

**ANALISIS METODE *LATENT DIRICHLET ALLOCATION* (LDA) UNTUK  
*CLUSTERING* TERJEMAHAN AL-QUR'AN BAHASA INDONESIA**

Skripsi

untuk memenuhi sebagai persyaratan  
mencapai derajat Sarjana S-1  
Program Studi Teknik Informatika



Disusun oleh:

**Ahmad Septiawan**

**16650053**

STATE ISLAMIC UNIVERSITY  
**SUNAN KALIJAGA**  
YOGYAKARTA

**PROGRAM STUDI TEKNIK INFORMATIKA**

**FAKULTAS SAINS DAN TEKNOLOGI**

**UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA**

**YOGYAKARTA**

**2020**

## HALAMAN PENGESAHAN



KEMENTERIAN AGAMA  
UNIVERSITAS ISLAM NEGERI SUNAN KALIJAGA  
FAKULTAS SAINS DAN TEKNOLOGI  
Jl. Marsda Adisucipto Telp. (0274) 540971 Fax. (0274) 519739 Yogyakarta 55281

### PENGESAHAN TUGAS AKHIR

Nomor : B-1738/Uln.02/DST/PP.00.9/07/2020

Tugas Akhir dengan judul : ANALISIS METODE LATENT DIRICHLET ALLOCATION (LDA) UNTUK CLUSTERING TERJEMAHAN AL-QUR'AN BAHASA INDONESIA

yang dipersiapkan dan disusun oleh:

Nama : AHMAD SEPTIAWAN  
Nomor Induk Mahasiswa : 16650053  
Telah diujikan pada : Senin, 27 Juli 2020  
Nilai ujian Tugas Akhir : A

dinyatakan telah diterima oleh Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta

#### TIM UJIAN TUGAS AKHIR



Ketua Sidang/Penguji I

Muhammad Didik Rohmad Wahyudi, S.T., MT.  
SIGNED

Valid ID: 5f4d8e25c5e5



Penguji II

Dr. Agung Fatwanto, S.Si., M.Kom.  
SIGNED

Valid ID: 5f489510c761



Penguji III

Rahmat Hidayat, S.Kom., M.Cs.  
SIGNED

Valid ID: 5f4d66118542



Yogyakarta, 27 Juli 2020  
UIN Sunan Kalijaga  
Plt. Dekan Fakultas Sains dan Teknologi

Dr. Murtono, M.Si.  
SIGNED

Valid ID: 5f4dab8b50673

STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

## SURAT PERSETUJUAN



Universitas Islam Negeri Sunan Kalijaga



FM-UINSK-BM-05-03/RO

### SURAT PERSETUJUAN SKRIPSI/TUGAS AKHIR

Hal : Persetujuan Skripsi

Lamp :

Kepada

Yth. Dekan Fakultas Sains dan Teknologi

UIN Sunan Kalijaga Yogyakarta

di Yogyakarta

*Axsalamu'alaikum wr. wb.*

Setelah membaca, meneliti, memberikan petunjuk dan mengoreksi serta mengadakan perbaikan seperlunya, maka kami selaku pembimbing berpendapat bahwa skripsi Saudara:

Nama : Ahmad Septiawan

NIM : 16650053

Judul Skripsi : Analisis Metode Latent Dirichlet Allocation (LDA) Untuk Clustering  
Terjemahan Al-Qur'an Bahasa Indonesia

sudah dapat diajukan kembali kepada Program Studi Teknik Informatika Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta sebagai salah satu syarat untuk memperoleh gelar Sarjana Strata Satu dalam Program Studi Teknik Informatika

Dengan ini kami berharap agar skripsi/tugas akhir Saudara tersebut di atas dapat segera dimunaqsyahkan. Atas perhatiannya kami ucapkan terima kasih.

*Wassalamu'alaikum wr. wb.*

Yogyakarta, 16 Juli 2020

Pembimbing

M. Didik R. Wahyudi, S.T., M.T.  
NIP. 19760812 200901 1 015

## PERNYATAAN KEASLIAN SKRIPSI

### PERNYATAAN KEASLIAN SKRIPSI

Saya yang bertanda tangan dibawah ini :

Nama : Ahmad Septiawan

NIM : 16650053

Jurusan : Teknik Informatika

Fakultas : Sains dan Teknologi

Menyatakan bahwa skripsi saya yang berjudul “Analisis Metode Latent Dirichlet Allocation (LDA) Untuk Clustering Terjemahan Al-Qur’an Bahasa Indonesia ” merupakan hasil penelitian saya sendiri, tidak terdapat pada karya yang pernah di ajukan untuk memperoleh gelar kesarjana di suatu perguruan tinggi, dan bukan plagiasi karya orang lain kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

Yogyakarta, 16 Juli 2020



Ahmad Septiawan

NIM.16650053

## KATA PENGANTAR

*Alhamdulillahirobbil'alamiin.* Segala puji syukur bagi Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi dengan judul **“Analisis Metode Latent Dirichlet Allocation untuk Clustering Terjemahan Al-Qur’an Bahasa Indonesia)”** dengan baik.

Penulis menyadari bahwa penulisan skripsi ini tidak terwujud tanpa adanya bantuan, bimbingan dan dorongan dari berbagai pihak. Oleh karena itu, dengan adanya segala kerendahan hati pada kesempatan ini penulis mengucapkan terimakasih kepada :

1. Bapak Dr. Phil. Sahiron, M.A., selaku Plt. Rektor UIN Sunan Kalijaga Yogyakarta.
2. Bapak Dr. H. Waryono, M.Ag., selaku Wakil Rektor Bidang Kemahasiswaan dan Kerjasama UIN Sunan Kalijaga Yogyakarta.
3. Ibu Dr. Khurul Wardati, M.Si., selaku Dekan Fakultas Sains dan Teknologi.
4. Ibu Maria Ulfa Siregar, S.Kom., M.I.T, Ph.d., selaku Ketua Program Studi Teknik Informatika UIN Sunan Kalijaga Yogyakarta.
5. Bapak Muhammad Didik Rohmad Wahyudi, S.T., M.T., selaku Dosen Pembimbing Skripsi dan juga Dosen Pembimbing Akademik yang telah sabar dan meluangkan waktunya untuk memberikan motivasi, koreksi, serta kritik saran kepada penulis sehingga skripsi ini dapat terselesaikan.
6. Bapak Ibu Dosen Program Studi Teknik Informatika UIN Sunan Kalijaga Yogyakarta yang telah memberikan banyak bekal ilmu kepada penulis.

7. Seluruh staf dan karyawan Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta.
8. Mas Ahmad Fathan Hidayatullah, S.Kom., M.Cs., Saudara dan juga tetangga dekat yang telah membimbing dan memberikan arahan dari awal masuk perkuliahan hingga tugas akhir.
9. Ucapan terimakasih yang terdalem kepada kedua orangtua tercinta, Bapak Amat Kalimi dan Ibu Kiptiyah yang senantiasa memberikan doa, kasih sayang serta dukungan yang tak terhingga.
10. Muroby Ruhina K.H Ahmad Imron Rosyidi yang sekaligus Founder dan Trainer Keluarga Besar Ruqyah Aswaja Nasional dan Internasional yang senantiasa mendoakan dan membimbing jejak langkah hidup ini.
11. Guru Besar K.H Ahmad Zabidi, Dr Ahmad Arifin Hidayatullah yang tidak henti hentinya memberikan semangat, motifasi, dan pengalamannya sehingga penulisan skripsi ini dapat terselesaikan
12. Seluruh teman-teman Teknik Informatika 2016 yang tidak dapat disebutkan satu per satu yang telah banyak memberikan bantuan, dukungan, serta motivasi dalam menuntut ilmu.
13. Teman-teman majelis Ratibul Hadad Jonggrangan Yogi Sumarno, Faqih, Ridwan, Fathurahman, Rino, Ali Akbar, Renaldi, Anas yang menambah semangat dan berkah dalam penyelesaian skripsi.
14. Serta semua pihak yang telah memberikan doa, bantuan dan dukungan selama menempuh strata satu Teknik Informatika khususnya dalam penyusunan skripsi ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari tentu masih banyak kekurangan dalam penulisan laporan skripsi ini, sehingga kritik serta saran dari pembaca sangat penulis harapkan. Semoga penelitian skripsi ini dapat dijadikan sebagai dasar penyempurna penelitian sebelumnya.



Yogyakarta, 28 Februari 2020

Penulis

STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

## HALAMAN PERSEMBAHAN

*Skripsi ini saya persembahkan teruntuk  
kedua orang tua saya (Bapak Amat Kalimi & Ibu Kiptiyah)  
yang telah bekerja keras untuk mendidik dan mencukupi kehidupan keluarga dan  
penuh kesabaran dalam membimbing anak tunggalmu ini.  
Semoga Allah Limpahkan ampunan, rahmat, dan berkah untuk kedua orang tua  
saya, diberikan istiqomah dalam ibadah kepada Allah hingga akhir usia  
diberikan khusnul khatimah.*



STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA



## HALAMAN MOTO

إِنَّ صَلَاتِي وَنُسُكِي وَمَحْيَايَ وَمَمَاتِي لِلَّهِ رَبِّ الْعَالَمِينَ

*“Sesungguhnya shalatku, ibadahku, hidupku dan matiku hanyalah untuk Allah,*

*Tuhan semesta alam”*



STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

## DAFTAR ISI

HALAMAN JUDUL.....	i
HALAMAN PENGESAHAN.....	ii
SURAT PERSETUJUAN .....	iii
PERNYATAAN KEASLIAN SKRIPSI.....	iv
KATA PENGANTAR .....	v
HALAMAN PERSEMBAHAN .....	viii
HALAMAN MOTO .....	ix
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR .....	xv
DAFTAR PERSAMAAN .....	xvii
INTISARI.....	xviii
ABSTRACT.....	xix
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah .....	3
1.4 Tujuan Penelitian .....	4
1.5 Manfaat Penelitian .....	4
1.6 Keaslian Penelitian .....	4
1.7 Sistematika Penulisan .....	5
BAB II TINJAUAN PUSTAKA DAN LANDASAN TEORI .....	7

2.1	Tinjauan Pustaka.....	7
2.2	Landasan Teori .....	16
2.2.1	Machine Learning .....	16
2.2.2	Text Mining .....	17
2.2.3	Topic Modeling .....	18
2.2.4	Latent Dirichlet Allocation (LDA).....	19
2.2.5	Topic Coherence.....	22
2.2.6	Al-Qur'an.....	24
2.2.7	Python.....	25
2.2.8	PyLDAvis .....	26
<b>BAB III</b>	<b>METODE PENELITIAN .....</b>	<b>28</b>
3.1	Metode Penelitian .....	28
3.2	Alur Penelitian .....	28
3.2.1	Studi Pendahuluan .....	29
3.2.2	Pengumpulan Data.....	29
3.2.3	Data Preprocessing .....	29
3.2.4	N Gram Model.....	30
3.2.5	Membentuk Input Model .....	30
3.2.6	Topic Modeling .....	31
3.2.7	Analisis Hasil.....	31

3.2.8	Luaran Model Topik .....	31
3.3	Kebutuhan Sistem .....	32
BAB IV HASIL DAN PEMBAHASAN .....		33
4.1	Pengumpulan Data .....	33
4.2	Pengolahan Data .....	34
4.2.1	Case Folding .....	34
4.2.2	Stopword Removing .....	36
4.2.3	Exploratory Data Analysis (EDA) .....	37
4.2.4	Wordcloud .....	39
4.2.5	Tokenisasi .....	40
4.2.6	N Gram Model .....	41
4.3	Analisis .....	41
4.3.1	Membentuk Input Model .....	41
4.3.2	Topic Coherence Measurement .....	42
4.3.3	<i>Topic Modeling</i> .....	43
4.4	Hasil .....	44
4.4.1	Analisis Hasil Pemodelan Topik LDA .....	44
4.4.2	Analisis Hasil Pemilihan Model Terbaik .....	46
4.4.3	Visualisasi Menggunakan PyLDAvis .....	48
4.4.4	Analisis Hasil Luaran Model Topik .....	48
BAB V PENUTUP .....		57

5.1.	Kesimpulan.....	57
5.2.	Saran.....	58
	DAFTAR PUSTAKA.....	59
	LAMPIRAN.....	61
	LAMPIRAN 2 LUARAN MODEL TOPIK LDA.....	68
	CURICULUM VITAE.....	70



STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

## DAFTAR TABEL

<b>Tabel 2.1</b> Tinjauan Pustaka .....	10
<b>Tabel 4.1</b> Tabel Indeks .....	34
<b>Tabel 4.2</b> Contoh Penerapan Case Folding .....	35
<b>Tabel 4.3</b> Contoh Penerapan Stopword Removing .....	36
<b>Tabel 4.4</b> Kualitas Model Topik (Sarah, 2019).....	47



## DAFTAR GAMBAR

<b>Gambar 2.1</b> Ilustrasi Topic Modeling (Blei 2012) .....	19
<b>Gambar 2.2</b> Representasi Graphical LDA Model (Blei et al., 2003) .....	21
<b>Gambar 2.3</b> Proses Perhitungan Topic Coherence (Röder & Hinneburg, n.d.) ..	23
<b>Gambar 2.4</b> Coherence Measurement Score (Mimno, Wallach, Talley, & Leenders, 2011).....	23
<b>Gambar 3.1</b> Skema Alur Penelitian .....	28
<b>Gambar 4.1</b> Flowchart Proses Analisis.....	33
<b>Gambar 4.2</b> Source Code Load Data.....	33
<b>Gambar 4.3</b> Source Code Data Cleaning.....	35
<b>Gambar 4.4</b> Source Code Exploratory Data Analysis .....	37
<b>Gambar 4.5</b> Diagram Batang EDA.....	38
<b>Gambar 4.6</b> Source Code Wordcloud.....	39
<b>Gambar 4.7</b> Wordcloud .....	40
<b>Gambar 4.8</b> Source Code Tokenisasi .....	40
<b>Gambar 4.9</b> Source Code Membentuk Input Model .....	41
<b>Gambar 4.10</b> Segmentasi Cv Coherence Measurement .....	42
<b>Gambar 4.11</b> Alur Topik Model.....	43
<b>Gambar 4.12</b> Gambaran Distribusi Topik dan Kata dalam Dokumen .....	44
<b>Gambar 4.13</b> Source Code Pencarian Model Terbaik .....	45
<b>Gambar 4.14</b> Source Code Percobaan Loop.....	46
<b>Gambar 4.15</b> Rank Hasil Perhitungan Coherence .....	46
<b>Gambar 4.16</b> Source Code Input Model Terbaik .....	47

<b>Gambar 4.17</b> Visualisasi PyLDAvis.....	48
<b>Gambar 4.18</b> Visualisasi Topik pertama.....	49
<b>Gambar 4.19</b> Visualisasi Topik Kedua.....	50
<b>Gambar 4.20</b> Visualisasi Topik Ketiga.....	51
<b>Gambar 4.21</b> Visualisasi Topik keempat.....	52
<b>Gambar 4.22</b> Visualisasi Topik Kelima.....	53
<b>Gambar 4.23</b> Visualisasi Topik Keenam.....	54
<b>Gambar 4.24</b> Visualisasi Topik ketujuh.....	55
<b>Gambar 4.25</b> Visualisasi Tokens.....	55



## DAFTAR PERSAMAAN

<b>Persamaan 2.1</b> Inisialisasi Parameter .....	21
<b>Persamaan 2.2</b> Distribusi Kata .....	21
<b>Persamaan 2.3</b> Memilih Distribusi Topik.....	21



STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

## **Analisis Metode *Latent Dirichlet Allocation* (LDA) untuk *Clustering***

**Terjemahan Al-Qur'an Bahasa Indonesia**

**Ahmad Septiawan**

**16650053**

### **INTISARI**

Al-Qur'an adalah kitab suci umat islam yang merupakan sumber hukum utama dalam kehidupan umat. Dalam memahami Al-Quran dituntut untuk berhati-hati, karena pembahasan suatu tema belum tentu terkumpul dalam satu surat, kadang terpisah antar surat yang lain. Maka dari itu dilakukan penelitian guna menemukan tema-tema dari keseluruhan ayat Al-Quran.

Penelitian ini bertujuan untuk mencari topik tersembunyi pada kumpulan data teks terjemahan Al-Quran Bahasa Indonesia secara otomatis guna memudahkan memahami ayat Al-Qura'an secara utuh menggunakan metode *topic modeling* yaitu *Latent Dirichlet Allocation* (LDA). Metode tersebut untuk mengekstrak sejumlah 6236 ayat Al-Quran lalu menemukan luaran model topik terbaik.

Hasil evaluasi *Cv coherence measurement* memberikan nilai 0.489256 dengan luaran model sebanyak 7 topik, diantaranya "hubungan manusia dengan Allah", "kebesaran Allah", "ciptaan Allah", "cobaan dan ujian manusia", "ancaman Allah", "firman Allah", "nur".

**Kata kunci :** *text mining*, *topic modeling*, LDA, terjemahan Al-Qur'an.

STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

# **Analysis of the Latent Dirichlet Allocation (LDA) Method for Clustering**

## **Indonesian Al-Quran Translations**

**Ahmad Septiawan**

**16650053**

### **ABSTRACT**

Al-Qur'an is the Muslim holy book which is the main source of law in the life of the people. In understanding the Koran, it is necessary to be careful, because the discussion of a theme may not necessarily be collected in one letter, sometimes separate from other letters. Therefore research is carried out to find themes from all verses of the Koran.

This study aims to find hidden topics in the Indonesian Koran text translation data collection automatically in order to make it easier to understand the verses of Al-Qura'an in full using the topic modeling method that is Latent Dirichlet Allocation (LDA). The method is to extract 6236 verses from the Koran and then find the best model topic outputs.

Cv coherence measurement evaluation results give a value of 0.489256 with a model output of 7 topics, including "*hubungan manusia dengan Allah*", "*kekuasaan Allah*", "*ciptaan Allah*", "*cobaan dan ujian manusia*", "*ancaman Allah*", "*firman Allah*", "*Nur*".

**Keywords:** text mining, topic modeling, LDA, Al-Qur'an translation.

STATE ISLAMIC UNIVERSITY  
SUNAN KALIJAGA  
YOGYAKARTA

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Islam adalah agama terbesar kedua di dunia ini setelah Kristen menurut data dari *Association Religion Data Archives (ARDA)* yang menyatakan bahwa terdapat 22,8% penganut Islam di dunia ini dari total populasi manusia di bumi (Johnson, T. M., & Grim, 2015). Menurut hasil sensus penduduk Indonesia 2010, 87% dari 237.641.326 penduduk Indonesia adalah pemeluk Islam, 6,96% Kristen, 2,9% Katolik, 1,69% Hindu, 0,72% Buddha, 0,05% Konghucu, 0,13% agama lainnya, dan 0,38% tidak terjawab (Statistics Indonesia, 2010). Menurut data tersebut membuat populasi muslim terbesar adalah Indonesia dengan total 12,7% dari populasi Muslim di dunia (Pew Research Center, 2015).

Al-Qur'an adalah salah satu pedoman hidup bagi Muslim yang di dalamnya terdiri dari 114 surat, 6.236 ayat, dan 77.477 kata yang disusun menggunakan Bahasa Arab (Osman dkk, 2016). Al-Qur'an adalah petunjuk utama bagi umat Muslim yang didalamnya terdapat aturan hukum yang mengatur semua aspek kehidupan manusia, difirmankan oleh Allah SWT dalam QS.Al-Baqarah ayat 2 yang berbunyi :

ذٰلِكَ الْكِتٰبُ لَا رَيْبَ فِيْهِ هٗ هُدًى لِّلْمُتَّقِيْنَ

“Kitab (Al-Qur'an) ini tidak ada keraguan padanya petunjuk bagi mereka yang bertaqwa.” (QS.Al-Baqarah:2).

Dalam mempelajari Al-Qur'an, seringkali hanya dilakukan dengan memahami setiap ayat pada surat tertentu tanpa memperhatikan ayat-ayat pada surat yang lainnya, padahal didalam Al-Qur'an sendiri belum tentu masalah dikemukakan secara urut dalam kumpulan ayat satu surat aja. Sebab dalam pembahasan masalah dalam Al-Qur'an terpecah satu dengan yang lainnya, tidak dalam satu bahasan (Choiruddin,2015).

Dewasa ini sering kali kita jumpai dalam berita di media sosial, terjadinya kekisruhan dan kekerasan dengan dalih Al-Qur'an, mereka membenarkan apa yang mereka lakukan dan memakai ayat Al-Qur'an dengan hawa nafsunya saja. Padahal sangat berbahaya jika kita hanya berpegang kepada satu ayat saja tanpa mempertimbangkan ayat-ayat yang lain. Maka pentingnya kita belajar memahami Al-Qur'an secara menyeluruh dan mengetahui tema yang terkandung dalam Al-Qur'an secara menyeluruh. Mengetahui adanya hubungan antara ayat-ayat dan surat-surat dapat membantu untuk memahami dengan tepat ayat-ayat dan surat-surat yang bersangkutan (Yusuf, 2012). Hal tersebut menyebabkan diperlukanya penelitian mengenai pengelompokan ayat Al-Qur'an berdasarkan topiknya, agar lebih mudah dalam memahami Al-Qur'an.

Salah satu cara untuk menemukan topik dalam Al-Quran adalah dengan menggunakan *Topic Modeling*. *Topic Modeling* adalah kumpulan algoritma yang digunakan untuk menemukan struktur tersembunyi dari tema yang terdapat dalam setiap dokumen (Blei dkk, 2003).

Pada penelitian kali ini, penulis akan melakukan melakukan *Topic Modeling* terjemahan Al-Quran dari Kementerian Agama Versi 02.07.2018 menggunakan

salah satu algoritma *Topic Modeling* yaitu *Latent Dirichlet Allocation*. Hasil penelitian ini diharapkan menemukan topik dan jumlah topik dengan nilai koherensi yang paling tinggi sehingga memudahkan orang awam dalam mempelajari ayat demi ayat melalui topik yang sama.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, maka permasalahan yang ada adalah bagaimana analisis algoritma *Latent Dirichlet Allocation* dalam melakukan clustering terjemahan Al-Qur'an Bahasa Indonesia versi Kemenag 02.07.2018 dan menemukan luaran model topik yang terbaik.

## 1.3 Batasan Masalah

Dalam penelitian ini terdapat beberapa batasan masalah yang dibahas agar penyusunan dan pembahasan penelitian dapat dilakukan secara terarah dan tercapai sesuai dengan yang diharapkan. Antara lain sebagai berikut:

1. Penerapan *text mining* menggunakan algoritma *Latent Dirichlet Allocation* dalam melakukan pemodelan topik terjemahan Al-Qur'an Bahasa Indonesia.
2. Data yang akan digunakan adalah 6236 ayat terjemahan Al-Quran Kementerian Agama.
3. Bahasa pemrograman yang akan digunakan adalah bahasa pemrograman *Python* dengan berbagai macam *library* di dalamnya.

#### 1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah melakukan analisis Metode *Latent Dirichlet Allocation* untuk clustering terjemahan Al-Qur'an Bahasa Indonesia versi kemenag 02.07.2018 dan menemukan luaran model topik terbaik.

#### 1.5 Manfaat Penelitian

Berdasarkan latar belakang dan tujuan di atas, adapuun manfaat dari penelitian ini adalah sebagai berikut:

1. Penelitian ini dapat menambah wawasan dan pengetahuan khususnya di bidang *text mining*.
2. Mengetahui pola topik abstrak pada terjemahan ayat Al-Qur'an Bahasa Indonesia.
3. Mengetahui seberapa jauh permodelan topik menggunakan *Latent Dirichlet Allocation* dapat diterapkan pada text Al-Qur'an.
4. Memberikan manfaat kepada umat Islam untuk menemukan topik topik dalam Al-Qur'an.

#### 1.6 Keaslian Penelitian

Penelitian menggunakan *text mining* sudah banyak dilakukan. Namun, penelitian Analisis Metode *Latent Dirichlet Allocation* (LDA) untuk clustering Terjemahan Al-Qur'an Bahasa Indonesia, yang diajukan sebagai Tugas Akhir strata S1 pada Program Studi Teknik Informatika Fakultas Sains dan Teknologi UIN Sunan Kalijaga Yogyakarta ini belum pernah dilakukan. Hal ini diketahui berdasarkan dari referensi dan tinjauan pustaka yang dilakukan oleh peneliti

sebelumnya.

## 1.7 Sistematika Penulisan

Sebagai gambaran dan kerangka yang jelas mengenai pokok bahasan setiap bab dalam penelitian ini, maka diperlukan sistematika penulisan. Penyusunan laporan tugas akhir ini memiliki sistematika penulisan yang diawali dari BAB I dan diakhiri BAB V. Berikut adalah penjelasan pada tiap-tiap bab dalam laporan penelitian ini:

### BAB I PENDAHULUAN

Bab pendahuluan berisikan penjelasan mengenai latar belakang dilakukannya penelitian, rumusan masalah penelitian, batasan masalah, tujuan penelitian, manfaat penelitian, keaslian penelitian, dan sistematika penulisan penelitian.

### BAB II TINJAUAN PUSTAKA DAN LANDASAN TEORI

Bab tinjauan pustaka dan landasan teori berisikan mengenai penelitian terdahulu dan teori-teori dasar yang terkait dengan penelitian ini. Teori yang digunakan terdiri dari *text mining*, *topic modeling*, metode *Latent Dirichlet Allocation*, *text preprocessing*, *N Gram*, *Python*, dan *PyLDAvis*.

### BAB III METODE PENELITIAN

Bab metode penelitian berisi tentang penjelasan mengenai metode ataupun algoritma yang digunakan serta tahapan-tahapan yang dilakukan untuk mencapai tujuan dan kesimpulan tugas akhir.



#### BAB IV HASIL DAN PEMBAHASAN

Bab hasil dan pembahasan membahas analisis data dan hasil dari penelitian yang telah dilakukan.

#### BAB V PENUTUP

Bab penutup berisi tentang kesimpulan dari hasil penelitian yang telah dilakukan. Selanjutnya, kekurangan yang ada pada penelitian dituliskan pada saran untuk pengembangan penelitian di masa yang akan datang.

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Berdasarkan penelitian yang telah dilakukan dapat disimpulkan bahwa algoritma *Latent Dirichlet Allocation (LDA)* dapat melakukan pemodelan topik terjemahan Al-Qur'an Bahasa Indonesia. Pada penelitian ini dilakukan percobaan range topik 1-10, untuk alpha dan beta range 0.01-1 lalu dicari koheren paling tinggi. Percobaan yang telah dilakukan menghasilkan nilai koheren paling tinggi yaitu 0.4892566080934023 dengan topik sebanyak 7, alpha 0.01 dan beta 1.

Kesimpulan topik dari ketujuh topik tersebut, yaitu topik 1 membahas hubungan manusia dengan Allah, topik 2 membahas tentang kebesaran Allah, topik 3 membahas tentang makhluk ciptaan Allah, topik 4 membahas tentang ujian dan cobaan manusia, topik 5 membahas tentang ancaman dan siksa Allah, topik 6 membahas tentang firman Allah secara umum, dan topik 7 membahas tentang nur atau cahaya.

Hasil topik tersebut diambil berdasarkan data statistic kata-kata penyusun yang sering muncul saja, walaupun memiliki nilai koheren yang cukup tinggi, tetapi dalam pencarian topik text terjemahan Al-Qur'an ini belum bisa dijadikan sumber hukum dan masih perlu dikaji oleh ahli tafsir, karena didalam ayat Al-Qur'an ada ayat muhkam yang dapat dipahami secara gamblang tanpa perlu takwil dan ada juga ayat mutasyabih yang dapat dipahami dengan penakwilan.

## 5.2 Saran

Pada penelitian ini masih banyak sekali kekurangan. Maka dari itu penulis menyarankan beberapa hal untuk penelitian selanjutnya, diantaranya:

1. Penelitian selanjutnya untuk mengkombinasi algoritma Topik modeling yang lain.
2. Melakukan validasi dan pertimbangan kepada ahli tafsir.
3. Memakai data teks tafsir Al-Qur'an yang lebih kompleks dan sudah dijabarkan ulama.
4. Menggunakan versi terjemahan dalam Bahasa yang lain.
5. Menggunakan versi terjemahan yang terbaru.
6. Memakai library yang lain untuk memperoleh hasil yang lebih baik.

### DAFTAR PUSTAKA

- Ahmad Wahid Faizin. (2018). *Implementasi K-MEANS Clustering pada Terjemahan Al-Qur'an Berdasarkan Keterkaitan Topik.*
- Al-augby, S. H. M. (2020). *LSA & LDA Topic Modeling Classification : Comparison study on E-books LSA & LDA Topic Modeling Classification : Comparison study on E-books.* (January).  
<https://doi.org/10.11591/ijeecs.v19.i1.pp>
- Alphaidin. (2015). *Introduction to Machine Learning Second Edition.*
- Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). *Latent Dirichlet Allocation.* 3, 993–1022.
- Douven, I., & Meijs, W. (2007). Measuring coherence. Retrieved from  
<https://doi.org/10.1007/s11229-006-9131-z>
- Institute, M. (2018). Pengenalan terhadap Machine Learning. Retrieved from  
<https://medium.com/@makersinstitute/pengenalan-terhadap-machine-learning-9011fe71d1e4>
- Johnson, T. M., & Grim, B. J. (2015). Religious Adherents. Retrieved from  
[http://www.thearda.com/internationalData/countries/Country\\_109\\_2.asp](http://www.thearda.com/internationalData/countries/Country_109_2.asp)
- Juairiah omar. (2017). *Kegunaan Terjemahan Qur'an Bagi Umat Muslim.*
- Kurniawan, W., & others. (2018). *SISTEM MONITORING PERCAKAPAN PADA TOKO ONLINE MENGGUNAKAN METODE LATENT DIRICHLET ALLOCATION (LDA) STUDI KASUS: TOKO ONLINE "BERRYBENKA.*

COM.”

Kusnanta, I. M., Putra, B., & Kusumawardani, P. (2017). *Analisis Topik Informasi Publik Media Sosial di Surabaya Menggunakan Pemodelan Latent Dirichlet Allocation ( LDA )*. 6(2), 4–9.

Mimno, D., Wallach, H. M., Talley, E., & Leenders, M. (2011). *Optimizing Semantic Coherence in Topic Models*. (2), 262–272.

Osman, M., Hegazi, A., Hilal, A., & Alhawarat, M. (2016). *Fine-Grained Quran Dataset*. (January). <https://doi.org/10.14569/IJACSA.2015.061241>

Pew Research Center. (2015). *The Future of the Global Muslim Population*.

Python – The new generation Language - GeeksforGeeks. (2020). GeeksforGeeks. Retrieved from <https://www.geeksforgeeks.org/python-the-new-generation-language/>

Röder, M., & Hinneburg, A. (n.d.). *Exploring the Space of Topic Coherence Measures*.

Shafiei, M. M. (2009). *LEVERAGING STRUCTURAL INFORMATION FOR STATISTICAL* Faculty of Computer Science. (August).

Statistics Indonesia. (2010). *Results of 2010 Population Census*. Retrieved from <https://sp2010.bps.go.id/>

Vijayarani, S., Ilamathi, M. J., & Nithya, M. (n.d.). *Preprocessing Techniques for Text Mining - An Overview*. 5(1), 7–16.

## LAMPIRAN

```
#import package
import numpy as np
import pandas as pd
from IPython.display import display
import tqdm
from collections import Counter
import ast
import matplotlib.pyplot as plt
import matplotlib.mlab as mlab
import seaborn as sb

from sklearn.feature_extraction.text import
CountVectorizer
from textblob import TextBlob
import scipy.stats as stats
import os
from sklearn.decomposition import TruncatedSVD
from sklearn.decomposition import
LatentDirichletAllocation
from sklearn.manifold import TSNE
from bokeh.plotting import figure, output_file, show
from bokeh.models import Label
from bokeh.io import output_notebook
output_notebook()

%matplotlib inline
%matplotlib inline
```

```
#load data
data=pd.read_csv('Indonesian-Bahasa-Indonesia-68.csv')
len(data)

#data cleaning
import re
# Remove punctuation
data['AyahText'] = data['AyahText'].map(lambda x:
re.sub('[,\.\!?!?]():&',' ', x))
# Convert the titles to lowercase
data['AyahText'] = data['AyahText'].map(lambda x:
x.lower())
# Print out the first rows of papers
data['AyahText'].head()

# Import the wordcloud library
from wordcloud import WordCloud
# Join the different processed titles together.
long_string = ','.join(list(data['AyahText'].values))
# Create a WordCloud object
wordcloud = WordCloud(background_color="white",
max_words=5000, contour_width=3,
contour_color='steelblue')
# Generate a word cloud
wordcloud.generate(long_string)
# Visualize the word cloud
```

```

# EDA

# Load the library with the CountVectorizer method
from sklearn.feature_extraction.text import CountVectorizer

import numpy as np

import matplotlib.pyplot as plt

import seaborn as sns

sns.set_style('whitegrid')

%matplotlib inline

# Helper function
def plot_10_most_common_words(count_data, count_vectorizer):
    import matplotlib.pyplot as plt

    words = count_vectorizer.get_feature_names()
    total_counts = np.zeros(len(words))

    for t in count_data:
        total_counts+=t.toarray()[0]

    count_dict = (zip(words, total_counts))
    count_dict = sorted(count_dict, key=lambda x:x[1], reverse=True)[0:10]
    words = [w[0] for w in count_dict]
    counts = [w[1] for w in count_dict]
    x_pos = np.arange(len(words))

    plt.figure(2, figsize=(15, 15/1.6180))
    plt.subplot(title='10 most common words')
    sns.set_context("notebook", font_scale=1.25, rc={"lines.linewidth": 2.5})
    sns.barplot(x_pos, counts, palette='husl')

    plt.xticks(x_pos, words, rotation=90)
    plt.xlabel('words')
    plt.ylabel('counts')
    plt.savefig('top10.png',idi=300)
    plt.show()

```



```

# Initialise the count vectorizer with the English stop words
count_vectorizer = CountVectorizer(stop_words='english')

# Fit and transform the processed titles
count_data = count_vectorizer.fit_transform(data['AyahText'])

# Visualise the 10 most common words
plot_10_most_common_words(count_data, count_vectorizer)

%%time
import gensim
from gensim.utils import simple_preprocess
def sent_to_words(sentences):
    for sentence in sentences:
        yield(gensim.utils.simple_preprocess(str(sentence), deacc=True)) #
deacc=True removes punctuations
data = data.AyahText.values.tolist()
data_words = list(sent_to_words(data))
print(data_words[:1])

# Build the bigram and trigram models
bigram = gensim.models.Phrases(data_words, min_count=5, threshold=100) #
higher threshold fewer phrases.
trigram = gensim.models.Phrases(bigram[data_words], threshold=100)

# Faster way to get a sentence clubbed as a trigram/bigram
bigram_mod = gensim.models.phrases.Phruaser(bigram)
trigram_mod = gensim.models.phrases.Phruaser(trigram)

#fungsi bigram dan trigram
def make_bigrams(texts):
    return [bigram_mod[doc] for doc in texts]
def make_trigrams(texts):
    return [trigram_mod[bigram_mod[doc]] for doc in texts]

```

```
# Form Bigrams
import spacy

data_words_bigrams = make_bigrams(data_words)
print(data_words_bigrams[:1])

import gensim.corpora as corpora

# Create Dictionary
id2word = corpora.Dictionary(data_words_bigrams)

# Create Corpus
texts = data_words_bigrams

# Term Document Frequency
corpus = [id2word.doc2bow(text) for text in texts]

# View
print(corpus[:1])

#optional
# supporting function
def compute_coherence_values(corpus, dictionary, k, a, b):
    lda_model = gensim.models.LdaMulticore(corpus=corpus,
        id2word=id2word,
        num_topics=10,
        random_state=100,
        chunksize=100,
        passes=10,
        alpha=a,
        beta=b,
        per_word_topics=True)

    coherence_model_lda =
    CoherenceModel(model=lda_model, texts=data_words_bigrams,
        dictionary=id2word, coherence='c_v')

    return coherence_model_lda.get_coherence()
```

```

#dipakai
import numpy as np
import tqdm
grid = {}
grid['Validation_Set'] = {}
# Topics range
min_topics = 2
max_topics = 11
step_size = 1
topics_range = range(min_topics, max_topics, step_size)
# Alpha parameter
alpha = list(np.arange(0.01, 1, 0.3))
alpha.append('symmetric')
alpha.append('asymmetric')
# Beta parameter
beta = list(np.arange(0.01, 1, 0.3))
beta.append('symmetric')
hasil = {'Topics': [], 'Alpha': [], 'Beta': [], 'Coherence': []}
for k in topics_range:
    for a in alpha:
        for b in beta:
            cv = compute_coherence_values(corpus=corpus,
dictionary=id2word,
k=k, a=a, b=b)

            hasil['Topics'].append(k)
            hasil['Alpha'].append(a)
            hasil['Beta'].append(b)
            hasil['Coherence'].append(cv)
pd.DataFrame(hasil).to_csv('percobaanallloop.csv',
index=False)

```

```

allmodels=pd.read_csv('percobaanallloop.csv')
allmodels.sort_values('Coherence',ascending=False)
#model terbaik
lda_model_final =
gensim.models.LdaMulticore(corpus=corpus,
id2word=id2word,
num_topics=7,
random_state=100,
chunksize=100,
passes=10,
alpha=0.01,
beta=1)

from pprint import pprint
# Print the Keyword in the 7 topics
pprint(lda_model_final.print_topics())
doc_lda = lda_model_final[corpus]
from gensim.models import CoherenceModel
# Compute Coherence Score
coherence_model_lda =
CoherenceModel(model=lda_model_final,
texts=data_words_bigrams, dictionary=id2word,
coherence='c_v')
coherence_lda = coherence_model_lda.get_coherence()
print('\nCoherence Score: ', coherence_lda)
#Pyldavis
import pyLDAvis.gensim
import pickle
import pyLDAvis
# Visualize the topics
pyLDAvis.enable_notebook()
LDAvis_prepared = pyLDAvis.gensim.prepare(lda_model_final,
corpus, id2word)
LDAvis_prepared

```

## LAMPIRAN 2 LUARAN MODEL TOPIK LDA

Topic: 0	'0.097*"orang" + 0.027*"allah" + 0.015*"hari" + 0.012*"benar" + ' '0.010*"kafir" + 0.009*"beriman" + 0.008*"manusia" + 0.007*"azab" + ' '0.007*"rasul" + 0.006*"datang"
Topic: 1	'0.029*"maha" + 0.027*"allah" + 0.018*"tuhan" + 0.013*"bumi" + ' '0.013*"langit" + 0.010*"manusia" + 0.010*"malaikat" + 0.010*"benar" + ' '0.009*"dialah" + 0.009*"tuhanmu"
Topic: 2	[(0, '0.012*"air" + 0.006*"surga" + 0.006*"mata" + 0.005*"gunung_gunung" + ' '0.004*"buah" + 0.004*"minum" + 0.004*"kedua" + 0.003*"binatang" + ' '0.003*"panas" + 0.003*"pohon"
Topic: 3	'0.007*"wanita" + 0.005*"buhul" + 0.003*"tukang_sihir" + 0.003*"kejahatan" + ' '0.003*"menghembus" + 0.002*"pergilah" + 0.002*"kesulitan" + 0.002*"penuh" + ' '0.002*"bangunan" + 0.002*"nasehat"
Topic: 4	'0.026*"neraka" + 0.012*"api" + 0.007*"jahannam" + 0.006*"syaitan" + ' '0.005*"menguasai" + 0.005*"berlindung" + 0.004*"masuk" + 0.004*"kayu" + ' '0.003*"tempat" + 0.003*"menyala_nyala"
Topic: 5	'0.017*"ayat" + 0.003*"makanan" + 0.003*"subuh" + 0.002*"dibacakan" + ' '0.002*"beban" + 0.002*"al_quran" + 0.002*"ditutup" + 0.002*"mendaki" + ' '0.002*"daun" + 0.001*"sukar"

Topic: 6	'0.004*"bulan" + 0.003*"kanan" + 0.002*"tiang" + 0.002*"digoncangkan" + '  '0.002*"cahayanya" + 0.002*"kemudahan" + 0.001*"muda" + 0.001*"mengira" + '  '0.001*"rencana" + 0.001*"seri"'
----------	--



## CURICULUM VITAE

### A. Biodata Diri

Nama Lengkap : Ahmad Septiawan  
Jenis Kelamin : Laki-Laki  
Tempat, Tanggal Lahir : Sleman, 17 September 1997  
Alamat Asal : Jonggrangan, Sumberadi,  
Mlati, Sleman, DIY  
Alamat Tinggal : Jonggrangan, Sumberadi, Mlati, Sleman, DIY  
E-mail : [septiawan.ahmad96@mail.com](mailto:septiawan.ahmad96@mail.com)



### B. Latar Belakang Pendidikan Formal

Jenjang	Nama Sekolah	Tahun
TK	TK ABA Sleman	2003 – 2004
SD	SDN Sleman 1	2004 – 2010
SMP	SMP NEGERI 3 Sleman	2010 – 2013
SMA	SMA NEGERI 1 GODEAN	2013 – 2016
S1	UIN SUNAN KALIJAGA YOGYAKARTA	2016 – 2020