JURNAL FASILKOM
Volume 14 No. 2 | Agustus 2024: 361-369

P-ISSN : 2089-3353
E-ISSN : 2808-9162

Sistem *Retrieval* E-Arsip Tirta Asata Menggunakan Algoritma *Vector Space Model*

Iqbal Hanan Junaidi[1], Sopingi[2], Sri Sumarlinda[3]
[1]Teknik Informatika, Fakultas Ilmu Komputer, Universitas Duta Bangsa Surakarta
[2,3]Sistem Informasi, Fakultas Ilmu Komputer, Universitas Duta Bangsa Surakarta
[1]202020345@mhs.udb.ac.id *, [2]sopingi@udb.ac.id, [3]sri_sumarlinda@udb.ac.id

Abstract

PT. Tirta Asasta Depok, facing challenges in document management. Currently, PT. Tirta Asasta Depok is still using manual archiving, which has barriers in the effectiveness and efficiency of time when searching for documents. This system implements an effective and efficient records management system at PT. Tirta Asasta Depok by utilizing text mining techniques, particularly the Vector Space Model algorithm. The problem faced by the company at this time is the storage and search of documents that are still manual, causing irregularity in the archives and hindering productivity. The research method used is to analyze document data in pdf format owned by PT. Tirta Asasta Depok. The Vector Space Model algorithm is applied to perform document similarity searches based on keywords entered by the user. Through term weighting and the ability to match partial queries with existing documents, this algorithm is expected to improve the effectiveness and efficiency of the company's records management. The results of this research are expected to produce a more organized, easily accessible, and quickly retrievable records management system when needed. The application of text mining technology, particularly the Vector Space Model algorithm, has been proven to automate the archiving process and improve the overall performance of the organization.

Keywords: Archive Management, Text Mining, Vector Space Model, Information Retrieval, Retrieval System

Abstrak

PT. Tirta Asasta Depok, menghadapi tantangan dalam pengelolaan dokumen. Saat ini, PT. Tirta Asasta Depok masih menggunakan pengarsipan secara manual, yang memiliki hambatan dalam efektivitas dan efisiensi waktu saat mencari dokumen. Sistem ini mengimplementasikan sistem manajemen arsip yang efektif dan efisien di PT. Tirta Asasta Depok dengan memanfaatkan teknik *text mining*, khususnya algoritma *Vector Space Model*. Permasalahan yang dihadapi perusahaan saat ini adalah penyimpanan dan pencarian dokumen yang masih manual, sehingga menyebabkan ketidakteraturan arsip dan menghambat produktivitas. Metode penelitian yang digunakan adalah dengan menganalisis data dokumen dalam format pdf yang dimiliki oleh PT. Tirta Asasta Depok. Algoritma *Vector Space Model* diterapkan untuk melakukan pencarian kemiripan dokumen berdasarkan kata kunci yang dimasukkan oleh pengguna. Melalui pembobotan kata (term) dan kemampuan mencocokkan sebagian *query* dengan dokumen yang ada, algoritma ini diharapkan dapat meningkatkan efektivitas dan efisiensi dalam manajemen arsip perusahaan. Hasil dari penelitian ini diharapkan dapat menghasilkan sistem manajemen arsip yang lebih teratur, mudah diakses, dan dapat ditemukan dengan cepat saat dibutuhkan. Penerapan teknologi *text mining*, khususnya algoritma *Vector Space Model*, terbukti dapat mengotomatisasi proses pengarsipan dan meningkatkan kinerja organisasi secara keseluruhan.

Kata kunci: Manajemen Arsip, *Text Mining*, *Vector Space Model*, *Information Retrieval*, Sistem Temu Kembali

1. Pendahuluan

Dalam era digital yang terus berkembang, banyak instansi, termasuk PT. Tirta Asasta Depok, menghadapi tantangan dalam pengelolaan dokumen. Saat ini, PT. Tirta Asasta Depok masih menggunakan pengarsipan secara manual, yang memiliki hambatan dalam efektivitas dan efisiensi waktu saat mencari dokumen. Seharusnya, dokumen-dokumen tersebut disimpan dengan rapi, mudah diakses, dan dapat ditemukan dengan mudah ketika dibutuhkan. Oleh karena itu, implementasi sistem pengarsipan surat yang efisien dan efektif menjadi sangat penting [1]. Sistem pengarsipan idealnya dilengkapi dengan fitur pencarian yang dapat memudahkan dalam menemukan dokumen dengan cepat. Seiring waktu berjalan, jumlah dokumen yang perlu diarsipkan akan bertambah. Oleh karena itu, pengaturan arsip harus dilakukan secara teratur. Dengan menggunakan teknologi, pengarsipan dapat dilakukan secara otomatis dan menghasilkan manajemen dokumen yang efisien. Penggunaan teknologi memudahkan akses informasi dan mempercepat proses pencarian dokumen, sehingga sistem pengarsipan dapat lebih efektif dan efisien [2].

Pengelolaan dokumen dan arsip merupakan aspek krusial bagi perusahaan atau organisasi. Salah satu tantangan utamanya adalah mengenai penyimpanan dan pencarian dokumen yang masih manual. Kondisi ini bisa mengakibatkan ketidakteraturan dalam penyimpanan arsip, yang akhirnya dapat menghambat produktivitas dan efisiensi perusahaan. Oleh karena itu, dibutuhkan pengaturan yang baik dalam

P-ISSN : 2089-3353
E-ISSN : 2808-9162

pengarsipan, dan teknologi dapat membantu mengotomatisasi proses pengarsipan untuk menciptakan manajemen dokumen yang efisien dan efektif. Pemanfaatan *text mining*, terutama dalam teknik *Information Retrieval* (IR), diyakini memiliki kemampuan untuk mendukung peningkatan manajemen arsip di perusahaan. Implementasi IR di perusahaan sangat krusial karena dapat terintegrasi dalam beragam fungsi, seperti menjelajah internet, perpustakaan digital, dan aplikasi pengarsipan [3]. Salah satu teknik dalam *Information Retrieval* yang bisa dimanfaatkan adalah *Vector Space Model*, yang unggul dalam kemampuan pencocokan *query* karena dapat mencocokkan bagian-bagian *query* dengan dokumen yang tersedia [4]. Model pencarian memungkinkan membandingkan tingkat kemiripan antara dokumen yang disimpan dalam *database* dan dokumen yang dicari oleh pengguna. Oleh karena itu penggunaan algoritma VSM dalam pencarian data arsip akan lebih efektif [5].

Ketidakteraturan dalam penyimpanan arsip dapat menghambat produktivitas dan efisiensi perusahaan. Saat harus mencari data, waktu yang dibutuhkan akan lebih lama dan hasilnya akan meluas dari topik pencarian yang sebenarnya dibutuhkan [6]. Oleh karena itu, penelitian ini dengan metode *text mining* bertujuan untuk meningkatkan manajemen arsip di PT. Tirta Asasta Depok.

Dengan menerapkan teknik *Vector Space Model*, penelitian ini dapat membantu dalam pengembangan sistem manajemen arsip yang lebih efektif dan efisien, yang pada gilirannya dapat meningkatkan performa keseluruhan organisasi. Dengan menggunakan VSM, diharapkan dapat mengukur tingkat kesamaan antara kata, frasa, dan dokumen melalui penggunaan bobot kata. Selain itu, model ini juga memungkinkan untuk melakukan pencocokan *query* dengan dokumen hanya sebagian. Sistem ini juga dapat disesuaikan dengan mudah melalui penyesuaian parameter, termasuk pengaturan bobot.

2. Metode Penelitian

Penelitian ini menggunakan data dokumen dari PT. Tirta Asasta Depok dalam bentuk pdf untuk melakukan pencarian kemiripan dengan sistem *retrieval*. Proses ini dimulai dengan indeksasi dokumen berdasarkan seluruh isi dalam dokumen dengan dilakukan pengolahan teks yang mencakup tokenisasi dan penghapusan *stopwords* [7]. Proses ini memecah dokumen menjadi unit-unit terkecil yang disebut token. Dalam proses ini, teks dapat dibagi menjadi kata, simbol, frasa, dan elemen penting lainnya. Kata-kata yang dianggap tidak relevan dihapus saat proses penghapusan kata sebelum dijadikan kata kunci dalam pencarian dokumen. Metode pembobotan yang diterapkan adalah TF-IDF dan nilai yang dihasilkan akan dimanfaatkan dalam perhitungan *Vector Space Model* (VSM) [7]. Sehingga pengguna dapat memasukkan kata kunci ke dalam sistem, sehingga sistem dapat menemukan dokumen yang paling mirip. Hasil akhirnya akan berupa tingkat kemiripan antara kata kunci dan dokumen yang disusun berdasarkan nilai tertinggi. Sistem aplikasi yang dimanfaatkan dalam penelitian ini dijelaskan dalam Gambar 1.

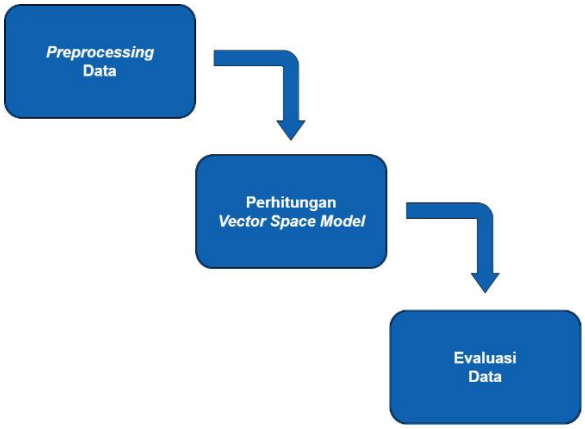

Gambar 1. Tahapan Metode Penelitian

2.1 *Preprocessing*

Preprocessing merupakan langkah yang sangat penting karena dapat mempengaruhi kualitas data. Pada tahap ini dipilih karakteristik yang mempunyai pengaruh signifikan terhadap proses yang dilakukan [8]. Pada tahap ini dilakukan *preprocessing* pada saat *text mining*. Ketika sebuah dokumen atau teks mengandung banyak elemen non-standar seperti simbol dan angka, maka setiap teks akan dibagi menjadi unit-unit yang lebih kecil, biasanya kata-kata, dengan makna yang lebih detail. Selanjutnya sistem menampilkan hasil *preprocessing* yaitu data bersih [9] dan setiap teks akan dibagi menjadi unit-unit yang lebih kecil, biasanya kata-kata, dengan makna yang lebih detail. Langkah-langkah yang ditemui dalam proses pengolahan teks adalah sebagai berikut:

2.1.1 Tokenisasi

Tokenisasi merupakan proses memecah dokumen menjadi unit-unit terkecil yang disebut token. Dalam proses ini, teks dapat dibagi menjadi kata, simbol, frasa, dan elemen penting lainnya. Di samping itu, proses ini juga melibatkan penghapusan karakter khusus seperti simbol dan tanda baca, dan mengonversi semua huruf menjadi huruf kecil secara simultan [10]. Dalam proses ini teks didalam dokumen dapat dipecah menjadi kata dan frasa untuk menghitung pembobotan yang dihitung menggunakan TF-IDF dalam perhitungan algoritma *Vector Space Model* untuk mengukur seberapa sering sebuah term muncul dalam sebuah dokumen.

Langkah-langkah tokenisasi adalah sebagai berikut:

1. Pemecahan Dokumen menjadi Unit-unit Terkecil: Teks dalam dokumen dipecah menjadi unit-unit terkecil seperti kata, simbol, frasa, dan elemen penting lainnya.

2. Penghapusan Karakter Khusus: Karakter khusus seperti simbol dan tanda baca dihapus dari teks.
3. Konversi Huruf menjadi Huruf Kecil: Semua huruf dalam teks dikonversi menjadi huruf kecil secara seragam.
4. Pemecahan Teks menjadi Kata dan Frasa: Teks yang telah dibersihkan dari karakter khusus dan dikonversi menjadi huruf kecil, selanjutnya dipecah menjadi kata-kata dan frasa-frasa.
5. Perhitungan Pembobotan dengan TF-IDF: Kata-kata dan frasa-frasa yang telah diekstrak selanjutnya dihitung pembobotan menggunakan TF-IDF (*Term Frequency-Inverse Document Frequency*) untuk mengukur seberapa sering sebuah term muncul dalam sebuah dokumen.
6. Integrasi dengan Algoritma *Vector Space Model*: Hasil tokenisasi dan pembobotan TF-IDF selanjutnya diintegrasikan dengan algoritma *Vector Space Model* untuk menghitung kemiripan antar dokumen berdasarkan kata kunci pencarian.

Dengan mengikuti langkah-langkah di atas, dokumen dapat dipecah menjadi unit-unit terkecil, dibersihkan dari karakter khusus, dan dihitung pembobotan menggunakan TF-IDF untuk kemudian digunakan dalam perhitungan algoritma *Vector Space Model*.

2.1.2 Penghapusan *Stopwords*

Pembersihan *stopword*, khususnya tahap pengolahan data, dilanjutkan dengan pemilihan data yang dianggap dapat digunakan [11]. Proses penghapusan kata-kata yang tidak penting pada dokumen dilakukan dengan memeriksa apakah kata-kata yang dihasilkan dari tokenisasi termasuk dalam daftar kata yang tidak relevan (*stoplist*) atau tidak [12]. Kata-kata yang dianggap tidak relevan dihapus saat proses penghapusan kata sebelum dijadikan kata kunci dalam pencarian dokumen. Kata-kata yang dianggap tidak signifikan (*stopwords*) seperti kata-kata yang terdiri hanya 2 huruf kecuali kata hubung 'di', 'ke', 'dari', 'dan', 'atau', 'yang' akan disaring dan dimasukkan ke dalam daftar *stoplists*. Hal ini dilakukan untuk mengurangi jumlah kata dalam *dataset* guna meningkatkan kecepatan dan performa kerja sistem [10].

Berikut adalah langkah-langkah penghapusan *stopwords*:

1. Identifikasi *Stopwords*: Identifikasi kata-kata yang dianggap tidak relevan atau tidak penting selama proses *text mining*, seperti kata-kata yang terdiri hanya 2 huruf kecuali kata hubung 'di', 'ke', 'dari', 'dan', 'atau', 'yang'.
2. Pembuatan Daftar *Stoplists*: Buat daftar *stopwords* yang telah diidentifikasi dan masukkan ke dalam daftar *stoplists*.
3. Pembersihan Teks dari *Stopwords*: Lakukan pembersihan teks dengan menghapus kata-kata yang terdapat di dalam daftar *stoplists*. Hal ini dapat dilakukan dengan menggunakan fungsi penghapusan atau penyaringan (*filtering*) pada *library*/modul pemrosesan bahasa alami (NLP) yang digunakan.
4. Tokenisasi Teks yang Bersih: Setelah teks dibersihkan dari *stopwords*, lakukan tokenisasi teks menjadi kata-kata atau n-gram yang akan digunakan untuk pemrosesan selanjutnya.
5. Pemilihan Fitur yang Relevan: Dari hasil tokenisasi, pilih kata-kata atau n-gram yang dianggap relevan dan signifikan untuk digunakan sebagai fitur dalam proses analisis teks selanjutnya.
6. Penyimpanan Daftar *Stoplists*: Simpan daftar stoplists yang telah dibuat untuk digunakan kembali pada proses pembersihan teks di masa mendatang.

2.2 Perhitungan *Vector Space Model*

Setelah proses *preprocessing* selesai, dilakukan perhitungan kemiripan antara kata kunci dan dokumen menggunakan algoritma VSM dengan prosedur pembobotan terlebih dahulu. Metode pembobotan menggunakan TF-IDF untuk menghitung bobot dalam proses pengambilan informasi. Setelah proses *preprocessing*, data akan diubah menjadi bentuk numerik menggunakan metode TF-IDF, di mana nilai TF berdasarkan frekuensi kata dalam dokumen. Jika suatu kata sering muncul maka nilai TFnya akan besar; jika suatu kata jarang muncul maka nilai TFnya akan kecil. Nilai IDF, di sisi lain, didasarkan pada frekuensi pencarian kata dalam kumpulan dokumen yang tersedia di database [10].

$$tf = tf_i \quad (1)$$

Perhitungan *Term Frequency* (*tf*)

Term frequency (*tf*) adalah suatu metode untuk mengukur seberapa sering sebuah term muncul dalam sebuah dokumen, sedangkan (tf_i) adalah banyaknya kemunculan *term* (t_i) dalam dokumen (d_j)

$$idf_i = log\frac{N}{dfi} \quad (2)$$

Perhitungan *Inverse Document Frequency* (*idf*)

idf_i adalah *inverse document frequency*, sedangkan *N* adalah jumlah dokumen dan df_i adalah banyaknya dokumen dalam koleksi Dimana *term* t_i muncul didalamnya.

$$W_{ij} = tf_{ij} \cdot log\frac{N}{dfi} \quad (3)$$

Perhitungan *Term Frequency Inverse Document Frequency* (*tfidf*)

W_{ij} adalah bobot dokumen yang dihitung, sedangkan tf_{ij} adalah banyaknya kemunculan *term* t_i pada dokumen d_j. *N* adalah jumlah dokumen dan df_i adalah banyaknya dokumen dalam koleksi dimana *term* t_i muncul didalamnnya.

$$|d_j| = \sqrt{\sum_{j=1}^{t}(Wij)^2} \quad (4)$$

Perhitungan Jarak Dokumen ($|d_j|$)

P-ISSN : 2089-3353
E-ISSN : 2808-9162

$|d_j|$ adalah jarak dokumen, sedangkan W_{ij} adalah bobot dokumen ke-i.

$$|q|=\sqrt{\sum_{j=1}^{t}(Wi,q)^2} \quad (5)$$

Perhitungan Jarak *Query* ($|q|$)

$|q|$ adalah jarak kueri, sedangkan $W_{i,q}$ adalah bobot kueri dokumen ke-i.

$$Sim(d,d_j)=\frac{dj\cdot q}{|dj|\cdot|q|}=\frac{\sqrt{\sum_{i=1}^{t}Wiq\cdot Wij}}{\sum_{i=1}^{t}(Wij)^2\cdot\sum_{j=1}^{t}(Wi,q)^2} \quad (6)$$

Perhitungan Pengukuran Similaritas *Query Document*

W_{ij} adalah bobot *term* dalam dokumen. W_{iq} adalah bobot kueri, sedangkan *Sim(q,dj)* adalah similaritas antara kueri dan dokumen.

Sistem akan menghitung nilai kemiripan antara *query* pada dokumen arsip di PT. Tirta Asasta Depok. Nilai kemiripan tertinggi akan ditampilkan oleh sistem dalam bentuk niali similaritas. Nilai ini menunjukkan seberapa besar kesamaan atau kesesuaian antara kata kunci dengan dokumen arsip.

Dengan kata lain, sistem akan mengidentifikasi dokuken arsip yang paling dekat atau paling mirip dengan kata kunci yang telah dicari. Hasil identifikasi ini akan disajikan dalam bentuk nilai kemiripan, sehingga memudahkan pengguna untuk memahami seberapa relevan dokumen arsip tersebut dengan kata kunci yang telah dicari.

2.3 Evaluasi

Tujuan dari tahap ini adalah untuk menilai hasil kesamaan yang dihasilkan oleh algoritma, yang dicapai dengan membandingkan nilai kesamaan antar dokumen yang berbeda [13]. Dalam evaluasi ini, dilakukan evaluasi terhadap nilai-nilai seperti jarak antar dokumen, jarak antara *query*, dan nilai similaritas untuk mendapatkan pemahaman mengenai seberapa baik algoritma menghitung data penelitian.

3. Hasil dan Pembahasan

Penelitian ini mengamil sumber data yang tersedia melalui observasi di objek penelitian untuk memperoleh data dokumen arsip yang dikumpulkan [14].

3.1 *Preprocessing*

Proses *preprocessing* dilakukan untuk membersihkan data yang diperoleh, terlebih dahulu menghilangkan teks dan kata-kata yang mengganggu proses analisis [15]. Sistem akan melakukan pencarian dokumen yang diarsipkan berdasarkan kata kunci. Sebelum dilakukan pencarian, terlebih dahulu dilakukan proses pembersihan data teks yang akan digunakan. Adapun kata kunci yang akan diuji ialah "Pembinaan rohani pegawai dan permohonan dinas pendampingan umroh". Kata kunci tersebut kemudian diuji pada data uji. Penelitian ini menggunakan data eksperimen dari dua makalah yang ditunjukkan pada Gambar 2 dan 3.

NOTA DINAS

Kepada : Yth. Plt. Direktur Umum
Dari : Plh. Manajer Sumber Daya Manusia
Tanggal : 13 Februari 2024
No. Surat : 800 / 65 / SDM / II / 2024
Perihal : Permohonan Perjalanan Dinas Pendampingan dan Pengantaran Pegawai Penerima Penghargaan Umroh

Sehubungan dengan akan dilaksanakannya ibadah Umroh bagi pegawai yang mendapatkan penghargaan tersebut pada tanggal 14 – 25 Februari 2024, maka dengan ini kami mengajukan pegawai berikut untuk melakukan pendampingan dan pengantaran ke Bandara Internasional Soekarno-Hatta pada hari Rabu, 14 Februari 2024 dengan nama dan jabatan sebagai berikut:

1. (Spv. Pengembangan Pegawai)
2. (Staf Kesejahteraan Pegawai)
3. (Staf Kesejahteraan Pegawai)
4. (Staf Pengembangan Pegawai)

Demikian permohonan ini diajukan, atas realisasinya diucapkan terima kasih.

Plh. Manajer Sumber Daya Manusia

Gambar 2. Data Penelitian 1

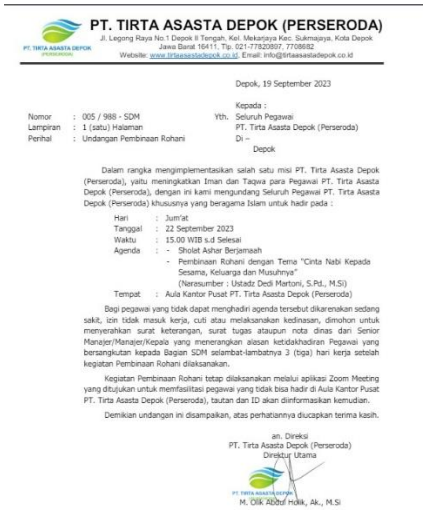

PT. TIRTA ASASTA DEPOK (PERSERODA)
Jl. Legong Raya No.1 Depok II Tengah, Kel. Mekarjaya Kec. Sukmajaya. Kota Depok Jawa Barat 16411. Tlp. 021-77820897, 7708682
Website: www.tirtaasastadepok.co.id Email: info@tirtaasastadepok.co.id

Depok, 19 September 2023

Nomor : 005 / 988 - SDM
Lampiran : 1 (satu) Halaman
Perihal : Undangan Pembinaan Rohani

Kepada :
Yth. Seluruh Pegawai
PT. Tirta Asasta Depok (Perseroda)
Di –
Depok

Dalam rangka mengimplementasikan salah satu misi PT. Tirta Asasta Depok (Perseroda), yaitu meningkatkan Iman dan Taqwa para Pegawai PT. Tirta Asasta Depok (Perseroda), dengan ini kami mengundang Seluruh Pegawai PT. Tirta Asasta Depok (Perseroda) khususnya yang beragama Islam untuk hadir pada :

Hari : Jum'at
Tanggal : 22 September 2023
Waktu : 15.00 WIB s.d Selesai
Agenda : - Sholat Ashar Berjamaah
- Pembinaan Rohani dengan Tema "Cinta Nabi Kepada Sesama, Keluarga dan Musuhnya"
(Naresumber : Ustadz Dedi Martoni, S.Pd., M.Si)
Tempat : Aula Kantor Pusat PT. Tirta Asasta Depok (Perseroda)

Bagi pegawai yang tidak dapat menghadiri agenda tersebut dikarenakan sedang sakit, izin tidak masuk kerja, cuti atau melaksanakan kedinasan, dimohon untuk menyerahkan surat keterangan, surat tugas ataupun nota dinas dari Senior Manajer/Manajer/Kepala yang menerangkan alasan ketidakhadiran Pegawai yang bersangkutan kepada Bagian SDM selambat-lambatnya 3 (tiga) hari kerja setelah kegiatan Pembinaan Rohani dilaksanakan.

Kegiatan Pembinaan Rohani tetap dilaksanakan melalui aplikasi Zoom Meeting yang ditujukan untuk memfasilitasi pegawai yang tidak bisa hadir di Aula Kantor Pusat PT. Tirta Asasta Depok (Perseroda), tautan dan ID akan diinformasikan kemudian.

Demikian undangan ini disampaikan, atas perhatiannya diucapkan terima kasih.

an. Direksi
PT. Tirta Asasta Depok (Perseroda)
Direktur Utama

M. Olik Abdul Holik, Ak., M.Si

Gambar 3. Data Penelitian 2

Setiap data uji sistem terlebih dahulu menjalani langkah prapemrosesan, termasuk pengkodean dan penghapusan kata-kata penghenti, kemudian proses pembobotan dilakukan menggunakan perhitungan *vector space model*.

3.1.1 Tokenisasi

Output dari langkah ini adalah kalimat dari dokumen yang telah dibagi menjadi kata-kata, seperti yang terlihat pada Gambar 4.

DAFTAR ISTILAH

```
Array
(
    [0] => tirta
    [1] => asasta
    [2] => depok
    [3] => perseroda
    [4] => legong
    [5] => raya
    [7] => tengah
    [8] => ke
    [9] => mekarjaya
    [10] => kec
    [352] => staf
    [353] => kesejahteraan
    [355] => faradisa
    [356] => athalla
    [360] => annisa
    [361] => deisy
    [362] => satria
    [369] => diajukan
    [371] => realisasinya
    [380] => haryadi
)
```

Gambar 4. Hasil Tokenisasi

3.1.2 Penghapusan *Stopwords*

Pada tahap ini, sistem melakukan penghilangan kata-kata yang tidak memiliki makna atau tidak relevan, seperti yang terlihat pada ilustrasi dalam Gambar 5.

P-ISSN : 2089-3353
E-ISSN : 2808-9162

Gambar 5. Hasil Penghapusan *Stopwords*

3.2 Perhitungan *Vector Space Model*

Penelitian ini dilkakukan pencarian kemiripan dokumen dengan kata kunci yang telah dicari yaitu "Pembinaan rohani pegawai dan permohonan dinas pendampingan umroh".

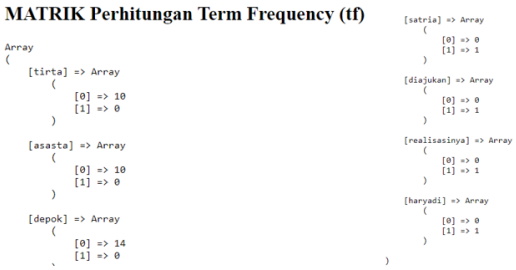

Gambar 6. Hasil Perhitungan TF

```
Function Terms Frequency
static function tf($terms, $dokumen){
  $jml_dokumen = count($dokumen);
  $matrik_tf = array();
  foreach ($terms as $item) {
    if (!empty($item)) {
      for ($i = 0; $i < $jml_dokumen; $i++) {
        $jml = substr_count(strtolower($dokumen[$i]['keyword']), $item);
        $matrik_tf[$item][$i] = $jml;
      }
    }
  }
  return $matrik_tf;
}
```

Fungsi tf tersebut menghitung *term frequency* (TF) untuk setiap istilah dalam daftar *terms* di setiap dokumen dalam koleksi. Hasil dari proses ini adalah sebuah matriks TF yang menunjukkan frekuensi kemunculan setiap istilah dalam setiap dokumen. Struktur matriks tersebut adalah sebagai berikut :

1. matrik_tf[istilah][dokumen_index]: Frekuensi kemunculan istilah dalam dokumen yang diindeks oleh dokumen_index.

Fungsi ini memastikan bahwa setiap istilah dihitung secara case-insensitive dan hanya menghitung istilah yang tidak kosong.

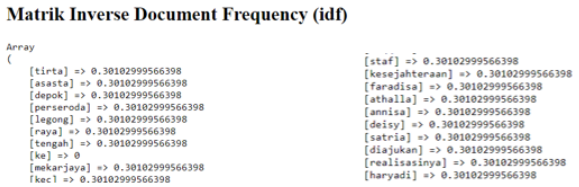

Gambar 7. Hasil Perhitungan IDF

```
Function IDF
static function idf($matrik_tf, $dokumen){
  $N = count($dokumen);
  $matrik_df = array();
  $matrik_idf = array();
  foreach ($matrik_tf as $key => $item){
    $matrik_df[$key] = 0;
    foreach ($item as $value) {
      if ($value > 0) {
        $matrik_df[$key]++;
      }
    }
  }
  foreach ($matrik_df as $key => $value) {
    if ($value == 0) {
      $matrik_idf[$key] = 0;
    } else {
      $matrik_idf[$key] = log10($N / $value);
    }
  }
  return $matrik_idf;
}
```

Fungsi IDF menghitung nilai *Inverse Document Frequency* (IDF) untuk setiap istilah yang terdapat dalam kumpulan dokumen. IDF adalah metrik yang menunjukkan tingkat signifikansi suatu istilah dalam keseluruhan koleksi dokumen. Perhitungan IDF melibatkan jumlah dokumen dalam koleksi dan jumlah dokumen yang mengandung istilah tersebut. Dengan rumus yang digunakan $idf_i = log\frac{N}{dfi}$ dimana :

1. N adalah jumlah total dokumen.
2. DF adalah jumlah dokumen yang mengandung istilah tersebut.

Fungsi tersebut juga menangani kasus di mana nilai *Document Frequency* (DF) adalah 0 untuk menghindari pembagian dengan nol. Dalam kasus seperti itu, nilai *Inverse Document Frequency* (IDF) akan diatur menjadi 0. Hasil akhir dari proses ini adalah matriks IDF yang menunjukkan kepentingan relatif dari setiap istilah dalam keseluruhan koleksi dokumen.

P-ISSN : 2089-3353
E-ISSN : 2808-9162

```
[ashar] => Array
    (
        [0] => 0.30102999566398
        [1] => 0
    )

[berjamaah] => Array
    (
        [0] => 0.30102999566398
        [1] => 0
    )

[pembinaan] => Array
    (
        [0] => 1.8061799739839
        [1] => 0
    )

[rohani] => Array
    (
        [0] => 2.1072099696479
        [1] => 0
    )
```

Gambar 8. Hasil Perhitungan TFIDF

Function TFIDF

```
Static function tfidf($matrik_tf, $matrik_idf) {
  $matrik_tfidf = array();
    foreach ($matrik_tf as $key => $item) {
      foreach ($item as $keyItem => $itemValue) {
        $matrik_tfidf[$key][$keyItem] = $itemValue * $matrik_idf[$key];
      }
    }
  return $matrik_tfidf;
}
```

Fungsi tfidf bertujuan untuk menghitung skor *Term Frequency-Inverse Document Frequency* (TF-IDF) untuk setiap istilah dalam setiap dokumen. Perhitungan nilai TF-IDF dilakukan dengan menggunakan matriks *term frequency* (TF) dan matriks *inverse document frequency* (IDF) yang telah diperhitungkan sebelumnya. TF-IDF merupakan ukuran yang sering dimanfaatkan dalam pemrosesan teks untuk mengevaluasi seberapa penting suatu istilah dalam dokumen tertentu, relatif terhadap keseluruhan koleksi dokumen. Dengan rumus yang digunakan $W_{ij} = tf_{ij} \cdot log\frac{N}{dfi}$ dimana :

1. tf_{ij}, TF (*Term Frequency*): Mengukur seberapa sering suatu istilah muncul dalam sebuah dokumen.
2. $log\frac{N}{dfi}$, IDF (*Inverse Document Frequency*): Mengukur seberapa penting istilah tersebut dalam seluruh koleksi dokumen.

TF-IDF diperoleh dengan mengalikan frekuensi *term* (TF) dengan frekuensi *invers* dokumen (IDF) untuk setiap istilah dalam setiap dokumen. Proses ini menghasilkan matriks TF-IDF yang menunjukkan bobot pentingnya setiap istilah dalam konteks masing-masing dokumen. Matriks TF-IDF ini dapat dimanfaatkan untuk berbagai keperluan pemrosesan teks, seperti pengukuran kesamaan dokumen, peringkatan dokumen, atau ekstraksi fitur yang relevan.

Perhitungan Jarak Dokumen (|dj|)

```
Array
(
    [0] => 9.322214162933
    [1] => 2.8078208759076
)
```

Gambar 9. Hasil Perhitungan Jarak Dokumen |dj|

Function |dj|

```
static function dj($matrik_tfidf, $dokumen){
  $matrik_w = array();
  $matrik_dj = array();
  $jml_dokumen = count($dokumen);
  for ($keyItem = 0; $keyItem < $jml_dokumen; $keyItem++) {
    $matrik_w[$keyItem] = 0;
  }
  foreach ($matrik_tfidf as $item) {
    foreach ($item as $keyItem => $itemValue){
      $kuadrat = $itemValue * $itemValue;
      $matrik_w[$keyItem] += $kuadrat;
    }
  }
  foreach ($matrik_w as $key => $item) {
    $matrik_dj[$key] = sqrt($item);
  }
  return $matrik_dj;
}
```

Fungsi dj tersebut menghitung panjang vektor (*magnitude*) dari nilai TF-IDF untuk setiap dokumen. Panjang vektor ini dihitung sebagai akar kuadrat dari jumlah kuadrat nilai TF-IDF untuk semua istilah yang terdapat dalam dokumen tersebut. Nilai panjang vektor ini digunakan untuk normalisasi dokumen, yang merupakan langkah penting dalam berbagai algoritma pemrosesan teks dan pembelajaran mesin. Normalisasi dokumen berdasarkan panjang vektor TF-IDF memungkinkan perbandingan yang adil antara dokumen-dokumen, terlepas dari panjang teks masing-masing. Menggunakan rumus $|d_j| = \sqrt{\sum_{j=1}^{t}(Wij)^2}$.

Langkah-langkah perhitungannya sistem :

1. Inisialisasi jumlah kuadrat nilai TF-IDF untuk setiap dokumen dengan 0.
2. Iterasi melalui setiap istilah dalam matriks TF-IDF dan tambahkan kuadrat nilai TF-IDF ke jumlah kuadrat untuk setiap dokumen.
3. Hitung akar kuadrat dari jumlah kuadrat nilai TF-IDF untuk mendapatkan panjang vektor untuk setiap dokumen.
4. Kembalikan panjang vektor untuk setiap dokumen.

P-ISSN : 2089-3353
E-ISSN : 2808-9162

Hasil dari fungsi dj tersebut adalah sebuah *array* yang menunjukkan panjang vektor (*magnitude*) untuk setiap dokumen. Nilai-nilai ini dapat dimanfaatkan untuk proses normalisasi dokumen atau digunakan dalam perhitungan-perhitungan lebih lanjut dalam analisis teks. Normalisasi dokumen berdasarkan panjang vektor TF-IDF memungkinkan perbandingan yang adil antar dokumen, terlepas dari panjang teks masing-masing. Selanjutnya, *array* panjang vektor ini dapat diintegrasikan ke dalam berbagai algoritma pemrosesan teks dan pembelajaran mesin untuk menghasilkan analisis yang lebih akurat dan bermakna.

Perhitungan Jarak Query (|q|)

q = 0.79645050569775

Gambar 10. Hasil Perhitungan Jarak *Query* |q|

Function |q|

```
static function q($matrik_tfidf_query){

  $w_query = 0;

  foreach ($matrik_tfidf_query as $item) {

    $kuadrat = $item * $item;

    $w_query += $kuadrat;

  }

  $q = sqrt($w_query);

  return $q;

}
```

Fungsi q tersebut menghitung panjang vektor (*magnitude*) dari nilai TF-IDF untuk sebuah *query*. Panjang vektor ini dihitung sebagai akar kuadrat dari jumlah kuadrat nilai TF-IDF untuk semua istilah yang terdapat dalam *query* tersebut. Nilai panjang vektor ini digunakan untuk normalisasi *query*, yang merupakan langkah penting dalam berbagai algoritma pemrosesan teks dan pembelajaran mesin. Normalisasi *query* berdasarkan panjang vektor TF-IDF memungkinkan perbandingan yang adil antara *query* dan dokumen, terlepas dari panjang teks masing-masing. Hasil dari fungsi q adalah sebuah nilai yang menunjukkan panjang vektor (magnitude) untuk *query*, yang dapat dimanfaatkan dalam perhitungan-perhitungan lebih lanjut dalam analisis teks. Menggunakan rumus $|q|=\sqrt{\sum_{j=1}^{t}(Wi,q)^2}$.

Langkah-langkah perhitungan sistem :

1. Inisialisasi jumlah kuadrat nilai TF-IDF untuk *query* dengan 0.
2. Iterasi melalui setiap nilai TF-IDF dalam *query* dan tambahkan kuadrat nilai TF-IDF ke jumlah kuadrat.
3. Hitung akar kuadrat dari jumlah kuadrat nilai TF-IDF untuk mendapatkan panjang vektor *query*.
4. Tampilkan dan kembalikan panjang vektor *query*.

Hasil dari fungsi q adalah nilai yang menunjukkan panjang vektor (*magnitude*) dari nilai TF-IDF untuk *query*. Nilai panjang vektor ini dapat dimanfaatkan untuk proses normalisasi *query* atau digunakan dalam perhitungan-perhitungan lebih lanjut dalam analisis teks. Normalisasi query berdasarkan panjang vektor TF-IDF memungkinkan perbandingan yang adil antara query dan dokumen, terlepas dari panjang teks masing-masing. Selanjutnya, nilai panjang vektor ini dapat diintegrasikan ke dalam berbagai algoritma pemrosesan teks dan pembelajaran mesin untuk menghasilkan analisis yang lebih akurat dan bermakna.

Perhitungan dj.q / |dj|.|q|

```
Array
(
    [0] => 0.32953795369075
    [1] => 0.24313226954193
)
```

Gambar 11. Hasil Perhitungan Similaritas

Function Similaritas

```
static function sim($matrik_sum_dj_q, $matrik_djq){

  $matrik_sim = array();

  foreach ($matrik_sum_dj_q as $key => $item){

    $matrik_sim[$key]=$item/$matrik_djq[$key];

 }

 return $matrik_sim;

}
```

Fungsi sim menghitung nilai kesamaan (*similarity*) antara *query* dan setiap dokumen dalam koleksi. Perhitungan kesamaan ini dilakukan menggunakan rumus kosinus kesamaan. Rumus kosinus kesamaan mengukur sudut antara dua vektor, dalam konteks ini vektor TF-IDF dari *query* dan vektor TF-IDF dari masing-masing dokumen. Semakin kecil sudut antara dua vektor, semakin besar nilai kesamaan atau similaritasnya. Nilai kesamaan yang dihasilkan oleh fungsi sim menunjukkan tingkat kemiripan antara *query* dan setiap dokumen, yang dapat dimanfaatkan dalam berbagai aplikasi pemrosesan teks seperti

P-ISSN : 2089-3353
E-ISSN : 2808-9162

perangkingan dokumen, temu kembali informasi, dan analisis topikalitas. Menggunakan rumus *similarity* $Sim(d,d_j)= \frac{dj \cdot q}{|dj| \cdot |q|} = \frac{\sqrt{\sum_{i=1}^{t} Wiq \cdot Wij}}{\sum_{i=1}^{t} (Wij)^2 \cdot \sum_{j=1}^{t} (Wi,q)^2}$, dimana :

1. dj·q adalah hasil perkalian antara vektor *query* dan dokumen.
2. |dj| adalah panjang vektor dokumen.
3. |q| adalah panjang vektor *query*.

Hasil dari fungsi sim adalah sebuah *array* yang menunjukkan nilai kesamaan (*similarity*) antara *query* dan setiap dokumen dalam koleksi. Nilai-nilai kesamaan ini dihitung menggunakan rumus kosinus kesamaan, yang mengukur sudut antara vektor TF-IDF *query* dan vektor TF-IDF masing-masing dokumen. Semakin kecil sudut antara dua vektor, semakin besar nilai kesamaannya. *Array* nilai kesamaan yang dihasilkan dapat digunakan untuk menentukan dokumen yang paling relevan dengan *query* yang diberikan. Informasi ini kemudian dapat dimanfaatkan dalam berbagai aplikasi pemrosesan teks seperti meranking dokumen, pencarian informasi, dan analisis topik untuk menghasilkan hasil yang lebih tepat dan sesuai dengan kebutuhan pengguna.

3.3 Evaluasi

Dalam sistem yang menggunakan algoritma *Vector Space Model*, terdapat dua informasi penting yang dihasilkan, yaitu panjang vektor (*magnitude*) dan nilai kesamaan (*similarity*). Sistem akan menghasilkan sebuah *array* yang menunjukkan panjang vektor dari nilai TF-IDF untuk setiap dokumen, yang dapat digunakan untuk proses normalisasi dokumen dan perhitungan lebih lanjut dalam analisis teks. Selain itu, sistem juga akan menghasilkan nilai kesamaan antara *query* dan setiap dokumen dalam koleksi, yang dihitung menggunakan rumus kosinus kesamaan dan dapat digunakan untuk mengevaluasi relevansi dokumen dengan *query*. Dalam sistem *retrieval*, setiap kata kunci yang dicari tidak diberikan bobot yang sama. Oleh karena itu, diperlukan metode pembobotan *term* untuk memudahkan fokus pencarian. Metode pembobotan ini memberi bobot lebih tinggi pada istilah-istilah yang dianggap lebih penting [16]. Metrik evaluasi yang dapat digunakan untuk menilai kinerja sistem berdasarkan informasi ini antara lain nilai jarak *query (*|q|), jarak dokumen (|dj|) dan perhitungan similaritas (dj.q/dj|.|q|), yang dapat mengukur ketepatan, kelengkapan, dan kualitas urutan hasil pencarian, sehingga dapat digunakan untuk meningkatkan performa sistem.

Gambar 12. Implementasi Sistem Similaritas

4. Kesimpulan

Perusahaan PT. Tirta Asasta Depok masih menggunakan sistem pengarsipan manual yang tidak efisien dan tidak efektif. Oleh karena itu, disarankan untuk menerapkan sistem pengarsipan elektronik dengan menggunakan algoritma *Vector Space Model* guna meningkatkan pengelolaan dokumen perusahaan. Algoritma ini telah terbukti membantu pencarian dokumen dengan cepat dan akurat melalui pembobotan kata dan pencocokan *query*. Implementasi sistem pengarsipan elektronik berbasis algoritma ini juga dapat meningkatkan kinerja organisasi secara keseluruhan dengan mempercepat proses pencarian dan akses dokumen yang diperlukan.

Hasil penelitian menunjukan bahwa dengan menggunakan algoritma *Vector Space Model* telah terbukti efektif dalam mengukur tingkat kemiripan antara kata kunci yang dicari dengan data dokumen yang tersimpan, dengan nilai similaritas 0,32953795369075 dan 0,24313226954193 menunjukkan seberapa mirip dokumen-dokumen tersebut dengan *query* yang memiliki nilai 0,79645050569775. Sistem dapat mengurutkan hasil pencarian berdasarkan tingkat kesamaan yang dihasilkan, mulai dari nilai tertinggi hingga terendah, fitur ini akan memudahkan pengguna dalam menemukan dokumen yang paling relevan dengan kebutuhan mereka. Pengukuran kemiripan dokumen yang akurat dan pengurutan hasil pencarian yang efektif akan sangat membantu PT. Tirta Asasta Depok dalam menemukan dokumen yang dibutuhkan dengan cepat dan tepat, meningkatkan efisiensi operasional perusahaan, mengurangi waktu yang dihabiskan untuk pencarian dokumen, dan meningkatkan produktivitas karyawan, serta memberikan keunggulan kompetitif bagi perusahaan melalui kemudahan akses informasi dan peningkatan kecepatan dalam menemukan dokumen yang relevan, menunjukkan komitmen perusahaan untuk meningkatkan kinerja manajemen arsip.

Ucapan Terimakasih

Penulis ucapkan terima kasih kepada PT. Tirta Asasta Depok dan Universitas Duta Bangsa Surakarta yang telah membantu dalam kegiatan penelitian ini.

Daftar Rujukan

[1] I. Setiawan, Y. Apridiansyah, Y. Darmi, and M. Mutahanah,

2023, "Sistem Pengarsipan Surat Pada Kantor Kecamatan Putri Hijau Dengan Metode Interpolation Search Sebagai Arsip Surat," *JUSIBI (Jurnal Sist. Inf. dan Bisnis)*, vol. 5, no. 2, pp. 70–77.

[2] A. Hamdani, T. Saleh, A. Samad, and M. F. Adiman, 2024, "Sistem Informasi E-Arsip Berbasis WEB di Kantor Desa Bulusari," *JUSTIFY J. Sist. Inf. Ibrahimy*, vol. 2, no. 2, pp. 124–134.

[3] K. A. Hambarde and H. Proenca, 2023, "Information retrieval: recent advances and beyond," *IEEE Access*.

[4] A. F. Firdaus and W. I. Firdaus, 2021, "Text Mining Dan Pola Algoritma Dalam Penyelesaian Masalah Informasi:(Sebuah Ulasan)," *JUPITER J. Penelit. Ilmu Dan Teknol. Komput.*, vol. 13, no. 1, pp. 66–78.

[5] A. M. Siregar, 2022, "Implementasi Vector Svace Model Untuk Pencarian Judul Novel Online Pada Aplikasi Novel Online," *Inf. dan Teknol. Ilm.*, vol. 9, no. 3, pp. 69–72.

[6] M. D. Trisetiyo and J. S. Wibowo, 2019, "Klasifikasi Surat Menggunakan Metode Naïve Bayes Pada Sistem Informasi Manajemen Surat (Studi Kasus: Bagian Humas Setda Kabupaten Batang)".

[7] A. B. Arifa, Gita Fadila Fitriana, and Ananda Rifkiy Hasan, 2019, "Temu Kembali Informasi pada Soal Ujian dengan Rencana Pembelajaran Menggunakan Vector Space Model," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 63–68, 2021, doi: 10.29207/resti.v5i1.2739.

[8] W. Wijiyanto, A. I. Pradana, and S. Sopingi, 2024, "PERBANDINGAN DATA UNTUK MEMPREDIKSI KETEPATAN STUDI BERDASARKAN ATRIBUT KELUARGA MENGGUNAKAN MACHINE LEARNING," *JIKA (Jurnal Inform.*, vol. 8, no. 2, pp. 221–228.

[9] I. Frianda Gultom, Sriani, and Suhardi, 2023, "Analisis Sentimen Kebijakan Pemberian Subsidi Motor Listrik Menggunakan Metode Support Vector Machine," *J. Fasilkom*, vol. 13, no. 3, pp. 511–517, 2023, doi: 10.37859/jf.v13i3.6225.

[10] A. B. Arifa, G. F. Fitriana, and A. R. Hasan, 2021, "Temu kembali informasi pada soal ujian dengan rencana pembelajaran menggunakan Vector Space Model," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 63–68.

[11] R. B. Ardi, F. E. Nastiti, and S. Sumarlinda, 2023, "Algoritma K-Means Clustering untuk Segmentasi Pelanggan (Studi Kasus: Fashion Viral Solo)," *INFOTECH J.*, vol. 9, no. 1, pp. 124–131.

[12] I. R. Priandono, N. F. Rozi, and M. Hakimah, 2020, "Implementasi Vector Space Model Dengan Pembobotan Berbasis Kelas Pada Mesin Pencari Dokumen Skripsi," *J. Inform. J. Pengemb. IT*, vol. 5, no. 2, pp. 54–58, 2020, doi: 10.30591/jpit.v5i2.2079.

[13] W. Wijiyanto and S. Sopingi, 2024, "Kontribusi Keluarga Dalam Prediksi Mahasiswa Lulus Tepat Waktu Menggunakan Model Support Vector Machine," *DutaCom*, vol. 17, no. 1, pp. 25–36.

[14] M. Puja Alif Budiman and D. Winarso, 2024, "Penerapan Algoritma K-Medoids Clustering untuk Pengelompokan Bulan Rawan Bencana Kabut Asap di Kota Pekanbaru," *J. Fasilkom*, vol. 14, no. 1, pp. 1–8, 2024, doi: 10.37859/jf.v14i1.6858.

[15] F. A. Artanto, 2024, "Support Vector Machine Berbasis Particle Swarm Optimization Pada Analisis Sentimen Anggota KPPS," *J. Fasilkom*, vol. 14, no. 1, pp. 75–79, 2024, doi: 10.37859/jf.v14i1.6795.

[16] A. Sujjada and A. Fergina, 2021, "Implementasi Metode Vector Space Model Untuk Deteksi Emosi Menggunakan Data Teks Twitter," *J. RESTIKOM Ris. Tek. Inform. dan Komput.*, vol. 3, no. 3, pp. 116–129.