

# 1. Pendahuluan

## 1.1 Latar belakang

Dengan semakin berkembangnya teknologi informasi jumlah dokumen teks berupa digital semakin berkembang dengan pesat. Hal ini mengakibatkan munculnya suatu cabang ilmu baru dalam teknologi informasi yaitu pencarian informasi ( *information retrieval* ). Pencarian informasi berbasis *query* (*query based retrieval*) yang digunakan secara tradisional sangat berguna untuk pencarian terarah tetapi tidak begitu efisien. *Query based retrieval* berguna ketika kita mengetahui benar kejadian asli atau fakta yang dicari. Cara ini tidak begitu efektif ketika kita membutuhkan informasi yang spesifik/khusus dalam kategori yang besar dan juga tidak efisien untuk mendapatkan berita yang relevan dalam penelusuran suatu kejadian. Dengan menggunakan cara ini biasanya hanya dapat diketahui berita-berita tertentu saja, sedangkan berita-berita lama yang berkaitan dengan berita tersebut sulit untuk ditelusuri. Selain pemilihan *query* yang tidak tepat akan menyebabkan membanjirnya dokumen- dokumen yang tidak relevan.

Pengelompokan (*clustering*) dokumen merupakan sebuah cara yang dapat digunakan untuk mempermudah pencarian dokumen dalam database. *Clustering* merupakan proses pengelompokan data sehingga semua anggota dari bagian data memiliki kemiripan berdasarkan perhitungan jarak/kemiripan term-term yang sudah dilakukan pembobotan pada tahapan sebelumnya (*preprocessing*). *Clustering* merupakan salah satu metode *data mining* yang bersifat tanpa arahan (*unsupervised*). Ada dua jenis *clustering* yang [3]sering dipergunakan dalam proses pengelompokan data yaitu *hierarchical* (hirarki) data *clustering* dan *non-hierarchical* (non hirarki) *clustering*. *Single pass clustering* merupakan salah satu metode data *clustering* non hirarki (*partisioning*) yang berusaha mengelompokkan data yang ada ke dalam bentuk satu atau lebih *cluster*. Salah satu aplikasi dari *clustering* adalah *document clustering*.

Tahapan-tahapan *clustering* yang pertama adalah representasi dokumen. Tiap-tiap dokumen akan direpresentasikan kedalam matrik dokumen berupa bobot dari term pada masing-masing dokumen, kedua adalah penentuan tingkat kemiripan antar dokumenn, ketiga adalah penggunaan algoritma *clustering*, dan yang terakhir adalah tahap evaluasi. Evaluasi ini bertujuan untuk mengetahui kinerja dari algoritma yang digunakan untuk klasterisasi dokumen. Sebelum melakukan pengelompokan dokumen, diperlukan tahap *preprocessing* [2] terlebih dahulu. Pada tahap *preprocessing* yang dilakukan adalah *case folding*, *stopwords*, *stemming* dan *term weighting*. Metode *term weighting* yang digunakan adalah TF-IDF yang merupakan kombinasi antara TF (*Term Frequency*) dengan IDF (*Invers Document Frequency*).

Tugas Akhir ini menerapkan pengelompokan dokumen dengan menggunakan algoritma *Single Pass Clustering*. *Single pass clustering* merupakan [14] suatu tipe *clustering* yang berusaha melakukan pengelompokan data satu demi satu dan pembentukan kelompok dilakukan seiring dengan evaluasi setiap data yang dimasukkan ke dalam proses *cluster*.

## 1.2 Perumusan masalah

Berdasarkan latar belakang yang telah diuraikan, dapat diambil rumusan masalah sebagai berikut :

1. Bagaimana melakukan pengelompokan dokumen dengan menggunakan algoritma *Single Pass Clustering* ?
2. Bagaimana mengetahui dan menganalisis kualitas *cluster* yang dihasilkan dengan menggunakan metode *cohesion* dan *separation* dan menganalisis parameter-parameter dari algoritma *Single Pass Clustering* yang berpengaruh terhadap kualitas *cluster* ?

## 1.3 Batasan masalah

Adapun batasan-batasan masalah dalam pengerjaan Tugas Akhir ini adalah:

1. Tugas Akhir ini menggunakan dokumen berita berbahasa Indonesia yang telah mengalami *preprocessing* terlebih dahulu.
2. Tidak melakukan analisis terhadap data *preprocessing*.
3. Kualitas *cluster* yang dihasilkan tidak dibandingkan dengan algoritma lain.
4. Tidak menangani kesalahan pada penulisan kata dalam dokumen.

## 1.4 Tujuan

Berdasarkan pada masalah yang telah diidentifikasi di atas, maka tujuan Tugas Akhir ini adalah :

1. Menerapkan Algoritma *Single Pass Clustering* serta mengetahui performansinya sebagai salah satu metode data mining dalam mengelompokkan dokumen berita kejadian bahasa Indonesia.
2. Menganalisis kualitas *cluster* yang dihasilkan dengan melihat nilai *cohesion* dan *separation* serta mengetahui parameter yang berpengaruh untuk menghasilkan kualitas *cluster* yang baik.

## 1.5 Metodologi penyelesaian masalah

Metode yang digunakan untuk menyelesaikan Tugas Akhir ini adalah :

1. Studi literatur dan tinjauan pustaka tentang :
  - a. Algoritma *Single Pass Clustering*.
  - b. Tahapan-tahapan pengelompokan dokumen berita bahasa Indonesia.
  - c. Tahapan *preprocessing* dokumen berita.
  - d. *Cluster* analisis dengan metode *cohesion* dan *separation*.
2. Pengumpulan data

Data yang digunakan sebagai sampel adalah dokumen berita bahasa Indonesia yang berhasil di download dari media online seperti [www.kompas.com](http://www.kompas.com) , [www.republika.com](http://www.republika.com), [www.detik.com](http://www.detik.com) dan [www.tempointeraktif.com](http://www.tempointeraktif.com) Analisis dan perancangan sistem menggunakan algoritma *Single Pass Clustering*

### 3. Implementasi

#### a. Ekstraksi dokumen

Proses ekstraksi ini bertujuan untuk menghasilkan *term-term* yang akan digunakan sebagai *prototype* bagi setiap dokumen yang berisi bobot term pada kumpulan dokumen. Ekstraksi dokumen dilakukan pada tahap *preprocessing*.

#### b. Penghitungan tingkat kemiripan

Perbandingan tingkat *similarity* yang digunakan pada TA ini adalah menggunakan *standard cosine similarity*. [4]

#### c. Pengelompokan dokumen.

Untuk melakukan pengelompokan dokumen algoritma yang digunakan adalah *Single Pass Clustering*. Dengan melakukan perbandingan tingkat *similarity* selanjutnya hasilnya akan dievaluasi untuk menentukan pasangan-pasangan dokumen yang dinyatakan mirip berdasarkan nilai *threshold* tertentu.

### 4. Testing dan analisis

Untuk mengetahui kinerja algoritma *Single Pass Clustering* pada tahap uji coba, dilakukan pengukuran berdasarkan kualitas *cluster* menggunakan dua parameter, yakni *cohesion* dan *separation*. Selain itu juga akan dilihat dari sisi waktu, berapa lama waktu eksekusi untuk melakukan pengelompokan dokumen dengan algoritma *Single Pass Clustering*.

### 5. Pengambilan kesimpulan dan penyusunan laporan Tugas Akhir.