

# PENERAPAN ALGORITMA *WEIGHTED TREE SIMILARITY* UNTUK PENCARIAN SEMANTIK

Riyanarto Sarno<sup>1</sup> Faisal Rahutomo<sup>2</sup>

<sup>1,2</sup>Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember  
Email: <sup>1</sup>riyanarto@its-sby.edu, <sup>2</sup>faisal\_r@cs.its.ac.id

*Full-text search and metadata-enabled search have weakness in the precision of the searched article. This research offers weighted tree similarity algorithm combined with cosine similarity method to count similarity in semantic search. In this method metadata is constructed based on the tree of labelled node, labelled and weighted branch. The structure of tree metadata is constructed based on semantic information like taxonomi, ontologi, preference, synonym, homonym and stemming. From testing result, the precision of search using weighted tree similarity algorithm is better than full-text search and metadata-enabled search.*

**Keywords:** *weighted tree similarity, semantic search, cosine similarity*

## 1 PENDAHULUAN

Pencarian *full-text* (*full-text search*) adalah tipe pencarian dokumen yang dilakukan komputer dengan menelusuri keseluruhan isi sebuah dokumen [1]. Cara kerjanya adalah mencari dokumen yang mengandung kata *query* pengguna. Hasil *query* diurutkan sesuai dengan tingkat kandungan kata, umumnya frekuensi kandungan kata diurutkan dari tinggi ke rendah. Penelusuran dokumen hanya menggunakan operasi dasar pencocokan kata (*string matching*) tanpa tambahan operasi algoritma lainnya [2]. Dengan metoda ini pengguna mengoperasikan dengan mudah, cukup memasukkan kata kunci yang diinginkan. Tampilan antarmuka relatif lebih sederhana tanpa memasukkan banyak pilihan.

Kekurangan dari metode pencarian *full-text* [1] adalah kelemahan linguistik, antara lain tidak dapat mengenali sinonim atau membedakan homonim, juga terjadi operasi perbandingan kata yang besar antara kata *query* pengguna dengan kata di dalam dokumen. Hasil pencarian *full-text* bisa berupa *list* yang sangat panjang. Ini terjadi bila di banyak dokumen mengandung kata yang dicari pengguna. Untuk mencari dokumen yang relevan pengguna harus melihat satu-persatu.

Pencarian dengan metadata biasa (*metadata enabled search*) adalah tipe pencarian dokumen yang dilakukan komputer dengan menelusuri metadata dokumen [3]. Pada metoda ini operasi perbandingan kata jauh lebih sedikit dibandingkan pencarian *full-text*. Tiap-tiap dokumen diindex dengan dibuat metadata-nya. Metadata merupakan 'data dari data' [2], yaitu sekumpulan *term* terstruktur yang terorganisasi dengan logika *AND*, *OR*, sehingga nilai kemiripannya dihitung berdasarkan aritmatika *sum of products* atau *product of sums* sesuai dengan susunan logika *AND* dan *OR* yang dipergunakan. Representasi metadata dapat berupa meta tag HTML, file XML atau data dalam *field* khusus di *database*. Metadata ini berfungsi semacam katalog dalam sebuah perpustakaan dan dokumen adalah bukunya. Pada metoda ini *query* pengguna dapat dilakukan secara lebih spesifik berdasarkan batasan-batasan tertentu. Batasan tersebut seperti pencarian berdasar nama pengarang tertentu, berdasar penerbit tertentu, atau berdasar tahun terbit tertentu. Hasil *query* menjadi lebih sedikit dibandingkan pencarian *full-text* karena pencarian lebih spesifik, yang diharapkan lebih relevan.

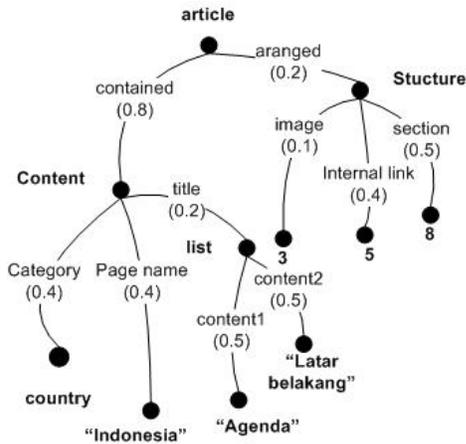
Pencarian dengan metadata biasa juga memiliki kelemahan linguistik sebagaimana pencarian *full-text* [1]. Kelemahan lainnya ada pada tambahan operasi pembangkitan metadata yang dapat dilakukan secara manual atau otomatis [3]. Pada dasarnya pencarian dengan metadata memfilter dokumen yang relevan dengan menggunakan logika *AND*, *OR* dan pemilihan kata yang tepat. Hal ini menyulitkan karena mencari kata yang tepat terdapat masalah linguistik, antara lain: *stemming*, *prefix*, *suffix*, *infix*, homonim, dan sinonim.

Dalam pencarian semantik yang menggunakan algoritma *weighted tree similarity*, metadata disusun berdasarkan *tree* yang memiliki *node* berlabel, cabang berlabel serta berbobot. Struktur metadata *tree* disusun berdasarkan informasi semantik semacam taksonomi, ontologi, *preference*, sinonim, homonim, dan *stemming*. Sehingga metadata yang digunakan dapat lebih merepresentasikan isi sebuah artikel, serta hasil pencarian dapat lebih tepat (*precision*).

Algoritma *weighted tree similarity* memiliki keunikan karena memiliki representasi *tree* yang berbeda dengan yang lain. *Tree* yang dipergunakan memiliki *node* berlabel, cabang berlabel serta berbobot. Untuk merepresentasikan *tree* dalam algoritma ini secara serial dipergunakan standar *Weighted Object Oriented RuleML* (WOORuleML) yang sesuai dengan standar *Extended Markup Language* (XML). Representasi ini dapat berfungsi sebagai metadata dokumen yang terindeks. Cabang yang berlabel memberikan pemahaman lebih kepada label nodenya. Begitu pula bobot cabang memungkinkan memberikan tingkat kecenderungan kepada cabang tertentu lebih dari yang lain.

Pencarian semantik dengan algoritma *weighted tree similarity* menggunakan algoritma penghitungan kemiripan semantik antara dua *tree* berbobot. Algoritma ini telah diterapkan untuk mencocokkan transaksi *e-business* [4], pencarian obyek pembelajaran [5], *virtual market* untuk jejaring listrik [6], transaksi kendaraan roda empat [7], estimasi biaya proyek [8], pencarian informasi yang tepat untuk *handheld device* [9], dan audit otomatis dokumen *the International Organization for Standardization* (ISO) [10].

Pengembangan algoritma yang diusulkan dalam makalah ini adalah pencocokan khusus untuk *subtree* khusus *term* dengan metode *cosine similarity*. *Subtree* khusus ini diberi nama *subtree keywords*. Pengembangan ini mengem-



Gambar 1: Contoh representasi tree

bangkan makalah sebelumnya [11] yang memperbaiki performa algoritma dalam pencocokan *leaf node tree*.

Struktur makalah ini terdiri atas 6 bagian. Bagian pertama berisi pendahuluan. Bagian kedua berisi dasar teori *weighted tree similarity*. Bagian ketiga berisi penjelasan pencarian semantik. Bagian keempat berisi studi komputasi. Bagian kelima berisi Pengujian dan bagian keenam kesimpulan dan saran.

## 2 WEIGHTED TREE SIMILARITY

### 2.1 Representasi Tree

Dokumen yang akan dihitung kemiripannya direpresentasikan dalam sebuah *tree* yang memiliki karakteristik *node* berlabel, cabang berlabel dan cabang berbobot. Contoh representasi *tree* bisa dilihat pada Gambar 1.

Gambar 1 menggambarkan representasi *query* pengguna terhadap sebuah artikel Wikipedia [12]. Di dalam representasi artikel tersebut, pengguna mencari sebuah artikel dengan kategori *country*, nama halaman Indonesia, subjudul agenda dan latar belakang. Artikel memiliki 3 gambar, 5 link dan 8 subbagian. Keunikan dari *weighted tree* ini adalah cabang yang berlabel dan berbobot. Pada contoh Gambar 1 pengguna lebih menekankan pencari untuk menemukan ketepatan pencarian berdasarkan cabang *content* (berbobot 0,8) dibandingkan strukturnya (berbobot 0,2). Penentuan tingkat kepentingan cabang ini terdapat dalam representasi *weighted tree*. Representasi *tree* dalam suatu *weighted tree* mengikuti aturan sebagai berikut [13]:

1. Nodenya berlabel
2. Cabang berlabel
3. Cabang berbobot
4. Label dan bobot ternormalkan. Label terurut sesuai abjad dari kiri ke kanan. Jumlah bobot dalam cabang setingkat *subtree* yang sama adalah 1.

Untuk merepresentasikan *tree* tersebut digunakan RuleML versi *Object Oriented Modelling*, yang disebut *Weighted Object Oriented RuleML* (WOORuleML)-yang mengacu

```

<cterm>
  <_opc><ctor>Article</ctor><_opc>
  <_r n="Content" w="0,8">
    <cterm>
      <_opc><ctor>Content</ctor><_opc>
      <_r n="category" w="0,4"><ind>Country</ind><_r>
      <_r n="page name" w="0,4"><ind>Indonesia</ind><_r>
      <_r n="title" w="0,2">
        <cterm>
          <_opc><ctor>List</ctor><_opc>
          <_r n="content1" w="0,5"><ind>Agenda</ind><_r>
          <_r n="content2" w="0,5"><ind>Latar Belakang</ind><_r>
        </cterm>
      </_r>
    </cterm>
  </_r>
  <_r n="Structure" w="0,2">
    <cterm>
      <_opc><ctor>Structure</ctor><_opc>
      <_r n="image" w="0,1"><ind>3</ind><_r>
      <_r n="internallink" w="0,4"><ind>5</ind><_r>
      <_r n="section" w="0,5"><ind>8</ind><_r>
    </cterm>
  </_r>
</cterm>

```

Gambar 2: Representasi tree dalam WOORuleML

pada standarisasi XML. Contohnya bisa dilihat pada Gambar 2.

Pada Gambar 2 terdapat beberapa simbol, adapun keterangan dari simbol-simbol ini antara lain:

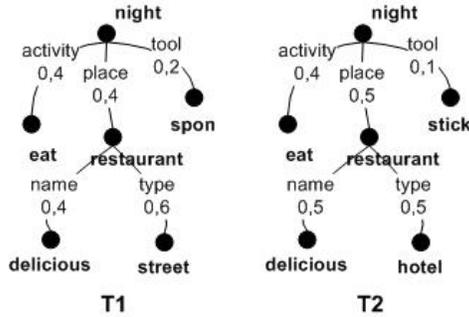
1. <cterm> = keseluruhan *tree*
2. <opc> = *root* dari *tree*
3. <ctor> = *node* label dari *root*
4. <\_r> = *role* dari setiap *arch/edge* dan memiliki beberapa atribut yaitu *n* mewakili label dan *w* yang mewakili bobot/*weight*
5. <ind> = label untuk *role*

*Subtree* dari sebuah *role* memiliki struktur yang sama atau identik yang diawali dengan <cterm> dan seterusnya seperti pada Gambar 2.

### 2.2 Penghitungan Kemiripan

Algoritma penghitungan kemiripan antara dua *weighted tree* ini terdapat di dalam makalah [4], [13]. Gambar 3 menunjukkan contoh dua buah *tree* T1 dan T2 yang dihitung kemiripannya. Nilai kemiripan tiap pasangan *subtree* berada diantara interval [0,1]. Nilai 0 bermakna berbeda sama sekali sedangkan 1 bermakna identik. Kedalaman (*depth*) dan lebar (*breadth*) *tree* tidak dibatasi. Algoritma penghitungan kemiripan *tree* secara rekursif menjelajahi tiap pasang *tree* dari atas ke bawah mulai dari kiri ke kanan. Algoritma mulai menghitung kemiripan dari bawah ke atas ketika mencapai *leaf node*. Nilai kemiripan tiap pasang *subtree* di level atas dihitung berdasar kepada kemiripan *subtree* di level bawahnya.

Sewaktu penghitungan, kontribusi bobot cabang juga diperhitungkan. Bobot dirata-rata menggunakan rata-rata



**Gambar 3:** Contoh kemiripan penghitungan dasar

aritmatika  $(w_i + w'_i)/2$ . Nilai rata-rata bobot sebuah cabang dikalikan dengan kemiripan  $S_i$  yang diperoleh secara rekursif. Nilai  $S_i$  pertama diperoleh berdasar kemiripan *leaf node* dan dapat diatur nilainya menggunakan fungsi  $A(S_i)$ . Pada awalnya algoritma *weighted tree similarity* hanya memberi nilai 1 bila *leaf node*-nya sama dan 0 bila berbeda [4]. Perumusan penghitungan kemiripan *tree* ini terdapat di dalam persamaan berikut:

$$\sum (A(S_i)(w_i + w'_i)/2) \quad (1)$$

dengan  $A(S_i)$  adalah nilai kemiripan *leaf node*,  $w_i$  dan  $w'_i$  adalah bobot pasangan *arc weighted tree*. Penilaian  $A(S_i)$  analog dengan logika AND sedangkan penilaian bobot pasangan analog dengan logika OR.

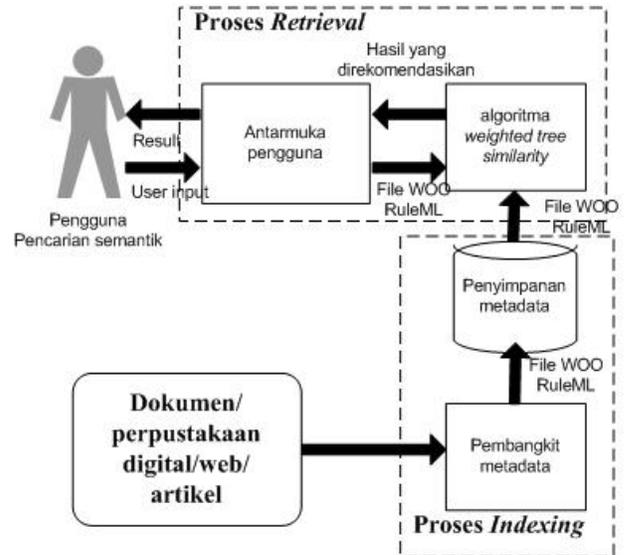
Di dalam contoh pada Gambar 3 perilaku algoritma dapat dijelaskan sebagai berikut. Pada awalnya dihitung kemiripan *node* cabang *activity* yang diperoleh 1. Kemiripan ini dikalikan rata-rata bobot cabang *activity*  $(0,4+0,4)/2$  menghasilkan kemiripan cabang. Algoritma kemudian mencari kemiripan *node* cabang berikutnya, *place*. Karena *node* ini bukan *leaf* maka algoritma akan turun ke bawah menghitung kemiripan cabang *name*. Algoritma kemudian menghitung kemiripan cabang *type* dan diakumulasi dengan kemiripan cabang *name*. Akumulasi ini merupakan nilai kemiripan *subtree restaurant*. Algoritma bergerak ke cabang *tool* dan akumulasi kemiripan dengan cabang lain yang setingkat menghasilkan kemiripan total.

### 3 PENCARIAN SEMANTIK

Merujuk pada makalah [5] pencarian semantik dengan algoritma *weighted tree similarity* diuraikan dalam Gambar 4. Sistem terdiri atas dua proses, proses *indexing* dan proses *retrieval*. Proses *indexing* terdiri atas pembangkit metadata dan penyimpanan metadata. Sedangkan proses *retrieval* berintikan algoritma *weighted tree similarity*. Pembahasan pembangkitan metadata *weighted tree* akan diuraikan lebih lanjut di dalam Bagian 3.1, sedangkan pembahasan penggabungan penghitungan *weighted tree similarity* dengan *cosine similarity* akan diuraikan di dalam Bagian 3.2.

#### 3.1 Pembangkitan Metadata Tree

Pembangkitan metadata sangat bergantung bentuk representasi *tree* yang ditetapkan dan ini bersifat kasuistik. Representasi *tree* yang cocok untuk jual beli mobil akan berbeda dengan representasi *tree* untuk berita *online* ataupun



**Gambar 4:** Pencarian semantik dengan algoritma *weighted tree similarity*

artikel Wikipedia. Sebagai contoh, dalam makalah [12] representasi *weighted tree* sebuah artikel ditetapkan sebagaimana dalam Gambar 5. Nilai-nilai *node* dan cabang *weighted tree* diperoleh dengan mengakses *field-field* tertentu dalam database Mediawiki.

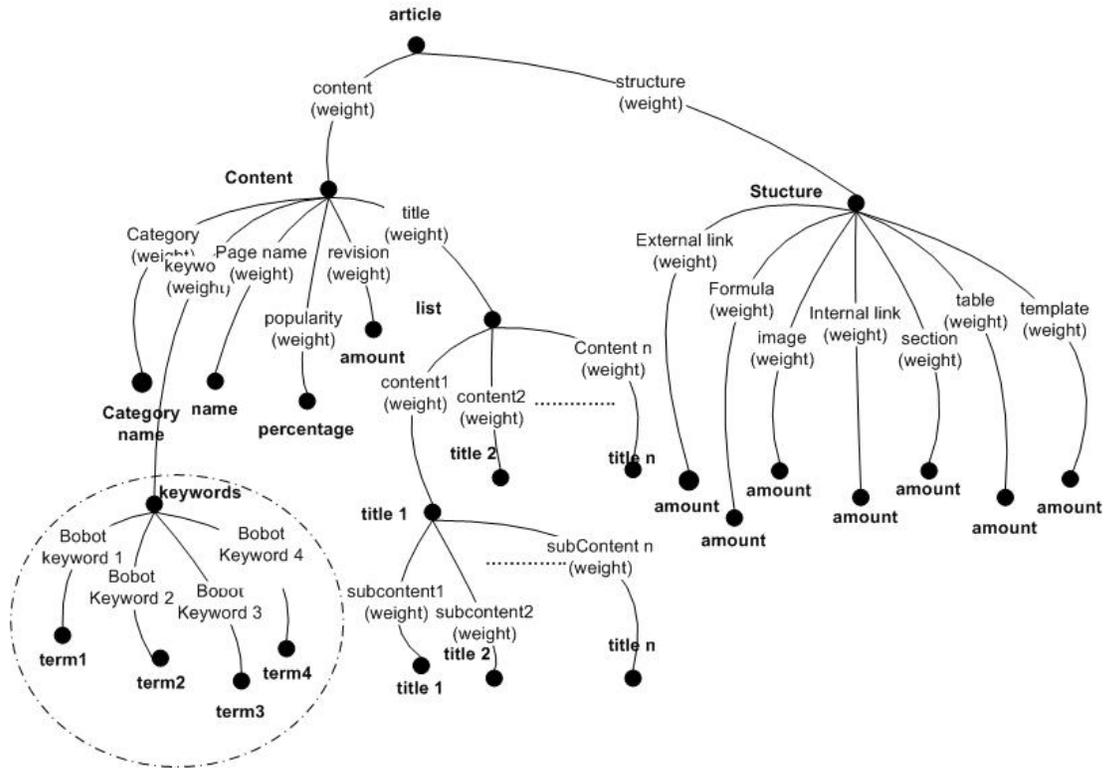
Pencarian semantik dengan algoritma *weighted tree similarity* dapat diterapkan pada pencarian dokumen, pencarian halaman web, atau pencarian artikel. Makalah ini mengusulkan pengindeksan koleksi dokumen dengan membangkitkan metadatanya sebelum pengguna melakukan *query*. Ketika pengguna melakukan *query* operasi penghitungan kemiripan dilakukan dengan metadata tidak dengan teks dokumen secara langsung. Dalam pembangkitan metadata ini diusulkan perlunya penelusuran teks secara menyeluruh untuk menemukan sekumpulan *term* representasi konten sebuah dokumen. Dengan kata lain dokumen direpresentasikan sebagai sebuah vektor *term*.

Dalam Gambar 5, representasi *tree* sebuah artikel Wikipedia memiliki sebuah *subtree keyword* dimana sekumpulan *term* mewakili konten sebuah dokumen. Sekumpulan *term* yang mewakili sebuah dokumen ini pada umumnya direpresentasikan sebagai vektor *term*. Di dalam makalah ini vektor *term* sebuah dokumen direpresentasikan pula sebagai *tree* berbobot agar metadata sebuah dokumen menjadi satu kesatuan file WOORuleML. Hal ini dilakukan karena standar metadata WOORuleML digunakan dalam makalah ini untuk merepresentasikan sebuah *tree* berbobot. *Tree* berbobot vektor *term* ini diberi nama *subtree keywords*. Uraian lebih lanjut *subtree keyword* terdapat dalam Bagian 3.1.1.

#### 3.1.1 Subtree Keywords

Dalam makalah ini konten dokumen direpresentasikan sebagai *term vectors* [14] dalam bentuk:

$$d = (d_0, d_1, \dots, d_n) \quad (2)$$



Gambar 5: Representasi tree sebuah artikel Wikipedia

Dimana setiap  $d_k$  mengidentifikasi *term* yang terdapat dalam dokumen  $d$ . Demikian juga pada *query* (*information request*) dari pengguna direpresentasikan dalam *term vectors*, sehingga dirumuskan:

$$q = (q_0, q_1, \dots, q_n) \tag{3}$$

Dimana setiap  $q_k$  menidentifikasi *term* yang terdapat pada *query*  $q$ .

Sehingga apabila ditentukan bobot (*weight*) pada setiap *term* untuk membedakan diantara *term* yang terdapat dalam dokumen maupun *query* dapat dituliskan:

$$w_d = (w_{d0}, w_{d1}, \dots, w_{dn}) \tag{4}$$

dan

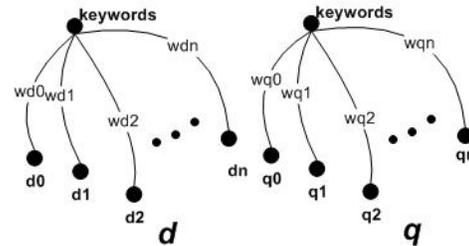
$$w_q = (w_{q0}, w_{q1}, \dots, w_{qn}) \tag{5}$$

Dimana  $w_{dk}$  merupakan bobot dari *term*  $t_k$  dalam dokumen  $d$ , sedangkan  $w_{qk}$  merupakan bobot *term*  $t_k$  dalam dokumen  $q$ .

Dengan demikian *subtree keyword query* pengguna dan *subtree keyword* dokumen digambarkan sebagai berikut:

Tampak dalam Gambar 6 *weighted tree* yang dibangun tidak memiliki label cabang. Penjelasan tentang ini ada dalam Bagian 3.2. Untuk membentuk *subtree keywords* terdapat dua proses utama yang dilakukan, menentukan *term* nilai *leaf node subtree* dan menentukan bobot *term* untuk nilai *arc subtree*.

Untuk menentukan *term* dilakukan proses *tokenizing*, *stoplist/wordlist*, *stemming*, dan penghitungan *term frequency* (TF). Dalam proses *tokenizing* terjadi proses pemotongan dokumen menjadi daftar kata yang berdiri sendiri.



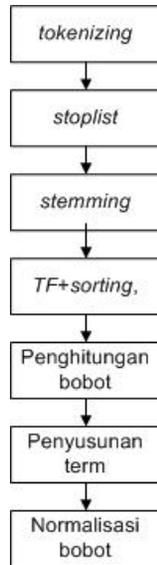
Gambar 6: Representasi tree dokumen (d) dan query pengguna (q)

Di dalam proses *stoplist* terjadi penyaringan kata-kata yang tidak layak untuk dijadikan kata kunci. Kata-kata yang tidak layak tersebut antara lain kata sambung, kata depan, kata ganti, kata sifat, dan lainnya. Di dalam proses *stemming* kata dikembalikan ke dalam bentuk dasarnya dengan menghilangkan imbuhan-imbuhan pada kata. Di dalam penghitungan TF dilakukan penghitungan frekuensi kemunculan kata. Pembobotan dilakukan dengan memperhatikan TF dalam sebuah dokumen. Penghitungan nilai bobot dilakukan berdasarkan persamaan sebagai berikut:

$$w = TF/TF_{total} \tag{6}$$

Dengan  $TF_{total}$  adalah jumlah total TF.

Jumlah *term* dalam *subtree keywords* dokumen ditentukan berdasar jumlah bobot *term*. Bobot *term* diperoleh mengikuti proses sebagaimana pada Gambar 7. Setelah melalui proses *tokenizing*, *stoplist/word-list*, *stemming*, dan



**Gambar 7:** Proses pembentukan *subtree keywords*

TF bobot tiap *term* ditentukan. *Term* kemudian diurutkan sesuai bobot kemudian diakumulasikan. *Term* dipergunakan dan berhenti bila akumulasi bobot  $term \geq 0,9$ . Nilai bobot total *term* yang tidak digunakan  $\pm 0,1$ , cukup kecil dan bisa ditolerir. Dengan demikian jumlah anak cabang *subtree keywords* dokumen dapat berubah-ubah tergantung dokumennya. Demikian pula pada *subtree keywords query* pengguna. Jumlah *term* dapat berubah-ubah tergantung term yang diinputkan oleh pengguna.

Contoh dari proses pembentukan *Subtree keywords* dokumen sebagai berikut. Setelah melalui proses *tokenizing*, *stoplist*, *stemming*, TF dan *sorting*, tiap-tiap term dihitung bobotnya dan dihasilkan Tabel 1.

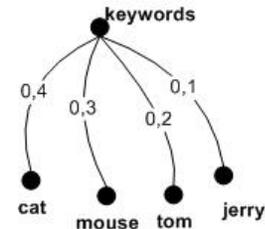
Berdasarkan Tabel 1 tampak *term* yang dipergunakan adalah *cat*, *mouse*, *tom*, dan *Jerry* karena jumlah akumulasi bobot berada di bawah batas 0,9. *Term* lainnya tidak dipergunakan untuk merepresentasikan dokumen lebih lanjut. Bobot ini kemudian dinormalkan agar jumlah bobot dalam *subtree* ini sama dengan 1. Tabel normalisasi terdapat dalam Tabel 2. Pada contoh ini nilai  $TF_{total}$  normalisasi sama dengan 50. Representasi *tree* pada contoh ini digambarkan dalam Gambar 8.

**Tabel 1:** Contoh penentuan *node* dan penghitungan bobot *subtree keywords* dokumen

Term	TF	Bobot	Akumulasi Bobot
Cat	20	0.350877	0.350877
Mouse	15	0.263158	0.614035
Tom	10	0.175439	0.789474
Jerry	5	0.087719	0.877193
Silvester	2	0.035088	0.912281
Tweety	1	0.017544	0.929825
Doraemon	1	0.017544	0.947368
Miky	1	0.017544	0.964912
Goofy	1	0.017544	0.982456
Donald	1	0.017544	1
Total	57		

**Tabel 2:** Normalisasi bobot

Term	TF	Bobot Normal
Cat	20	0.4
Mouse	15	0.3
Tom	10	0.2
Jerry	5	0.1
Total	50	



**Gambar 8:** *Subtree keywords* dokumen contoh

### 3.2 Penghitungan Kemiripan Gabungan

Algoritma *weighted tree similarity* pada awalnya bersifat *string matching* di bagian *leaf node*-nya. Dengan demikian apabila *leaf node*-nya sama menghasilkan nilai 1, sedangkan bila berbeda menghasilkan nilai 0. Misalkan terdapat dua buah nilai 70 dan 85, algoritma ini tidak menganggap adanya kemiripan antara dua nilai ini, sehingga *similarity*-nya 0, walaupun secara intuitif kita dapat menilai kemiripan antara dua nilai tersebut.

Pada makalah [11] telah diusulkan penggunaan penanganan khusus *local similarity* untuk *leaf node* tertentu. Penghitungan kemiripan *leaf node*-nya dilakukan berdasarkan karakteristik *leaf node* tersebut. Apakah ia merupakan bilangan, kata, tanggal, atau lainnya. Peningkatan ini membuat nilai kemiripan *leaf node* dapat bernilai kontinyu antara 0 sampai dengan 1 yang berarti meningkatkan unjuk kerja algoritma secara umum. Sebagaimana telah diusulkan penelitian [15] dengan menggunakan fuzzy, diusulkan penelitian [8] dengan menggunakan rasio, diusulkan makalah [7] untuk dua buah *image*, dan juga penelitian [10] untuk dua buah dokumen.

Sebagaimana dipaparkan dalam Bagian 3.1.1, dalam makalah ini konten dokumen direpresentasikan sebagai vektor *term*. Makalah ini menggunakan penghitungan kemiripan dua vektor yang telah mapan yaitu *cosine similarity* [2]. Dimana kemiripan dua buah vektor diwakilkan ke dalam besar sudut antara dua vektor tersebut.

$$\text{Cosine}(q, d) = \frac{q \cdot d}{\|q\| \|d\|} \quad (7)$$

Bila dipaparkan lebih lanjut bisa dirumuskan sebagai berikut:

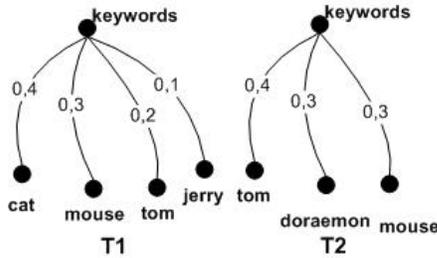
$$\text{Cosine}(q, d) = \frac{\sum_{k=1}^m w_{qk} \times w_{dk}}{\sqrt{\sum_{k=1}^m (w_{qk})^2} \cdot \sqrt{\sum_{k=1}^t (w_{dk})^2}} \quad (8)$$

Dengan:

$W_{ij}$  : bobot *term j* terhadap dokumen *i*

*q* : vektor dokumen Q

*d* : vektor dokumen D



Gambar 9: Subtree contoh T1 dan T2

$m$  : dimensi vektor  $Q$  dan  $D$

Dalam Gambar 8 tampak bahwa *subtree keywords* tidak memiliki label cabang. Hal ini dilakukan untuk memberi fleksibilitas pada tiap *term* berpindah posisi cabang dalam penghitungan kemiripan. Hal ini mengantisipasi kemungkinan adanya *term* yang sama pada posisi cabang yang berbeda. Karena kondisi ini berbeda dengan aturan standar *weighted tree* [5] maka pengembangan yang diajukan pada penelitian ini agar algoritma *weighted tree similarity* memiliki penanganan khusus untuk *subtree keywords*. Sedangkan pada penelitian [11] baru diajukan penambahan penanganan khusus penghitungan *local similarity leaf node*. *Subtree* ini bersifat khusus baik dari pembentukannya yang tidak memiliki label *arc* maupun penghitungan kemiripannya yang menggunakan *cosine similarity*.

Langkah pertama penghitungan adalah penghitungan kemiripan *term* yang paling tinggi. Operasi perbandingan *term* ini masih menggunakan operasi *string matching*, oleh karenanya hanya menghasilkan nilai 1 atau 0 tidak diantaranya. Setelah diketahui pasangan cabang yang memiliki kemiripan 1 kemudian dilakukan perhitungan kemiripan dengan *cosine similarity*.

Komputasi *similarity* dua *weighted tree* yang mengandung *subtree keywords* dipaparkan sebagai berikut. Terdapat penanganan khusus di dalam algoritma untuk *subtree keywords*. Khusus *subtree keywords* dipergunakan penghitungan *cosine similarity* berdasarkan Persamaan 8 sedangkan kemiripan gabungan dihitung dengan perhitungan *weighted tree similarity* berdasarkan Persamaan 1.

Contoh penghitungan kemiripan dua *subtree keywords* dan penghitungan *weighted tree* yang mengandung *subtree keywords* dijelaskan pada Bagian 4.

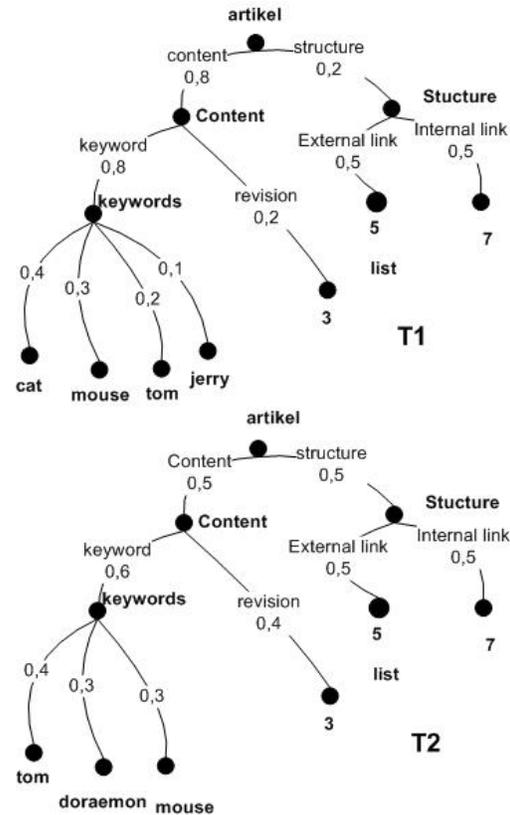
#### 4 CONTOH KOMPUTASI

Contoh komputasi kemiripan *weighted tree* diterangkan di dalam bagian ini. Pada awalnya diterangkan komputasi kemiripan dua *subtree keywords* di bagian 4.1. Kemudian baru komputasi kemiripan dua *weighted tree* yang mengandung *subtree keywords* dengan *weighted tree similarity* dipaparkan di bagian 4.2.

##### 4.1 Subtree Keywords

Terdapat contoh *weighted tree query* pengguna (T2) dan *weighted tree dokumen* (T1) sebagaimana Gambar 9. T1 ingin dihitung kemiripannya dengan T2.

Komputasi kemiripan cabang menghasilkan Tabel 3 sebagai berikut: Berdasar Tabel 3 dapat diketahui terdapat



Gambar 10: Contoh perhitungan total

dua *term* yang terkandung baik dalam *subtree* T1 dan T2. *Term* tersebut adalah tom dan mouse. Dari proses ini dapat dilakukan komputasi kemiripan *subtree keywords* berdasarkan Persamaan 8 sebagai berikut:

$$\begin{aligned} \text{Cosine}(q, d) &= \frac{(0,4 \cdot 0) + (0,3 \cdot 0,3) + (0,2 \cdot 0,4) + (0,1 \cdot 0)}{\sqrt{0,4^2 + 0,3^2 + 0,2^2 + 0,1^2} \cdot \sqrt{0,4^2 + 0,3^2 + 0,3^2}} \\ &= 0,532 \end{aligned} \quad (9)$$

##### 4.2 Kemiripan Gabungan

Terdapat contoh *weighted tree query* pengguna (T2) dan *weighted tree dokumen* (T1) sebagaimana Gambar 10. T1 ingin dihitung kemiripannya dengan T2. Pada contoh ini *subtree keywords* sama dengan Gambar 9. Perhitungan *subtree* ini telah dilakukan pada Bagian 4.1 dan menghasilkan nilai 0,532. Dengan demikian, kemiripan T1 dan T2 di dalam Gambar 9 adalah  $\text{Sim}(T1, T2) = 0,78706$ .

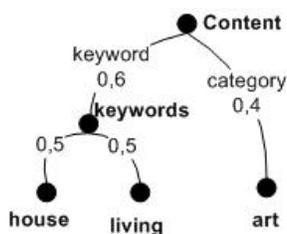
#### 5 UJI COBA DAN EVALUASI

Uji coba dilakukan pada Kiwix, versi portabel Wikipedia bahasa Inggris (dapat didownload di <http://www.kiwix.org>). Kiwix berisi 1964 artikel Wikipedia. Pengukuran kinerja pencarian ditentukan dengan suatu perhitungan *Precision* dengan rumusan sebagai berikut [2]:

$$\text{Precision} = \frac{|R_a|}{|A|} \quad (10)$$

**Tabel 3:** Penghitungan kemiripan cabang

T1	T2	S
Cat	Tom	0
Mouse	Tom	0
Tom	Tom	1
Jerry	Tom	0
Cat	Doraemon	0
Mouse	Doraemon	0
Tom	Doraemon	0
Jerry	Doraemon	0
Cat	Mouse	0
Mouse	Mouse	1
Tom	Mouse	0
Jerry	Mouse	0

**Gambar 11:** *Weighted tree* pengujian

Dengan Ra adalah jumlah artikel yang relevan dari hasil pencarian, sedangkan A adalah jumlah seluruh artikel hasil pencarian. Nilai *precision* 1 mengindikasikan kinerja yang tertinggi dan nilai *precision* 0 terendah.

Pengujian pertama dilakukan pada pencarian *full-text* dengan relasi OR antara *term*. Sebagai contoh pada Tabel 4 *query* pertama bermakna *query term house OR living*. Pengujian kedua dilakukan pada pencarian menggunakan metadata. Relasi antara *term* tetap OR dengan tambahan *filter AND* untuk pemilihan kategori secara spesifik. Sebagai contoh pada Tabel 4 *query* pertama bermakna *query term house OR living AND kategori:arts*. Nilai-nilai hasil pengujian terdapat di dalam Tabel 4. Tampak dari Tabel 4 dengan lima kali pengujian, pencarian dengan metadata menggunakan tambahan *filter AND* kategori memberikan rata-rata nilai *precision* yang lebih tinggi dibandingkan pencarian *full-text*. Hal ini tidak berlaku pada pemilihan kategori yang keliru.

Pengujian ketiga dilakukan dengan pencarian menggunakan algoritma *weighted tree similarity*. Struktur *tree* yang dipergunakan terdapat pada Gambar 11 sebagai contoh bentuk *tree* untuk *query* pertama (Q1) Tabel 5. Pada *query* selanjutnya (Q2 s/d Q5) nilai *term house* dan *living* digantikan oleh *term* yang lain sedangkan nilai *arts* digantikan nilai kategori yang lain mengikuti data dalam Tabel 4. Nilai bobot cabang *subtree keywords* adalah  $1/n$  dengan  $n$  menunjukkan banyaknya *query term*. *Tree* artikel dibangkitkan pula dengan bentuk pada Gambar 11. Pembangkitan *subtree keywords* mengikuti langkah-langkah pada Bagian 3.1.1. Penghitungan kemiripan gabungan mengikuti langkah-langkah pada Bagian 3.2.

Tabel 5 mencatat nilai *precision* antara *tree query* penguna (Q1 s/d Q5) dengan *tree* artikel pada pencarian menggunakan algoritma *weighted tree similarity*. Batas suatu artikel dianggap relevan jika  $precision \geq 0,8$ . Nilai  $x/y$

**Tabel 4:** Hasil pengujian Full-text dan metadata

No	Query terms	Kategori	Precision	
			Full-text	Metadata
1	House living	Arts	0.04	0.35
2	Animal kingdom	Biology and Medicine	0.04	0.5
3	Animal song	Biology and Medicine	0.08	0.29
4	Car	Transport	0.23	0.4
5	Book	Literature	0.25	0.67
	Rata-rata		0.13	0.44

**Tabel 5:** Hasil pengujian dengan *weighted tree similarity*

No	Query	Precision dengan nilai kemiripan $\geq 0,8$
1	Q1	1/1
2	Q2	1/1
3	Q3	1/2
4	Q4	2/2
5	Q5	2/2
	Rata-rata	0.9

dalam kolom *precision* menunjukkan  $x$  adalah jumlah artikel yang relevan dari hasil pencarian, sedangkan  $y$  adalah jumlah seluruh artikel hasil pencarian. Hasil pada Tabel 5 dan Tabel 4 menunjukkan secara empirik dengan lima kali pengujian, pencarian semantik dengan *weighted tree similarity* menghasilkan nilai rata-rata *precision* yang lebih baik (0,9) dibandingkan dengan pencarian *full-text* (0,13) dan metadata biasa (0,44).

## 6 KESIMPULAN DAN SARAN

Dalam makalah ini telah ditunjukkan bahwa penggabungan algoritma *weighted tree similarity* dengan *cosine similarity* efektif diimplementasikan untuk pencarian semantik. Struktur metadata *tree* disusun berdasarkan informasi semantik semacam taksonomi, ontologi, *preference*, sinonim, homonim dan *stemming*. Hasil uji coba pada artikel Wikipedia menunjukkan bahwa ketepatan (*precision*) pencarian menggunakan algoritma *weighted tree similarity* lebih tinggi daripada pencarian *full-text* maupun pencarian dengan metadata biasa.

Penelitian dapat dikembangkan lebih lanjut dengan penggunaan metoda *word similarity* untuk pencocokan *term* pada *leaf node subtree keywords*.

## DAFTAR PUSTAKA

- [1] Beall, J.: *The Weaknesses of Full-Text Searching*. The Journal of Academic Librarianship (September 2008)
- [2] Yates, R.B., Neto, B.R.: *Modern Information Retrieval*. Addison Wesley Longman Limited (1999)
- [3] Baca, M., et.al: *Introduction to Metadata*. Getty Research Institute, Los Angeles (2008)
- [4] V.C.Bhavsar, Boley, H., Yang, L.: *A Weighted-Tree Similarity Algorithm for Multi-agent System in E-Business Environments*. In: Proceeding Workshop

- on Business Agents and the Semantic Web, National Research Council of Canada, Institute for Information Technology, Fredericton (June 2003) 53–72
- [5] Boley, H., Bhavsar, V.C., Hirtle, D., Singh, A., Sun, Z., Yang, L.: *A Match-making System for Learners and Learning Objects*. International Journal of Interactive Technology and Smart Education (2005)
- [6] Sarno, R., Yang, L., Bhavsar, V.C., Boley, H.: *The AgentMatcher Architecture Applied to Power Grid Transactions*. In: Proceeding of the First International Workshop on Knowledge Grid and Grid Intelligence, Halifax, Canada (2003) 92–99
- [7] Budianto, Sarno, R.: *Shape Matching using Thin-Plate Splines Incorporated to Extended Weighted-tree Similarity Algorithm for Agent Matching in Virtual Market*. In: Proceedings International Seminar on Information and Communication Technology. (August 2005)
- [8] Fabianto, E.: *Ratio Extended Weighted Tree Similarity Algorithm Applied to Cost Estimate of Software Development*. Master's thesis, Program Pasca Sarjana, Fakultas Teknologi Informasi, ITS Surabaya (July 2005)
- [9] Solihin, F., Sarno, R.: *Penerapan Arsitektur Agent Matcher Menggunakan Algoritma Extended Weighted Tree Similarity untuk Menyediakan Informasi yang Optimal pada Handheld Device*. In: Proceeding Seminar Nasional Pascasarjana VI, Surabaya (August 2006) 38–43
- [10] Sulistyono, W., Sarno, R.: *Auto Matching Antar Dokumen dengan Metode Cosine Measure*. In: Seminar Nasional Teknologi Informasi dan Komunikasi, Department of Informatics, ITS Surabaya (Mei 2008)
- [11] Yang, L., Ball, M., Bhavsar, V.C., Boley, H.: *Weighted Partonomy Taxonomy Trees with Local Similarity Measures for Semantic Buyer-Seller Matchmaking*. In: Proceeding of 2005 Workshop on Business Agents and the Semantic Web, Victoria, Canada (May 2005) 23–35
- [12] Rahutomo, F., Sarno, R.: *Semantic Search Wikipedia by Applying Agent Matcher Architecture*. In: Proceedings International Conference on Information and Communication Technology and System, Department of Informatics, ITS Surabaya (August 2008) 646–653
- [13] Yang, L., Sarker, B.K., Bhavsar, V.C., Boley, H.: *A Weighted-Tree Simplicity Algorithm for Similarity Matching of Partial Product Descriptions*. In: Proceeding of ISCA 14th International Conference on Intelligent and Adaptive Systems and Software Engineering, Toronto (July 2005) 55–60
- [14] Tan, P.N., Steinbach, M., Kumar, V.: *Introduction to Data Mining*. Addison Wesley-Pearson International Edition (2006)
- [15] Setyawan, S.H., Sarno, R.: *Fuzzy Logics Incorporated to Extended Weighted-Tree Similarity Algorithm for Agent Matching in Virtual Market*. In: Proceeding International Seminar on Information and Communication Technology. (August 2005)