. Makna ini akan hilang bila jenis kata ini tidak ikut diindeks.

Kata sandang yang tidak masuk ke dalam stoplist, perlu dipertimbangkan masuk. Berdasarkan data responden, kata sandang ini jarang mereka gunakan di mesin perambah internet.


Menariknya, kata depan yang banyak dilibatkan di dalam stoplist ternyata sering digunakan perambah internet. Pendalaman kuesioner mengungkapkan bahwa responden menggunakannya ketika mencari hotel atau makanan, semacam kata pencarian "makanan enak di sawojajar". Terdapat perbedaan makna yang besar antara kata pencarian tersebut dengan "makanan enak sawojajar". Atau perambah mencari cara "bagaimana cara ke Surabaya". Sangat jauh berbeda dengan makna "bagaimana cara Surabaya".

Ringkasan hasil kuesioner di dalam Tabel 4 ditampilkan secara visual di dalam Gambar 3. Dari data ini didapatkan ide baru, penyusunan stoplist yang bisa diatur berdasarkan kebutuhan unjuk kerja sistem yang dibangun. Persentase kemunculan kata bisa diterapkan sebagai nilai ambang batas, kemudian daftar katanya diambil dari kamus. Hipotesisnya, semakin banyak jenis kata yang dilibatkan, semakin sederhana indeks sistem yang dibangun, semakin sedikit media penyimpan yang diperlukan, dan semakin cepat unjuk kerjanya. Sebaliknya ia semakin tidak sensitif dan kehilangan banyak makna penting. Pengguna dapat mencari

| Tabel 5. | Kemunculan | Jenis Ka | ta di Go | ogle Trends |
|----------|------------|----------|----------|-------------|
| | | | | |

| | topik | | b | ulan | konsistensi |
|-----------------|---------------|-------------|---------------|---------|--------------|
| jenis kata | ada/ tidak | contoh | ada/ tidak | contoh | |
| kata benda | ada | salon | ada | kukang | ٧ |
| kata kerja | ada | penyergapan | ada | sarapan | \checkmark |
| kata sambung | ada | yang | ada | dan | \checkmark |
| kata depan | tidak | | tidak | | \checkmark |
| kata keadaan | ada | gerhana | ada | dingin | $\sqrt{}$ |
| kata keterangan | ada | dekat | tidak | | x |
| kata bilangan | ada | 2016 | ada | 7 | \checkmark |
| kata ganti | tidak | | tidak | | \checkmark |
| kata sandang | tidak | | tidak | | $\sqrt{}$ |
| kata seru | tidak | | tidak | | $\sqrt{}$ |

sesuatu konten yang ternyata tidak tersedia di indeks karena kata yang mewakili konten tersebut telah dipangkas dengan sistem *stopword filtering*.



Gambar 3. Persentase penggunaan jenis kata

4.3. Hasil Tren Pencarian Google

Hasil penelusuran kata pencarian populer di Google Trends dapat dilihat berdasarkan topik maupun berdasarkan Bulan. Penelitian ini menggunakan kata pencarian populer di tahun 2016. Dari daftar kata tersebut, penelitian ini membentuk matriks yang menyandingkan jenis kata di dalam Bahasa Indonesia dengan kata-kata yang muncul secara populer di dalam Google Trends. Hasilnya ditampilkan di Tabel 5. Tampak dari tabel tersebut, beberapa jenis kata secara konsisten tidak pernah muncul di dalam pencarian populer Google: kata depan, kata ganti, kata sandang, dan kata seru. Kata sambung, bagian dari kata partikel muncul dengan frekuensi yang kecil. Hanya satu jenis kata yang tidak tentu munculnya, yaitu kata keterangan. Kata ini di daftar kata populer per topik muncul, tetapi per bulan tidak muncul. Kata-kata yang secara konsisten tidak muncul sangat layak untuk dilibatkan di dalam daftar stoplist.

4.4. Pembahasan Hipotesis

Di Bagian 3 disampaikan beberapa hipotesis penelitian. Fakta-fakta yang ditemukan berdasarkan penelitian dapat dipaparkan sebagai berikut:

- Hipotesis: *Stoplist* yang ada dibangun dengan memilih jenis-jenis kata tertentu yang dianggap tidak penting.
 - Fakta: *Stoplist* dibangun dengan analisis frekuensi kemunculan kata. Hampir seluruh jenis kata masuk ke dalam *stoplist*, tetapi dengan persentase kecil. Hanya satu jenis kata yang tidak terlibat: kata sandang.
- Hipotesis: *Stoplist* mengandung kata-kata yang tidak pernah digunakan oleh perambah internet. Fakta: *Stoplist* mengandung kata-kata yang ternyata juga digunakan perambah internet: kata sambung dan kata depan. Bahkan *stoplist* juga mengandung kata benda dan kata kerja yang banyak digunakan.
- Hipotesis: *Stoplist* yang dibangun Fadilah Tala adalah *stoplist* yang paling bisa dipertanggung jawabkan secara ilmiah.

Fakta: Proses pengembangan *stoplist* Tala dilakukan saat yang bersangkutan menyelesaikan studi masternya. Buku tesis yang bersangkutan dapat diunduh dengan mudah oleh orang lain, sehingga dapat dirujuk pijakan ilmiahnya.

5. KESIMPULAN

Kesimpulan dari penelitian ini bisa disarikan sebagai berikut. Stoplist yang ada: Tala, Doyle, dan Wibisono dibangun dengan analisis frekuensi kemunculan kata. Hampir seluruh jenis kata masuk ke dalam *stoplist* tersebut, tetapi dengan persentase kecil dengan rata-rata di bawah 15% dari kata yang ada di dalam kamus. Kata sandang tidak digunakan di dalam stoplist, padahal ia hanya digunakan 20,15% responden penelitian ini. Kata tersebut juga tidak muncul di dalam kata populer pencarian Google Trends. Stoplist banyak mengandung katakata yang juga digunakan perambah internet: kata sambung (71,6% responden) dan kata depan (64,18% responden). Dengan persentase yang cukup besar bergabung di dalam istilah partikel sebanyak rata-rata 23,15%. Bahkan stoplist juga mengandung sedikit kata benda (rata-rata 10,35%) dan kata kerja (19,39%) yang banyak digunakan reponden, berturut-turut: 89,55% dan 77,61% responden. Proses pengembangan stoplist Tala dilakukan dengan pijakan ilmiah yang dapat dipertanggungjawabkan dan mudah diakses.

Sedangkan saran lanjutan penelitian ini adalah menggagas sebuah mekanisme *stoplist* dinamik yang dapat menghasilkan *stoplist* yang tepat sesuai unjuk kerja sistem yang diperlukan. Data hasil kuesioner dan data Kamus Tesaurus Bahasa Indonesia dapat digunakan untuk tujuan ini.

6. DAFTAR PUSTAKA

- ALWI, H., DARDJOWIDJOJO, S., LAPOLIWA, H., & MOELIONO, A. M., 2010. *Tata Bahasa Baku Bahasa Indonesia* (3rd ed.). Jakarta: Pusat Bahasa dan Balai Pustaka.
- BAEZA-YATES, R., & RIBEIRO-NETO, B., 2008.

 Modern Information Retrieval: The
 Concepts and Technology Behind Search
 (2nd ed.). USA: Addison-Wesley
 Publishing Company.
- BAHASA, P., 2008. *Kamus Tesaurus Bahasa Indonesia*. Departemen Pendidikan Nasional.
- DOYLE, D., tanpa tahun. Indonesian Stopword. https://www.ranks.nl/stopwords/indonesian
- FLOOD, B. J., 1999. Historical Note: The Start of a Stop List at Biological Abstracts. *JASIS*, 50(12), 1066.
- FOX, C., 1992. Information Retrieval. In W. B. Frakes & R. Baeza-Yates (Eds.) (pp. 102–130). Upper Saddle River, NJ, USA: Prentice-Hall, Inc.
- HAMIZAN, Y., 2015. Pedoman Umum Ejaan Bahasa Indonesia yang Disempurnakan dan Intisari Kata Bahasa Indonesia (1st ed.). Seruni Multi Aksara.
- LUHN, H. P., 1959. Key word-in-context index for technical literature (kwic index). *American Documentation*, 11(4), 288–295.
- MANNING, C. D., RAGHAVAN, P., & SCHÜTZE, H., 2008. *Introduction to Information Retrieval*. New York, NY, USA: Cambridge University Press.
- SALTON, G., & BUCKLEY, C., 1988. Termweighting approaches in automatic text retrieval. *Inf. Process. Manage.*, 24(5), 513–523.
- SALTON, G., WONG, A., & YANG, C. S., 1975. A Vector Space Model for Automatic Indexing. *Commun. ACM*, 18(11), 613–620.
- WIBISONO, Y., 2008. Indonesian Stopword. https://yudiwbs.wordpress.com/2008/07/23/stop-words-untuk-bahasa-indonesia/
- Z TALA, F., 2003. A Study of Stemming Effects on Information Retrieval in Bahasa Indonesia.
- ZIPF, H., 1949. Human Behaviours and the

Principle of Least Effort. Cambridge, MA: Addison-Wesley.

