

**MENENTUKAN ENTITAS DARI PEMBERITAAN MEDIA DARING  
MENGGUNAKAN HIDDEN MARKOV MODEL  
UNTUK METODE POS TAGGING**

**SKRIPSI**



Disusun Oleh:

**Husain Abdul Aziz**

**14.11.7723**

**PROGRAM SARJANA  
PROGRAM STUDI INFORMATIKA  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA  
2018**

**MENENTUKAN ENTITAS DARI PEMBERITAAN MEDIA DARING  
MENGGUNAKAN HIDDEN MARKOV MODEL  
UNTUK METODE POS TAGGING**

**SKRIPSI**

untuk memenuhi sebagian persyaratan  
mencapai gelar Sarjana  
pada Program Studi Informatika



Disusun Oleh:

**Husain Abdul Aziz**

**14.11.7723**

**PROGRAM SARJANA  
PROGRAM STUDI INFORMATIKA  
FAKULTAS ILMU KOMPUTER  
UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA  
2018**

## **PERSETUJUAN**

### **SKRIPSI**

#### **MENENTUKAN ENTITAS DARI PEMBERITAAN MEDIA DARING MENGGUNAKAN HIDDEN MARKOV MODEL DAN METODE POS TAGGING**

yang dipersiapkan dan disusun oleh

**Husain Abdul Aziz**

**14.11.7723**

telah disetujui oleh Dosen Pembimbing Skripsi  
pada tanggal 20 Juli 2017

Dosen Pembimbing,



**Hartatik, S.T., M.Cs.**  
**NIK. 190302232**

**PENGESAHAN**  
**SKRIPSI**  
**MENENTUKAN ENTITAS DARI PEMBERITAAN MEDIA DARING**  
**MENGGUNAKAN HIDDEN MARKOV MODEL**  
**UNTUK METODE POS TAGGING**

yang dipersiapkan dan disusun oleh

**Husain Abdul Aziz**

14.11.7723

telah dipertahankan di depan Dewan Pengaji  
pada tanggal 23 Agustus 2018

**Susunan Dewan Pengaji**

**Nama Pengaji**

Mardhiya Hayaty, S.T., M.Kom  
NIK. 190302108

Erni Seniwati, S.Kom, M.Cs  
NIK. 190302231

Yuli Astuti, M.Kom  
NIK. 190302146

**Tanda Tangan**

Skripsi ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Sarjana Komputer  
Tanggal 10 September 2018



## **PERNYATAAN**

Saya yang bertandatangan dibawah ini menyatakan bahwa, skripsi ini merupakan karya saya sendiri (ASLI), dan isi dalam skripsi ini tidak terdapat karya yang pernah diajukan oleh orang lain untuk memperoleh gelar akademis di suatu institusi pendidikan tinggi manapun, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis dan/atau diterbitkan oleh orang lain, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Segala sesuatu yang terkait dengan naskah dan karya yang telah dibuat adalah menjadi tanggungjawab saya pribadi.

Yogyakarta, 5 September 2018

METERAI  
TEMPEL

A1889AFF184988420

6000  
ENAM RIBU RUPIAH

Husain Abdul Aziz

NIM. 14.11.7723

## MOTTO

*"Man Jadda Wa Jada"*

**Anon**

*"Kerahkan hati, pikiran, dan jiwasu kedalam aksimu yang paling kecil sekalipun.*

*Inilah rahasia kesuksesaan."*

**Swarmi Sivanda**

*"Betapa bodohnya manusia, dia menghancurkan masa depan kini sambil  
mengkawatirkan masa depan Tapi menangis dimasa depan dengan mengingat  
masa lalunya."*

**Ali bin Abi Thalib**



## **PERSEMBAHAN**

Alhamdulilah segala puji syukur atas berkat rahmat dan karunia Allah SWT yang telah memberikan kemudahan dan kelancara bagi penulis dalam menyelesaikan skripsi ini dengan sebaik-baiknya. Skripsi ini penulis persembahkan untuk:

1. Kedua orang tua penulis yang tercinta, Bapak Mustofa dan Ibu Sunarni yang telah memberikan dukungan terbesar, menguatkan, dan menyemangati penulis dalam suka maupun duka.
2. Adik-adik penulis, Lina Azizah Fathin dan Azizah Qoidatu Fariha yang selalu memberikan dukungan pada penulis.
3. Ibu Hartatik selaku dosen pembimbing yang telah memberikan bimbingannya untuk penulisan skripsi ini.
4. Seluruh teman-teman kelas 14-S1.TI-02, terimakasih untuk waktu, kebersamaan, susah, senang, canda, tawa dan dukungan yang diberikan kepada penulis.
5. Bapak Kun Budiharta dan Bapak Rahadian P. Paramita, yang telah membimbing penulis dalam melakukan penelitian ini.
6. Untuk Wulan, Aldo, Samuel, Mas Marji, Eka, Sigit, Nuzul, Ariyo, Joko, Palupy, Arief, serta masih banyak lagi yang belum disebutkan. Terima kasih atas semangat, dukungan dan doa yang diberikan kepada penulis.

## KATA PENGANTAR

Puji syukur atas kehadiran Allah SWT yang telah melimpahkan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan skripsi dengan judul “Menentukan Entitas dari Pemberitaan Media Daring Menggunakan Hidden Markov Model dan Metode POS Tagging” dengan sebaik-baiknya. Tidak lupa shalawat serta salam penulis haturkan kepada junjungan besar Nabi Muhammad SAW.

Dengan selesainya skripsi ini, maka penulis mengucapkan terima kasih kepada:

1. Allah SWT yang telah memberikan petunjuk dan membantu seluruh proses dalam penulisan skripsi ini.
2. Bapak M. Suyanto, Prof., Dr., M.M selaku Ketua Universitas Amikom Yogyakarta.
3. Ibu Hartatik, S.T, M.Cs selaku dosen pembimbing yang telah membantu dan memberi arahan dengan sabar kepada penulis sehingga skripsi ini dapat diselesaikan dengan sebaik-baiknya.
4. Ibu, Bapak, Adik-adik penulis yang selalu setia memberikan semangat, dan doa kepada penulis, sehingga skripsi ini dapat selesai seperti yang diharapkan.
5. Bapak Kun Budiharta yang telah memberikan bimbingan dan dukungan dalam penyusunan skripsi ini.
6. Bapak Rahadian P. Paramita telah memberikan bimbingan dalam penyusunan skripsi ini.
7. Wahyu Setiawan selaku alumni AMIKOM Yogyakarta yang membantu dalam penelitian skripsi ini.

8. Khotimah Tri Wulandari yang selalu sabar dalam membantu, memotivasi dan memberikan dukungan dalam pembuatan skripsi ini.
9. Febyola Aldo Brilyansyah yang telah membantu dan memberikan dukungan kepada penulis.
10. Para Dosen dan Staff Universitas Amikom Yogyakarta yang telah membantu memberikan ilmu pengetahuan, pengalaman, dan motivasi selama proses perkuliahan.
11. Seluruh teman-teman kelas 14-S1.TI-02 dan semua pihak yang telah membantu dan tidak dapat disebutkan satu persatu.

Penulis menyadari bahwa dalam penyusunan skripsi ini masih banyak kekurangan. Besar harapan penulis untuk kritik, saran, bimbingan dan arahan menuju perbaikan dalam skripsi ini. Dan semoga skripsi ini dapat bermanfaat bagi penulis maupun pembaca.

Yogyakarta, 5 September 2018

Penulis



Husain Abdul Aziz

NIM. 14.11.7723

## DAFTAR ISI

PERSETUJUAN .....	ii
PENGESAHAN .....	iii
PERNYATAAN.....	iv
MOTTO .....	v
PERSEMBAHAN.....	vi
KATA PENGANTAR .....	vii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	i
DAFTAR GAMBAR .....	ii
INTISARI.....	iv
ABSTRACT .....	v
BAB I PENDAHULUAN .....	1
1.1    Latar Belakang .....	1
1.2    Rumusan Penelitian .....	2
1.3    Batasan Penelitian .....	3
1.4    Tujuan Penelitian.....	3
1.5    Manfaat Penelitian.....	3
1.6    Metodologi Penelitian .....	4
1.6.1    Tahapan Pengumpulan Data .....	4
1.6.2    Tahapan Penelitian .....	4
1.7    Sistematika Penulisan.....	5
BAB II LANDASAN TEORI .....	7
2.1    Tinjauan Pustaka .....	7

2.2	Text Mining .....	11
2.3	Scraping.....	11
2.4	Pre-processing .....	12
2.5	N-Gram.....	13
2.6	POS Tag .....	13
2.7	Hidden Markov Model (HMM).....	15
2.8	Named Entity Recognition (NER) .....	20
2.9	Confusion Matrix .....	21
2.10	Flowchart .....	23
<b>BAB III PERANCANGAN .....</b>		<b>25</b>
3.1	Analisis Masalah .....	25
3.2	Solusi yang Dipilih.....	26
3.3	Analisis Kebutuhan .....	26
3.3.1	Analisis Kebutuhan Fungsional .....	26
3.3.2	Analisis Kebutuhan Non-Fungsional .....	27
3.4	Hidden Markov Model .....	28
3.4.1	Scraping & Cleaning Data .....	28
3.4.2	Tokenization.....	29
3.4.3	Anotasi .....	32
3.4.4	HMM POS Tagger .....	34
3.4.5	Entity Extraction .....	36
3.5	Named Entity Recognition .....	38
3.5.1	Preparing Data.....	38
3.5.2	Anotasi .....	40
3.5.3	Training and Testing .....	43

3.6	Perancangan Aplikasi .....	43
3.7	Perancangan Interface .....	46
3.7.1	Perancangan Halaman Utama .....	46
3.7.2	Perancangan Halaman Kategori.....	46
3.7.3	Perancangan Halaman Hasil NER .....	47
3.7.4	Perancangan Halaman Statistik.....	48
3.7.5	Perancangan Halaman Today Entity .....	48
3.7.6	Perancangan Halaman Repository .....	49
	BAB IV IMPLEMENTASI .....	50
4.1	Implementasi Sistem .....	50
4.2	Pembuatan Database.....	50
4.1	Implementasi Pengumpulan Data Google News.....	51
4.2	Implementasi Perancangan Fungsi dan Sistem .....	53
4.2.1	Perancangan Fungsi dan Sistem HMM Post Tagger .....	53
4.2.2	Perancangan Fungsi dan Sistem Named Entity Recognition.....	58
4.5	Pembuatan Interface .....	62
4.6	Evaluasi Program .....	66
	BAB V KESIMPULAN .....	70
5.1	Kesimpulan.....	70
5.2	Saran .....	70
	DAFTAR PUSTAKA .....	72

## DAFTAR TABEL

Tabel 2.1 Tabel Perbandingan Penelitian.....	9
Tabel 2.2 Tabel <i>Tagset</i> Bahasa Indonesia.....	14
Tabel 2.3 Tabel <i>Confusion Matrix</i> .....	21
Tabel 2.4 Tabel Penjelasan <i>Flowchart</i> .....	23
Tabel 3.1 Tabel Proses <i>Sentence Tokenization</i> .....	30
Tabel 3.2 Tabel <i>Word Tokenization</i> .....	31
Tabel 3.3 Tabel Hasil Anotasi.....	32
Tabel 3.4 Ilustrasi <i>Matrix Graf</i> Kata.....	35
Tabel 3.5 Tabel Proses <i>Entity Extraction</i> .....	38
Tabel 3.6 Tabel Daftar Label Entitas .....	40
Tabel 3.7 Tabel Proses Anotasi Entitas .....	41
Tabel 4.1 Tabel Percobaan 5.000 Kalimat .....	67
Tabel 4.2 Tabel Percobaan 10.000 Kalimat .....	67
Tabel 4.3 Tabel Percobaan 15.000 Kalimat .....	68
Tabel 4.4 Tabel Percobaan 20.000 Kalimat .....	68
Tabel 4.5 Tabel Hasil Percobaan Terbaik .....	69

## DAFTAR GAMBAR

Gambar 2.1 Ilustrasi Contoh Kasus <i>Markov Chain</i> .....	16
Gambar 3.1 <i>Flowchart</i> Proses <i>Scraping</i> Berita.....	28
Gambar 3.2 Flowchart Proses <i>Cleaning</i> Berita.....	28
Gambar 3.3 <i>Flowchart</i> Proses <i>Scrapping &amp; Cleaning</i> Data .....	29
Gambar 3.4 <i>Flowchart</i> Proses <i>Tokenization</i> .....	30
Gambar 3.5 <i>Flowchart</i> Proses Anotasi POS <i>Tag</i> .....	32
Gambar 3.6 Gambar Kemungkinan Perpindahan Antar Label Kata.....	35
Gambar 3.7 Lintasan Untuk Label Kata Terbaik .....	36
Gambar 3.8 <i>Flowchart</i> Proses <i>Entity Extraction</i> .....	37
Gambar 3.9 <i>Flowchart</i> Proses <i>Formating</i> Data <i>Prodigy</i> .....	39
Gambar 3.10 <i>Flowchart</i> Proses Anotasi NER .....	40
Gambar 3.11 <i>Flowchart</i> Proses Keseluruhan Sistem.....	43
Gambar 3.12 <i>Flowchart</i> Proses Keseluruhan Sistem.....	45
Gambar 3.13 Rancangan Tampilan Halaman Utama.....	46
Gambar 3.14 Rancangan Tampilan Halaman Kategori .....	47
Gambar 3.15 Rancangan Tampilan Halaman Hasil NER .....	47
Gambar 3.16 Rancangan Tampilan Halaman Statistik .....	48
Gambar 3.17 Rancangan Tampilan Halaman Entitas .....	49
Gambar 3.18 Rancangan Halaman Repository .....	49
Gambar 4.1 <i>Query</i> Pembuatan <i>Database</i> .....	50
Gambar 4.2 <i>Query</i> Pembuatan Tabel “ <i>template</i> ” .....	51
Gambar 4.3 <i>Query</i> Pembuatan Tabel Kategori .....	51
Gambar 4.4 <i>Script</i> untuk <i>Scraping Content</i> .....	52
Gambar 4.5 <i>Script</i> untuk Mengambil <i>Dataset</i> .....	54
Gambar 4.6 Isi file <i>corpus.txt</i> Sebelum Anotasi .....	54
Gambar 4.7 Isi file <i>corpus.txt</i> Setelah Anotasi.....	55
Gambar 4.8 <i>Script</i> untuk Menyiapkan <i>Dataset HMM</i> .....	55
Gambar 4.9 <i>Script</i> untuk <i>Training</i> model HMM .....	56
Gambar 4.10 Hasil <i>Testing</i> model HMM.....	56

Gambar 4.11 <i>Script</i> untuk Menyimpan Model HMM .....	56
Gambar 4.12 <i>Script</i> untuk Membuka Model HMM .....	57
Gambar 4.13 <i>Script</i> untuk <i>Entity Extraction</i> .....	57
Gambar 4.14 <i>Script</i> untuk Menyiapkan <i>Dataset NER</i> .....	58
Gambar 4.15 Isi <i>file gold_corpus.txt</i> dengan format <i>Prodigy</i> .....	58
Gambar 4.16 <i>Command</i> untuk Menjalankan <i>Prodigy</i> .....	59
Gambar 4.17 Tampilan <i>Prodigy</i> untuk proses Anotasi.....	59
Gambar 4.18 <i>Command</i> untuk Menyimpan <i>Gold Corpus</i> .....	59
Gambar 4.19 Isi dari <i>file gold_corpus.json</i> .....	60
Gambar 4.20 <i>Script</i> untuk <i>Training NER</i> .....	61
Gambar 4.21 <i>Script</i> untuk <i>Testing</i> model NER .....	62
Gambar 4.22 Hasil NER .....	62
Gambar 4.23 Tampilan Halaman Utama .....	63
Gambar 4.24 Tampilan Halaman Kategori .....	63
Gambar 4.25 Tampilan Halaman hasil NER.....	64
Gambar 4.26 Tampilan Halaman Statistik .....	65
Gambar 4.27 Tampilan Halaman <i>Today Entity</i> .....	65
Gambar 4.28 Tampilan Halaman <i>Repository</i> .....	66

## INTISARI

Seiring dengan berkembangnya zaman, tidak dapat dipungkiri bahwa kebutuhan manusia akan suatu informasi yang cepat dan akurat semakin meningkat. Dengan adanya teknologi internet, informasi yang dibutuhkan dapat dengan sangat cepat sampai ke para pembaca. Persebaran berita pun semakin luas jangkauannya, mulai dari sumber berita yang dikota maupun desa yang bisa dengan mudah untuk diakses. Pembaca berita pun bervariasi dengan latar belakang yang berbeda-beda, sehingga akan terjadi perbedaan dalam menerima suatu informasi dari berita yang sedang terjadi.

Metode *POS Tagging* (*Part-of-Speech Tagging*), merupakan sebuah metode untuk memberikan label kelas kata pada suatu kata sehingga akan diketahui keterangan dari masing-masing kata. *Hidden Markov Model* (HMM), adalah suatu model statistik yang terdiri dari dua bagian state yang saling terkait. Bagian yang dapat diamati adalah *observed state*, sedangkan bagian yang tersembunyi disebut *hidden state*. Pada metode *POS Tagging*, *observed state* adalah urutan kata sedangkan *hidden state* adalah urutan tag atau label.

Tujuan dari perancangan aplikasi berbasis *web* ini adalah untuk mendapatkan berita dari pemberitaan media daring dan memberikan label untuk setiap kata pada beritanya, sehingga bisa diketahui entitas yang dibicarakan dalam masing-masing berita. Penulis bertujuan untuk dapat membantu pengguna mengetahui siapa dan apa saja yang dibicarakan dalam suatu berita, tanpa harus membaca keseluruhan dari isi beritanya.

**Kata Kunci:** *Hidden Markov Model, POS Tagging, Named Entity Recognition*

## ABSTRACT

*Along with the development of the times, it cannot be denied that human needs for fast and accurate information are increasing. With the advent of internet technology, the information needed can very quickly reach the readers. The spread of news is even wider, ranging from news sources in the city and villages that can be easily accessed. News readers also vary with different backgrounds, so there will be differences in receiving information from the news that is happening.*

*POS Tagging method (Part-of-Speech Tagging), is a method to labeling the part of speech on a word so that it will know the description of each word. Hidden Markov Model (HMM), is a statistical model consisting of two interrelated state parts. The observable part is the observed state, while the hidden part is called the hidden state. In POS Tagging method, observed state is word order while hidden state is sequence of tag.*

*The purpose of this web application design is to get the news from the online news media and to labeling every word in the news so that any entity can be found in each news. The author aims to be able to help users know who and what is discussed in a news, without having to read the entire content of the news.*

**Keyword:** *Hidden Markov Model, POS Tagging, Named Entity Recognition*

