

PENGELOMPOKAN ABSTRAK SKRIPSI MENGGUNAKAN METODE *SUFFIX TREE* *CLUSTERING* DAN *SINGULAR VALUE DECOMPOSITION*

Lina Tri Andaru¹⁾, Bambang Soedijono W²⁾, Armadyah Amborowati³⁾

^{1) 2)}MTI Program Pasca Sarjana STMIK AMIKOM Yogyakarta

³⁾Teknik Informatika STMIK AMIKOM Yogyakarta

Jl Ring road Utara, Condongcatur, Sleman, Yogyakarta 55281

Email : arlin21@gmail.com¹⁾, armadyah.a@amikom.ac.id³⁾

Abstrak

Perkembangan teknologi informasi mulai merambah ke berbagai bidang pada suatu Negara, salah satunya dunia pendidikan. Mahasiswa tidak dapat memahami setiap informasi yang ada pada skripsi karena keterbatasan waktu dan banyaknya skripsi menjadi salah satu masalah. Selain itu juga STMIK Sinar Nusantara juga kesulitan dalam mempergunakan skripsi sebagai bahan pengukur dalam memberikan kebijakan atau pengarahan kepada mahasiswa untuk melakukan penelitian skripsi. Oleh karena itu, diperlukan sebuah metode untuk mengelompokkan skripsi melalui abstrak khususnya kata kunci agar memudahkan dalam pengambilan informasi atau data sesuai kebutuhan mahasiswa dan instansi tersebut .

Permasalahan tersebut dapat diatasi dengan menggunakan model clustering untuk mengelompokkan skripsi yang sesuai dengan kompetensi bidang penelitian yang terkait sehingga memudahkan pengguna dalam memilih dokumen skripsi yang relevan dengan penelitian skripsi. Penelitian ini menggunakan metode Suffix Tree Clustering (STC) untuk mengelompokkan skripsi. Selain itu juga digunakan metode Singular Value Decomposition (SVD) sebagai pendukung dalam perhitungan similarity pada kombinasi base cluster.

Hasil pengujian adalah metode Suffix Tree Clustering dan Singular Value Decomposition dapat digunakan dalam pengelompokan abstrak skripsi menggunakan kata kunci menjadi tiga kelompok yaitu Komputer Akutansi, Ebusines dan Sistem Informasi Perusahaan/Instansi pada STMIK Sinar Nusantara Surakarta dengan nilai keakurasian 87,67%.

Kata kunci: STC, SDV, pengelompokan.

1. Pendahuluan

STMIK Sinar Nusantara merupakan salah satu Sekolah Tinggi Manajemen dan Komputer di Surakarta yang memiliki banyak mahasiswa. Hal ini didukung dengan adanya ISO dan akreditasi B pada salah satu jurusannya. Salah satu jurusan di STMIK Sinar Nusantara adalah S1 Sistem Informasi. Jurusan sistem Infomasi memiliki bidang kompetensi yang

harus dikuasai yaitu Komputerisasi Akuntansi, E-Business dan Sistem Informasi Perusahaan/Instansi.

Data berukuran besar yang sudah disimpan jarang digunakan secara optimal karena manusia seringkali tidak memiliki waktu dan kemampuan yang cukup untuk mengelolanya [1]. Skripsi merupakan salah satu data yang disimpan dan jarang digunakan secara optimal. Skripsi hanya diletakkan di rak perpustakaan tanpa adanya informasi yang mengelompokkan skripsi ke dalam kelompok tertentu. Hal ini menyebabkan, mahasiswa yang ingin mencari referensi terkadang kesulitan dalam memilih referensi. Mahasiswa tidak memahami setiap informasi yang ada pada skripsi karena keterbatasan waktu dan banyaknya skripsi menjadi salah satu masalah. Selain itu juga STMIK Sinar Nusantara juga kesulitan dalam mempergunakan skripsi sebagai bahan pengukur dalam memberikan kebijakan atau pengarahan kepada mahasiswa untuk melakukan penelitian skripsi. Oleh karena itu, diperlukan sebuah metode untuk mengelompokkan skripsi melalui abstrak khususnya kata kunci agar memudahkan dalam pengambilan informasi atau data sesuai kebutuhan mahasiswa dan instansi tersebut.


Peningkatan jumlah dokumen dalam format teks yang cukup signifikan membuat proses pengelompokan atau klusterisasi dokumen (*document clustering*) menjadi penting. Zhao dan Karypis [2] mendefinisikan klusterisasi sebagai proses yang membagi suatu set objek menjadi beberapa jumlah kelompok (klaster) secara spesifik. Klusterisasi merupakan salah satu metode yang dapat digunakan untuk menemukan keterkaitan antar dokumen. Klusterisasi dokumen bertujuan membagi dokumen dalam beberapa kelompok sedemikian hingga dokumen-dokumen dalam klaster yang sama (*intra-klaster*) memiliki kesamaan yang tinggi, sementara dokumen-dokumen dalam klaster yang berbeda (*inter-klaster*) memiliki kesamaan yang rendah [3].

Permasalahan tersebut dapat diatasi dengan menggunakan model clustering untuk mengelompokkan skripsi yang sesuai dengan kompetensi bidang penelitian yang terkait sehingga memudahkan pengguna dalam memilih dokumen skripsi yang relevan dengan penelitian skripsi. Penelitian ini menggunakan metode Suffix Tree

Clustering (STC) untuk mengelompokkan skripsi. Selain itu juga digunakan metode *Singular Value Dekomposition (SVD)* sebagai pendukung dalam perhitungan *similarity* pada kombinasi base cluster.

Tujuan yang ingin dicapai dalam penelitian ini adalah Untuk mengetahui apakah penelitian dengan metode *Suffix Tree Clustering* dan *Singular Value Dekomposition* dapat digunakan untuk mengelompokkan skripsi pada jurusan Sistem Informasi di STMIK Sinar Nusantara Surakarta menjadi 3 bidang kompetensi yaitu Komputerisasi Akuntansi, E-Business dan Sistem Informasi Perusahaan/Instansi.

Gambar 1 , menjelaskan tahapan yang dilakukan dalam penelitian. Tahapan mulai dari proses *preprocessing*, identifikasi *base cluster*, kombinasi *base cluster* sampai dengan tahap perhitungan *SVD*.



Gambar 1. Alur Penelitian

2. Tinjauan Pustaka Suffix Tree Clustering

Penggunaan algoritma *clustering*. Algoritma *Suffix tree Clustering (STC)* memiliki dua kunci utama, yaitu :1). Menggunakan *phrase* sebagai dasar pembentukan

clusternya.2). Menggunakan suatu definisi *cluster* sederhana.

Dalam penelitian Novan [4], *Suffix tree Clustering* memiliki dua langkah utama. Dalam langkah pertama, pencarian *shared phrase* untuk semua dokumen berita yang dikoleksi. Disebut *shared phrase* sebagai *phrase cluster* atau *base cluster*, yang ditemukan dengan menggunakan suatu struktur data yang dinamakan *suffix tree*. Dalam langkah kedua, mengkombinasikan *base cluster-base cluster* ke dalam suatu *cluster*. Penggabungan antar dua *base cluster* didasarkan pada jumlah dokumen yang melakukan *overlap* diantara kedua *base cluster* tersebut . Suatu *phrase* yang dimaksud dalam konteks algoritma ini adalah urutan satu atau lebih kata-kata. *STC* memiliki tiga langkah utama, yaitu :

1. *Cleaning* Dokumen.
2. Identifikasi *Base Cluster* menggunakan *Suffix tree*.
3. Mengkombinasikan *Base Cluster* ke dalam suatu *cluster*.

Singular Value Decomposition

Algoritma *Singular Value Decomposition (SVD)* pertama kali diusulkan oleh Eckart and Young [5] termasuk metode eksplorasi statistik multidimensi dengan latar belakang matematika aljabar linier. Algoritma *Singular Value Decomposition (SVD)* mempunyai kelebihan pada efisiensi waktu proses [6] dapat digunakan untuk memaksimalkan perhitungan *similarity*.

Singular Value Decomposition adalah metode aljabar linier [7] yang memecah matriks A (*terms-documents*) berdimensi $t \times d$ menjadi tiga matriks TSD . T adalah matriks kata (*terms*) berukuran $t \times r$, S adalah matriks diagonal berisi nilai skalar (*eigen values*) berdimensi $r \times r$, dan r ditentukan sebelumnya, dan D adalah matriks dokumen berukuran $r \times d$. Dekomposisi nilai singular dari matriks A dinyatakan sebagai $A = TSDT$.

SVD dapat mereduksi dimensi dari matriks A dengan cara mengurangi ukuran r dari matriks diagonal S . Pengurangan dimensi dari matriks S dilakukan dengan cara mengubah semua nilai diagonal matriks S menjadi nol, kecuali untuk nilai diagonal dari dimensi yang tersisa. Pengalihan ketiga matriks $TSDT$ akan membentuk matriks A awal dengan nilai setiap elemennya mendekati nilai sebenarnya [8]

Pengelompokkan (Clustering)

Metode *clustering* adalah metode yang memiliki kemampuan untuk menganalisis serta mengelompokkan secara otomatis dokumen-dokumen. Teknik *Clustering* pada umumnya menggunakan kata dan dokumen yang biasanya dianggap sebagai kumpulan kata-kata tanpa adanya urutan atau disebut dengan bag of word. *Suffix Tree Clustering (STC)* adalah algoritma pertama yang menggunakan frasa (*multi word term*) sehingga


prosesnya lebih sederhana dibandingkan dengan algoritma yang lain [9].

Algoritma Nazief & Adriani

Algoritma *stemming* untuk bahasa yang satu berbeda dengan algoritma *stemming* untuk bahasa lainnya. Sebagai contoh bahasa Inggris memiliki morfologi yang berbeda dengan bahasa Indonesia sehingga algoritma *stemming* untuk kedua bahasa tersebut juga berbeda. Proses *stemming* pada teks berbahasa Indonesia lebih rumit/kompleks karena terdapat variasi imbuhan yang harus dibuang untuk mendapatkan *root word* (kata dasar) dari sebuah kata. Pada umumnya kata dasar pada bahasa Indonesia terdiri dari kombinasi[10]

Perancangan Sistem

Langkah awal dalam merancang sistem ini dengan menggunakan UML (Unified Modelling Language). Rancangan pertama dengan membuat Use Case diagram yang merupakan penggambaran sistem dapat dilihat dari sudut pandang pengguna (user/ actor) sistem tersebut. Gambar 2, menjelaskan *usecase* yang memiliki dua aktor. Aktor pertama adalah admin yang dapat melakukan semua proses yang ada, sedangkan aktor kedua adalah bidang akademik yang hanya dapat melakukan satu proses.



Gambar 2. Use case diagram

3. Pembahasan

a. Preprocessing

1)Tokenisasi

Tahap ini tidak terlalu digunakan, karena data yang dibaca berupa kata kunci yang sudah ada pemecahan tiap kata dan tidak menggunakan simbol yang tidak bernilai. Tahap ini digunakan jika data yang kita inputkan banyak dan memiliki beberapa simbol.

2)Stopword dan stoplist removal

Kata yang dihasilkan bermacam macam, mulai dari kata yang bernilai sampai dengan kata yang tidak dapat digunakan atau tidak bernilai, seperti kata sambung, kata depan dan lain-lain. Kata-kata tersebut langsung dihilangkan tanpa proses penyimpanan terlebih dahulu.

3)Steaming

Pengambilan kata dasar menggunakan algoritma nazief dan andriani. Proses ini akan dilakukan pengambilan kata dasar setelah proses *stopword removal*.

b. Identifikasi base cluster

Pada proses ini dilakukan identifikasi *base cluster* tiap data. Dari 100 abstrak yang ada, dilakukan proses *prepossessing* dan merubahnya menjadi *base cluster*. Gambar 3, menjelaskan tentang hasil dari identifikasi *base cluster*.

HOME	DATA SKRIPSI	IDENTIFIKASI	PENGELOMPOKAN	DIAGRAM	LOGOUT
------	--------------	--------------	---------------	---------	--------

Base cluster	Halaman: 1/2 (1/15)																	
Score base cluster																		
Kombinasi base cluster	MM	00	04	0005600	04	0005400	04	0004400	04	0004200	04	0004100	04	0004000	04	0003000	04	00029
KATA																		
AHP	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
analitichearti 1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
apikasi	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
bank	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
busines	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
ditelp	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
DSS	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Ekonomi	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
fuzzy	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
pinusan	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
karyawan	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
kegiatan	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Gambar 3. Identifikasi base cluster

c. Kombinasi base cluster

Pada tahap kombinasi *base cluster*, didapat total kombinasi data yang diperoleh dari perhitungan

tiap *base cluster*. Gambar 4, menampilkan kombinasi *base cluster*.

Base cluster	Kombinasi Cluster				
Score base cluster	Node	Kata	BI	NP	SB
Kombinasi base cluster	23	penilaian	2	4	2
	22	pengujian	2	5	2
	21	percarian	2	5	2
	20	perbantuan	1	4	4
	19	perbelanjaan	2	1	6
	18	onlineshop	2	4	2
	17	Halvabayar	2	4	2
	16	multibuyer	1	5	2
	15	Mining	2	1	2
	14	keuntungan	2	5	7
	13	komputerisasi	1	4	2
	12	klasifikasi	2	4	2
	11	kinerja	2	4	3
	10	karyawan	2	4	2

Gambar 4. Kombinasi *base cluster*

d. Perhitungan SVD

Pada tahap ini dilakukan perhitungan *SVD* yang digunakan untuk mengelompokkan skripsi. Pada 100 skripsi yang telah diproses ada beberapa kata yang hanya muncul di satu atau dua abstrak saja. Oleh karena itu, perlu dilakukan penghilangan kata-kata tersebut untuk mempercepat proses perhitungan. Proses reduksi yang dihasilkan memiliki nilai akurasi yang berbeda-beda.


Pada reduksi ke 30% nilai akurasi yang dicapai lebih baik dibandingkan reduksi lainnya yaitu 87.67%. Berikut tampilan nilai reduksi dan hasil akurasi pada tabel 1 :

Tabel 1. Hasil Perhitungan SVD

Reduksi Dimensi	Nilai SVD	Jumlah <i>basecluster</i>	Akurasi
10%	10	3	73.45%
20%	13	8	76.67%
30%	15	11	87.67%
40%	17	13	72.56%
50%	18	15	68.67%
60%	20	20	56.33%
70%	23	24	53.33%
80%	24	28	33.33%
90%	25	30	33.33%

Gambar 5, merupakan tampilan laporan berupa grafik hasil pengelompokan abstrak skripsi berdasarkan kata kunci adalah sebagai berikut :

Admin Clustering SKRIPSI di SINUS



admin_electronic@stmik Sinus Masendara Surakarta/2014

Gambar 5. Hasil Pengelompokan

Pengujian Sistem

Pengujian dilakukan dua cara seperti berikut :

a). *Recall*, yakni tingkat keberhasilan mengenali suatu kompetensi dari seluruh kompetensi yang seharusnya dikenali. Rumusnya $r = a/(a+c)$ untuk $a+c > 0$. Selain itu tidak didefinisikan

b). *Precision*(presisi), yakni tingkat ketepatan hasil kluster terhadap suatu kompetensi. Artinya, dari seluruh dokumen hasil klustering, berapa persentase yang dinyatakan benar. Rumusnya adalah $p = a/(a+b)$ jika $a+b > 0$. Hasil pengujian sebagai berikut :

Tabel 2, menampilkan hasil pengujian recall dan pengujian presisi, dengan akurasi 87,67%. Tabel tersebut merupakan hasil dari pengelompokan yang dikenali dan tidak dikenali. Ada sekitar 6 Abstrak yang tidak dikenali dengan nilai akurasi 87.67%.

Tabel 2. Hasil Pengujian

Jml data	Tidak dikenali	Dikenali	Kelomp	Akurasi	recall	presisi
100	6	54	SI	87.67 %	0.33	0.37
		26	Akutansi			
		14	Bisnis			

4. Penutup
Kesimpulan

1. Metode *Suffix Tree Clustering* dan *Singular Value Decomposit* dapat digunakan dalam pengelompokan abstrak skripsi menggunakan kata kunci menjadi tiga kelompok yaitu Komputer Akutansi, Ebusines dan Sistem Informasi Perusahaan/Instansi pada STMIK Sinar Nusantara Surakarta.
2. Akurasi yang sesuai diperoleh pada 100 data abstrak dengan menggunakan reduksi dimensi 30% yaitu akurasi 87.67% dengan hasil 54 data pada kelompok Sistem Informasi Perusahaan/Instansi, 14 data terkelompok dalam Ebusines dan 26 data terkelompok dalam Komputer akutansi (pengujian *recall* adalah 0.33 dan *presisi* sebesar 0.37).

Saran

Perlu dilakukan penelitian lebih lanjut dengan metode lain, agar didapat metode yang tepat dengan akurasi yang lebih baik untuk semua bidang kompetensi keahlian dalam proses pengelompokkan dokumen abstrak dengan kata kunci.

Daftar Pustaka

[1] Hermadi, I. 2007. Clustering Menggunakan Self-Organizing Maps (Studi Kasus: Data PPMB IPB). *FMIPA Institut Pertanian Bogor*. 5: 2

[2] Zhao, Y. & Karypis, G. 2005, "Empirical and theoretical comparisons of selected criterion functions for document clustering", *Machine Learning* 55 (3), hal.50-62

[3] Jain, A.K., Murty, M.N. & Flynn, P.J. 1999, "Data Clustering : A Review", *ACM Computing Survey* Vol. 31, No. 3, hal.264-323

[4] Novan S. 2001. *Implementasi Aplikasi Information Retrieval Untuk Pendeteksian dan Klasifikasi Berita Kejadian Berbahasa Indonesia Berbasis Web*. Tugas Akhir, Jurusan Teknik Informatika Fakultas Teknologi Informasi ITS Surabaya

[5] Lipovetsky, Stan. 2009. "*PCA and SVD with nonnegative loadings*," *GfK CustomResearch for excellence*, vol. 42, no. 1, pp. 1-30

[6] Sembiring, Rahmat Widia; Zain, Jasni Mohamad; Embong, Abdullah.2011. "Dimension Reduction of Health Data Clustering," *International Journal onNew Computer Architectures and Their Applications (IJNCAA)*, vol. 3, no. 1, pp. 1041-1050

[7] Bau III, David, Lloyd N. Trefethen, 1997. *Numerical Linear Algebra*. Philadelphia: Society for Industrial and Applied Mathematics

[8] Ratna, Anak Agung Putri, Bagio Budiardjo, Djoko Hartanto, 2007. *Simple.Sistim Penilai Esei Otomatis untukMenilai Ujian dalam Bahasa Indonesia*. Departemen Elektro, Fakultas Teknik,Universitas Indonesia. Depok, Indonesia April 2007: 5-11: Makara

[9] Kusamaya. 2007.Pengembangan Suffix Tree Clustering untuk Comparative Text Mining. Tesis. Bandung: Institute Teknologi Bandung

[10] Nazief, Bobby dan Mirna Adriani. 1996. *Confix-Stripping: Approach to Stemming Algorithm for Bahasa Indonesia*, *Fakulty of Computer Science University of Indonesia*.

Biodata Penulis

Lina Tri Andaru Penulis Pertama, memperoleh gelar Ahli Madya (A.Md), Jurusan Manajemen InformatikaUniversitas Sebelas Maret Surakarta, lulus tahun 2010. Memperoleh gelar Sarjana Komputer(S.Kom), Jurusan Sistem Informasi STMIK Sinar Nusantara Surakarta, lulus tahun 2012. Saat ini sedang menempuh Program Pasca Sarjana Magister Teknik Informatika di STMIK AMIKOM Yogyakarta

Bambang Soedijono W, Penulis Kedua, memperoleh S1 Fak. MIPA, UGM,lulus tahun 1970. Memperoleh S3 Program Pascasarjana UGM,lulus tahun 1992. Saat ini sebagai dosen Magister Teknik Informatika di STMIK AMIKOM Yogyakarta

Armadyah Amborowati Penulis Ketiga, memperoleh gelar Sarjana Komputer (S.Kom), Jurusan Sistem Informasi STMIK AMIKOM Yogyakarta. Memperoleh gelar Master of Engineering(M.Eng) tahun 2009,di Program Pasca Sarjana Magister Teknologi Informasi Fakultas Teknik Elektro Universitas Gajah Mada Yogyakarta. Saat ini sedang menempuh S3 di fakultas Ilmu Komputer Universitas Gajah Mada Yogyakarta. Saat ini sebagai dosen Teknik Informatika di STMIK AMIKOM Yogyakarta