

***TOPIC MODELLING DOKUMEN SKRIPSI MENGGUNAKAN METODE  
LATENT SEMANTIC ANALYSIS***

**SKRIPSI**



**UIN SUNAN AMPEL  
S U R A B A Y A**

**Disusun Oleh:**

**RIFQI HAKIM  
NIM: H06216022**

**PROGRAM STUDI SISTEM INFORMASI  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL  
SURABAYA  
2020**

## PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

NAMA : RIFQI HAKIM

NIM : H06216022

PROGRAM STUDI : Sistem Informasi

ANGKATAN : 2016

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul “*TOPIC MODELLING* DOKUMEN SKRIPSI MENGGUNAKAN METODE *LATENT SEMANTIC ANALYSIS*”. Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 20 Juli 2020



RIFQI HAKIM

NIM. H06216022

## LEMBAR PERSETUJUAN PEMBIMBING

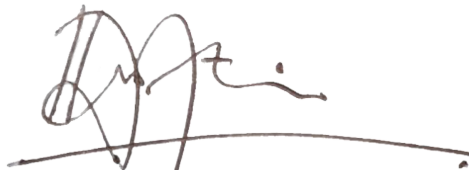
JUDUL : *TOPIC MODELING* PADA ABSTRAK SKRIPSI  
MENGUNAKAN METODE *LATENT SEMANTIC  
ANALYSIS*  
NAMA : RIFQI HAKIM  
NIM : H06216022

Mahasiswa tersebut telah melakukan proses bimbingan dan dinyatakan layak  
untuk mengikuti Sidang Skripsi.

Surabaya, 20 Juli 2020

Menyetujui,

Dosen Pembimbing 1



Dwi Rolliawati, MT

NIP. 197909272014032001

Dosen Pembimbing 2



Khalid, M. Kom


NIP. 197906092014031002

**PENGESAHAN TIM PENGUJI SKRIPSI**


Skripsi Rifqi Hakim ini telah dipertahankan  
di depan tim penguji skripsi  
di Surabaya, 22 Juli 2020.

Mengesahkan,  
Dewan Penguji

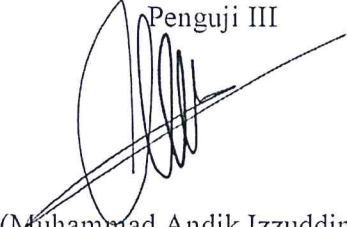
Penguji I

  
(Dwi Rolliawati, MT)  
NIP. 197909272014032001


Penguji II

  
(Khalid, M.Kom)  
NIP. 197906092014031002

Penguji III

  
(Muhammad Andik Izzuddin, MT)  
NIP. 198403072014031001


Penguji IV

  
(Mohammad Khusnu Milad, M.MT)  
NIP. 197901292014031002

Mengetahui,

Plt. Dekan Fakultas Sains dan Teknologi

Sunan Ampel Surabaya

  
  
(Evi Fatimatur Rusydiyah, M.Ag.)  
NIP. 197312272005012003



**KEMENTERIAN AGAMA**  
**UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA**  
**PERPUSTAKAAN**

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300  
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI  
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : RIFQI HAKIM  
NIM : H06216022  
Fakultas/Jurusan : SAINS DAN TEKNOLOGI/SISTEM INFORMASI  
E-mail address : rifqihakim5889@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Skripsi     Tesis     Desertasi     Lain-lain (.....)  
yang berjudul :

TOPIC MODELLING DOKUMEN SKRIPSI MENGGUNAKAN METODE LATENT  
SEMANTIC ANALYSIS

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 12 Agustus 2020

Penulis

(RIFQI HAKIM)

















Klasifikasi teks pada topik skripsi merupakan suatu proses yang mengelompokkan suatu teks dalam skripsi yang mewakili isi keseluruhan skripsi untuk dikelompokkan kedalam suatu kategori tertentu (Somantri et al., 2017). Sehingga salah satu pengolahan dokumen dengan *text mining* melalui pemodelan topik (*topic modeling*) bisa menjadi alternatif solusi untuk mengklasifikasikan topik suatu dokumen, yang mana klasifikasi dilakukan dengan melihat kumpulan kata yang merupakan representasi suatu dokumen (Suhartono, 2015). Sehingga dengan penentuan topik yang telah dilakukan, selanjutnya dapat dilihat tren tiap topik penelitian skripsi yang diangkat mahasiswa.

Usaha untuk pemodelan topik pada dokumen disebut ekstraksi topik. Salah satu metode untuk mengekstrak topik adalah *Latent Semantic Analysis (LSA)* (Farida et al., 2019). Pada penelitian sebelumnya telah dibahas pemodelan topik dengan metode LSA, seperti pada penelitian dengan judul “Algoritma *Latent Semantic Analysis (LSA)* Pada Peringkasan Dokumen Otomatis untuk Proses *Clustering* Dokumen” memiliki akurasi *clustering* yang baik pada suatu dokumen dengan persentase *summary document* 40% menghasilkan nilai *f-measure* dengan rata-rata 71.04% (Luthfiarta et al., 2013). Kemudian pada penelitian “Klasifikasi Topik *Multi Label* pada Hadis Shahih Bukhari Menggunakan *K-Nearest Neighbor* dan *Latent Semantic Analysis*” mendapatkan hasil akurasi dengan kombinasi LSA-KNN sebesar 90.28% dengan waktu komputasi sebesar 19 menit 21 detik (Hidayati et al., 2020). Sedangkan pada studi kasus Program Studi Sastra Inggris UIN Sunan Ampel Surabaya, pemodelan topik menggunakan metode *Latent Dirichlet Allocation* yang dibahas dalam penelitian “*Topic Modelling* Skripsi Menggunakan Metode *Latent Dirichlet Allocation*” dan berhasil menghasilkan sejumlah topik penelitian dari dokumen skripsi tahun 2014 sampai 2019 (Alfanzar, 2019).

Dengan melihat penelitian dari studi kasus yang sama yakni pada penelitian (Alfanzar, 2019), maka penelitian ini dimaksudkan untuk mengetahui informasi tren dari topik yang terbentuk pada penelitian skripsi Program Studi Sastra Inggris UINSA setiap tahun antara tahun 2014 sampai 2019. Metode *Latent Semantic Analysis (LSA)* digunakan untuk mengambil kata-kata semantik yang merupakan representasi isi suatu dokumen. Kemudian pemodelan topik dilakukan pada dataset abstrak skripsi Program Studi Sastra Inggris UINSA tahun 2014 sampai dengan









(LSA) dan Teknik Steinberger & Jezek (Saputra, Jerry. Fachrurrozi, 2017)	<i>precision</i> tertinggi 0.75, dan nilai <i>f-measure</i> tertinggi 0.71	awal untuk mendukung dalam pemodelan topik.
--	--	---

Tabel 2.1 sebagai rujukan penelitian sebelumnya dengan studi kasus serupa, yakni pada penelitian (Alfanzar, 2019) melakukan pemodelan topik (*Topic Modelling*) skripsi menggunakan metode *Latent Dirichlet Allocation*. Dalam penelitian tersebut menghasilkan topik pada skripsi Program Studi Sastra Inggris UINSA meliputi *strategy, maxim, utterance, politeness, advertisement, speech, type, character, positive, dan movie*. Sedangkan pada penelitian ini akan mencoba untuk menghasilkan topik dengan metode berbeda serta mencoba untuk melihat tren dari topik penelitian yang terbentuk.

Untuk penelitian yang menggunakan metode *Latent Semantic Analysis* memiliki beberapa kegunaan, seperti klasifikasi topik dokumen, pendeteksi kemiripan semantik (makna) pada tiap halaman dokumen, pencarian dokumen berdasarkan kata semantik (makna), dan peringkasan dokumen. Untuk kegunaan klasifikasi, dapat dilihat dalam penelitian (Hidayati et al., 2020), yakni berusaha membangun sistem untuk klasifikasi hadis shahih bukhari terjemahan bahasa Indonesia yang mampu mengenali hadis berdasarkan jenis informasinya yaitu anjuran, larangan, dan informasi. Pada penelitian tersebut juga mengevaluasi sistem dengan *F1-Score*. Dari hasil evaluasi menunjukkan bahwa penambahan fitur *Rule-Based* pada proses ekstraksi dokumen dengan *TF-IDF* menunjukkan nilai yang lebih baik pada pengenalan kata anjuran daripada tanpa penambahan fitur *Rule-Based*. Kemudian pada penggunaan *stemming* dalam pembangunan sistem untuk *preprocessing data* tidak memberikan performansi yang lebih baik daripada tanpa *stemming*, hal ini dikarenakan *stemming* dapat menghilangkan karakteristik dari setiap topik. Korelasi dengan penelitian ini adalah penggunaan metode *Latent Semantic Analysis* digunakan untuk pemodelan topik dengan tidak adanya penetapan kategori topik terlebih dahulu.

Kemudian, untuk deteksi kemiripan kata berdasarkan semantik (makna kata), dapat dilihat pada penelitian (Jadhira et al., 2018) yakni Deteksi Kemiripan Bagian-bagian Terjemah Al-Qur'an dengan Menggunakan Metode *Latent Semantic Analysis* menunjukkan bahwa metode yang digunakan cukup baik dalam mendeteksi kemiripan pasangan halaman yang mengandung kesamaan semantik

yang tinggi, terbukti dengan hasil nilai kemiripan yang mendekati 1. Korelasi dengan penelitian adalah penggunaan metode *Latent Semantic Analysis* untuk mengecek tingkat kepentingan suatu *term/* kata berdasarkan kemiripan untuk mendukung proses pembobotan dalam pemodelan topik.

Selanjutnya, untuk pencarian dokumen berdasarkan kata semantik, terdapat pada penelitian (Azharyani & Kusumo, 2019) yakni Implementasi *Semantic Search* pada *Open Library* menggunakan Metode *Latent Semantic Analysis*, menunjukkan penggabungan *LSA* dan *weighted tree* didapatkan rata-rata *precision* 57.12% dan rata-rata *recall* 85.08%. Sehingga dapat disimpulkan bahwa sistem pencarian dengan penggabungan *LSA* dan *weighted tree* dapat digunakan untuk mendapatkan informasi yang relevan dalam merepresentasikan hubungan antar kata dan dokumen yang berkaitan, namun rendah dalam menentukan dalam mengukur ketepatan pencarian. Korelasi dengan penelitian adalah berusaha membuat keluaran informasi, namun perbedaannya adalah informasi yang ditampilkan berupa daftar topik yang relevan terhadap data masukan.

Dan untuk peringkasan dokumen, dapat dilihat pada penelitian (Saputra et al., 2017) dengan judul Peringkasan Teks Berita Berbahasa Indonesia Menggunakan Metode *Latent Semantic Analysis (LSA)* dan Teknik *Steinberger & Jezek*, menghasilkan ringkasan dokumen sebesar 50% dari dokumen asli dengan nilai *recall* tertinggi yang didapat sebesar 0.71, nilai *precision* tertinggi sebesar 0.75, dan nilai *f-measure* tertinggi sebesar 0.71. Korelasi dengan penelitian adalah penggunaan metode *Latent Semantic Analysis* untuk meringkas dokumen, namun bedanya tujuan dari peringkasan adalah untuk mendukung penentuan topik.

Dari penelitian yang pernah dilakukan, metode *Latent Semantic Analysis* memiliki banyak kegunaan dalam pengelolaan atau penggalian informasi suatu dokumen, sehingga dalam penelitian ini mencoba untuk mengembangkan salah satu kegunaan metode *Latent Semantic Analysis* yakni untuk pemodelan topik. Pengembangan yang dilakukan berkaitan dengan pemodelan topik skripsi Program Studi Sastra Inggris untuk melihat kesesuaian dengan penelitian sebelumnya dan lebih lanjut melihat tren topik pada dokumen skripsi tahun 2014 sampai 2019.

## 2.2. Bahasa *Python*

*Python* dikembangkan pada tahun 1989, oleh Guido van Rossum dan diperkenalkan pada tahun 1991. *Python* sendiri disebut bahasa pemrograman *high level language* (tingkat tinggi) yang dibuat untuk mempermudah *developer* aplikasi dalam pekerjaannya. *Python* dirancang untuk menunjang efisiensi waktu, memudahkan dalam pengembangan program, serta memiliki kompatibilitas dengan berbagai sistem (Qutsiah, Sophan, & Hendrawan, 2016).

Bahasa pemrograman *Python* juga disebut sebagai alat bantu yang dapat digunakan pada proses *text mining* dan tampilan grafis pendukungnya (Petrus, 2019).

## 2.3. *Text Mining*

*Text mining* dalam Bahasa Indonesia artinya menambang teks adalah teknik analisis teks yang sumber datanya berasal dari suatu dokumen. *Text Mining* berfungsi untuk mencari intisari berupa kata atau kumpulan kata yang mewakili isi/informasi dari keseluruhan dokumen. Sehingga dengan adanya intisari dari suatu dokumen, maka dapat dilangsungkan analisis keterkaitan, dan kelas antar dokumen (Hartanto, 2017). Lebih lanjut *text mining* melakukan pengolahan pada data teks yang tidak terstruktur yang merupakan bagian dari keilmuan *information retrieval* (temu balik informasi). *Text mining* memiliki tiga tahapan utama secara berurut yakni *text preprocessing*, *feature selection*, dan *text analytic* (Priyanto & Ma'arif, 2018). Penjelasan lebih lanjut mengenai tahapan dalam *text mining* adalah sebagai berikut.

### 2.3.1. Text Preprocessing

Pada tahap *text preprocessing* memiliki fungsi yakni sebagai tahap awal pengolahan teks sebelum diolah lebih lanjut. Data teks yang tidak terstruktur memiliki *noise* seperti angka, karakter khusus, tanda baca atau simbol, dan imbuhan. Tahap ini, data teks dibersihkan/ dinormalkan hingga tersisa bentuk kata dasar saja, yang kemudian dapat dianalisis lebih lanjut (Priyanto & Ma'arif, 2018). Tahapan *text processing* secara umum terdiri dari 4 langkah, yaitu *Case folding*, *Tokenizing*, *Stemming*, dan *Filtering* (Hermawan & Ismiati, 2020) yang dijelaskan lebih lanjut sebagai berikut.

1. *Case Folding*

Proses *case folding* dapat dipahami sebagai proses menghilangkan karakter-karakter selain huruf, yakni tanda baca dan angka. Serta mengubah huruf menjadi *lowercase* atau *uppercase* (Rahman, 2017).

2. *Tokenizing*

*Tokenizing/ Tokenization* merupakan proses yang dimaksudkan untuk memotong kalimat berdasarkan tiap kata yang menyusunnya (Rahman, 2017). Dapat dipahami juga sebagai proses pemotongan satu kalimat menjadi beberapa kata.

3. *Stemming*

*Stemming* dapat dipahami sebagai proses untuk memotong imbuhan atau mengembalikan suatu kata berimbuhan menjadi kata dasar (Rahman, 2017). Hal ini bertujuan agar setiap kata yang memiliki kata dasar sama dapat dikelompokkan menjadi satu kelompok.

4. *Filtering*

*Filtering* atau *stopword removal* dapat dipahami sebagai proses penghilangan *stopwords* atau kata-kata yang tidak menggambarkan isi tulisan, sehingga dapat dibuang. Proses ini bertujuan untuk mengurangi jumlah kata yang tidak menggambarkan informasi (Rahman, 2017).

### 2.3.2. *Feature Selection*

Dalam proses *feature selection* ini bertujuan untuk menemukan kata kunci yang menjadi ciri dari suatu dokumen yang membedakan kata antar dokumen dalam satu korpus. Tahap ini memiliki peran yang penting dalam akurasi *text analytic*. Empat pendekatan yang umum dalam *feature selection* adalah *Document Frequency (DF)*, *Term Frequency (TF)*, *Inverse Document Frequency (IDF)* dan *Term Frequency/Inverse Document Frequency (TF/IDF)* (Priyanto & Ma'arif, 2018). Penjelasan mengenai pendekatan dalam *feature selection* adalah sebagai berikut.

1. *Document Frequency (DF)*

Prinsip dari DF adalah membuang kata yang umum pada suatu dokumen yang ada pada suatu korpus. Sehingga kata yang tersisa dalam suatu dokumen































































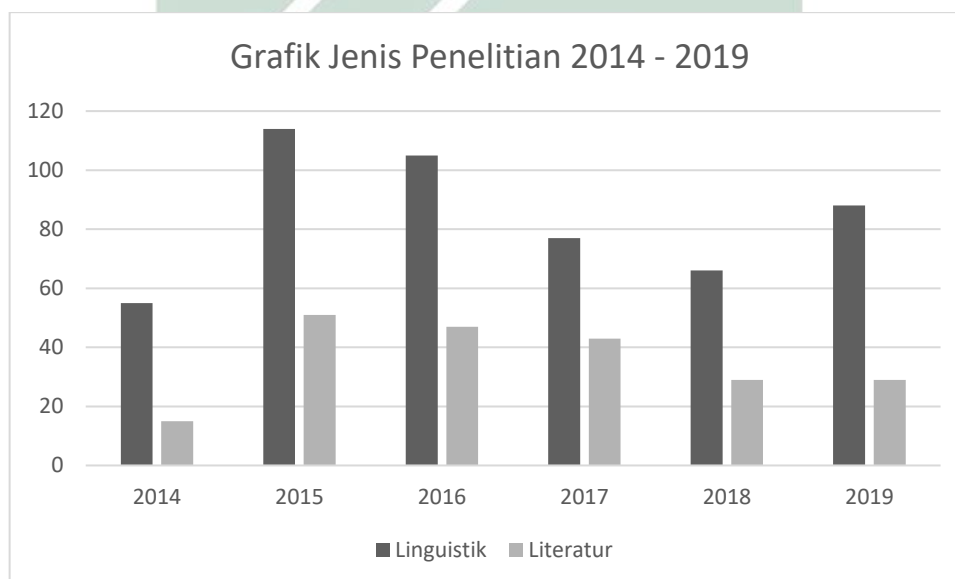




Tabel 4.10. Jumlah Jenis Penelitian Setiap Tahun

Tahun	Dataset	Linguistik	Literatur
2014	71	55	16
2015	165	114	51
2016	152	105	47
2017	120	77	43
2018	95	66	29
2019	117	88	29

Dari data jenis penelitian setiap tahun dibagi menjadi dua jenis penelitian yakni linguistik dan literatur dari tahun 2014 sampai 2019. Kemudian dari data yang telah diperoleh tersebut divisualisasikan dalam grafik yang dapat dilihat pada Gambar 4.7 berikut.



Gambar 4.7. Grafik Jenis Penelitian Setiap Tahun

Model grafik yang dihasilkan pada data jenis penelitian skripsi sastra inggris UINSA mengalami fluktuasi untuk masing-masing jenis penelitian, dengan data tiap tahun untuk jenis penelitian linguistik selalu lebih banyak daripada literatur.

#### 4.5.4 Menghitung Jumlah Tren Topik

Setelah mengetahui data statistik untuk jenis penelitian setiap tahun maka selanjutnya akan dicoba untuk menampilkan tren topik dari masing-masing jenis penelitian setiap tahun. Untuk menampilkan tren topik terlebih dahulu dihitung topik dan diambil beberapa topik yang paling sering muncul. *Pseudocode* untuk menentukan tren topik adalah sebagai berikut.

























