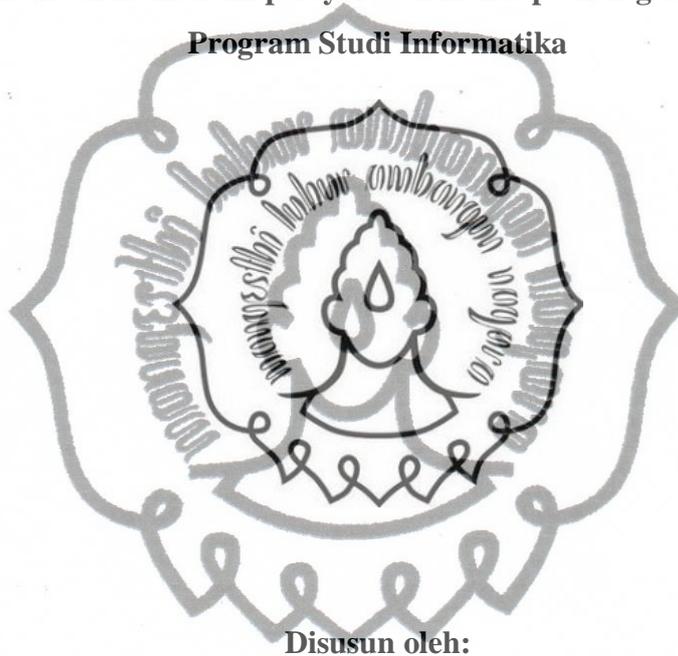


**ANALISIS PEMODELAN TOPIK PADA ARTIKEL BERITA
MENGUNAKAN METODE LATENT DIRICHLET ALLOCATION**

SKRIPSI

**Diajukan untuk memenuhi persyaratan mendapatkan gelar Strata Satu
Program Studi Informatika**



Disusun oleh:

HANIF SULTHAN RIZQULLAH

M0514019

PROGRAM STUDI INFORMATIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS SEBELAS MARET

SURAKARTA

2019

SKRIPSI
ANALISIS PEMODELAN TOPIK PADA ARTIKEL BERITA
MENGGUNAKAN METODE LATENT DIRICHLET ALLOCATION

Disusun oleh:

HANIF SULTHAN RIZQULLAH

NIM. M0514019

Skripsi ini telah disetujui untuk dipertahankan di hadapan dewan penguji
pada tanggal 24 Januari 2019

Pembimbing 1,

Pembimbing 2,



Afrizal Doewes, S.Kom., M.Sc.

NIP. 198508312012121004

Haryono Setiadi, ST., M.Eng

NIP. 198003272005011002

SKRIPSI

ANALISIS PEMODELAN TOPIK PADA ARTIKEL BERITA
MENGUNAKAN METODE LATENT DIRICHLET ALLOCATION

Disusun oleh:

HANIF SULTHAN RIZQULLAH

NIM. M0514019

telah dipertahankan di hadapan dewan penguji pada tanggal,

29 Januari 2019

Susunan Dewan Penguji

1. Afrizal Doewes, S.Kom., M.Sc. (Ketua) ()
NIP. 198508312012121004
2. Haryono Setiadi, ST., M.Eng (Sekretaris) ()
NIP. 198003272005011002
3. Dr. Techn. Dewi Wisnu Wardani, S.Kom, M.S. (Anggota) ()
NIP. 197810262005012002
4. Ristu Saptono, S.Si., M.T. (Anggota) ()
NIP. 197902102002121001

Disahkan oleh

Kepala Program Studi Informatika

Drs. Bambang Harjito, M.App.Sc., Ph.D.

NIP. 196211301991031002

MOTTO



“Maka nikmat Tuhan-mu yang manakah yang kamu dustakan?”

QS. Ar-Rahman[55]:13

PERSEMBAHAN



Skripsi ini penulis persembahkan kepada:

**Ayah, Ibu, adik, dan Keluarga Besar,
serta teman-teman S1 Informatika UNS khususnya “iFourteen”.**

KATA PENGANTAR

Segala puji dan syukur Penulis panjatkan kepada Allah *Subhaanahu wa Ta'ala* atas berkat dan rahmat-Nya, Penulis dapat menyelesaikan Tugas Akhir dengan judul “Analisis Pemodelan Topik pada Artikel Berita Menggunakan Metode Latent Dirichlet Allocation” sebagai syarat untuk memperoleh gelar Sarjana Informatika di Universitas Sebelas Maret Surakarta.

Dalam penyusunan Tugas Akhir ini banyak pihak yang telah memberi bantuan, oleh karena itu tidak lupa penulis mengucapkan terima kasih kepada:

1. Bapak Drs. Bambang Harjito, M.App.Sc., Ph.D selaku Kepala Program Studi Informatika Universitas Sebelas Maret Surakarta dan Pembimbing Akademis.
2. Bapak Afrizal Doewes, S.Kom., M.Sc. selaku Dosen Pembimbing I yang telah memberikan bimbingan serta masukan dalam penyusunan Tugas Akhir.
3. Bapak Haryono Setiadi, ST., M.Eng selaku Dosen Pembimbing II yang telah memberikan bimbingan serta masukan dalam penyusunan Tugas Akhir.
4. Kedua Orang tua serta keluarga yang selalu memberikan motivasi dan do'a.
5. Teman-teman khususnya Informatika angkatan 2014 “*iFourteen*” dan KKN Batu UNS 2018 yang telah memberikan bantuan dan motivasi dalam menyelesaikan laporan Tugas Akhir ini.
6. Semua pihak yang tidak dapat Penulis sebutkan satu per satu.

Penulis menyadari masih banyak kekurangan dalam penyusunan laporan Tugas Akhir ini baik dari segi penulisan maupun materi yang dijelaskan. Dengan adanya laporan Tugas Akhir ini, diharapkan mampu memberikan manfaat dan menambah wawasan bagi pembaca maupun Penulis sendiri.

Surakarta, Januari 2019

Penulis

ANALISIS PEMODELAN TOPIK PADA ARTIKEL BERITA MENGUNAKAN METODE LATENT DIRICHLET ALLOCATION

HANIF SULTHAN RIZQULLAH

Program Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Sebelas Maret

ABSTRAK

Berita merupakan sebuah informasi berupa fakta atau pendapat seseorang yang berasal dari sebuah kejadian/peristiwa yang sifatnya menarik untuk diketahui dan dimuat melalui media massa, termasuk portal online berita. Dalam menemukan topik tersembunyi yang terdapat dalam kumpulan artikel berita salah satu metode yang cepat dan efisien adalah pemodelan topik, dan *Latent Dirichlet Allocation* (LDA) merupakan salah satunya. Tahap-tahap dalam penelitian ini antara lain pengumpulan data, *text preprocessing*, pemodelan topik, dan analisis hasil. Pemodelan topik dengan metode LDA menghasilkan 8 topik sebagai jumlah topik terbaik berdasarkan nilai *perplexity* terendah dengan nilai *perplexity* 3087,927 dan berdasarkan hasil analisa model dari dua eksperimen yang dilakukan yaitu eksperimen terkait dengan jumlah *passes* dan eksperimen terkait dengan jumlah topik.

Kata kunci: pemodelan topik, *Latent Dirichlet Allocation*

TOPIC MODELING ANALYSIS ON NEWS ARTICLE BY USING LATENT DIRICHLET ALLOCATION

HANIF SULTHAN RIZQULLAH

Department of Informatics, Faculty of Mathematics and Natural Sciences,
Universitas Sebelas Maret

ABSTRACT

News is an information comes from an event based on fact or someone opinion that is interesting to know and being published on mass media including online news portals. Topic modelling is one of the quickest and efficient methods to discover hidden topics in a collection of news article, and Latent Dirichlet Allocation (LDA) is one of them. Methodology in this research consists of data collection, text preprocessing, topic modelling, and result analysis. Topic modelling using LDA yields 8 topics as the best number of topics based on the lowest perplexity with value 3087.927 and based on model analysis from two experiments, experiments related to the number of passes and experiments related to the number of topics.

Keywords: *topic modeling, Latent Dirichlet Allocation*

DAFTAR ISI

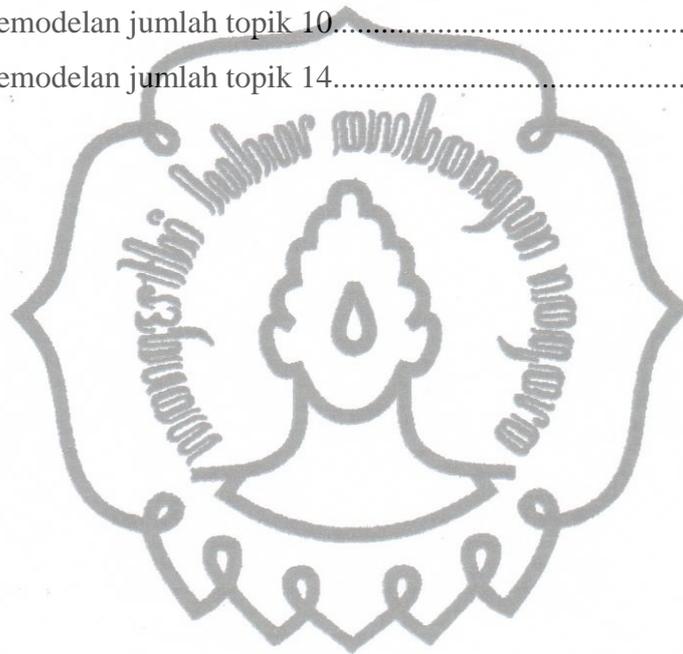
HALAMAN JUDUL.....	i
HALAMAN PERSETUJUAN.....	ii
HALAMAN PENGESAHAN.....	iii
MOTTO.....	iv
PERSEMBAHAN.....	v
KATA PENGANTAR.....	vi
ABSTRAK.....	vii
ABSTRACT.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
DAFTAR LAMPIRAN.....	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian.....	3
1.5 Manfaat Penelitian.....	3
1.6 Sistematika Penulisan.....	4
BAB II TINJAUAN PUSTAKA.....	5
2.1 Dasar Teori.....	5
2.1.1 <i>Text Mining</i>	5
2.1.2 Text Preprocessing.....	5

2.1.3	Pemodelan Topik	8
2.1.4	Latent Dirichlet Allocation	8
2.1.5	Perplexity	11
2.2	Penelitian Terkait.....	12
	Tabel 2.1 Perbandingan Hasil Penelitian Terkait.....	17
BAB III METODOLOGI PENELITIAN.....		20
3.1	Pengumpulan Data.....	20
3.2	Text Preprocessing	21
3.2.1	Unitize and Tokenization	22
3.2.2	Standardization and Cleaning	22
3.2.3	Stop Word Removal.....	22
3.2.4	Lemmatization.....	22
3.2.5	Bag-of-Words.....	22
3.3	Pemodelan Topik.....	23
3.3.1	Inisialisasi.....	23
3.3.2	E-Step.....	24
3.3.3	M-Step.....	25
3.4	Analisis Hasil.....	25
3.4.1	Analisis berdasarkan jumlah <i>passes</i>	25
3.4.2	Analisis berdasarkan jumlah topik.....	26
BAB IV PEMBAHASAN.....		28
4.1	Hasil Pengumpulan Data	28
4.2	Hasil Text Preprocessing.....	28
4.2.1	Unitize and Tokenization	29
4.2.2	Standardization and Cleaning	29

4.2.3	Stop Word Removal.....	29
4.2.4	Lemmatization.....	30
4.2.5	Bag-of-Words.....	30
4.3	Pemodelan Topik.....	32
4.3.1	Inisialisasi.....	32
4.3.2	E-Step.....	33
4.3.3	M-Step.....	36
4.4	Analisis Pemodelan Topik.....	37
4.4.1	Analisis pemodelan topik berdasarkan jumlah <i>passes</i>	38
4.4.2	Analisis pemodelan topik berdasarkan jumlah topik.....	38
BAB V PENUTUP.....		42
5.1	Kesimpulan.....	42
5.2	Saran.....	42
DAFTAR PUSTAKA.....		43
LAMPIRAN.....		46

DAFTAR TABEL

Tabel 2.1 Perbandingan Hasil Penelitian Terkait.....	17
Tabel 4.1 Jumlah data yang didapatkan	28
Tabel 4.2 Representasi id token	31
Tabel 4.3 Rincian Inisialisasi Parameter.....	32
Tabel 4.4 Pemodelan jumlah topik 10.....	40
Tabel 4.5 Pemodelan jumlah topik 14.....	41



DAFTAR GAMBAR

Gambar 2.1 Data teks asli	6
Gambar 2.2 Hasil unitize dan tokenize	6
Gambar 2.3 Hasil standardization dan cleaning	6
Gambar 2.4 Hasil stop word removal	7
Gambar 2.5 Hasil stemming	7
Gambar 2.6 Hasil lemmatization	8
Gambar 2.7 Representasi Model LDA (Blei, et al., 2003)	9
Gambar 3.1 Alur Metodologi Penelitian	20
Gambar 3.2 Tahap Text Preporcessing	21
Gambar 3.3 Pola Regex untuk Tokenization	22
Gambar 3.4 Tahap pemodelan topik LDA oleh gensim	23
Gambar 3.5 Rancangan visualisasi grafik eksperimen berdasarkan jumlah passes	26
Gambar 3.6 Rancangan visualisasi grafik eksperimen berdasarkan jumlah topik	27
Gambar 4.1 Data asli	29
Gambar 4.2 Tahap Unitize and Tokenization	29
Gambar 4.3 Tahap Standardtization and Cleaning	29
Gambar 4.4 Tahap Stop Word Removal	30
Gambar 4.5 Tahap Lemmatization	30
Gambar 4.6 Bag-of-words	30
Gambar 4.7 Nilai perplexity berdasarkan jumlah passes	38
Gambar 4.8 Nilai perplexity berdasarkan jumlah topik	39

DAFTAR LAMPIRAN

Lampiran 1 Dataset penelitian	46
Lampiran 2 Hasil <i>Text Preprocessing</i>	46
Lampiran 3 Hasil Inisialisasi, E-step, dan M-step	47
Lampiran 4 Hasil Pemodelan Topik LDA	60

